

D-8 Ülkeleri İçin Karbondioksit Emisyonun Yapay Sinir Ağları ile Tahmin Edilmesi: Levenberg-Marquardt Algoritması

Ayşe ÇAY-ATALAY (<https://orcid.org/0000-0002-3600-368X>), Atatürk University, Türkiye;
ayatalay@atauni.edu.tr

Forecasting Carbon Dioxide Emissions for D-8 Countries by Artificial Neural Networks: Levenberg-Marquardt Algorithm

Abstract

In recent years, growth, development, and sustainability-oriented lifestyles have created a separate problem, especially for developing countries. In this study, GDP per capita, energy consumption per capita (renewable, fossil, total), and urban population for D-8 countries (Indonesia, Bangladesh, Iran, Egypt, Malaysia, Pakistan, Nigeria, and Türkiye), all of which are developing countries, between 1990 and 2020. The carbon dioxide emission rates of the countries were estimated using the artificial neural networks (ANN) method by using the data of increase and carbon dioxide emission. In the ANN model established in the study, 70% of the database data was randomly divided into training, 15% validation and 15% test data. This artificial neural network is trained with the Levenberg-Marquardt method. Regression R values, one of the performance indicators of the model, were determined as 0,99 for training data, 0,97 for validation data and 0,99 for test data. The regression R-value for all data used in the model was determined as 0,99.

Keywords : D8 Countries, Artificial Neural Networks (ANN), Levenberg-Marquardt Method, Carbon Dioxide Emission.

JEL Classification Codes : B21, B23, C45, C55, C67.

Öz

Son yıllarda büyüme, kalkınma ve sürdürülebilirlik odaklı yaşam tarzı özellikle gelişmekte olan ülkeler için ayrı bir sorunsalı oluşturmaktadır. Bu çalışmada 1990-2020 yılları arasında tamamı gelişmekte olan ülkelere ait karbondioksit emisyonu oranları tahmin edilmiştir. Çalışmada kurulan YSA modelinde veri tabanı verilerinin rastgele olarak %70'i eğitim, %15'i doğrulama ve %15'i test verilerine ayrılmıştır. Oluşturulan bu yapay sinir ağı, Levenberg-Marquardt algoritması ile eğitilmiştir. Modelin performans göstergelerinden Regresyon R değerleri eğitim verileri için 0,99, doğrulama verileri için 0,97 ve test verileri için 0,99 olarak belirlenmiştir. Modelde kullanılan tüm veriler için regresyon R değeri 0,99 olarak belirlenmiştir.

Anahtar Sözcükler : D8 Ülkeleri, Yapay Sinir Ağları (YSA), Levenberg-Marquardt Yöntemi, Karbondioksit Emisyonu.

1. Giriş

Dünya hızla artan bir çevre kirliliği sorunu ile karşı karşıyadır. Buna rağmen son 50 yılda tüm ülkeler için büyüme vazgeçilemez ve yavaşlatılamaz bir kavramdır. Kirlilik ise büyüme ile doğru orantılı artmaktadır. Bu ikilem içerisinde büyüme durdurulamazken kirliliği azaltmak için yenilenebilir enerji kaynakları ve yeşil büyüme stratejileri gün geçtikçe önemli hale gelmektedir (OECD, 2012: 31-35). Dünyada ise ülkeler arasında hem büyüme hem kirlilik ile mücadele açısından eşit rekabet koşulları mevcut değildir. Gelişmiş olan ülkeler çevre ve enerji üzerine çalışmalarını 1990'lı yılların başında yoğunlaştırmışlardır. Bunu yaparken ilk aşamada kirlilik yaratan fosil yakıt tüketimini azaltmak için yenilenebilir enerji kaynaklarının tüketimini artırıp, geri dönüşümü desteklemeye özen göstermişlerdir. Hatta gelişmiş ülkeler üretimlerinin büyük bir kısmını az gelişmiş ve gelişmekte olan ülkelere kaydırmışlardır (Zhou et al., 2018: 1). Bu durumda az gelişmiş ya da gelişmekte olan ülkeler, gelişmiş ülkelerdeki sanayi kollarının "kirlilik sığınağı" ya da "kirlilik cenneti" (Pollution Haven Hypothesis) haline gelmesine sebep olmuşlardır (Fullwood et al., 2009: 58-64).

Çevre ile ilgili çalışmaları yaparken şüphesiz Çevresel Kuznets Eğrisi hipotezi ışığında, endüstriyel gelişmenin ekonomik büyüme üzerindeki etkisini göz ardı etmemek gerekmektedir. Çevresel Kuznets Eğrisi (ÇKE) hipotezi, ekonomik büyüme ile çevre arasında ilişki kuran modeller içinde, büyümenin çevreye verdiği zararları yorumlamak için en yaygın kullanılan yöntemlerden biridir. ÇKE hipotezine göre; büyüme ile paralel olarak önce gelir artmakta, gelir artışı çevre kirliliğini artırmakta bu artış belli bir süre devam ettikten sonra hem gelir artışı hem de çevre kirliliği azalmaktadır (Grossman & Krueger, 1991: 3914). Endüstriyel üretim dünya çapında ekonomik büyümeye katkı sağlarken, aynı zamanda çevresel bozulmanın maliyetlerini de artırmaktadır. Çevresel maliyetler başta küresel nüfus olmak üzere, özellikle az gelişmiş ve gelişmekte olan ülkelerde daha yüksek olabilmektedir. Herhangi bir ülkenin özellikle sanayileşme yoluyla büyümesi, enerji tüketimi ve doğal kaynak tüketimini artırırken, çevre kirliliğini de aynı oranda artırmaktadır. (Xing et al., 2023; Musah et al., 2021). Günümüzde büyümenin çevre üzerindeki etkilerini farklı yöntemler (Stirpat, ARDL, PMG vb.) ile test etmeye yönelik çalışmaların sayısı gün geçtikçe artmaktadır. Bu çalışmada son yıllarda tüm bilim dallarında ve çevre çalışmalarında da yaygın olarak kullanılmaya başlanan yöntemlerden biri olan Yapay Sinir Ağı yöntemi de eklenmiştir.

Bu çalışma, tamamı gelişmekte olan ülkelere oluşan, D-8 ülkeleri üzerine yapılmıştır. D-8 ülkelerinin toplam nüfusu 1,1 milyar olup, dünya nüfusunun 1/7'sini oluştururken bu ülkelerin toplam ekonomik büyüklükleri 4 trilyon doları aşmaktadır (<www.mfa.gov.tr>). D-8 ülkeleri aynı zamanda doğal kaynak zenginliği ile petrolde Dünya rezervlerinin %12'sini doğal gazda ise toplam Dünya rezervlerin %21'ini bünyesinde barındırmaktadır. D-8 ülkeleri batılı ülkeler ile karşılaştırıldığı zaman kişi başına düşen gelir miktarı (GSYH) açısından düşük olmalarına rağmen, yoğun nüfusları nedeniyle toplu olarak oldukça önemli bir paya sahiplerdir (Kamel, 2001: 251). Ayrıca topluluğa üye ülkelerin

sosyoekonomik ve coğrafi farklılıklarının, büyüme ve kirlilik ilişkisine etkisi D-8 ülkeleri üzerine çalışma yapmayı cazip kılmıştır.

Çalışmada kullanılan veri seti için aralık olarak 1990-2020 dönemi belirlenmiştir. Belirlenen zaman aralığı seçilirken, tüm dünyada özellikle kirlilik artışının yoğunlaşmaya başladığı 1990 yılı başlangıç noktası olarak belirlenirken, en son verilere ulaşılabilen ve çalışmanın güncelliğini artırmak için en yakın zamana tekabül eden 2020 yılları seçilmiştir. Değişkenler seçilirken, gelişmekte olan ülkelerin içinde bulunduğu büyüme kirlilik sarmalı dikkate alınmıştır. Çünkü gelişmekte olan ülkeler, sürdürülebilir kalkınmaya ulaşma konusunda, gelişmiş ekonomilere göre farklı sorunlarla karşı karşıyadırlar. Gelişmişliğin en belirgin göstergesi olan kişi başı gelir (GSYH), gelişmiş ülkelere göre daha düşük seviyededir. Bu durumdan kurtarmak isteyen gelişmekte olan ülkeler için çözüm ise üretimi daha da artırmaktır (Gürlük, 2010: 85-99). Üretim artışı ise çevre sorunlarını artırıcı başlıca unsurdur. Ancak gelişmekte olan ülkeler sürdürülebilir büyümenin devam edebilmesi için yol haritası belirlerken, gelişmiş ekonomilerin çevreyi dikkate almadan hazırladıkları kalkınma süreçlerinde yaptıkları hataları dikkate almalıdırlar. Geçmiş tecrübelerden yararlanma gelişmekte olan ülkeler için avantaja dönüşecektir. Bu durumda gelişmekte olan ekonomilerin büyüklüğü ve enerji sistemleri, radikal dönüşümlerin uygulanmasını kolaylaştıracaktır. Böylece gelişmiş emsallerine göre daha hızlı ve daha yönetilebilir hale getirme fırsatı sunacaktır (Cantarero, 2020: 70).

Gelişmekte olan ülkelerin daha fazla büyüme ihtiyaçları daha fazla enerji talebini kaçınılmaz kılmaktadır (BP Enerji İstatistikleri Sitesi; Muhumuza et al., 2018; Solarin, 2020). 2017 ile 2040 arasında dünya genelinde büyümenin %48 artacağı tahmin edilmektedir. (Dünya Enerji Görünümü, 2017: 1-5). Büyüme ile birlikte artan enerji talebinin çevre üzerindeki olumsuz etkileri ise sürdürülebilir kalkınma açısından risk teşkil etmektedir. Bu açıdan değerlendirildiği zaman kirliliğin oluşturduğu tehdit, sadece gelişmekte olan ülkeler için değil tüm dünya ülkeleri için büyük sorun oluşturmaktadır (Nepal & Paija, 2019: 164-173). Gelişmekte olan ülkelerin yenilenebilir enerji kullanımları ise daha kısıtlıdır (Cherni & Jouini, 2017; Kararaslan & Çamkaya, 2022). Bu nedenle, bu ülkelerin CO₂ emisyonunu azaltmak için enerji tüketim tercihlerini, yenilenebilir enerjiden yana kullanmaları daha önemlidir. Karbondan arındırma ve sürdürülebilir kalkınma arasındaki korelasyon göz önüne alındığında, birçok gelişmekte olan ülke bunu başlatmıştır. Hatta son birkaç yılda, GSYH bazında bakıldığında, gelişmekte olan ülkelerin bu teknolojilere, gelişmiş ülkelere daha fazla yatırım yaptıkları gözlemlenmektedir (REN21; Renewables 2020 Global Status Report, 2020). Bununla birlikte, 2019 yılında başlayan Covid-19 pandemisi nedeniyle ortaya çıkan ekonomik ve finansal sıkıntılar, gelecekte yenilenebilir enerji projelerine yapılacak yatırımları önemli ölçüde etkileyeceği tahmin edilmektedir. Sürdürülebilir kalkınma çerçevesinde, sürdürülebilir ve yenilenebilir enerji sistemlerine başarılı bir geçiş yapan ya da yapacak olan ülkelerin bu noktada desteklenmesi büyük önem arz etmektedir (Ouedraogo, 2017: 106).

Gelişmekte olan ülkelerde, büyüme ile birlikte artan kentleşme olgusu, kirlilik artışını tetikleyen başka bir unsurdur (Liang & Yang, 2019; Aslan et al., 2021). Birleşmiş Milletler

Nüfus Departmanına göre; 2040 yılına kadar Dünya nüfusunun yaklaşık üçte ikisi kentlerde yaşayacaktır. Bu süreçte kentsel değişim üç şekilde gerçekleşecektir. İlk olarak, daha fazla insan kent merkezlerine taşınacak, küresel nüfusun büyük bir bölümü kentlerde yaşayacaktır. İkinci olarak, gelecek nüfusu dünyadaki yoksulların daha büyük bir kısmına ev sahipliği yapacaktır. Üçüncüsü, gerçekleşen değişimler mekânsal yayılım gösterip şehirler, çevre ve insanlar üzerinde olumsuz etkiler oluşturacaktır (Vlahov et al., 2007: 16-26). Ayrıca, plansız şehirleşme bu ülkelerde doğal kaynakların sürdürülemez şekilde kullanımını ve doğal afetleri (su kıtlığı, iklim değişikliği, bitki ve hayvan türlerindeki azalma / yok olma) daha hissedilir kılacaktır (Baloch et al., 2019: 632-638).

Dünya çapında ekonomik, coğrafi, nüfus ve doğal kaynaklar açısından büyük bir potansiyele sahip olmasına rağmen D-8 ülkeleri üzerine yapılan çalışma sayısı, nedeni bilinmeyen bir şekilde sınırlıdır. Bu çalışma ile D-8 ülkelerinin sahip olduğu potansiyele tekrar dikkat çekilmesi hedeflenmiştir. Çalışma sonucunda; elde edilen bulguların güçlü tahmin içermesi, bu tarz sınamaların, farklı ülke ve bölgelerin çok uluslu veri kümelerinin üzerine yapılması hususunda, literatüre katkı sağlayacağı umulmaktadır. (YSA)'nın kullanarak CO₂ emisyonu tahmini yapmak, mevcut literatürdeki (EKC, STIRPAT vb.) büyüme kirlilik ilişkisini farklı yöntemler ile de ölçülmesinin geliştirilmesi adına literatüre farklı bakış açılarıyla yönelme eğilimini destekleyecektir. Çünkü kirlilik ile ilgili çalışmalar yapılırken, merak edilen soru daima, sonuçlar ne kadar tutarlı sorusuna cevap aramak olmuştur. Yine literatürde önceden yapılmış çalışmalarla sonuçların karşılaştırılması yapılarak, yöntemler arası karşılaştırma olanağı da katkı sağlayacaktır.

2. Literatür

Dünya son yıllarda iki sorunla ciddi şekilde mücadele etmektedir. Bir yandan küresel ısınmayı 1,5 °C ile sınırlamak; diğer yandan, kapsayıcı ve eşitlikçi bir sosyoekonomik kalkınmanın sağlanması (Aktaş, 2023: 5). Her iki sorunun çözümü içinse gelişmekte olan ülkeler kilit rol oynamaktırlar. Özellikle gelişmekte olan ülkelerde, ekonomik kalkınma, sosyal içerme ve çevresel sürdürülebilirlik beklentileri daha fazladır. Yine yenilenebilir enerji potansiyelinin çoğu, gelişmekte olan ülkelerde bulunduğundan, bu ülkeler kilit role sahiptir (Wang et al., 2021: 277). Bu makale, ulusal ve uluslararası literatür incelenerek hazırlanmıştır. Aşağıda konu ile ilgili dikkat çeken araştırmaların bazılarında örnekler sunulmuştur.

Pabuççu ve Bayramoğlu (2016), çalışmalarında Türkiye için büyüme kirlilik paradoksuna dikkat çekmek istemişlerdir. Sera gazı emisyonlarının en önemli nedenlerini; enerji üretimi ve tüketimi, kitlesel üretim ve ulaşım için gerekli olan enerji ihtiyacından kaynaklandığını savunmuşlardır. Avrupa Birliği ülkelerine Türkiye'yi de dahil ederek, 1990-2030 yılları arasında beşer yıllık dönemler halinde Yapay Sinir Ağları Modeli (YSA) ile tahmin yapmışlardır. Değişken olarak nüfus, enerji üretimi ve tüketimi, GSYH, ulaşım için talep edilen enerji miktarı ve sera gazı salınım miktarlarını kullanmışlardır. Türkiye'nin 2020-2025-2030 yılları için CO₂ eş değeri salım miktarlarını tahmin etmişlerdir. Elde edilen bulguların Türkiye'nin Paris İklim Zirvesi'nde 2030 yılı için söz verdiği 929 milyon ton CO₂

salınım miktarının çok üzerinde olduğuna vurgu yapmışlardır. Çalışmada CO₂ emisyonu tahmini yaparken, YSA yönteminin kullanılması ve AB ülkelerine Türkiye'nin de dahil edilerek analiz yapılması bu çalışmayı da destekleyici niteliktedir. Çalışmada YSA yöntemi ile dönemler halinde geleceğe yönelik tahmin yapmak ise bu çalışmadan farklı yönünü ortaya koymaktadır.

Marjanovic vd. (2016), yaptıkları çalışmada karbondioksit emisyonları ile gayri safi yurtiçi hasıla (GSYH) arasındaki bağıntıyı ortaya koymaya çalışmışlardır. Çalışma Avrupa Birliği üzerine yapılmış olup, CO₂ emisyonuna neden olan enerji kaynakları; katı, sıvı, gaz olarak ayrıştırılmıştır. Bilindiği üzere, ekonomik büyüme ile karbondioksit emisyonları arasındaki ilişki en önemli ampirik kanıtlardan biri olarak kabul edilmektedir. Ancak, güvenilir iklim değişikliği politikaları için karbondioksit CO₂ emisyonları ile ekonomik büyüme arasındaki ilişkinin nedensel analizi hala sınırlıdır. Bu çalışmada, CO₂ emisyonlarına dayalı olarak GSYH'daki değişimi tahmin etmek için Ekstrem Öğrenme Makinesi (ELM) geliştirilerek, uygulanmıştır. ELM sonuçları, Genetik Programlama (GP) ve Yapay Sinir Ağı (YSA) ile karşılaştırılmıştır. Hesaplamalı modellerin güvenilirliğine, simülasyon sonuçlarına dayalı olarak ve çeşitli istatistiksel göstergeler kullanılarak erişilmiştir. ELM, YSA ve GP yöntemleri için belirleme katsayıları sırasıyla 0.9271, 0.8756 ve 0.4475 olarak bulunmuştur. ELM yöntemi ile GSYH tahminlerinin tutarlı olduğu sonucuna varılmıştır. Çalışma AB üzerine yapılsa da kullanılan yöntem ve büyüme ile enerji kullanımı arasındaki ilişkinin CO₂ emisyonu üzerindeki etkisi, bu çalışmada da destekleyici olmuştur. Birden fazla yöntemin karşılaştırılmalı olarak kullanımı ise bu çalışmadan farklı yönünü ortaya koymaktadır.

Zeng vd. (2017) çalışmalarında dünya üretiminin önemli bir ölçөгünü elinde bulunduran Çin ekonomisi üzerinde yapmışlardır. 1978-2013 arası Çin'in yıllık enerji arzı, enerji tüketimini karşılayamamıştır. Çalışmada, enerji tüketimini tahmin etmek için uyarlanabilir bir geri yayılma sinir ağı (BPNN) modeli olan ADE-BPNN adlı melez model uygulanmıştır. Önerilen melez modelde, girdi olarak nüfus, ithalat, ihracat ve gayri safi yurtiçi hasıla, verileri yer almaktadır. Elde edilen bulgular ile karbon emisyonunu azaltan bir yöntem geliştirmeyi hedeflenmiştir. Önerilen ADE-BPNN modelinin uygulanabilirliğini ve doğruluğunu karşılaştırmalı bir örnek (Çin ve ABD) üzerinde sınımışlardır. Test veri kümelerindeki hatalar, modelin alışıl gelmiş geri yayımlı sinir ağı modeli ve diğer bilinen mevcut modellerle karşılaştırılması yapıldığı zaman enerji tüketimini başarılı bir şekilde tahmin edilebildiği gözlemlenmiştir. Çalışmanın özellikle YSA modellerinin mevcut modeller ile karşılaştırıldığı zaman daha başarılı sonuçlar içermesinin ampirik olarak kanıtlanması bu çalışmada kullanılan modelin özgünlüğünü destekleyici nitelikte olmuştur.

Ahmadi vd. (2023) çalışmalarında, Sera gazı emisyonlarının, küresel ısınmaya ve iklim değişikliğine önemli ölçüde neden olduğunu belirtmişlerdir. Çalışmada, birincil enerji kaynağı olarak kullanılan çeşitli enerji kaynaklarının paylarını temelinde en önemli sera gazı olan karbondioksit emisyonlarını belirlemek için bir Yapay Sinir Ağı (YSA) yaklaşımı olan Grup Veri İşleme Yöntemi (GMDH) kullanılmışlardır. Çalışmalarında, Birleşik Arap Emirlikleri (BAE), Katar, Kuveyt, İran, Suudi Arabistan da dahil, beş orta doğu ülkesi

üzerine yapmışlardır. Geliştirilen model tarafından elde edilen sonuçlar ile gerçek büyüklüklerin karşılaştırılması sonucunda, YSA modelinin CO₂ tahmininde kabul edilebilir doğruluğa sahip olduğunu tespit etmişlerdir. Çalışmanın, beş Ortadoğu ülkesi üzerine yapılması, bu çalışmanın ise D-8 ülkeleri üzerine yapılması benzer coğrafi alan açısından destekleyici olmuştur. Çalışmada kullanılan değişkenler ve yöntem ilişkisi ise bu çalışmanın özgünlüğüne vurgu yapmaktadır.

Acheampong ve Boateng (2019), çalışmalarını Avustralya, Brezilya, Çin, Hindistan ve ABD üzerinde yapmışlardır. CO₂ emisyonu fazla olan bu ülkelerde emisyon yoğunluğunu tahmin etmek için Yapay Sinir Ağı (YSA) yöntemini uygulamışlardır. Çalışmada, modelleri geliştirmek, eğitmek ve doğrulamak için adı geçen ülkelere ait 1980-2015 dönemine ait üç aylık veriler kullanılmıştır. Girdi değişkenler; Ar-Ge, ekonomik büyüme, ticari açıklık, finansal gelişme, doğrudan yabancı yatırımları, enerji tüketimi, sanayileşme ve kentleşme seçilmiştir. Çalışma sonucunda yüksek belirleme katsayısına sahip olan ülkeler ve değişkenler ise şöyledir. Avustralya için Ar-Ge, Brezilya ve ABD için kentleşme, Çin için nüfus büyüklüğü, Hindistan'da ise enerji tüketimi en yüksek belirleme katsayısı olan (R²)'ye sahip oldukları belirlemişlerdir. Çalışma nüfus yoğunluğu fazla olan ülkelerin CO₂ emisyonunun YSA yöntemi ile tahmini yaparken, ekonomik büyüme, enerji tüketimi ve kentleşme oranı değişkenlerinin kullanılması, bu çalışmayı da destekler niteliktedir.

Ashin-Nishan ve Villanthenkodath (2020) çalışması Hindistan üzerinde yapılmıştır. Çalışmanın amacı Hindistan gibi hızla büyüyen gelişmekte olan ülkelerde temiz enerjinin büyüme üzerine etkisini ortaya koyabilmektir. Çalışmada enerji kullanımı (fosil ve yenilenebilir enerji) girdi değişkeni olarak alarak, karbondioksit emisyonlarının ve büyüme tahminini Yapay Sinir Ağı (YSA) tekniği ile tahmin etmişlerdir. Elde edilen bulgular ile büyüme devam ederken CO₂ emisyonunu azaltmak için makine öğrenimi teknikleri kullanılarak, iyileştirilebileceğini ileri sürmüşlerdir. Sonuçta, fosil yakıt kullanımından yenilenebilir enerji kullanımına geçişin, ekonomik büyümeden ödün vermeden karbondioksit emisyonlarını azaltmanın olası bir yolu olduğunu özellikle vurgulamışlardır. Çalışma çevre çalışmaları için umut verici olmuştur. Bu çalışma göstermiştir ki oluşturulacak politikalar fosil yakıt kullanımını azaltacak veya enerji verimliliğini artıracak şekilde düzenlenebilirse, daha iyi sonuçlar alınabilir. Çalışma gelişmekte olan ve nüfus yoğunluğu fazla olan Hindistan üzerine yapılırken, kullanılan yöntem ve değişkenler ile elde edilen sonuçlar bu çalışma ile benzer bulguları desteklemektedir.

Özhan (2020), çalışmasında Türkiye'nin 1960-2014 yılları arasındaki özellikle sektörlerin yarattığı sera gazı emisyon miktarlarının ölçümü ve gelecek tahmini yapılması hedeflenmiştir. CO₂ eşdeğeri sera gazı emisyonu ölçümleri ile yaptığı çalışmasında sera gazlarının atmosferdeki buldukları şekillerine ve paylarına göre metan (CH₄), azot oksit (N₂O), hidroflorokarbonlar (HFC'ler), perflorokarbonlar (PFC'ler), sülfür heksaflorür (SF₆) değerlerini CO₂ eşdeğerlerine dönüştürerek emisyonları ölçümlemeyi hedeflemiştir. Çalışmada için önce Zaman serisi analizi yapılmış, ardından Yapay Sinir Ağları (YSA) ve algoritmaları ile örüntüler elde edilmiştir. Bu değerlere göre iki model arasında yapılan karşılaştırma sonucu en az hata veren modelin YSA olduğu tespit edilmiştir. YSA'nın daha

doğru tahminler yapacağı bulgusundan hareketle 2021 yılına kadar olan tahminler yapılmıştır. Model sonucunda Türkiye için 2021 yılı CO₂ emisyonunu tahmini 366,3972 milyon tondur. Çalışma mantık olarak YSA yöntemi ile CO₂ emisyonun tahminini yaparak bu çalışma ile benzerlik göstermektedir. Ancak tek ülke Türkiye üzerine yapılması, sera gazlarının atmosferdeki şekillerine göre ölçülmesi ve farklı iki yöntem sınanıp, yöntem karşılaştırmasına gitmesi bu çalışmadan, farklı yönlerini ortaya koymaktadır. Bir başka farklılık olarak ise çalışmada geleceğe yönelik tahminlerde bulunulmuştur.

Jena vd. (2021), çalışmalarında gelişmiş ve gelişmekte olan 17 kilit ülkenin CO₂ emisyonlarını tahmin ediyorlar. Emisyonları tahmin etmek için doğrusal istatistiksel modellemelerin aksine çok katmanlı bir yapay sinir ağı modeli kullanmışlardır. Modelde, CO₂ emisyonlarının öngörücüleri olarak gayri safi yurtiçi hasılayı (GSYH), kentsel nüfus oranını ve ticari açıklığı kullanmışlardır. Sonuçlar, Çin, Hindistan, İran, Endonezya ve Suudi Arabistan gibi yüksek emisyonla sahip ülkelerin yakın gelecekte emisyonlarının daha da artacağını göstermiştir. Brezilya, Güney Afrika, Türkiye ve Güney Kore gibi düşük emisyonlu ülkeler de ise emisyonun büyüme ile orantılı artacağı öngörülmüştür. Öte yandan ABD, Japonya, İngiltere, Fransa, İtalya, Avustralya ve Kanada gibi ülkelerin ise emisyonlarını sürekli azaltacağını belirtmişlerdir. Çalışmada, bu çalışmadan farklı olarak gelişmiş ve gelişmekte olan ülkelerin karması oluşturulmuştur. Ayrıca GSYH, kentsel nüfus oranı değişkenlerine, diğer bu ve diğer çalışmalardan farklı olarak, ticari açıklık değişkeni sınanmıştır. Çalışmanın YSA yönteminin kullanılması ise bu çalışmayı destekler niteliktedir.

Sel ve Tekgün (2022), Türkiye üzerine yaptıkları çalışmada, sera gazı salınımının artması nedeniyle, büyümenin gerekliliği ile sürdürülebilirlik endişesi arasındaki çelişkiye vurgu yapmışlardır. Çalışmada, karbondioksit salınımı tahmini için hem bulanık mantık hem Yapay Sinir Ağları (YSA) yönteminin birlikte kullanıldığı Uyarlamalı Sinirsel Bulanık Çıkarım Sistem (ANFIS) yöntemi kullanılmışlardır. Uygulamanın ilk kısmında ithalat, ihracat, Gayri Safi Yurt İçi Hasıla (GSYH), nüfus, değişkenleri kullanılarak 1998- 2018 yılları için aylık veri seti kullanılarak 2019-2020 yılları karbon emisyonu ($R^2=0,964$) olarak tahmin edilmiştir. İkinci kısımda ise ilk kısımda elde edilen veriler kullanılarak aylık karbon emisyonu değerleri ile birlikte 2021, 2022 ve 2023 yılları için karbon emisyonu tahmininde bulunmuşlardır. Çalışmada, bu çalışmadan farklı olarak yine tek ülke üzerine analiz yapılmıştır. CO₂ emisyonun tahmini için yöntem olarak ise YSA yöntemi ile birlikte ANFIS yöntemi de sınanmıştır. Ayrıca gelecek ile ilgili tahminler yapılmıştır.

Birjandi vd. (2022), yaptıkları çalışmalarında, dört Güneydoğu Asya ülkesinin 2000-2019 yılları arasındaki enerji kullanımı ve ekonomik büyümenin, sera gazı emisyonları üzerindeki etkisini incelemişlerdir. Çalışmada; Malezya, Endonezya, Singapur ve Vietnam'ın GSYH verileri ile enerji tüketim miktarları ve türleri girdi olarak belirlenmiştir. CO₂ emisyonunun üretimini modellemek için normalleştirilmiş radyal tabanlı ve tansig olmak üzere iki transfer fonksiyonlu Yapay Sinir Ağı (YSA) yöntemini kullanmışlardır. Model kurulurken farklı enerji kaynaklarının kullanılmasından kaynaklanan farklı CO₂ emisyon miktarlarının oluşacağı dikkate alınmıştır. Çalışma sonucunda CO₂ emisyonlarının


oluşmasında en büyük payın enerji ile ilgili faaliyetlerin oluşturduğunu tespit etmişlerdir. Çalışmada CO₂ emisyonun tahmini için YSA yönteminin farklı bir modelini kullanmıştır. Kullanılan değişkenlerden biri olan, enerji değişkeni ise türlerine göre modellenerek, bu ve benzeri çalışmalara aynı değişkenlerin farklı özellikleri dikkate alınarak da CO₂ emisyonu üzerindeki etkisinin ölçülebileceğini göstermiştir.

Çalışmaların tamamına bakıldığı zaman, karbon emisyonu tahmini yapılırken, kirlilik üzerinde etkili çok sayıda değişken olması, değişkenler ile yapılan çalışmanın niteliğine ve kullanılan yöntemlere göre değişiklik gösterebilmektedir. Yapay Sinir Ağı (YSA) ile yapılan tahminlerin ise kullanılan değişkenler gibi farklı YSA modelleri ile sınılanması mümkündür. Ancak tüm çalışmalarda YSA'nın kullanımının genelde sağlıklı ve güvenilir sonuçlar vermesi yöntemin kullanımı ve sağladığı avantajlar açısından daha da yaygınlaşacağı bakımından umut vericidir.

3. Veri ve Yöntem

Yapay Sinir Ağları (ANN - Artificial Neural Network), insan beynini baz alınarak tasarlanan ve basit sinir hücresinin çalışma şeklini taklit eden bir yazılımdır. Yapay sinir ağları aracılığıyla öğrenme işlemi, hedeflenen gayeye ulaşmak için hücreler arasındaki sinaptik iletim (komşu sinir hücreleri arasındaki gönderim) bağlantılarının ayarlanması ile çalışır (Nilson, 1998; Luger, 2002). İlk yapay sinir ağı örneği 1943 yılında nörolog Warren McCulloch ve mantıkçı olan Walter Pitts tarafından "A Logical Calculus of Ideas Immanent in Nervous Activity" başlıklı makalenin yayınlanması ile çığır açmıştır. Literatüre McCulloch-Pitts nöronu olarak geçmiştir. YSA aslında insan beyninde bulunan biyolojik sinir ağlarını taklit eden bileşimsel yapılardır. Eğitimden sağlığa, savunmadan mühendisliğe kadar birçok alanda geleneksel yöntemler ve işlemleyicilerin yetki sunmadığı alanlarda sorunların çözümünde etkindirler. Günümüzde YSA kullanılarak başarılı çalışmalara imza atılmıştır (Russell & Norving, 1995: 27).

Şekil: 1
Biyolojik ve Sentetik Yapay Sinir Ağı Hücresi



Kaynak: URL 1, 2023

Kaynak: URL 2, 2023

Girdiler (x_1, x_2, \dots, x_n), başka hücrelerden ya da ortam dışından hücreye giren bilgilerdir. Girdiler ağı öğrenmesini istediğimiz örnekler aracılığıyla belirlenir. Ağırlıklar (w_1, w_2, \dots, w_n), ise girdiler ya da kendinden bir önceki katmandaki başka bir işlem elemanının süreç üzerindeki etkisini gösteren değerlerdir. Her girdi, o girdiyi süreç ögesine bağlayan ağırlık değeriyle çarpılarak, (b) eşik değeri ile toplanır. Toplam fonksiyonu vasıtasıyla da birleştirilir. Toplam fonksiyonu bir hücreye gelen net fonksiyonu hesaplar. Eşitlik (1) de ki gibi gösterilir.

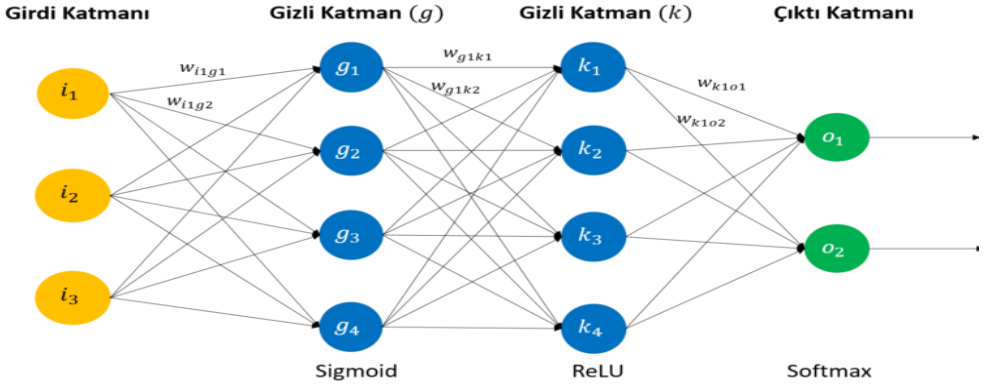
$$net = \sum_{i=1}^n w_i x_i + b \quad (1)$$

Toplam fonksiyonu sonucunda elde edilen değer doğrusal ya da doğrusal olmayan biçimde türevi alınabilir. Böylece transfer fonksiyonundan geçirilen işlem ögesinin çıktısı hesaplanmış olur (Eşitlik 2).

$$y = f(net) = f(\sum_{i=1}^n w_i x_i + b) \quad (2)$$

Yapay Sinir Ağlarında bilgiler ve algoritmalar kesin değildir, istenen sonuca ulaşmak için geçmiş deneyimlerden yararlanır. Gerekli deneyimlerden faydalanmak için çeşitli öğrenme algoritmaları sınanır. Bu çalışmada, MATLAB programı ve Neural Net Fitting araç kutusu (toolbox) kullanılarak, Levenberg- Marquardt yöntemi ile Yapay Sinir Ağı eğitilmiş olup, belirlenen değişkenler ile D-8 ülkeleri için karbon emisyonu tahmini yapılmıştır.

Şekil: 2
Geri Yayımlı Öğrenme Algoritması



Kaynak: Öztürk & Şahin, 2018: 31.

3.1. Geri Yayımlı Öğrenme

Geri yayımlı öğrenme algoritması çok tabakalı ağ yapısında (Şekil 2) kullanılan algoritmalardan bir tanesidir. Ağa gönderilen eğitim verisi (input) ve ağı kendi ürettiği çıktı verisi (output), beklenen değer (target) ile karşılaştırılır. Gerçekleşen ve beklenen iki değer arasındaki fark ise hata değerini belirler. Bulunan hata değeri, bir sonraki tekrarlama da ağı

ağırlık değerleri arasında yeniden dağıtılarak, işlem sonucundaki hata değerinin düşürülmesi amaçlanır (Nabiyev, 598: 2016).

Newton algoritmalarının türetilmesi ile oluşturulan Levenberg-Marquardt algoritması, değişken güncelleme işlemleri için bütün girdilerden oluşturulmuş hata vektörü ve Jakoben matrisi ile yapılmaktadır. Levenberg-Marquardt algoritmasının, bir başka avantajı ise sistem kaynaklarını diğer algoritmalara göre daha fazla kullanmaktadır. Böylece ağırlık eğitilmesi daha kısa sürede gerçekleşmektedir. Uygulamada genel olarak iyileşme durdurulduğunda, eğitim sonlanmaktadır (Marquardt,1963; Hagan & Menhaj, 1994; Hagan et al., 1996).

$$\Delta w = (J^T J + \mu I)^{-1} J^T e \quad (3)$$

Eşitlik 3'te belirtilen I, birim matrisi, μ , kombinasyon katsayısı ve w, ağırlık vektörüdür. J, [(P x n), N] boyutunda Jacobian matrisini, e, [(P x n), 1] boyutunda hata vektörünü ifade eder. P, eğitilen örnek sayısını, n, çıktı sayısını ve N, ağırlık sayısını gösterir. μ ayarlanabilir bir parametredir. Eğer elde edilen parametre çok küçükse Newton metodu gibi davranırken elde edilen parametre çok büyükse yöntem dik iniş metodu gibi davranacaktır. Söz konusu parametre için uyarlamalı bir yapı Eşitlik 4'te verilmiştir (Çizmeçi vd., 2018: 184).

$$\mu(n) = \begin{cases} \mu(n-1)k E(n) > E(n-1) \\ \mu(n-1)/k E(n) \leq E(n-1) \end{cases} \quad (4)$$

3.2. Matlab Programına Özel Geliştirilen Sinir Ağı Araç Kutusu (Neural Network Toolbox For Matlab)

YSA için kullanılabilecek birçok araç (toolbox) ve program arayüz bulunmaktadır. Bu araçlardan biri de bu çalışma içinde kullanılan MATLAB programı kapsamında geliştirilmiş Neural Network Toolbox'dır. Bu Toolbox yüzeysel ve derin sinir ağlarını oluşturmak, görselleştirmek, eğitmek için kullanılır. Ayrıca benzeşim için algoritmalar, daha önce eğitilmiş model ve uygulamaları da sunar.

3.3. Veri Tabanı


Bu çalışmada, aralarında Türkiye'nin de bulunduğu gelişmekte olan ülkeler (Developing-8) olarak adlandırılan D-8 (Türkiye, Bangladeş, Mısır, Endonezya, İran, Malezya, Nijerya ve Pakistan) ülkelerinde karbon emisyonu tahmini YSA yöntemi kullanılarak yapılmıştır. Çalışmada özellikle D-8 ülkelerinin seçilme nedeni; gelişmekte olan ülkeler arasında sahip oldukları geniş coğrafi alan, nüfus potansiyeli ve hızla gelişen ülkeler arasında yer almalarıdır.

Çalışmada 1990-2020 yılları arasındaki 30 yıllık dönem için D-8 Ülkelerine ait ve karbon emisyonu üzerinde etkili olduğu düşünülen değişkenler kullanılmıştır. Değişkenler belirlenirken literatürdeki çalışmalar (Aytun vd., 2017; Garces et al., 2019; Ashraf et al.,

2020; Patterson et al., 2021; Komeli-Birjandi et al., 2022) baz alınmıştır. Veriler yıllık olarak kullanılmıştır. Elde edilen veriler, Dünya Bankası veri tabanı, BP Dünya Enerji İstatistikleri Raporu ve ülkelerin kendi resmi istatistik sitelerinden parçalar halinde ve manuel olarak toplanmıştır. Matlab programı dahilinde geliştirilen sinir ağı araç kutusu (Neural Network Toolbox) içerisinde bulunan, Neural Net Fitting uygulamasına, eğitim verisindeki girdiler (inputs) ve hedefler (target) tanımlanmıştır.

Bu çalışmada kurulan YSA modelinde veri tabanı verilerinin rastgele olarak %70'i eğitim, %15'i doğrulama ve %15'i test verilerine ayrılmıştır. YSA modelinde girdi değişkenleri; yenilenebilir enerji tüketim miktarı, fosil yakıt tüketimi, Gayri Safi Yurtiçi Hasıla (GSYİH), kentsel nüfus artış oranı olurken, çıktı değişkeni CO₂ emisyonları olarak belirlenmiştir. Ağda kullanılan gizli nöron sayısı 10 olarak saptanmıştır. Oluşturulan bu yapay sinir ağı, Levenberg-Marquardt algoritması ile eğitilmiştir (Şekil 3).

Şekil 3
YSA Model Değişkenler



Not: Şekil 3 yazar tarafından oluşturulmuştur.

Tablo 1'de eğitim, doğrulama ve test verilerinin sayısal dağılımları şöyle olmuştur. Eğitim verisi 174, doğrulama verisi ve test verileri ise 37 şer tane olup, toplamda 248 tane veri kullanılmıştır.

Tablo: 1
Değişkenlerin Sayısal Dağılımları


Veri Seti Adı	% Oranı	Sayısı
Eğitim	70	174
Doğrulama	15	37
Test	15	37
Toplam	100	248

Not: Yazar tarafından oluşturulmuştur.

Yapay sinir ağı yönteminin iki önemli avantajı bulunmaktadır. Birincisi sürekli değerli girdi ve çıktılar için uygundur. İkincisi ise doğrusal olmayan verileri açıklamayı yeteneğine sahiptirler. Yapay sinir ağları insan beynindeki bilgi işleme ve saklama şeklini taklit ettiği için veriyi çevreden alan, saklayan gerektiğinde kullanan bir yapıya sahiptir. İnsan beynindeki sinir hücrelerini taklit eden, nöronlar aslında matematiksel işlemler arasında bağlantılar oluşturarak çalışır. Nöronlar birbirlerine ağırlıklı katmanlar halinde bağlanır ve düzenlenir. Bir katmanda yer alan sinir hücresi kendinden önceki ve sonraki katmanlarda bulunan sinir hücrelerine bağlıdır (Ercan, 2021: 3269).


YSA'daki nöronların işleyiş şekli (Şekil 4) şöyledir. Giriş kısmındaki x nöronlarından alınan veri seti toplam fonksiyonu ile birleştirilip daha sonra doğrusal olmayan bir aktivasyon fonksiyonuna gönderilerek elde edilen çıktı, tarafından diğer sinir hücrelerine yönlendirilir. Her bir sinir hücresi tek çıkış sinyali üretirken, tüm giriş sinyallerini aynı anda sinir hücresine ulaşır. Her giriş sinyali aynı zamanda bir bağlantı ağırlığı ile ilişkilidir. Başka bir ifade ile bir sinir hücresi çok sayıda giriş sinyali alırken, sadece bir tane çıkış sinyali gönderir. Ağırlıklar ise giriş sinyalinin sinir hücresi tarafından iletilen sonuç sinyalini üretmedeki sahip olacağı göreceli önemi belirler. Bias olarak adlandırılan eşik değeri ise genellikle girdi olarak kullanılan ve regresyon modelindeki sabit olarak adlandırılan yapı ile benzerdir. Çalışmada verilen yapay sinir ağları denetimli bir öğrenme modeli olarak kullanılır. YSA'da öğrenme genelde geri yayılım algoritması adı verilen bir algoritma ile gerçekleştirilir (Giudici, 2003; Larose, 2005; Ercan, 2021).

Şekil: 4
YSA'da Yer Alan Nöronların Genel Yapısı



Kaynak: Haykin, 2008: 11.

Şekil: 5
YSA Modelinin Tabaka Sayıları



Not: Matlab programı aracılığı ile modele göre oluşturulan tabaka sayılarının gösterimidir.

Çalışmada YSA modeli beş adet girdi değişkeni ve bir adet çıktı değişkeni ile oluşturulmuştur. Modelin belirlediği gizli tabaka sayısı on ve çıktı tabaka sayısı birdir. Modelin yapısı, Şekil 5'teki gibi oluşmuştur. Modelin eğitim verilerini eğitmek için Levenberg-Marquardt algoritması kullanılmıştır. Modelin performans göstergeleri Tablo 4'te belirtilmiştir.

Tablo: 4
YSA Modelinin Performans Göstergeleri

Veri Seti	Veri Sayısı	Hata Kareler Ortalaması (MSE)	Regresyon Değeri (R)
Eğitim	174	0,0013455	0,992
Doğrulama	37	0,0025065	0,978
Test	37	0,0024826	0,990

Not: Yazar tarafından oluşturulmuştur.

Regresyon değeri, YSA model sonucu ile gerçek değer arasındaki korelasyon ilişkisinin değeridir. Regresyon (R) değeri, modeldeki bağımsız değişkenlere göre bağımlı değişkenin, değişkenliğinin ne kadarının model tarafından açıklanabileceğini gösterir. Korelasyon katsayısının karesidir. Regresyon modelinde fazla sayıda bağımsız değişken varsa model eğitim verilerine çok iyi sağlayabilir. Ancak test modelinde istenen sonuç alınamayabilir. Bu yüzden Düzeltilmiş R Kare kullanılır. R değerinin 1'e yakın olması modelin başarılı sonuç verdiğini göstermektedir. MSE değerinin küçük olması istenen bir durum olsa da sıfır olması durumunda modelin hata verdiği anlamına gelmez. Çalışmada elde edilen bulgular (Tablo 4: dördüncü sütun) üç test içinde modelin başarılı olduğunu göstermektedir.

$$R^2 = 1 - \frac{SS_{Kalıntı}}{SS_{Toplam}} \quad (5)$$

$$R^2_{adj} = 1 - \frac{MS_{Kalıntı}}{MS_{Toplam}} \quad (6)$$


Minimum karesel hata (MSE) / Kök ortalama kare hatası değeri, YSA model sonuçları ile gerçek sonuçlar arasındaki farkın karelerinin ortalama değeridir. Ortalama Kare Hatası, bize tahminler ile gerçek değerler arasında karşılaştırma yapacağımız mutlak bir sayı verir. Ancak farklı modeller ile karşılaştırıp daha sağlıklı sonuçlar elde etmek için Kök Ortalama Karekök Hatası (RMSE) kullanılır. Bu, MSE'nin kareköküdür. MSE'den farklı olarak sunduğu avantaj ise bazen MSE değeri kolayca karşılaştırma yapamayacak kadar büyük olabilir. Bu yüzden RMSE hata karesi ile hesaplanır ve böylece yorum yapmayı kolaylaştırır (Kendal et al., 1963: 552).

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (7)$$

Bu çalışmada eğitim, doğrulama, test veri setleri ve tüm veriler kullanılarak YSA modeli oluşturulmuştur. YSA modelinin tahmin değerleri ile gerçek değerler arasındaki hata değerlerinin histogram grafiği Şekil 6'daki gibi elde edilmiştir. Gerçek değerler (Target), YSA modelinin tahmin sonuçları (Output) arasında oluşan matematiksel farkın ifadesidir.

Her bir histogram içerdiği test değerlerine göre farklı renklerden oluşmaktadır. Sarı düz çizgi sıfır hatayı temsil etmektedir. Yani tahmin ve test değerlerinin tamamen uyumlu olduğu noktayı ifade eder (Wang & Lu, 2018: 2).

Şekil: 6
Tahmin ve Test Değerlerinin Grafikselleştirilmesi



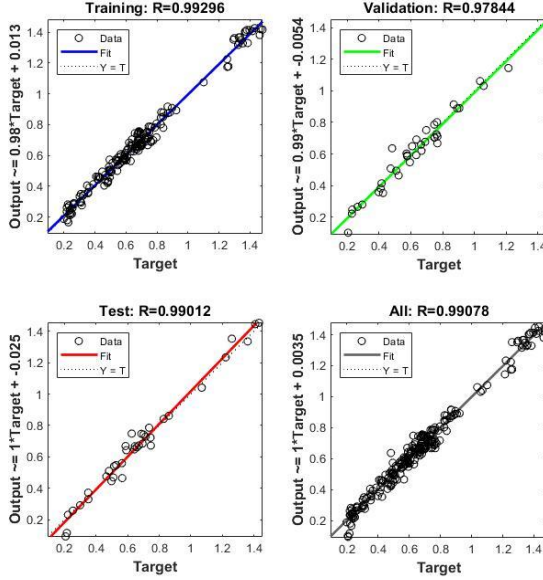
Not: Matlap programı aracılığıyla oluşturulan tahmin ve test değerleri grafiğidir.

Şekil 7’de eğitim, doğrulama, test ve tüm verileri bir arada gösteren regresyon çizgisi üzerinde sonuçlara göre oluşturulmuş değerler yer almaktadır. Belirleme katsayısı (R) değerleri beklenen ile gerçekleşen arasındaki farkı ifade etmektedir. Elde edilen R değerleri sırasıyla eğitim verileri için 0,99 doğrulama verileri için 0,97 test verileri için 0,99 tüm veriler için 0,99 olarak bulunmuştur. Elde edilen sonuçların 1’e yakın olması tahminlerin güçlü olduğunu göstermektedir. Çalışmada kullanılan bütün veri seti dikkate alındığında gerçek değerler ile YSA modelinin tahmin değerleri arasındaki ilişki eşitlik (7) deki gibi elde edilmiştir. Sonuçlar incelendiği zaman, tahmin ve test değerlerinin uygun aralık içerisinde oldukları görülmektedir. Yapılan bu çalışma ile ülkelerin karbon emisyonunu tahmin ederken geleneksel yöntemlerle (EKC, STIRPAT vb.) hesaplanmasının yanı sıra tahmin işlemlerinin, yapay sinir ağları kullanılarak da yapılabileceğini ortaya koymaktadır.

$$Output = 0,98 * Target + 1,3 * 10^2 \quad (7)$$

Eşitlik 7’de output, YSA model tahmin değeri, Target ise gerçek değeri göstermektedir.

Şekil 7
Modelin Sonuçları



Not: Eğitim, doğrulama, test ve tüm verilerin model sonuçları ile karşılaştırılması.

4. Sonuç ve Öneriler

Son yıllarda yaşanan küresel iklim krizi nedeniyle çok sayıda çevre felaketinin yaşanması (kasırga, sel, yangınlar, kuraklık, aşırı soğuk ve sıcaklar vb.) çevre bozulması üzerinde insan faaliyetlerinin olumsuz etkisini sıklıkla gündeme getirmektedir. Ekonomik büyüme sürecine öncelik veren gelişmekte olan ülkelerin, kirlilik üzerinde yarattıkları olumsuz baskı nedeniyle, konu ile ilgili çalışmalarda sıkça gündeme gelmektedirler. Sadece gelişmiş ülkeler için çevre üzerine yapılan çalışmaların sonucuna bakarak, genel bir değerlendirme yapmak ise hatalı yorumlara yol açabilir. Çünkü küresel kirlilikte, gelişmekte olan ülkelerin sayıca fazla olmaları daha fazla negatif dışsallık oluşturmalarına yol açmaktadır.

Dünyanın neredeyse üçte ikisi gelişmekte olan ülkelere aittir. Çalışmanın D-8 ülkelerinin üzerine yapılmasının nedeni gelişmekte olan ülkelerin büyüme bazlı eğilimlerinin etkilerini, karbon emisyonu açısından değerlendirmektir. D-8 örgütünün kuruluş amacı, ülkelerin ellerinde bulundurdukları ekonomik potansiyeli ve sahip oldukları kaynakları geniş nüfus avantajı ile de birleştirerek, ticaret ilişkilerini daha avantajlı hale getirmektir. D-8 ülkelerinin diğer bir amacı ise bölgesel ekonomik bir güç olmaktan ziyade küresel ekonomik bir güç olabilmeyi başarabilmektir. Bu birlikteliğin başlatılmasında,

ülkelerin ekonomik potansiyeli, kaynak etkinliği, önemli nüfus avantajı ve geniş bir coğrafi alana yayılmaları şüphesiz etkin olmuştur. D-8 ülkelerinin, ticari ilişkilerde yeni olanaklar yakalamak ve çeşitlendirmek, uluslararası düzeyde karar alma süreçlerine katkıda bulunmak, muasır medeniyet düzeyinde yaşam koşulları sağlamak, belirli ortak projeler çerçevesinde iktisadi seferberlik geliştirmeleri hedeflenmektedir. Belirlenen amaçlar incelendiği zaman gelişmekte olan ülkelerin dünya ekonomisindeki perspektifleri de değişmektedir.

D-8 ülkelerinde kirlilik üzerinde etkin olan değişkenlerin tahmini için yapılan bu çalışmada YSA yöntemi kullanılmıştır. Son yıllarda bilim dünyasında yapay zekâ uygulamaları sıkça gündeme gelmektedir. YSA'da en yaygın yapay zekâ yazılımlarında birisidir. Çalışmada kullanılan veriler seçilirken literatürde özellikle son beş yılda kirlilik üzerine YSA ile yapılan çalışmalar ve değişkenleri dikkate alınmıştır. YSA kullanılarak yapılan çalışmaların sonuçlarında, genel olarak tahminlerin doğruluk derecesi ve başka yöntemler ile karşılaştırıldığı zaman daha başarılı sonuçlar elde edildiği vurgulanmıştır. Klasik kirlilik modellerinde (EKC, STIRPAT, ARDL vb.) kullanılan yabancı yatırımlar, ihracat, ithalat göstergelerinin aksine farklı değişkenler (enerji tüketimi, kentleşme oranı, vb.) kullanılarak da farklı bir bakış açısı geliştirmek hedeflenmiştir. Çalışmada veri seti olarak, yenilenebilir enerji tüketim miktarı, fosil yakıt tüketimi, Gayri Safi Yurtiçi Hasıla (GSYH), kentsel nüfus artış oranı ve çıktı değişkeni olarak CO₂ emisyonları olarak kullanılmıştır. Çalışma sonucunda eğitim, doğrulama ve test verilerine ait R değerleri sırasıyla; 0,99; 0,97; 0,99 olarak bulunmuştur. Tüm değişkenler için R değeri 0,99 olarak gözlemlenmiştir. Elde edilen bulgular, istenen aralıkta olup, tahmin başarılı kabul edilmiştir.

Çalışmanın kirlilik konusunda, gelecekte yapılacak farklı çalışmalara da katkı sağlaması beklenmektedir. Bunun için önceden klasik yöntemler ile yapılan çalışmalar aynı dönemler için YSA yöntemi ile yapıp, sonuçların yöntemler açısından karşılaştırması açısından fırsatı sunabilecektir. Çalışmalar yine tamamen farklı ülke ya da ülke grupları üzerinde sınanabilir. Çalışmanın gelişmiş ülkeler üzerinde sınanması yapılarak farklı bakış açıları geliştirilebilir. Böylece bu ve benzeri çalışmalarla farklı yöntemlerle ve farklı değişkenlerle de kirlilik çalışmaları yapılabileceğini destekleyecektir. Çalışma yapılırken en büyük kısıt veri bulma sıkıntısı olarak görülmüştür. Özellikle bazı ülkelerin son beş yıla ait değerleri kendi istatistik siteleri üzerinden manuel olarak toplanabilmektedir.

Gelişmekte olan ülkelerin kirlilik üzerindeki etkileri dikkate alındığı zaman, ekonometrik bulgularla uyumlu olarak, aşağıdaki politika önerilerini sunulmuştur. Bu politikalar ancak devlet eliyle hayata geçirilebilecek politikalardır. Çevresel politikaların bireysel önlemler olarak ya da kamu otoritesi olmaksızın başarılı olması çok olası değildir.

Ekonomik büyüme, küresel ısınmayla mücadelede önemli bir araçtır. Gelişmekte olan ülkelerin büyüme-kirlilik ilişkisini ortaya koyan Çevresel Kuznets Eğrisi hipotezinin temelinde de sürekli ekonomik büyüme ile belirli bir gelir düzeyine ulaşılabileceği ve bunun sonucunda CO₂ emisyonlarının azalacağı varsayılmaktadır. Bu açıdan bakıldığında,

ekonomik büyümenin ilerletilmesi gerekmektedir. Ancak büyüme CO₂ salınımını azaltıcı etkisi olan yenilenebilir enerji kullanımı ve yatırımları ile desteklenmesi önemlidir.

Fosil yakıtlardan elde edilen enerji yerine çevre dostu kaynakları ile yeni evlerin, işyerlerinin ve fabrikaların tükettikleri enerjinin en azından belli bir bölümünü karşılayan sistemler devlet tarafından desteklenebilir. Yine var olan yapıların bakımı ve revize edilmesi için devlet teşviki başlatılabilir. Ayrıca enerjiye çok ihtiyaç duyan ve yenilenemeyen enerji kaynaklarının büyük ölçüde kullanıldığı imalat sektöründe, sektör sahiplerine finansal destek sağlanabilir. Bu tür yatırımlar, kısa ve uzun vadede karbon salınımının azaltılmasına katkı sağlamanın yanı sıra, enerjide büyük ölçüde dışa bağımlılığı azaltacaktır.

Ulaşım şüphesiz son yüzyılın vazgeçilemez bir olgusudur. Aynı zamanda en fazla kirlilik saçan sektördür. Ulaşımında gelişmekte olan ülkeler yine büyük oranda fosil yakıt kullanımını sürdürmektedir. Gelişmekte olan ülkelerde de özellikle yenilenebilir enerji ile kullanılan araçların sayısı hızla artırılmalıdır. Bunun için devlet alımları artıracak şekilde ödeme kolaylığı ya da uzun süreli kredi kullanımı sağlayabilir. Kısa mesafeler için toplu ulaşım zorunluluğu, uçak seferlerinin belirli bir mesafe üzerinde gerçekleşmesi (Fransa 2,5 saat altındaki uçuşları 24.05.2023 tarihi itibarıyla yasakladı.) gibi ulaşımında kirliliği azaltmak için uygulamalar ile orta vadede ulaşımın neden olduğu kirlilik miktarı en aza indirilebilir.

Çevre konusunda mutlaka ki çok sayıda öneri sunmak mümkündür. Ancak hızla artan tüketim ve atık miktarı karşısında gelişmiş ülkelerin özellikle geri kalmış ya da gelişmekte olan ülkeleri para karşılığında kirlilik sığmağı olarak görmesi kabul edilebilir bir durum değildir. Ayrıca tüm dünya ülkeleri artık bilmelidir ki, kirlilik nerede olursa olsun sonuçları tüm dünyayı etkileyecektir. Geline nokta tüm ülkeler için sürdürülebilir büyüme olmadıkça, acımasız küçülmeye gidecektir. 22 Nisan 2016 Paris Konferansı'nda hazırlanan raporda, sürdürülebilir kalkınmanın ekonomik büyüme için önemli bir araç olduğu kabul edilirken, büyümenin ancak çevre dostu üretim politikaları devam edeceği vurgusu yapılmıştır. Böylece büyümenin yarattığı gelir etkisi önce kişisel geliri artıracak, artan kişisel gelir, uzun dönemde çevre bilinci ve çevreye dost kaynak kullanım talebini artıracaktır. Böylece büyümede sürdürülebilirlik yakalanabilecektir. Sürdürülebilir büyüme tüm Dünya ülkelerinin ortak sorumluluğunda olup, çözüm ancak ortak eylem planı ile mümkün olacaktır.

Kaynaklar

- Acheampong, A.O. & E.B. Boateng (2019), "Modelling Carbon Emission Intensity: Application of Artificial Neural Network", *Journal of Cleaner Production*, 225, 833-856.
- Ahmadi, M.H. et al. (2023), "Carbon Dioxide Emissions Prediction of Five Middle Eastern Countries Using Artificial Neural Networks", *Energy Sources, Part A: Recovery, Utilization, And Environmental Effects*, 45(3), 9513-9525.
- Aktaş, M.T. (ed.) (2023), *İklim ve Enerji Krizi Kısacasında İktisadi Kalkınma*, Efe Akademi Yayınları.

- Ashin-Nishan, M.K. & M.A. Villanthenkodath (2020), “Role of Energy Use in The Prediction of CO2 Emissions And Economic Growth in India: Evidence from Artificial Neural Networks (ANN)”, *Environmental Science And Pollution Research*, 27, 23631-23642.
- Ashraf, S. et al. (2020), “Relationships among environmental pollution, energy use and economic growth: a global perspective”, *OPEC Energy Review*, 44(4), 511-534.
- Aslan, A. et al. (2021), “The link between urbanization and air pollution in Turkey: evidence from dynamic autoregressive distributed lag simulations”, *Environmental Science and Pollution Research*, 28(37), 52370-52380.
- Association Internationale Pour L'évaluation du Rendement Scolaire (2017), *Energy Access Outlook 2017: From Poverty to Prosperity*, IEA.
- Aytun, C. vd. (2017), “Gelişen Ülkelerde Çevresel Bozulma, Gelir ve Enerji Tüketimi İlişkisi”, *Ömer Halis Demir Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 10(1), 1-11.
- Baloch, M.A. et al. (2019), “Effect of Natural Resources, Renewable Energy and Economic Development on CO2 Emissions in BRICS Countries”, *Science of the Total Environment*, 678, 632-638.
- BP (2023), *Statistical Review of World Energy*, <<https://www.bp.com/en/global/corporate/energy-economics/statistical-review-of-world-energy.html>>, 20.05.2023.
- Cantarero, M.M.V. (2020), “Of Renewable Energy, Energy Democracy, And Sustainable Development: A Roadmap To Accelerate The Energy Transition in Developing Countries”, *Energy Research & Social Science*, 70, 101716.
- Cherni, A. & S.E. Jouini (2017), “An ARDL approach to the CO2 emissions, renewable energy and economic growth nexus: Tunisian evidence”, *International Journal of Hydrogen Energy*, 42(48), 29056-29066.
- Çizmeçi, H. vd. (2018), “Yapay Sinir Ağları Kullanılarak Yükseköğretimde Öğrenci Adaylarının Başarı Durumlarının Tahmin Edilmesi”, *20. Akademik Bişim Konferansı* (183-186), Karabük, Türkiye.
- Endonezya İstatistik Ofisi (2023), <<https://www.bps.go.id/>>, 18.04.2023.
- Ercan, U. (2021), “Ev Dışı Gıda Tüketim Sınıflarının Yapay Sinir Ağları ile Tahmin Edilmesi”, *İşletme Araştırmaları Dergisi*, 13(4), 3265-3277.
- Fullwood, M.J. et al. (2009), “An Oestrogen-Receptor-A-Bound Human Chromatin Interactome”, *Nature*, 462(7269), 58-64.
- Garcés, E.F.M. et al. (2019), “Artificial Neuronal Networks to Predict The Emissions of Carbon Dioxide (CO₂) Using A Multilayer Network With The Levenberg-Marquardt Training Method”, *WSEAS Transactions On Environment And Development*, 16, 346-354.
- Giudici, P. (2003), *Applied Data Mining Statistical Methods for Business and Industry*, West Sussex, England: John Wiley & Sons.
- Grossman, G.M. & A.B. Krueger (1991), “Environmental impacts of a North American free trade agreement”, *NBER Working Paper* No: 3914.
- Gürlük, S. (2010), “Sürdürülebilir kalkınma gelişmekte olan ülkelerde uygulanabilir mi”, *Eskişehir Osmangazi Üniversitesi İİBF Dergisi*, 5(2), 85-99.
- Hagan, M.T. & M. Menhaj (1994), “Training feed-forward networks with the Marquardt algorithm”, *IEEE Transactions on Neural Networks*, 5(6), 989-993.
- Hagan, M.T. et al. (1996), *Neural Network Design*, Boston, MA: PWS Publishing.

- Haykin, S. (2008), *Neural Networks and Learning Machines Third Edition*, New Jersey: Pearson, Prentice Hall.
- Jena, P.R. et al. (2021), "Forecasting The CO2 Emissions At The Global Level: A Multilayer Artificial Neural Network Modelling", *Energies*, 14(19), 6336.
- Kamel, A. (2001), "D-8 Ekonomik Birliği Örgütü", *Avrasya Dosyası*, 7(2), 250-260.
- Karaaslan, A. & S. Çamkaya (2022), "The relationship between CO2 emissions, economic growth, health expenditure, and renewable and non-renewable energy consumption: Empirical evidence from Turkey", *Renewable Energy*, 190, 457-466.
- Kendall, M.G. et al. (1963), *The advanced theory of statistics*, Griffin, London.
- Komeili-Birjandi, A. et al. (2022), "Modeling Carbon Dioxide Emission of Countries in Southeast of Asia by Applying Artificial Neural Network", *International Journal of Low-Carbon Technologies*, 17, 321-326.
- Larose, D.T. (2005), *Discovering Knowledge in Data an Introduction to Data Mining*, New Jersey: John Wiley&Sons, Inc.
- Liang, W. & M. Yang (2019), "Urbanization, economic growth and environmental pollution: Evidence from China", *Sustainable Computing: Informatics and Systems*, 21, 1-9.
- Luger, G.F. (2002), *Artificial Intelligence: Structures and Strategies for Complex Problem Solving*, 4th edition, Addison Wesley.
- Marjanović, V. et al. (2016), "Prediction of GDP Growth Rate Based on Carbon Dioxide (CO2) Emissions", *Journal of CO2 Utilization*, 16, 212-217.
- Marquardt, D. (1963), "An Algorithm for Least-Squares Estimation of Nonlinear Parameters", *SIAM Journal on Applied Mathematics*, 11(2), 431-441.
- Muhumuza, R. et al. (2018), "Energy consumption levels and technical approaches for supporting development of alternative energy technologies for rural sectors of developing countries", *Renewable and Sustainable Energy Reviews*, 97, 90-102.
- Musah, M. et al. (2021), "Trade openness and CO2 emanations: a heterogeneous analysis on the developing eight (D8) countries", *Environmental Science and Pollution Research*, 28, 44200-44215.
- Nepal, R. & N. Paija (2019), "A multivariate time series analysis of energy consumption, real output and pollutant emissions in a developing economy: new evidence from Nepal", *Economic Modelling*, 77, 164-173.
- Nilsson, N.J. (1998), *Artificial Intelligence: A New Synthesis*, Morgan Kaufmann Publishers.
- Ouedraogo, N.S. (2017), "Africa Energy Future: Alternative Scenarios And Their Implications for Sustainable Development Strategies", *Energy Policy*, 106, 457-471.
- Özhan, E. (2020), "Yapay Sinir Ağları ve Üstel Düzleştirme Yöntemi ile Türkiye'deki CO2 Emisyonunun Zaman Serisi ile Tahmini", *Avrupa Bilim ve Teknoloji Dergisi*, (19), 282-289.
- Öztürk, K. & M.E. Şahin (2018), "Yapay Sinir Ağları ve Yapay Zekâ'ya Genel Bir Bakış", *Takvim-i Vekayi*, 6(2), 25-36.
- Pabuçcu, H. & T. Bayramoğlu (2016), "Yapay Sinir Ağları İle CO2 Emisyonu Tahmini: Türkiye Örneği", *Gazi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 18(3), 762-778.
- Pakistan Federal İstatistik Bürosu (2023), <<https://www.pbs.gov.pk/>>, 15.04.2023.

- Patterson, D. et al. (2021), “Carbon Emissions And Large Neural Network Training”, *Arxiv Preprint Arxiv*: 2104.10350.
- REN21 (2023), *Renewables Global Status Report 2020*, <https://www.ren21.net/wp-content/uploads/2019/05/gsr_2020_full_report_en.pdf>, 15.04.2023.
- Russell, S. & P. Norvig (1995), *Artificial Intelligence: A Modern Approach*, Prentice-Hall.
- Sel, A. & B. Tekgün (2022), “Anfis Yöntemi ile Türkiye Karbondioksit Salınımı Tahmini”, *Vizyoner Dergisi*, 13(34), 486-504.
- Solarin, S.A. (2020), “An environmental impact assessment of fossil fuel subsidies in emerging and developing economies”, *Environmental Impact Assessment Review*, 85, 106443.
- The Worldbank Orgazitation (2023), <<http://www.worldban.org>>, 15.03.2023.
- Türkiye Cumhuriyeti Dışişleri Bakanlığı (2023), <<https://www.mfa.gov.tr.>>, 10.04.2023.
- Türkiye İstatistik Ofisi (2023), <https://www.tuik.gov.tr/Kurumsal/Istatistik_Ofisleri>, 10.04.2023.
- UNEP (2023), *Renewables Global Status Report 2021*, <<https://www.unep.org/resources/report/renewables-2021-global-status-report>>, 15.04.2023.
- URL 1 (2023), <<https://ennurcitir.wordpress.com/2020/02/19/yapay-sinir-aglari/>>, 24.08.2023..
- URL 2 (2023), <<https://www.akanesen.com/2017/09/yapay-sinir-agnn-ana-ogeleri.html>>, 24.08.2023.
- V.V. Nabiyev (2016), *Yapay Zeka*, Seçkin Yayıncılık, Ankara.
- Vlahov, D. et al. (2007), “Urban As A Determinant of Health”, *J Urban Health*, 84 (1), 16-26.
- Wang, S. et al. (2021), “Global value chains, technological progress, and environmental pollution: Inequality towards developing countries”, *Journal of Environmental Management*, 277, 110999.
- Wang, W. & Y. Lu (2018), “Analysis of the Mean Absolute Error (MAE) and the Root Mean Square Error (RMSE) in Assessing Rounding Model”, in: *IOP Conference Series: Materials Science And Engineering*, 324, 012049.
- Xing, L. et al. (2023), “Investigating the impact of economic growth on environment degradation in developing economies through STIRPAT model approach”, *Renewable and Sustainable Energy Reviews*, 182, 113365.
- Zeng, Y.R. et al. (2017), “Multifactor-Influenced Energy Consumption Forecasting Using Enhanced Back-Propagation Neural Network”, *Energy*, 127, 381-396.
- Zhou, Y. et al. (2018), “The impact of economic growth and energy consumption on carbon emissions: evidence from panel quantile regression”, *Journal of Physics: Conference Series*, 1053, 012118.