



# Kömür Kullanımı ile Üretilen Enerji Miktarının Yapay Sinir Ağlı Modeliyle Tahmini: Çin Üzerine Örnek Uygulama

## *Estimation of the Amount of Energy Produced by Coal Use With Artificial Neural Network Model: Example Application on China*

Mehmet Hurşut GÜVEN<sup>1\*</sup> Faruk KILIÇ<sup>2</sup> Faik Ümit DİRİ<sup>3</sup>

<sup>1</sup>Milli Savunma Üniversitesi, Alparslan Savunma Bilimleri ve Milli Güvenlik Enstitüsü, Harp Silah ve Araçları Ana Bilim Dalı, Ankara, Türkiye

<sup>2</sup>Milli Savunma Üniversitesi, Mühendislik Fakültesi, Makine Mühendisliği Bölümü, Ankara, Türkiye

<sup>3</sup>Milli Savunma Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü, Ankara, Türkiye

### Makale Bilgisi

Araştırma makalesi  
Başvuru: 10.06.2024  
Düzelteme: 10.09.2024  
Kabul: 11.10.2024

### Keywords

Artificial Neural  
Network  
Electric Production  
Coal  
China

### Önemli Noktalar

YSA (Yapay Sinir Ağı) son dönemlerde verilerin analiz edilen verilerden farklı bir verinin tahmin edilmesinde kullanılmaktadır. Yapılan çalışmada elde edilen sonuçlar gerçek değerler ile oldukça yakındır.

### Şekilsel Özeti



### Anahtar Kelimeler

Yapay Sinir  
Ağrı  
Elektrik Üretimi  
Kömür  
Çin

### Özet

Son yıllarda çevresel etkilerinden dolayı fosil yakıtların; özellikle de kömürün yakılması ile elektrik üretimi terkedilerek yenilenebilir enerji kaynaklarının kullanımına ağırlık verilmektedir. Bu eğilim Çin üzerinde incelendiğinde, 2007 yılı sonrasında kömür kullanımlarla elektrik üretiminin azalma eğilimine girdiği görülmektedir. Bu çalışmada Çin'de hydropower (su gücü), rüzgar gücü, nükleer güç ve toplam elektrik üretim miktarları input verisi olarak kullanılarak kömür yakıtlarla üretilen elektrik miktarları 2000-2020 yılları için Yapay Sinir Ağı (YSA) aracılığı ile tahmin çalışması yapılmıştır. Yapay zekanın altı parçalarından olan YSA belirsizlik ve değişkenlik içeren sorunların çözümü oldukça uygun olduğu tespit edilmiştir. Çin'de kömürden elde edilen elektrik üretimi tahminine yönelik olarak yapılan YSA analiz sonucunda; Training, Validation, Test ve All için regresyon değerleri sırası ile 0,99958, 1, 1 ve 0,99961 olarak belirlenmiştir. Ayrıca analiz sonucunda yapılan tahmine yönelik olarak hata miktarlarının hesaplanması farklı yöntemler ile yapılmış ve MAE için 0,017, MAPE için % 1,7, MAD için 352,619, MSE için 358772,14 ve RMSE için ise 598,9759 sonuçları bulunmuştur.

### Abstract

In recent years, due to their environmental effects of fossil fuels; In particular, electricity generation by burning coal is abandoned and emphasis is placed on the use of renewable energy sources. When this trend is examined specifically in China it is seen that electricity production using coal has started to decrease after 2007. In this study, the amounts of electricity produced by burning coal in China were tried to be estimated through Artificial Neural Network (ANN) for the years 2000-2020, using hydropower, wind power, nuclear power and total electricity production amounts as input data. ANN, one of the sub-parts of artificial intelligence, is very suitable for solving problems involving uncertainty and variability.

As a result of the ANN analysis conducted for the estimation of electricity production from coal in China; Regression values for Training, Validation, Test and All were determined as 0.99958, 1, 1 and 0.99961 respectively. In addition, the error amounts were calculated for the prediction made as a result of the analysis and results were found to be 0.017 for MAE, 1.7% for MAPE, 352,619 for MAD, 358772,14 for MSE and 598,9759 for RMSE.

\*Corresponding author, e-mail: mhguven@kho.msu.edu.tr

## 1. GİRİŞ (INTRODUCTION)

Enerji tüketim miktarı bir devletin refah seviyesini gösterdiği gibi aynı zamanda, o devletin sosyal ve ekonomik gelişimi içinde oldukça büyük öneme sahiptir. Geleneksel olarak en yoğun enerji üretimi petrol, kömür, doğal gaz gibi kaynaklar kullanılarak gerçekleşmektedir. Fakat bu kaynaklar kaçınılmaz olarak iklim değişikliği, çevresel sorunlar, ozon tabakasının yok oluşu gibi yan etkilere sahiptir. Ayrıca, fosil yakıtlar yenilenebilir olmadıkları için kullanıldıkça tükenmeye doğru gitmektedirler[1], [2].

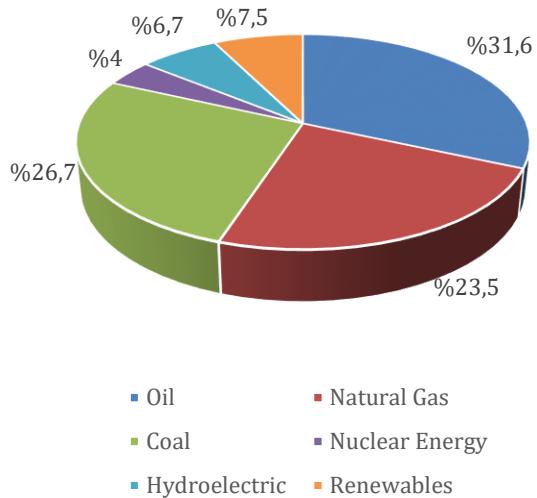
Endüstriyel devrim ve ekonomik gelişim ile birlikte enerji tüketimi artmıştır. İnsanlığın enerji ihtiyacı artmış enerji kaynaklarının çeşitlendirilmesine yönelik çalışmalar sonucunda 1861 yılında ABD'de açılan ilk petrol kuyusu açılmış ve sonrasında ham petrol ilk arabanın üretimi ve sonrasında motorlu araçların yaygınlaşması ile en önemli enerji üretme malzemelerden biri haline gelmiştir[3].

Doğal gaz ve ham petrolün dünyanın sadece belirli bölgelerinde bulunması ve siyasi, ekonomik kargaşalar sırasında fiyatlarında meydana gelen aşırı değişiklikler, nükleer enerji atıklarının kontrol edilmesi ve beklenmeyen kazalar, yenilenebilir enerjilerin yüksek maliyeti gibi sebeplerden dolayı insanlığın en eski enerji kaynaklarından olan kömür halen enerji üretiminde oldukça önemlidir[4].

Kömür yakılarak elektrik enerjisi üretmenin, oluşan kül atığı ve bunun sebep olduğu verim düşüklüğü, çevre sorunları ve bakım maliyetleri gibi önemli dezavantajları bulunmaktadır. Yanma sonrasında kömürün bünyesinde yer alan inorganik malzemeler yine inorganik buhar,

sıvılar ve katı malzemelere dönüştürmektedir. Oluşan bu gaz, sıvı ve katı atıklar toksik ve çevre açısından zararlı atıklardır[5]. Uluslararası Enerji Birliğinin verilerine göre Covid 19 pandemisinin etkisi ile 2019 ilk çeyreğine göre 2020 yılındaki kömür ve petrole olan talep sırası ile % 8 ve % 5 oranında düşmüştür. Bu durumun diğer sebebi ise fosil yakıtların dünya üzerindeki yaşama ve atmosferdeki karbondioksit ( $\text{CO}_2$ ) gibi gazların artmasına yol açtılarından yenilenebilir enerji kaynaklarına birkaç on yıldır önemli bir kayma gerçekleşmiştir. Kullanılan fosil yakıtların çevre üzerindeki etkisinin azaltılması için kullanılan yakıtın azaltılması yanında enerjinin daha verimli kullanılması, verimli enerji çevrim cihazlarının geliştirilmesi, gibi önlemler zehirli gazların salınımını azaltmaktadır[6].

Dünya üzerinde hızla artan insan nüfusu ile birlikte enerjiye talep artmaktadır. Artan bu talebi karşılayabilmek ve fosil yakıtların çevre üzerinde oluşturduğu baskının azaltılabilmesi için yenilenebilir enerji kaynaklarına yönelik başlamıştır[3],[7]. Yenilenebilir enerji kaynakları arasında güneş panelleri, rüzgâr, jeotermal, su gücü gibi tekrar üretebilen kaynaklar bulunmaktadır. Yenilenebilir enerji kaynaklarından elde edilen enerjinin tüketiminin gelecek 30 yılda % 147 büyümesi beklenmektedir[8], [9].



**Şekil 1:** 2022 Yılı için Dünya enerji tüketimi  
[10]

Enerji üretiminde kullanılan kaynaklar 2022 yılı istatistikleri verileri Şekil 1.'de verilmiştir[10] Şekil-1 incelendiğinde 2022 yılı için elektrik üretim kaynakları olarak halen %81.8 ile fosil yakıtlar en büyük kaynağı oluşturmaktadır. Nükleer Enerji santralleri aracılığı ile üretilen enerji miktarı ise %4 olarak gerçekleşmiştir. Hydropower (su gücü)'de eklendiğinde yenilenebilir enerji kaynakları ile elde edilen elektrik enerjisi oranı %14,2 olarak gösterilmiştir. Enerji kaynaklarındaki değişimin gerek çevresel etkiler gerekse maliyet gibi sebepler nedeni ile öncümüzdeki yıllarda değişmesi beklenmektedir. Bu değişimin oranının geleceğe yönelik olarak tahmin edilebilmesi için istatistiksel ve yapay sinir ağları (ANN) yöntemleri kullanılarak son yıllarda oldukça fazla çalışma yapılmıştır.

Yapay sinir ağları yapay nöronların bir araya gelmesi ile oluşan hesaplama yöntemidir. Yapay sinir ağını oluşturan nöronlar kendi başlarına (aktivasyon fonksiyonu) sonuç vermektedir. Yapay sinir ağının aldığı sonucu belirleyen;

nöronlar arasındaki bağlantı, bu bağlantıların ağırlıkları ve nöronların herbirinden elde edilen sonuçlardır. Yapay sinir ağları yöntemi genel olarak lineer olmayan, belirsiz ve konveks olmayan sistemler ile ilgilenmektedir[11], [12], [13], [14], [15].

Enerji üretiminde faydalanan kaynaklardan başlıcaları yenilenebilir enerji kaynakları, fosil yakıtlar ve nükleer enerjidir. Kriz dönemlerinde her ülke enerji temininde sorunlar yaşamaktadır; özellikle 1973 yılında gerçekleşen enerji krizi başta olmak üzere enerji arzında meydana gelen sorunlar nedeni ile enerji sistemlerinde enerji tüketimi oldukça önemlidir. Hangi sektörün ne kadar enerji tükettiğin takibi zor olmakla beraber YSA kullanarak dağılımın tahmin edilebilmesi mümkündür. YSA, politika yapıcılarının özellikle kriz dönemlerin enerji politikaları konusunda karar vermesine katkı sunabilmektedir[16], [17]. Yapay zekâ, enerji yönetiminin otomasyonu için oldukça önemli role sahiptir. Yapay zekâ ile erişilebilen enerji miktarı, enerji programlanması, talep miktarı ve enerji ticareti üzerine tahmin yapılmaktadır. Yapay sinir ağları ve vektör makineleri yapay zekânın bu konuda kullandığı araçlar olmaktadır[18], [19].

Olabi ve arkadaşları tarafından yapılan çalışmada termal enerjinin depolanmasına, optimizasyonuna ve kontrolüne yönelik olarak yapay zekâ kullanılarak tahmin edilmesi için çalışma yapılmıştır. Enerji sistemlerinin sınıflandırılması, rolü ve enerji sistemlerinin farklı yapay zeka yaklaşımıları kullanılarak oluşturulan uygulamaların tasarlanması için çalışılmıştır[6].

Kılıç tarafından yapılan çalışmada G8 üyesi ve Avrupa ülkesi olan Almanya'nın toplam Rüzgâr

ve Güneş Enerjisi Toplam Kapasitesi (WSEC) ve Rüzgâr ve Güneş Enerjisi toplam üretim (WSEG) değerleri Yapay Sinir Ağları kullanılarak tahmin edilmiştir. Nüfus, işsizlik, GSYH büyümesi ve toplam yenilenebilir enerji parametreleri girdi değişkenleri olarak kullanılmıştır. Yapay sinir ağları tarafından hesaplanan WSEC ve WSEG analizi sonucunda eğitim ve test regresyonları sırası 1 ve 0,99988 olmuştur[20].

MATLAB programının yapay zekâ modülü kullanılarak endüstriyel binaların enerji verimliliğinin arttırılmasının bu binalardaki enerji tüketimine olan etkisi Zhao tarafından incelenmiştir. Yapılan çalışma sonucunda yapay zekâ temelli enerji koruma sistemlerinin enerji tüketimine olumlu katkısı olduğu görülmüştür[18].

Enerji ve enerji tüketim indisinin analizinin modellenmesine yönelik yapılan çalışmada Yapay Sinir Ağı yani Yapay Zekâ kullanılmıştır. Bu çalışmada enerji tüketim miktarı ve enerji indisi modellenmiş ve miktarları tahmin edilmeye çalışılmıştır. Analiz sonucunda hata kriterine göre yüksek doğrulukta ve analiz test değeri  $R^2 = 0,98$  bulunmuştur. Enerji tüketim indisini ve yakıt tüketimini düşürmek için kullanılan kompresörlerin veriminin artırılması için farklı metotlar sunulabilir[16].

Bu çalışmalar dışında da Yapay Sinir Ağları kullanılarak yapılmış olan birçok çalışma bulunmaktadır. Bunlardan Khamehchi ve

arkadaşları tarafından yapılan çalışmada ağır yağ (dead oil) vizkozitesi hesaplanmaya çalışılmıştır[21]. Salehar ve arkadaşı tarafından yapılan çalışmada ise kömür kalitesinin kömür kullanarak elektrik üreten tesislerde oluşan sorunlara etkisi YSA kullanılarak incelenmiştir[5]. Yapılan bir diğer çalışmada Türkiye'de kömür kullanılarak enerji üretilen tesislerinin veriminin artırılması Yapay Sinir Ağı kullanılarak incelenmiştir[4]. Tedarik zinciri yönetiminin optimizasyonuna yönelik olarak Soori ve arkadaşları tarafından yapılan çalışmada Yapay Zekâ yöntemi olan Yapay Sinir Ağları kullanılmıştır (Artificial Neural Network). Dozic ve arkadaşları tarafından yapılan çalışmada ise Avrupa Birliği enerji politikalarının uzun dönemli olarak tahminine yönelik olarak yapay sinir ağları kullanılmıştır[22]. Bas ve arkadaşları tarafından yapılan çalışmada ise medyan dentritik yöntemi kullanılarak yapılan Yapay Sinir Ağları analizi ile yıllara dağılmış olarak tahmini üzerine çalışma yapılmıştır[23]. Egrioglu ve arkadaşları tarafından yapılan çalışmada ise bulanık resimlerin tanımlanması, modellenmesi ve tahmini için yeni yapay sinir ağları modeli geliştirilmesine yönelik olarak çalışılmıştır[24]. Birleşmiş güç döngüsü ve soğutma sistemlerinde CO<sub>2</sub>'nin dinamik davranışının tahminine yönelik olarak He ve arkadaşları tarafından yapılan çalışmada Yapay Sinir Ağlarının ve Yapay Sinir Ağlarında yer alan modellerin karşılaştırılmasına yönelik çalışma yapılmıştır[25].

**Tablo 1:** Çalışmada yer verilen makalelerin özeti

Referans	Veri Sistemi	YSA rolü	YSA kullanmanın amacı	Özet
Olabi ve arkadaşları[6]	Termal enerji depolama sistemleri	Tahmin	Termal enerji depolama sistemlerinin tahmin, optimizasyon ve kontrolü	YSA, konvansiyonel sistemler ile karşılaştırıldığında sahip olduğu esneklik ve ucuzluk gibi avantajlarının yanı sıra tahmin konusunda konvansiyonel sistemlerden daha iyi performans sergilemektedir.
Kılıç [20]	Elektrik üretimi	Tahmin	Almanya için güneş ve rüzgâr ile Elektrik üretim kapasitesinin tahmini	Yapılan tahmini etkileyen çok sayıda parametre olmasına rağmen, YSA metodu ile yüksek doğrulukta tahmin edilmiştir.
Zhao[18]	Binaların enerji dostu sistemlerinin yönetimi	Tahmin	Endüstriyel binaların enerji tüketimi verimlerinin geliştirilmesi	Yapılan çalışma ile geliştirilen enerji tasarrufu yönetim sistemi modelinin olumlu katkı sağladığı görülmüştür.
Sarvestani ve arkadaşları [16]	Binalarda enerji tüketiminin indirgenmesi	Optimizasyon	Endüstriyel tesislerdeki enerji tüketiminin azaltılması için yeni metodun geliştirilmesi	Yapılan çalışma ile geliştirilen metod yüksek doğrulukta olduğu görülmüştür.
Khamehchi ve arkadaşları [21]	Hafif ve orta ölü petrol sistemlerinin viskozitesi	Modelleme	Pertol çıkarma veriminin geliştirilmesi	YSA metodu ile geliştirilen metod diğer yöntemler ile elde edilenlerden daha iyi performans gösterdiği görülmüştür.
Salehfar ve arkadaşları [5]	Kömür atıklarındaki kül oluşumu	Tahmin	Kömürden Elektrik üreten tesislerin kül üretme miktarının tahmini	Geliştirilen yeni model geleneksel yöntemlere göre hızlı, verimli ve ekonomik olduğu görülmüştür.
Dozie ve arkadaşları[22]	Uzun dönemli enerji politikalarının tahmini	Tahmin	Avrupa Birliği enerji politikaları kapsamında karbondioksit salımının tahmini	Yapılan analiz kabul edilebilir doğruluk seviyesine sahip olduğu görülmüştür.

Liu ve arkadaşları tarafından Yapay Sinir Ağlarının geliştirilmiş Red Fox Optimizer (IRFO) modeli kullanılarak enerji transfer taleplerine yönelik tahmini üzerine çalışma

yapılmışlardır[26]. Enerji tüketimi ve yenilenebilir enerji üretimine yönelik olarak yapay sinir ağları, makine öğrenmesi ve derin öğrenme teknikleri kullanılarak uzun dönemli tahmini için Wazirali

ve arkadaşları tarafından çalışma yapılmıştır[27]. Liu ve arkadaşları Yapay Sinir Ağları kullanılarak yenilikçi bir elektrik tüketim tahmini için çalışma yapmışlardır[28].

Knoerzer tarafından yapılan çalışmada basitleştirilmiş adibatik sıkıştırma ısınmasının tahmini için konvansiyonel sayısal yaklaşım ile Yapay Sinir Ağları yöntemleri ile hesaplanmış ve sonuçları karşılaştırılmıştır. Bu çalışma sonucunda Yapay Sinir Ağları adiabatik sıkışmalı sistemlerinin ısısının tahmininde etkili olduğunu ve sistemin modellenmesinde esnek ve verimli bir yaklaşımı sunduğu gözlenmiştir[29].

Musadi ve arkadaşları tarafından Kuzey Jakarta'da yerleşik olan Tanjung Priok Limanında yürütülen işlemlerin gerçekleşen gelgit yükselmesinden etkilenmemesi için gelgit miktarının tahminine yönelik çalışma yapılmıştır. Yapılan çalışmada Yapay sinir ağı ve karar ağacı algoritması kullanılmış ve elde edilen sonuçlar karşılaştırılmıştır. Yapılan çalışma sonucunda YSA ile elde edilen MSE değerinin karar ağacı algoritmasından elde edilenden daha küçük olduğu görülmüştür[30].

Çin yaklaşık olarak Dünya'da kömürden üretilen elektrik miktarının yarısından sorumludur. Verilere göre 2009 ile 2019 arasında Çin'de 1269 kömürden elektrik üreten santral bulunmaktadır[31]. Kömürün elektrik üretimi dışında klasik şekilde ısınma amaçlı kullanımı da oldukça yaygındır. Son dönemlerde özellikle Çin'in kuzey bölgelerinde kömürün ısınma kaynağı olarak kullanılması nedeni ile bir diğer çevresel etki olan hava kirliliği görülmüştür[32].

Bu çalışmada dünyanın en fazla nüfusuna sahip olan Çin, aynı zamanda sanayileşme oranı, üretim

kapasitesi ve yüksek üretim miktarı nedeni ile incelenmiştir. Yüksek sanayileşme oranı ve üretim kapasitesinin yüksek olması aynı zamanda fazla miktarda enerjiye ihtiyaç duymak anlamına gelmektedir. Bu nedenle Çin'in enerji ihtiyacını karşılayabilmek için yüksek miktarda enerji üretmesi gerekmektedir. Çin, enerji üretiminde kullandığı kaynakları su, rüzgâr, nükleer ve toplam elektrik üretimi kullanılarak; kömürden üretilen elektrik miktarları tahmin edilmeye çalışılmıştır.

## 2. DENEYSEL ÇALIŞMALAR (EXPERIMENTAL STUDIES)

### 2.1. Materyal ve Metot

Bu çalışmada 2000 ile 2020 yılları arasında Çin'de hydropower (su gücü), nükleer güç, rüzgâr tribünleri ve toplam elektrik üretimi girdi değerleri input verisi alınarak kömür yakılması sonucunda üretilen elektrik miktarları Yapay Sinir Ağları (YSA) kullanılarak tahmin edilmiştir. Tahmin çalışmasında kullanılan girdi verilerinden hydropower (su gücü), nükleer güç, rüzgâr tribünlerinden üretilen elektrik enerjisi miktarları ve kömürden üretilen elektrik miktarları Global Energy Monitor[33]'den alınmıştır. Çin'de üretilen toplam elektrik miktarı ise Enerdata[34] kaynağından alınmıştır. Çalışmada kullanılan girdi verileri Tablo-1'de, verilerin grafiği Şekil-2'de verilmiştir.

#### 2.1.1. Veri Paketleri

Çin, petrol kaynakları yetersiz olduğu için Ortadoğu'da bulunan enerji kaynaklarına ihtiyaç duymaktadır. Bu durumu değiştirmek adına enerji kaynaklarını çeşitlendirmekte ve çevresel etkiler nedeni ile yenilenebilir enerji kaynaklarına önem vermektedir. Kömür ise sahip olduğu kötü çevresel etki özellikleri nedeni ile

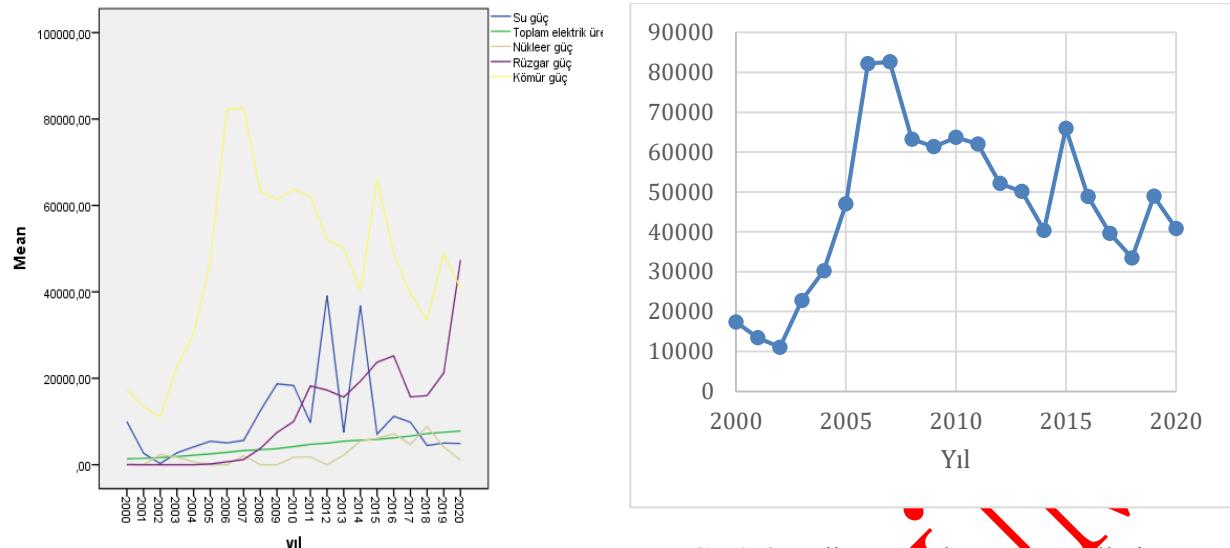
enerji üretiminde terkedilemeye çalışılmaktadır. Çalışmada MATLAB/2021 içerisinde yer alan Yapay Sinir Ağları modülü kullanılmıştır.

Tablo 2 incelendiğinde su gücünden elde edilen elektrik haricinde genel olarak artış gözlenmektedir. Tüm dünyada su sıkıntısı

yaşandığından su gücünden elde edilen elektrik değerlerinin genel olarak azalması beklenen bir durumdur. Düzensiz değerlerin olması tamamen iklimsel değişiklikteki negatifliklerin bir sonucu olarak ifade edilebilmektedir.

**Tablo 2:** Çin'de üretilen elektrik enerjisi miktarları[34], [35]

Yıl	Çin'de hydropower (su gücü)'den Üretilen Elektrik MW	Çin'in Toplam Elektrik Üretimi TWh	Çin'de Nükleer Güç ile Üretilen Elektrik MW	Çin'de Rüzgar Gücünden Üretilen Elektrik MW
2000	9960	1355.738	0	21
2001	2682	1480.949	0	0
2002	265	1654.164	2368	0
2003	2746	1910.755	1718	0
2004	4126	2203.502	650	0
2005	5429	2500.466	0	163
2006	5042	2865.954	0	667
2007	5631	3281.79	2120	1206
2008	12488	3467.185	0	3761
2009	18710	3715.061	0	7471
2010	18327	4207.993	1746	10021
2011	9753	4715.761	1771	18227
2012	39099	4994.045	0	17278
2013	7498	5447.247	2218	15638
2014	36805	5678.945	5472	19329
2015	7083	5859.515	6122	23728
2016	11215	6217.967	7205	25177
2017	9833	6635.480	4675	15702
2018	4440	7181.800	8840	15994
2019	5009	7519.345	4086	21253
2020	4903	7797.561	1118	47414



**Şekil 2:** Çin'de üretilen elektrik enerjisi miktarlarının yıllara göre dağılımı

Tablo-2 ve Şekil-2 incelendiğinde hydropower (su gücü) ile üretilen elektrik enerjisinde 2010-2015 arasındaki verilerde değişkenlik olmakla beraber genel olarak birbirine yakın değerlerdedir. Nükleer enerji santralleri ile elektrik üretiminde 2005 yılı sonrasında keskin bir artış görülmüştür. Ayrıca, rüzgâr santralleri kullanılarak elektrik üretiminde 2010 sonrasında düzenli artış görülmüşken 2018 sonrasında sert bir düşüş gerçekleşmiştir. Çin'e ait toplam elektrik üretimi ise 2000 yılı sonrasında daha hızlı yükseliş eğilimi göstermiştir.

Elektrik üretiminde kömür santrallerinin elektrik üretiminde kullanılmasının çevreye olan etkileri nedeni ile diğer kaynakların gelişmesi ile birlikte düşüşe geçmiştir. Şekil incelendiğinde kömürden elektrik üretiminde 2006 yılı sonrasında düşüş trendine girdiği görülmüştür. Yapılan bu çalışmada input verileri kullanılarak Çin'de elektrik üretimi tahmin edilmeye çalışılmıştır.

**Şekil 3:** Yıllara göre kömür santralleri kullanılarak üretilen elektrik üretimi[33]

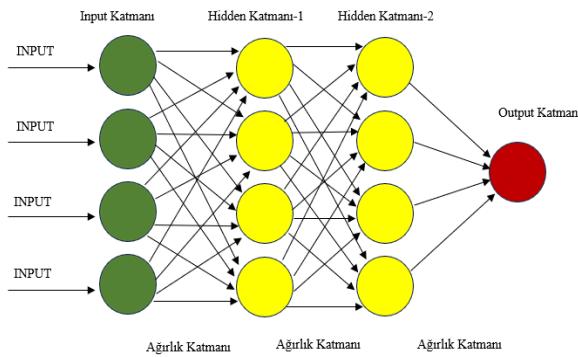
Çin'in enerji üretimi 2000 yılı sonrasında artmakla birlikte Covid-19 salgınının başlaması ile 2019 sonrasında enerji talebinde düşüş gözlenmiştir. Yaşanan bu düşüş mevsimsel olmamakla beraber daha önceki yıllarda yaşanan düşüşler gibi dönemsel bir düşüştür.

### 2.1.2. Yapay Sinir Ağları

İnsan beyin yapısı ve fonksiyonlarının taklit edilerek gerçekleştirilen makine öğrenmesi Yapay Sinir Ağları (YSA) olarak tanımlanabilir. Yapay sinir ağları karmaşık kurallar ve matematiksel formüller yerine insan beyninin öğrenme biçimini taklit eden sistemlerdir. Yapay sinir ağları yoğun veri içerisinde anahtar bilgiyi öğrenebilmenin yanı sıra bilgi yiğini içinde gürültü durumundaki veriyi temizleyebilme yeteneği sonucunda problemi çözebilmektedir. YSA tahmin yaparken sunduğu yeni metot ile daha önce kayıt altına alınmış olan ve sisteme girilen parametreler kullanılarak kontrollü veya kontrolsüz parametreler arasında ilişki kurabilmektedir[35], [36], [37].

Gerçek yaşamdaki gibi Yapay Sinir Ağlarında da tekrarlayan denemeler öğrenme ile

sonuçlanmaktadır[20]. Yapay Sinir Ağları (YSA) kompleks tahmin ve patern sorunlarını çözmek için geliştirilmiştir. Yapay sinir ağlarında girdi katmanı (input layer), gizli katman (hidden layer) ve çıktı katmanı (output layer) olarak 3 katmandan oluşmaktadır. Çok katmanlı yapay sinir ağlarında nöronlar ilk işlemciler olmaları nedeni ile tüm katmanlarda yer almaktadır[27].



**Şekil 4:** Yapay sinir ağı çalışma katmanları

Yapay Sinir Ağlarının eğitiminde hata miktarını azaltmak için en fazla kullanılan yöntemlerinden biri Back Propagation (BP) sürecidir. Bu teknigin en önemli dezavantajı bazı özel durumlarda sorun yaşamaya eğilimli olmasıdır. Bu dezavantajlar pattern oluşturulmasında ciddi sorunlara yol açmaktadır. Oluşan sorunların çözümü için çok sayıda teknik önerilmiştir[26].

MATLAB programı kullanılarak yapılan Yapay Sinir Ağı analizinde input verileri programa girilmenden önce normalizasyon uygulanmıştır. Yapılan normalizasyon işlemi ile tüm veriler 0 ile 1 arasındaki eş değerlere indirgenmiştir. Kullanılan formülasyon Eşitlik 1'de verilmiştir. Aşağıda verilen eşitliklerde  $G_t$  girdi değerlerini,  $H_t$  yapılan tahmin sonucunda bulunan değeri ve  $n$  ise veri sayısını göstermektedir.

$$N = \frac{G_t}{\sqrt{\sum_{t=1}^n G_t^2}} \quad (1)$$

Analiz sonucunda elde edilen çıktı değerlerine Eşitlik 2'deki formülasyon kullanılarak tahmin edilen değerlere ulaşılmıştır.

$$H_t = N * \sqrt{\sum_{t=1}^n G_t^2} \quad (2)$$

### 2.1.3. Hata Ölçüm Parametreleri

Tahmin edilen değer ile gerçek değer arasındaki fark hata olarak isimlendirilmektedir. Hata aynı zamanda uygulanan çözümün performansını göstermektedir. Tahmin edilen değer ile gerçek değer arasındaki farkı gösteren hata değerini hesaplamaya dönük farklı yaklaşım vardır. Bu hata değerleri ne kadar küçük olursa modelin en az hata ile tahmin yaptığı gösterir. Hatanın hesaplanması için Root Mean Square Error (RMSE), Mean Percent Error (MPE), Mean Absolute Deviation(MAD), Mean Absolute Error (MAE) ve Mean Absolute Percentage Error (MAPE) formülleri kullanılmıştır[8], [20]. Hata hesaplamalarında kullanılan formüller Eşitlik 3-7'de verilmiştir. Kullanılan formüllerde  $G_t$  girdi değerlerini,  $H_t$  yapılan tahmin sonucunda bulunan değeri ve  $n$  ise veri sayısını ifade etmektedir.

$$MAD = \frac{\sum_{t=1}^n |H_t - G_t|}{n} \quad (3)$$

$$MSE = \frac{\sum_{t=1}^n (H_t - G_t)^2}{n} \quad (4)$$

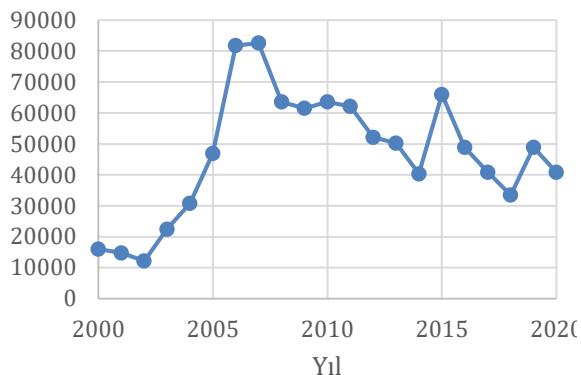
$$RMSE = \sqrt{\frac{\sum_{t=1}^n (H_t - G_t)^2}{n}} \quad (5)$$

$$MAE = \frac{\sum_{t=1}^n |H_t - G_t|}{n} \quad (6)$$

$$MAPE = \frac{\sum_{t=1}^n \left| \frac{H_t - G_t}{H_t} \right|}{n} \times 100 \quad (7)$$

## 3. SONUÇLAR VE TARTIŞMA (RESULTS AND DISCUSSION)

Kömürden üretilen enerjini yaklaşık yarısından fazlası sadece Çin tarafından gerçekleştirilmiştir.



**Şekil 5:** Çin için kömürden elektrik üretim tahmini (MWh)

Kömürün çevresel etkileri düşünüldüğünde Çin tarafından tüketilen kömürün miktarı önem kazanmaktadır. 2021 yılında dünya ölçüğinde salınan 15.3 milyar ton CO<sub>2</sub>'nin yaklaşık %40'ın kömür kullanımı sayesinde gerçekleşmektedir[31]. Kömürün kullanımının sebep olduğu çevresel etkiler nedeni ile kömür kullanım miktarının tahmin edilmesi önemlidir. Kömür kullanım miktarının tahmin edilebilmesi için Yapay Sinir Ağı (YSA) kullanılan yöntemlerden biridir. YSA yöntemi kullanılarak Çin'in kömürden elektrik üretme miktarları Şekil- 5'te verilmiştir. Gerçek değerler ile tahmin edilen değerlerin karşılaştırılma grafiği ise Şekil 6'da verilmiştir. Şekil 3 ve Şekil 5 üst üste oturmasından dolayı şeklin ve eldelerin daha iyi yorumlanması amacıyla “Çin için kömürden elektrik üretim tahmini” öncelikle sade kısımıyla verilmiştir.

Verilen ve elde edilen değerlere bakıldığında Şekillerin neredeyse üst üste oturduğu görülmektedir. Bu durum regresyon çıktı değerlerinden de anlaşılacağı gibi çok düşük hata elde edilmiştir.

Yapılan YSA tahminine ait regresyon sonuçları Şekil 7'de verilmiştir. Yapılan tahminlere göre

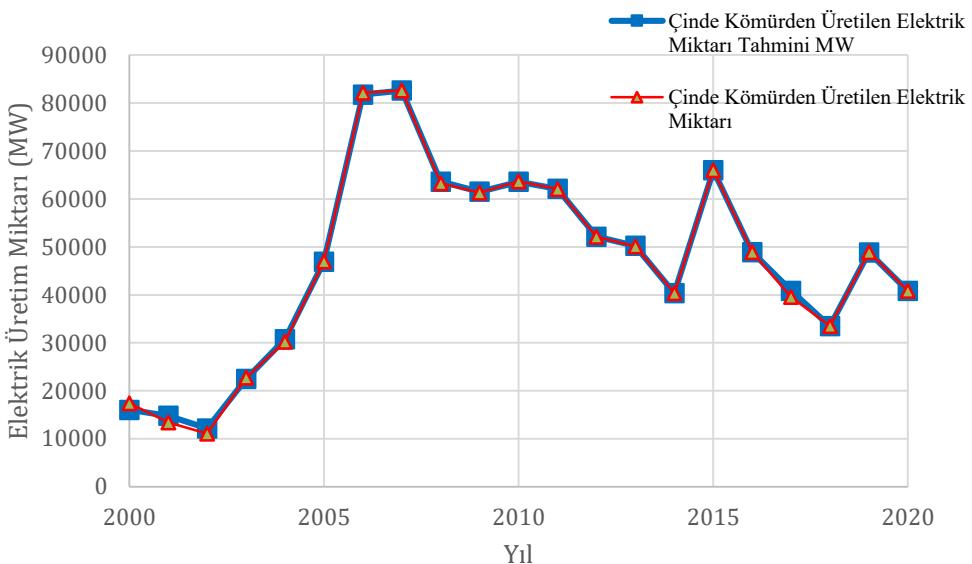
test ve validasyonun regresyon değerleri 1 çıkarken, training regresyon değeri 0.99958 ve All için regresyon değeri ise 0,99961 olarak hesaplanmıştır. Bulunan regresyon sonuçlarının 1'e yakın olması yapılan tahminin doğruluk derecesini göstermektedir.

Yapılan çalışmanın güvenilirliğinin tespiti için YSA kullanılarak elde edilen tahmin sonuçları ile gerçek değerler Mean Absolute Deviation (MAD), Mean Squared Error (MSE), Root Mean Square Error (RMSE), Mean Absolute Error (MAE) ve Mean Absolute Percentage Error (MAPE) değerleri hesaplanmıştır. Bulunan sonuçlar Tablo 3'de verilmiştir.

Yapılan çalışmada Levenberg -Marquardt modeli ile yapılmış, input verirlerinin %70'i eğitme %15'i validasyon ve %15'i test amaçlı olarak kullanılmıştır. YSA analizinde dört input verisi ve 2 hidden katmanı ve 1 output katmanı olmak üzere üç katmanlı yapı tercih edilmiştir.

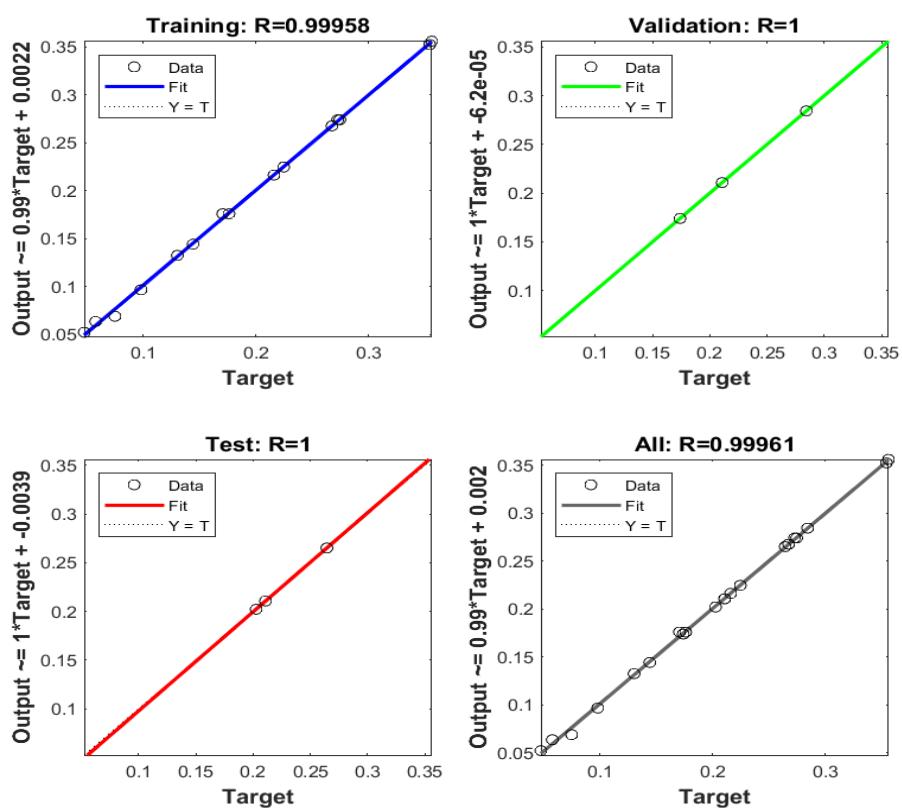
Yapılan tahminde hesaplanan regresyon değerlerinin 1'e yakınlığı yapılan çalışmanın doğruluğunu göstermektedir. Hesaplanan regresyon değerleri Çin kömürden elektrik üretim miktarları yüksek doğruluk ile tahmin edildiğini göstermektedir.

Zaaoumi ve arkadaşları tarafından yapılan çalışmada parabolik güneş panellerinin enerji üretim miktarlarının YSA kullanılarak tahmin edilmesinde elde edilen training ve validation regresyon değerleri sırası ile 0.97033 ve 0.96923 olarak bulunmuştur. Ayrıca söz konusu çalışmada YSA dışında AM I ve AM II modelleri kullanılmıştır. YSA tahmin sonuçlarına göre hesaplanan MAE değerleri modellerden AM I .



**Şekil 6:** Çin için kömürden elektrik üretim tahmini ile gerçek değerlerin karşılaştırılması

HATA DEĞERLERİ	MAD	MSE	RMSE	MAE	MAPE (%)
	352,619	358772,14	598,9759	0,017	1,7



**Şekil 7:** Yapay sinir ağının (YSA) Regresyon Şekilleri

icin 3.5 iken AM II modeli icin 3.09 olarak hesaplanmistir[2].

Sarvestani ve arkadasları tarafından yapılan çalışmada ise enerji tüketimin azaltılması ve yönetimi modern yapay zekâ yöntemleri ile çalışılmıştır. Yapılan çalışmanın YSA analizi sonucunda test ve training regresyon değerleri sırası ile 0,9851 ve 0,9861 olarak hesaplanmıştır. Söz konusu çalışmanın MSE değerleri ise  $6.53 \times 10^5$  ve  $7.46 \times 10^5$  olarak hesaplanmıştır[16]

Yapılan çalışmada ise Training, Validation, Test ve All için regresyon değerleri sırası ile 0,99958, 1, 1, ve 0,99961 olarak hesaplanmıştır. Aynı zamanda hesaplanan error değerleri ise MAE için 0,017, MAPE için % 1,7, MAD için 352,619, MSE için 358772,14 ve RMSE ise 598,9759 olarak hesaplanmıştır. Zaaoumi ve arkadaşları tarafından training ve validation için regresyon değerleri sırası ile 0,97033 ve 0,96923 bulunurken, söz konusu değerler bu çalışmada bulunana göre daha düşüktür. Ayrıca elde edilen tahmin değerleri kullanılarak hesaplanan MAE değerleri 0,017'den daha kötü olan 3,5 ve 3,09 olarak hesaplanmıştır. Benzer şekilde Sarvestani ve arkadaşları tarafından yapılan YSA analizinde training ve test regresyon değerleri 0,9851 ve 0,9861 olarak hesaplanırken MSE değerleri ise  $6.53 \times 10^5$  ve  $7.46 \times 10^5$  olarak yapılan çalışmadan daha kötü sonuçlar hesaplanmıştır.

#### 4. SONUÇLAR (CONCLUSIONS)

Yapılan çalışmada Çin'de 2000-2020 yılları arasındaki toplam üretilen elektrik enerjisi, su gücü ile üretilen, nükleer güç ile üretilen ve rüzgâr gücü ile üretilen elektrik miktarları input olarak alınarak aynı yıllar için kömür kullanılarak üretilen elektrik miktarı YSA kullanılarak tahmin

edilmeye çalışılmıştır. YSA tahmininde MATLAB programında yer alan YSA modülü input, 2 adet hidden ve output katmanlarını içerecek şekilde kullanılmıştır. Analiz sonucunda training için regresyon değeri 0,99958, validation için regresyon değeri 1, test için regresyon değeri 1 ve All için regresyon değeri 0,99961 olarak hesaplanmıştır. Yapılan tahmin değerleri ve gerçek değerler kullanılarak hata değerleri olan MAE için 0,017, MAPE için % 1,7, MAD için 352,619, MSE için 358772,14 ve RMSE için ise 598,9759 olarak hesaplanmıştır.

Yapılan tahminlerdeki hata payının düşürülmesinde kullanılan input çeşitliliğinin ve veri sayısının ve sıklığının arttırılmasının etkili olacağı düşünülmektedir. Ayrıca YSA için kullanılan yazılımın ve modellerin geliştirilmesinin sonuçlar üzerinde etkili olduğu görülmüştür. Yapılan çalışma sonucunda elde edilen verilerin uzun dönem enerji yatırım planlamalarında katkıda bulunabileceği düşünülmektedir. Benzer çalışmaların yüksek enerji üretim ve tüketim miktarlarına sahip olan gelişmiş ülkeler üzerinde tekrarlanmasıının önumüzdeki yıllarda enerji üretiminden kaynaklanan çevre etkileri ve iklim değişiklikleri konusundaki çalışmalara katkı sunabileceği düşünülmektedir.

Bu bulgulardan sonra yapılacak çalışmalarda;

- İleri tahmin metotları incelenmesinin daha iyi sonuçlar getireceği
- Farklı yapay zekâ modelleri geliştirilebileceği
- Derin öğrenme modellerinin de denenerek karşılaştırmada kullanılabilirliği
- Makine öğrenme modeli geliştirilebilirliği

- Farklı metodlarda karşılaştırma açısından daha iyi modeller tespit edilebileceği
- Daha az hata ile daha iyi sonuçlar elde edileceği düşünülmektedir.

## TEŞEKKÜR (ACKNOWLEDGMENTS)

Bu araştırma hiçbir dış finansman almamıştır.

## YAZAR KATKILARI

**Mehmet Hurşut GÜVEN:** Kavramsal tasarım, Yazma

**Faruk KILIÇ:** Veri düzenleme, Analiz, Gözden geçirme

**Faik Ümit DİRİ:** İstatistiksel analiz, veri düzenleme

## ÇIKAR ÇATIŞMALARI

Yazarlar, herhangi bir çıkar çatışması olmadığını beyan eder.

## KAYNAKLAR (REFERENCES)

- [1] M. M. Rahman *vd.*, “Prospective Methodologies in Hybrid Renewable Energy Systems for Energy Prediction Using Artificial Neural Networks”, *Sustainability*, c. 13, sy 4, Art. sy 4, Oca. 2021, doi: 10.3390/su13042393.
- [2] A. Zaaoumi *vd.*, “Estimation of the energy production of a parabolic trough solar thermal power plant using analytical and artificial neural networks models”, *Renew. Energy*, c. 170, ss. 620-638, Haz. 2021, doi: 10.1016/j.renene.2021.01.129.
- [3] A. Entezari, A. Aslani, R. Zahedi, ve Y. Noorollahi, “Artificial intelligence and machine learning in energy systems: A bibliographic perspective”, *Energy Strategy Rev.*, c. 45, s. 101017, Oca. 2023, doi: 10.1016/j.esr.2022.101017.
- [4] Y. Kasap, C. Şensoğüt, ve Ö. Ören, “Efficiency change of coal used for energy production in Turkey”, *Resour. Policy*, c. 65, s. 101577, Mar. 2020, doi: 10.1016/j.resourpol.2019.101577.
- [5] H. Salehfar ve S. A. Benson, “Electric utility coal quality analysis using artificial neural network techniques”, *Neurocomputing*, c. 23, sy 1, ss. 195-206, Ara. 1998, doi: 10.1016/S0925-2312(98)00083-6.
- [6] A. G. Olabi *vd.*, “Application of artificial intelligence for prediction, optimization, and control of thermal energy storage systems”, *Therm. Sci. Eng. Prog.*, c. 39, s. 101730, Mar. 2023, doi: 10.1016/j.tsep.2023.101730.
- [7] P. Canbay ve H. Taş, “Yapıların Isıtma ve Soğutma Yükünün Yapay Zeka ile Tahmini”, *Int. J. Pure Appl. Sci.*, c. 8, sy 2, ss. 478-489, Ara. 2022, doi: 10.29132/ijpas.1166227.
- [8] T. E. Boukelia, O. Arslan, ve M. S. Mecibah, “ANN-based optimization of a parabolic trough solar thermal power plant”, *Appl. Therm. Eng.*, c. 107, ss. 1210-1218, Agu. 2016, doi: 10.1016/j.applthermaleng.2016.07.084.
- [9] J. Li, M. S. Herdem, J. Nathwani, ve J. Z. Wen, “Methods and applications for Artificial Intelligence, Big Data, Internet of Things, and Blockchain in smart energy management”, *Energy AI*, c. 11, s. 100208, Oca. 2023, doi: 10.1016/j.egyai.2022.100208.
- [10] R. Rapier, “Global Energy Trends: Insights From The 2023 Statistical Review Of World Energy”, Forbes. Erişim: 20 Aralık 2023. [Çevirmiçi]. Erişim adresi: <https://www.forbes.com/sites/rrapier/2023/08/06/global-energy-trends-insights-from-the-2023-statistical-review-of-world-energy/>
- [11] A. P. Marugán, F. P. G. Márquez, J. M. P. Pérez, ve D. Ruiz-Hernández, “A survey of artificial neural network in wind energy systems”, *Appl. Energy*, c. 228, ss. 1822-1836, Eki. 2018, doi: 10.1016/j.apenergy.2018.07.084.
- [12] D. S S, M. S. N B, ve U. Subramaniam, “Artificial Neural Network based Solar Energy Integrated Unified Power Quality Conditioner”, *Energy Sources Part Recovery Util. Environ. Eff.*, c. 0, sy 0, ss. 1-25, 2021, doi: 10.1080/15567036.2021.1919247.
- [13] W. N. Wan Md Adnan, N. Yenita Dahlan, ve I. Musirin, “Artificial Neural Network Optimization in Prediction Baseline Energy Consumption to Quantify Energy Savings in

- Commercial Building”, içinde *2020 11th IEEE Control and System Graduate Research Colloquium (ICSGRC)*, Agu. 2020, ss. 393-397. doi: 10.1109/ICSGRC49013.2020.9232655.
- [14] F. Yang, H. Cho, H. Zhang, J. Zhang, ve Y. Wu, “Artificial neural network (ANN) based prediction and optimization of an organic Rankine cycle (ORC) for diesel engine waste heat recovery”, *Energy Convers. Manag.*, c. 164, ss. 15-26, May. 2018, doi: 10.1016/j.enconman.2018.02.062.
- [15] R. Kumar, R. K. Aggarwal, ve J. D. Sharma, “Energy analysis of a building using artificial neural network: A review”, *Energy Build.*, c. 65, ss. 352-358, Eki. 2013, doi: 10.1016/j.enbuild.2013.06.007.
- [16] M. Ebrahimzadeh Sarvestani, S. Hoseiny, D. Tavana, ve F. Di Maria, “Strategic management of energy consumption and reduction of specific energy consumption using modern methods of artificial intelligence in an industrial plant”, *Energy*, c. 286, s. 129448, Oca. 2024, doi: 10.1016/j.energy.2023.129448.
- [17] K. Ermis, A. Midilli, I. Dincer, ve M. A. Rosen, “Artificial neural network analysis of world green energy use”, *Energy Policy*, c. 35, sy 3, ss. 1731-1743, Mar. 2007, doi: 10.1016/j.enpol.2006.04.015.
- [18] H. Zhao, “Intelligent management of industrial building energy saving based on artificial intelligence”, *Sustain. Energy Technol. Assess.*, c. 56, s. 103087, Mar. 2023, doi: 10.1016/j.seta.2023.103087.
- [19] C. Zeng, C. Wu, L. Zuo, B. Zhang, ve X. Hu, “Predicting energy consumption of multiproduct pipeline using artificial neural networks”, *Energy*, c. 66, ss. 791-798, Mar. 2014, doi: 10.1016/j.energy.2014.01.062.
- [20] F. Kılıç, “Forecasting the Electricity Capacity and Electricity Generation Values of Wind & Solar Energy with Artificial Neural Networks Approach: The Case of Germany”, *Appl. Artif. Intell.*, c. 36, sy 1, s. 2033911, Ara. 2022, doi: 10.1080/08839514.2022.2033911.
- [21] E. Khamehchi, M. R. Mahdiani, M. A. Amooie, ve A. Hemmati-Sarapardeh, “Modeling viscosity of light and intermediate dead oil systems using advanced computational frameworks and artificial neural networks”, *J. Pet. Sci. Eng.*, c. 193, s. 107388, Eki. 2020, doi: 10.1016/j.petrol.2020.107388.
- [22] D. J. Đožić ve B. D. Gvozdenac Urošević, “Application of artificial neural networks for testing long-term energy policy targets”, *Energy*, c. 174, ss. 488-496, May. 2019, doi: 10.1016/j.energy.2019.02.191.
- [23] E. Bas, E. Egrioglu, ve T. Cansu, “Robust training of median dendritic artificial neural networks for time series forecasting”, *Expert Syst. Appl.*, c. 238, s. 122080, Mar. 2024, doi: 10.1016/j.eswa.2023.122080.
- [24] E. Egrioglu, E. Bas, U. Yolcu, ve M. Y. Chen, “Picture fuzzy time series: Defining, modeling and creating a new forecasting method”, *Eng. Appl. Artif. Intell.*, c. 88, s. 103367, Şub. 2020, doi: 10.1016/j.engappai.2019.103367.
- [25] Jintao He vd., “Applying artificial neural network to approximate and predict the transient dynamic behavior of CO<sub>2</sub> combined cooling and power cycle - ScienceDirect”. Erişim: 18 Aralık 2023. [Çevrimiçi]. Erişim adresi: <https://www.sciencedirect.com/science/article/pii/S0360544223028451>
- [26] Y. Liu, G. Yan, ve A. Settanni, “Forecasting the transportation energy demand with the help of optimization artificial neural network using an improved red fox optimizer (IRFO)”, *Heliyon*, c. 9, sy 11, s. e21599, Kas. 2023, doi: 10.1016/j.heliyon.2023.e21599.
- [27] R. Wazirali, E. Yaghoubi, M. S. S. Abujazar, R. Ahmad, ve A. H. Vakili, “State-of-the-art review on energy and load forecasting in microgrids using artificial neural networks, machine learning, and deep learning techniques”, *Electr. Power Syst. Res.*, c. 225, s. 109792, Ara. 2023, doi: 10.1016/j.epsr.2023.109792.
- [28] S. Liu, H. Chen, P. Liu, F. Qin, ve A. Fars, “A novel electricity load forecasting based on probabilistic least absolute shrinkage and selection operator-Quantile regression neural network”, *Int. J. Hydrot. Energy*, c. 48, sy 88, ss. 34486-34500, Eki. 2023, doi: 10.1016/j.ijhydene.2023.04.091.
- [29] “Leveraging artificial intelligence for simplified adiabatic compression heating prediction: Comparing the use of artificial neural networks with conventional numerical approach”, *Innov. Food Sci. Emerg. Technol.*, c. 91, s. 103546, Oca. 2024, doi: 10.1016/j.ifset.2023.103546.
- [30] “Comparing Artificial Neural Network and Decision Tree Algorithm to Predict Tides at

Tanjung Priok Port”, *Procedia Comput. Sci.*, c. 227, ss. 406-414, Oca. 2023, doi: 10.1016/j.procs.2023.10.540.

[31] Q. Wu, C. Tan, D. Wang, Y. Wu, J. Meng, ve H. Zheng, “How carbon emission prices accelerate net zero: Evidence from China’s coal-fired power plants”, *Energy Policy*, c. 177, s. 113524, Haz. 2023, doi: 10.1016/j.enpol.2023.113524.

[32] W. Wang ve F. Li, “Study on substitutable value of electric heating instead of coal heating in northern China under carbon constraints”, *J. Clean. Prod.*, c. 260, s. 121155, Tem. 2020, doi: 10.1016/j.jclepro.2020.121155.

[33] “Global Energy Monitor”, Global Energy Monitor. Erişim: 20 Aralık 2023. [Çevrimiçi]. Erişim adresi: <https://globalenergymonitor.org/>

[34] “Enerdata”. Erişim: 20 Aralık 2023. [Çevrimiçi]. Erişim adresi: <https://www.enerdata.net/>

[35] S. A. Kalogirou, C. C. Neocleous, ve C. N. Schizas, “Artificial neural networks for modelling the starting-up of a solar steam-generator”, *Appl. Energy*, c. 60, sy 2, ss. 89-100, Haz. 1998, doi: 10.1016/S0306-2619(98)00019-1.

[36] S. Wang ve X. Dong, “Predicting China’s Energy Consumption Using Artificial Neural Networks and Genetic Algorithms”, içinde *2009 International Conference on Business Intelligence and Financial Engineering*, Tem. 2009, ss. 8-11. doi: 10.1109/BIFE.2009.11.

[37] S. A. Kalogirou, “Applications of artificial neural-networks for energy systems”, *Appl. Energy*, c. 67, sy 1, ss. 17-35, Eyl. 2000, doi: 10.1016/S0306-2619(00)00005-2.

ERKEN GÖRÜNMÜM