



Türkiye'deki Farklı Sektörlere Ait Sera Gazı Emisyon Değerlerinin Çok Katmanlı Algılayıcılar ve Topluluk Öğrenmesi Yöntemleri ile Tahmin Edilmesi

Prediction with Ensemble Learning Methods and Multi-layer Perceptions of Greenhouse Gas Emission Belonging to Different Sectors in Turkey

Okan Oral¹ , Sinan Uğuz² 

¹Akdeniz Üniversitesi, Mekatronik Mühendisliği Bölümü, 07070, Antalya, TÜRKİYE

²Isparta Uygulamalı Bilimler Üniversitesi, Bilgisayar Mühendisliği Bölümü, 32260, Isparta, TÜRKİYE

Başvuru/Received: 12/11/2019

Kabul / Accepted: 14/06/2020

Çevrimiçi Basım / Published Online: 30/06/2020

Son Versiyon/Final Version: 30/06/2020

Öz

Küresel ısınmaya neden olan karbondioksit (CO₂), Nitroz oksit (N₂O) ve Metan (CH₄) çeşitli sektörler tarafından oluşturulan sera gazlarıdır. Birleşmiş milletler iklim değişikliği çerçeve sözleşmesince (UNFCCC) Türkiye'nin de içinde olduğu ülkelerin çeşitli sektörleri tarafından oluşturulan sera gazı emisyon değerleri kayıt altına alınarak takip edilmektedir. Ülkelerin oluşturdukları sera gazı emisyon değerleri zaman içinde birçok etkene göre farklılık oluşturabilir. Bu değerlerin tahmin edilmesi ülkeler açısından önemlidir. Çalışmada 1990-2014 yılları arasındaki farklı sektörlerdeki sera gazı emisyon değerleri ile yapay sinir ağı modeli ve topluluk öğrenme yöntemleri kullanılarak en iyi tahmin modelini oluşturmak için çeşitli deneyler gerçekleştirilmiştir. Çok katmanlı algılayıcı (ÇKA) modeli ile en yüksek R² performans değeri üretim, enerji endüstrisi, yerleşim ve ulaşım sektörleri için sırasıyla 0.86, 0.93, 0.91 ve 0.95 olarak bulunmuştur. Topluluk öğrenme yöntemlerine dayanan algoritmalar da ise ortalama R² değerleri bakımından en iyi performansı Extra Tree regresyon ile kurulan model sağlamıştır. Kullanılan tahmin modellerinde en iyi performans Çok Katmanlı Algılayıcı tabanlı model ile elde edilmiştir. Çalışmada yer alan sektörlerden 2020 yılında doğaya salınacağı öngörülen sera gazı emisyon değerleri açısından geçmiş dönemi kapsayan salınım değerlerinin ortalamaları ile önemli farklılıklar olduğu görülmektedir. Ayrıca geçmiş döneme oranla üretim sektörü alanında ortalama %36, enerji endüstrisi sektöründe %64 ve ulaşım sektöründe %63 oranında bir artış öngörülmektedir.

Anahtar Kelimeler

"Sera gazı emisyonu, Makine öğrenmesi, Çok katmanlı algılayıcı, Yapay sinir ağları, Topluluk öğrenmesi yöntemleri"

Abstract

Global warming causatives such as carbon dioxide (CO₂), Nitrous oxide (N₂O) and Methane (CH₄) are greenhouse gases created by various sectors. Greenhouse gas emission values created by various sectors of countries including Turkey are registered and tracked by the United Nations framework agreement on climate change (UNFCCC). The greenhouse gas emission values created by the countries may vary over time depending on many factors. Estimating this value is important for countries. In the study, various experiments were carried out to create the best estimation model with artificial neural network model and community learning methods by using greenhouse gas emission values in different sectors between 1990-2014. The highest R² performance value with the multi-layer sensor (MLS) model was 0.86, 0.93, 0.91 and 0.95 respectively for the production, energy industry, residential and transportation sectors. Algorithms based on community learning methods also provided the best performance in terms of average R² values with a model established by Extra Tree regression. The best performance in the prediction models used was achieved with the Multi-Layer Sensor-based model. It is observed that there are significant differences between the averages of the oscillation values covering the past period in terms of greenhouse gas emission values, which are projected to be released into nature in 2020 from the sectors involved in the study. In addition, an average increase of 36% is expected in the field of production sector, 64% in the energy industry sector and 63% in the transportation sector compared to the past period.

Key Words

"Greenhouse gas, Machine learning, Multi-layer perceptron, Artificial neural networks, Ensemble Methods"

1.Giriş

Atmosfer içerisinde, küçük miktarda asal gazların da yer aldığı birçok farklı gaz bulunmaktadır. Yer küreyi ısıtan güneş ışınları ile kısa dalga boyuna sahip ışınların bir kısmı atmosferi geçerken bu gazlar tarafından tutulmaktadır. Atmosferin ısıyı tutma özelliği sayesinde yeryüzünün sıcaklığı dengede kalırken okyanus, akarsu vb. donması engellenmiş olur. Öte yandan, ısıyı tutan atmosfer gazlarının miktarındaki aşırı artış, atmosfer ısısının gereğinden fazla yükselmesi ile sonuçlanarak küresel ısınmaya sebep olmaktadır. Küresel ısınma ise doğal afetlere neden olarak iklim değişimlerine yol açmaktadır. Bu şekilde oluşan atmosfer kaynaklı ısıtma ve yalıtma etkisine sera etkisi adı verilirken (Dam, 2014; Özmen, 2009), atmosferde kızıl ötesi ışınları soğuran gaz bileşimlerine ise sera gazı denilmektedir (Kara, Yalınız, & Sayar, 2019). Sera gazı; atmosferde farklı miktarlarda mevcut su buharı (H₂O), karbondioksit (CO₂), metan (CH₄), azotoksit (N₂O), ozon (O₃) gazları ve endüstriyel üretim sürecinde meydana gelen Hidroflorokarbon (HFC), Perflorokarbon (PFC), Sülfürhekzaflorid (SF₆) vb. florlu bileşiklerden oluşmaktadır (Dam, 2014). Bu gazlardan CO₂, içlerinde en baskın olanlarından birisidir ve toplam sera gazı miktarının %80'i civarındadır (Ersoy, 2017; Işık, 2014; Jatmiko vd., 2016; Nwulu & Agboola, 2012). Sera etkisi yaratma ve iklim değişiminde CO₂ gazının oranı %50 düzeyindedir (Kovancılar, 2001). CO₂ gazı, kloroflorokarbonlar (CFCs), CH₄ ve N₂O'ye göre insanlığın meydana getirdiği sera gazlarının en önemlisidir. ABD ve Çin, CO₂ salınımının büyük miktarını yapan ülkelerin başında gelmektedir. Sera gazı salınımında etkin olan ülkelerdeki CO₂ emisyonunun sektörlere göre dağılımı incelendiğinde, %22'lik oran ile birinci sırada sanayi sektörü, ikinci sırada %20'lik oran ile ulaşım sektörü gelmektedir (Işık, 2014; Kumar & Muhuri, 2019). N₂O, SO₂ gibi kükürt oksitleri ve ayrıca CH₄ gibi diğer sera gazları da inorganik gübrelerden oluşmaktadır (Fu vd., 2019; Kolasa-Więcek, 2018; Mahesh, 2018).

Endüstriyel dönemin başlamasıyla insan faaliyetine bağlı sera gazı üretiminin, dünya sıcaklığındaki anormal artışın ana nedeni olduğu anlaşılmıştır (Araabi, 2012; Cui, Sham, Lo, & Lum, 2011; Quesada-Rubio, Villar-Rubio, Mondéjar-Jiménez, & Molina-Moreno, 2011). Sıcaklık artışının geçen yüzyıl boyunca yaklaşık 0.4°C ile 0.8°C arasında olduğu ve yüzyılın sonuna kadar bu değer yaklaşık 2°C olacağı öngörülmektedir (Fu vd., 2019; Kumar & Muhuri, 2019). Sera gazlarının miktarlarındaki anormal artışın canlıların yaşamında birçok olumsuz faktörü beraberinde getirdiği bir gerçektir. Bu problemin önüne geçilebilmesi için dünya çapında organizasyonlar başlatılmıştır. İlk olarak 1988 yılında BM Çevre Programı ve Dünya Meteoroloji Örgütü'nün desteğiyle hükümetler arası İklim Değişikliği Paneli (IPCC) oluşturulmuştur (Dam, 2014; Güçlü, 2006). IPCC raporunda, küresel yüzey sıcaklığının yirmi birinci yüzyılda 1.1°C ile 6°C arasında artacağı öngörülmüştür (Solomon et al., 2007). Sera gazlarındaki olağan dışı bu artışın devamıyla IPCC'de 2030 yılı için bazı olumsuz senaryolar çizilmiştir. Bunlar arasında en öne çıkanları sıcak hava dalgaları, okyanus tuzluluğu, orman yangınları, tarımsal haşereler, kasırgalar, tropikal fırtınalar, biyolojik çeşitlilik, tarımsal ürün depolama zorlukları ve hastalık taşıyan zararlıların yayılmaları olarak gösterilebilir (Change, 2007; Özmen, 2009). 1992 yılında Rio de Janeiro'da düzenlenen Birleşmiş Milletler Çevre ve Kalkınma Konferansı'nda imzalanan IPCC Sözleşmesi ve 1997 yılının aralık ayında Japonya'da düzenlenen Kyoto Protokolü (KP) iklim değişikliği ve küresel ısınma için önlem alınması hakkında düzenlenen diğer önemli girişimler arasındadır (Dam, 2014). KP, 37 sanayi ülkesi ile Avrupa'nın sera gazı emisyon miktarlarının düşürülmesi için ağır sorumluluklar yüklemektedir. Protokolün ana amacı altı sera gazının (CO₂, CH₄, N₂O, SF₆, HFC, PFC) 2008-2012 yıllarını kapsayan beş yıllık dönemde 1990'lardaki oran ortalamasının %5'inden daha az olmasını sağlamasıdır (Özmen, 2009; Yılmaz & Yılmaz, 2013). 2015'de yapılan Paris İklim Zirvesi'nde Türkiye'nin de içinde bulunduğu 196 ülke, geleceğe dönük çevresel verilerin daha da kötüleşmemesi için anlaşma yapmışlardır (Işık, 2014; Pabuçcu & Bayramoğlu, 2016). Paris anlaşmasına göre, gelişmekte olan ekonomilere, istenen sera gazı emisyon seviyelerine ulaşmaları için daha fazla zaman tanınmıştır (Abid, 2017). Çünkü sanayileşmede kullanılan altyapı ve hizmetler, araçlar, elektrikli makine ve fabrikalar enerjilerini biyo yakıtlardan (Fan, Zhang, Zhang, & Peng, 2015) sağlamaktadır. Baskın sera gazı olan CO₂, bu yakıtlardan türemektedir (Kumar & Muhuri, 2019).

Günümüzde küresel ısınma sorunları tüm uluslar için evrensel bir sorun haline gelmiştir. IPCC'ye katılan bilim insanları, küresel ısınmanın çoğunun artan sera gazı ve diğer insan faaliyet konsantrasyonlarından kaynaklandığından emin olduklarını bildirmişlerdir (IPCC, 2014). Küresel iklim değişikliğinin etkilerinin azaltılmasında sera gazı emisyonlarının azaltılmasının önemi hakkında yaygın bir kanı mevcuttur (Işık, 2014). 2002'de ABD, dünya genelinde atmosfere salınan sera gazlarının % 36.1'den, Çin % 13.6, Hindistan %4.2, Avustralya'nın ise %2.1 den sorumlu olduğu ve en büyük sorumluluğun gelişmiş sanayi ülkelerinin olduğu görülmektedir. Türkiye'deki durum ise kısaca şöyle ifade edilebilir. IPCC, Küresel İklim Modelleri ile yaptığı projeksiyonlara göre 2030'da Türkiye'nin genelinin artan kuru ve sıcak bir iklim etkisine girebileceği ve kışın 2°C, yazın ise 2°C ile 3°C arasında bir sıcaklık artışının olabileceği belirtilmektedir (Özmen, 2009). Sera Gazı Emisyonları ve Niyet Edilen Ulusal Olarak Belirlenmiş Katkı Belgesi (INDC), Türkiye'nin IPCC sözleşmesi kapsamında 2017 yılında sunduğu ulusal envanter raporuna göre, 2015 yılı için toplam emisyonun %72 enerjiden, %13 endüstriyel proseslerden, %12 tarımdan, %3 atıktan kaynaklandığını bildirmektedir. Türkiye, sektörlere göre sera gazı emisyonları dağılımını, alınan önlemler ile 2030 yılı itibarıyla %21 azaltmayı kabul etmiştir (Ağaçayak & Öztürk, 2017). Bu bağlamda sera gazı salınımının kontrollü olarak gerçekleşmesi için geleceğe dair emisyon değeri tahminleri önemli bir gereksinim olarak ortaya çıkmaktadır. Literatürde birçok araştırmacı sera gazı salınımının azaltılarak küresel ısınmanın kararlı bir duruma getirilebilmesine katkıda bulunmak için geleceğe dönük emisyon değerlerinin tahmininde Yapay Sinir Ağları (YSA) gibi yöntemler kullanmıştır (Baghban, Ahmadi, & Shahraki, 2015; Behrang, Assareh, Assari, & Ghanbarzadeh, 2011; Kainuma, Matsuoka, & Morita, 2000; Yılmaz & Yılmaz, 2013). Bu çalışmada Türkiye'deki üretim, enerji endüstrisi, yerleşim ve ulaşım sektörlerine ait 1990-2014 yılları arasındaki sera gazı emisyon değerleri ile yapay sinir ağı modeli olan çok katmanlı algılayıcının yanı sıra topluluk öğrenme yöntemlerinden olan Random Forest Regresyon, Extra Tree Regresyon ve XGBoost Regresyon algoritmaları kullanılarak en iyi tahmin modelini oluşturmak için çeşitli deneyler gerçekleştirilmiştir.

2. Literatür Çalışmaları

Literatürde birçok araştırmacı sera gazı salınımının azaltılarak küresel ısınmanın kararlı bir duruma getirilebilmesine katkıda bulunmak için geleceğe dönük emisyon değerlerinin tahmininde makine öğrenmesine dayalı yöntemler kullanmışlardır. Yapay sinir ağı (YSA) modeli olan Çok katmanlı algılayıcı (ÇKA) ve Topluluk öğrenme yöntemleri (TÖY) algoritmalarından Random forest regresyon (RFR), Extremely randomized tree regresyon (ERTR) ve XGBoost regresyon (XGR) modelinin kullanıldığı bu çalışmanın literatür araştırması ÇKA tabanlı ve TÖY tabanlı araştırmalar olarak iki bölümde incelenmiştir.

2.1. ÇKA Tabanlı Literatür Çalışmaları

Sera gazı emisyonlarının büyük bölümünün fosil yakıtların kullanılması sonucu meydana gelmesi, küresel ısınma etkilerini azaltmak-önlemek için etkili stratejiler benimsenmede CO₂ emisyonlarının öngörülmesi, çevre üzerindeki artan etkilerin araştırılmasını önemli hale getirmiştir. Son yıllarda, CO₂ emisyonunun değerinin tahmin edilmesi konusunda birçok araştırma yapılmıştır (Assareh & Nedaei, 2018; Cui vd., 2011; Liao, Lu, & Tseng, 2011; Lu, Lewis, & Lin, 2009; Sangeetha & Amudha, 2018; Yılmaz & Yılmaz, 2013). Araştırmacılar atmosferdeki sera gazı salınımının gün geçtikçe yükseldiğini bilimsel çalışmalarla göstermişlerdir (Dam, 2014). Li, Zhou, & Ma, (2010) çalışmalarında Çin'in CO₂ emisyonlarını tahmin etmek için bir YSA modeli geliştirmişlerdir. YSA ağını 1990 ile 2004 yılları arasındaki verileri kullanarak eğitmiş ve 2008 yılına kadar olan verileri ise geliştirilen modelin uygunluğunu test etmek için test veri seti olarak kullanmışlardır. Krstanoski (2006) çalışmasında, Makedonya taşımacılık sektörü kaynaklı CO₂ emisyonu için bir model oluşturmuştur. Çalışmasını önce emisyonu azaltıcı politika tedbirlerinin olmadığı, sonraki 25 yıl sürecinde ise önlemlerin uygulandığı iki aşamada gerçekleştirmiştir. Çalışma sonucunda, 2030 yılına kadar karayolu sektörü CO₂ emisyonunun, politika uygulanmayan durumdan uygulanan durumun %32 oranında azalacağını vurgulamıştır. Hamzacebi & Karakurt, (2015) çalışmalarında Gri Tahmin Yöntemi ile Türkiye'de 1965-2012 ile 2013-2025 yılları arası enerji sektörü verileri ile sera gazı emisyon tahmininde bulunmuşlardır. Çalışma sonucu, CO₂ tahmininin 2015'de 354,879 Mt, 2020'de 424,245 Mt ve 2025'de 530,370 Mt değerlerinde olduğunu belirterek Gri Tahmin yönteminin uygunluğundan bahsetmişlerdir. Diğer bir çalışmada yazarlar (Saleh, Dzakiyullah, & Nugroho, 2016), CO₂'yi tahmin etmek için adaptif bir nöron bulanık girişim sistemi ve ÇKA yapay sinir ağı modeli geliştirilmişlerdir. Geliştirilen her iki yöntemde de CO₂ emisyonunu tahmin edebileceği öngörülmektedir. Assareh & Nedaei (2018) çalışmalarında, CO₂ emisyonlarının gelecekteki tahmini için Ray Optimizasyonu adlı yeni bir optimizasyon yöntemini uygulamışlar ve bu yöntem ile beraber ÇKA kullanmışlardır. 1980'den 2006'ya kadar olan veriler hem modelleri eğitmek (1980-1999), hem de modelleri test etmek için (2000-2006) kullanılmaktadır. Çalışma sonucunda küresel CO₂ emisyonlarının 2025 yılına kadar tahmini yapılabilmektedir. Nwulu & Agboola, (2012) çalışmalarında Nijerya'daki CO₂ emisyonlarını modelleme için iki sinir ağını araştırmışlardır. Kullandıkları ÇKA ağı sayesinde, CO₂ emisyonlarının modellenmesinde önceki çalışmalardan daha fazla cesaret verici sonuçlar elde etmişlerdir. Yazarlar çalışmada öncelikle kullanılan veri setini tanıtip, veri seti için geliştirilen iki sinir modelini açıklamışlardır. Ardından elde ettikleri sonuçları ayrıntılandırıp tartışmışlardır. Kolasa-Więcek (2018) çalışmalarında temel olarak ÇKA ağı kullanarak ülkelerin tarımsal emisyonlarının modellenmesini gerçekleştirmeyi amaçlamışlardır. Çalışma sonucunda ÇKA yönteminin sera gazı emisyonlarını modellemek için etkili bir araç olduğu sonucuna varmışlardır. Diğer bir çalışmada (Jatmiko vd., 2016), algoritmayı optimize etmede ÇKA'yı aynı zamanda Kanonik Parçacık Sürü Optimizasyonu (KPSO) ile birleştirilmişlerdir. Sonuçta ÇKA-KPSO kullanarak modellemenin göreceli mutlak hatada orijinal ÇKA ve ÇKA-PSO'dan sırasıyla %25 ve %15 daha doğru olduğunu göstermiştir.

Çeşitli sektörler için sera gazı emisyonlarının öngörülmesi, tahminin çeşitli modelleme yöntemleri kullanılarak yapılması ile ilgili literatürde birçok çalışma mevcuttur (Azid vd., 2014; Bolanča, Strahovnik, Ukić, Stankov, & Rogošić, 2017; Chen, Li, Grace, & Mosier, 2008; Khoshnevisan, Rafiee, Omid, Yousefi, & Movahedi, 2013). Tarımsal üretimin özellikle de sera gazı emisyonlarının çevre üzerindeki etkisi, yapılan bazı çalışmalarda (Kolasa-Więcek, 2018; Krstanoski, 2006) tartışılmaktadır. Wang, Li, Zhang, & Lu (2012) çalışmalarında, Çin'in karayolu taşımacılığının karbon emisyonu üzerindeki etki faktörlerini araştırmıştır. Ayrıca Assareh & Nedaei (2018) çalışmalarında, IPCC tarafından sunulan bir tekniği kullanarak karayolu yük taşımacılığında kaynaklanan karbon emisyonlarını belirlemiştir. Bu çalışmaların yanında sera gazı emisyonu ile ilgili çok sayıda araştırma yapılmıştır (Çoban & Şahbaz Kılınç, 2014; Ergün & Atay Polat, 2017; Fu vd., 2019; Hamzacebi & Karakurt, 2015; Yan & Crookes, 2010).

2.2. Topluluk Öğrenme Yöntemleri Tabanlı Literatür Çalışmaları

Sera gazı emisyonlarının azaltılmasına yönelik hedeflerin formüle edilmesinde gelecekteki iklim tahminleri büyük öneme sahiptir. Tahmin sürecinde ortaya çıkan bir dizi belirsizlik kaynağı ile başa çıkmak ve tahmindeki doğruluğu arttırmak için yeni yaklaşımlar geliştirilmiştir (Collins, 2007). TÖY, aynı öğrenmeyi çözmek için tek bir sınıflandırıcı yerine birden çok sınıflandırıcıyı eğitmektedir (Zhou 2012). Ortaya çıkan sınıflandırıcı, genellikle topluluğu oluşturan her bir sınıflandırıcıdan daha doğrudur (Khan & Awasthi, 2020; Parker, 2010). Topluluk öğrenmesinin amacı, tek bir sınıflandırıcı üzerindeki öngörüğü genelleştirerek doğruluğu arttırmada çeşitli temel sınıflandırıcıların kararlarını veya tahminlerini birleştirmektir (Chen, Zahiri, & Zhang, 2017). Çeşitli çalışmaların sonuçları, geçmiş veri özelliklerini kullanan topluluk öğrenme tabanlı modelin, varsayılan özelliklere sahip tek bir model kullanarak gerçekleştirilenden daha doğru performans sağladığını göstermiştir (Choi & Hur, 2020; Li, Han, Wang, & Zhao, 2018). Topluluk yöntemleri kullanılarak CO₂ emisyonunun değerinin tahmin edilmesi konusunda çeşitli araştırmalar yapılmıştır (Choi & Hur, 2020; Parker, 2010). Khan & Awasthi (2020), çalışmalarında Kanada'daki yolcu ve yük karayolu taşımacılığında kaynaklanan sera gazı emisyonlarını tahmin etmek için veri madenciliği ve denetimli makine öğrenme algoritmalarına (regresyon ve sınıflandırma) dayalı yeni modeller önermişlerdir. YSA ÇKA, çoklu doğrusal regresyon, çok terimli lojistik regresyon ve karar ağacı modellerini araştırmışlardır. Sonuçta YSA ÇKA modelinin, diğerlerine göre daha iyi öngörücü performans gösterdiği bulunmuştur. Geliştirilmiş ÇKA modeline, topluluk yöntemi (Bagging & Boosting)

uygulandığında ise bu modelin öngörücü performansının önemli ölçüde artırdığını tespit etmişlerdir. Diğer bir çalışmada Buisson, Grenouillet, Casajus, & Lek (2010), Fransa genelindeki dere balık türünün mevcut ve gelecekteki dağılımlarını modellemeyi sera gazı emisyon senaryoları ve her bir bileşene bağlı olarak gelecekteki balık türleri dağılımındaki değişkenliği ölçmek ve iklim değişikliğinin balık türleri üzerindeki potansiyel etkilerini değerlendirerek gelecekteki oluşabilecek değişkenliği açıklayan bir topluluk tahmini yönteminden yararlanmışlardır. Zhu (2012) çalışmasında karbon miktarını tahmin etmek için ampirik mod ayrışmasını (EMD), genetik algoritmayı (GA) ve YSA'ı birleştiren çok ölçekli bir topluluk tahmin modeli önermiştir. Zhou, Yu, & Yuan (2018) çalışmalarında Çin'de yine karbon miktarını tahmin etmek için EMD'ye dayanan çok ölçekli bir topluluk tahmin modeli önermiştir. Mohammed & Aung (2016) çalışmalarında, 24 saatlik ileri güneş enerjisi tahminleri oluşturmak için yedi bireysel makine öğrenimi modelinden türetilen olasılık tahmini için üç farklı yöntem önermişlerdir. Tüm makine öğrenme modelleri geleneksel kıyaslama modellerinden daha doğru olmasına rağmen, topluluk modellerinin tek başına herhangi bir bireysel makine öğrenme modelinden daha doğru sonuçlar sunduğunu göstermişlerdir.

2.3. Araştırma Motivasyonu ve Literatüre Katkı

Literatür incelendiğinde dünya genelinde CO₂ emisyonu tahmini konusunda çalışmaların yapılmış olduğu ancak sektörel bazda CO₂, N₂O ve CH₄ gazlarının tümünün ve ayrıca sadece Türkiye özelinde ileri tarihteki emisyon miktarının ÇKA ve TÖY kullanılarak tahmini konusunda çalışmaların sınırlı düzeyde olduğu görülmüştür. Bu bağlamda bu çalışmada Türkiye'deki üretim, enerji endüstrisi, yerleşim ve ulaşım sektörlerine ait 1990-2014 yılları arasındaki sera gazı emisyon değerleri kullanılarak ÇKA ve TÖY temelli bir tahmin modeli oluşturulması amaçlanmıştır. Bu amaç doğrultusunda oluşturulan model ile bu sektörler tarafından doğaya salınımı yapılan CO₂, N₂O ve CH₄ gazlarının 2020 yılına ait değerleri tahmin edilmiştir. Çalışma sonunda elde edilen bulguların ÇKA ve TÖY performanslarının karşılaştırılması bakımından da literatüre katkı sağlayacağı düşünülmektedir.

3. Materyal ve Metod

Türkiye'deki farklı sektörler için sera gazı emisyon değerlerinin tahminine dönük gerçekleştirilen bu çalışmanın ilk aşamasını veri setinin elde edilmesi oluşturmaktadır. Eğitim ve test veri setlerinin oluşturulmasının ardından ÇKA ve TÖY için modeller kurulmuştur. Tüm modeller için farklı parametre optimizasyonları ile deneyler gerçekleştirilmiş ve performans değerlendirme ölçütleri ile en iyi performansı veren modeller oluşturulmuştur. Hem ÇKA hem de topluluk öğrenme modelleri için Python programlama dili kütüphanelerinden yararlanılmıştır. Numpy, Pandas, Scipy gibi temel Python kütüphanelerinin yanı sıra makine öğrenmesi uygulamaları için geliştirilmiş olan Scikit-learn ve Keras kütüphaneleri de kullanılmıştır. Analizler Python 3.6.5 ve Keras 2.0.6 sürümleri kullanılarak geliştirilmiş kodlar ile gerçekleştirilmiştir.

3.1. Veri Setinin Elde Edilmesi

UNFCCC, (2019) v19 veri seti, Türkiye'nin de aralarında bulunduğu 35 Avrupa Birliği ülkesine ait çeşitli sektörler tarafından yayılan sera gazlarına ait emisyon değerlerini içermektedir. 1990-2014 yılları arasındaki döneme ait olan veri setinde yaklaşık 550 bin veri örneği bulunmaktadır. Veri setinde Türkiye'ye ait veri sayısı ise toplam 13575 adettir. Veri setinde 8 farklı seragazı türü için enerji, toprak kullanımı ve ormanlar, tarım, atık yönetimi, endüstriyel süreçler, üretim gibi sektörler ve bunlara ait alt sektörler için emisyon verileri bulunmaktadır. Bazı seragazı emisyon değerleri veri setinde yer almadığı için tüm sektörler ve seragazı türleri çalışmaya dahil edilmemiştir. Bu sebeple çalışmada Türkiye'deki üretim, enerji endüstrisi, yerleşim ve ulaşım sektörleri tarafından salınımı gerçekleştirilen CO₂, N₂O ve CH₄ türü sera gazlarına ait emisyon değerleri kullanılmıştır. Veri setinde bu dört ana sektöre ait alt sektörler de yer almaktadır. Bu alt sektörlerin toplamı alınarak 4 ana sektöre ait emisyon değerleri üzerinden çalışma gerçekleştirilmiştir. Örneğin enerji endüstrisi sektörünün alt sektörleri olan kamu elektriği ve ısı üretimi, petrol arıtma, katı yakıtların üretimi, demir ve çelik, kimyasallar, taşıma vb. sektörlerin emisyon değerleri toplanarak enerji endüstrisi sektörüne ait tek bir değer elde edilmiştir. Tablo 1'de, çalışmada kullanılan veri setine ait en küçük değer, en büyük değer, ortalama ve standart sapma değerlerinden oluşan tanımlayıcı istatistik ifadeleri görülmektedir.

Tablo1. Veri setine ait bazı tanımlayıcı istatistik değerleri

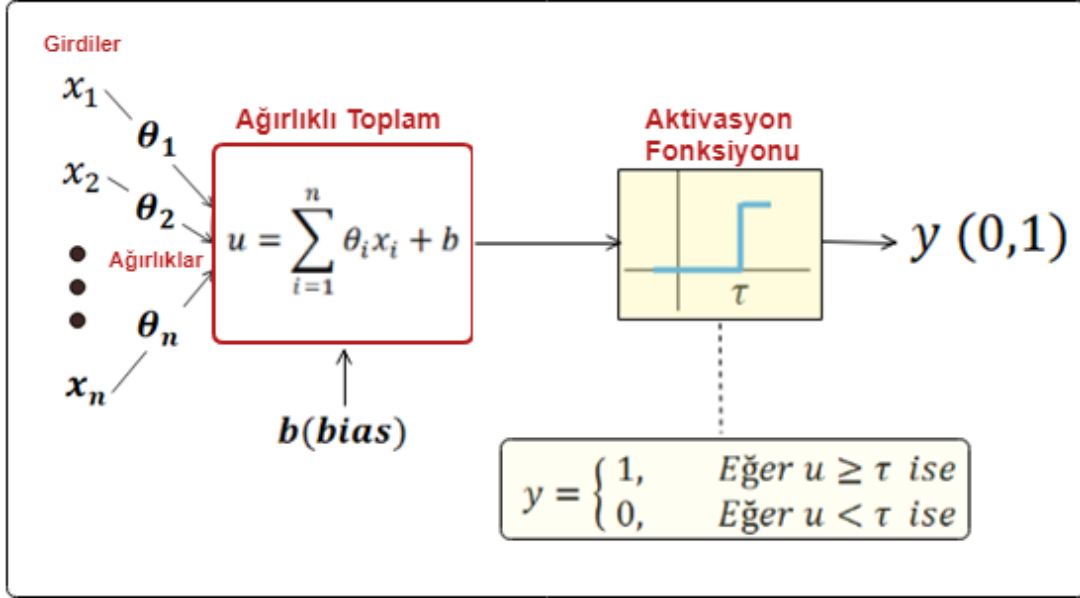
	Üretim Sektörü			Enerji endüstrisi Sektörü			Yerleşim Sektörü			Ulaşım Sektörü		
	CH ₄	N ₂ O	CO ₂	CH ₄	N ₂ O	CO ₂	CH ₄	N ₂ O	CO ₂	CH ₄	N ₂ O	CO ₂
Ek	1.9343	0.3241	34975	0.4601	0.3546	33820	95.81	0.8885	19934	3.8501	2.0019	25013
Eb	5.5312	0.8881	92111	1.8119	1.2257	131827	160.45	1.4736	56481	14.149	3.8482	72199
Ort	3.3082	0.5390	58956	1.0679	0.7065	74939	120.55	1.2352	33123	8.5822	2.6496	40535
Std	0.9757	0.1595	16810	0.4307	0.2431	30169	19.20	0.1724	12377	3.0501	0.4162	12310

Ek: En Küçük Değer, **Eb:** En Büyük Değer, **Ort:** Ortalama, **Std:** Standart Sapma

3.2. Çok Katmanlı Algılayıcı Modelinin Kurulması

1958 yılında Rosenblatt tarafından geliştirilen Algılayıcı (Perceptron) modeli (Rosenblat, 1958), Hebb öğrenme modelini (Hebb, 1949) temel alarak geliştirilmiş, öğrenen bir yapay sinir ağı modelidir. Modelde, girdiler ve girdilere ait ağırlıkların çarpımlarının toplanması ile elde edilen değere bias ilave edilerek ağırlıklı toplam hesaplanır. Daha sonra bu toplam değeri bir aktivasyon fonksiyonundan geçirilir. Aktivasyon fonksiyonunun temel görevi ağırlıklı toplam değerini belirlenen eşik değerine göre 0 ya da 1 olarak sınırlamaktır. Eğer ağırlıklı toplam belirlenen eşik değerine eşit ya da büyük ise çıktı 1, aksi durumda çıktı 0 olarak

belirlenir. İşte Şekil 1’de görülen bu basit model aynı zamanda girdilerden çıktılara doğru ileri beslemeli bir ağ yapısı örneğini de oluşturmaktadır.



Şekil 1. Algılayıcı Modeli

Bir algılayıcı eğer sadece girdi katmanı ve çıktı katmanından meydana geliyor ise tek katmanlı sinir ağları olarak ifade edilebilir. Girdi katmanı ve çıktı katmanı arasında gizli katmanlar eklendiğinde oluşan yapay sinir ağı mimarisi ise, çok katmanlı sinir ağları olarak ifade edilir (S. Khan, Rahmani, Shah, & Bennamoun, 2018). Basit bir yapıya sahip olan algılayıcı modelinin aksine çok katmanlı algılayıcı modelleri girdi ve çıktı katmanları arasında en az bir adet gizli katman içeren bir mimariye sahiptirler. 1980’li yıllarda geliştirilmiş olan çok katmanlı algılayıcı modeli, algılayıcı modelinin çözemediği XOR gibi problemlerde başarı sağlayarak yapay sinir ağları alanında yeni bir dönemin başlangıcını oluşturmuştur (Theodoridis & Koutroumbas, 2003). Çok katmanlı algılayıcılar kullanılan geri yayılım algoritması ile bu ve benzeri problemlerin çözümünde büyük başarı elde etmiştir (Uğuz, 2019). Geri yayılım algoritmasında ilk aşama, ağı ait girdilerin girdi katmanından çıktı katmanına doğru ilerlemesidir. İkinci aşamasında ise, çıktı biriminde gerçek değer ile hesaplanan değer arasındaki fark olarak ifade edilebilen hatanın hesaplanması ve hatanın geriye doğru yayılımı gerçekleştirilir. Geriye doğru yayılan hata dikkate alınarak katmanlar arasındaki ağırlıkların ve bias değerlerinin güncellenmesi gerçekleştirilir. Bu döngüsel yapı istenen iterasyon sayısına ya da başta belirlenen hata değerine ulaşıldığında sona erer.

Bir ÇKA modelinin performansını etkileyen birçok unsur bulunmaktadır. Bunlar gizli katman sayısı, katmanlardaki nöron sayısı, aktivasyon fonksiyonunun türü, kullanılan normalizasyon tekniği, öğrenme algoritmasının türü, öğrenme oranı ve momentum faktörü gibi parametreler olarak sıralanabilir. En iyi ÇKA performansını elde etmek, bu sayılan faktörlerde denemeler yapmayı gerektirir (Gurney, 2014; Nunes & Silva 2018). Çalışmada öncelikle veri setindeki örnekler normalizasyon işlemine tabi tutularak belirli bir değer aralığında ifade edilmiştir. Literatürde en çok kullanılan veri tiplerinden biri olan (Priddy & Keller 2005) ve Denklem 1’de görülen min-max normalizasyonu uygulanmıştır.


$$x'_i = (max_t - min_t) \left[\frac{(x_i - min_d)}{(max_d - min_d)} \right] + min_t \quad (1)$$

Denklem 1’de, min_d ve max_d veri setindeki her bir örneğe ait minimum ve maksimum değerleri, min_t ve max_t ise sırasıyla dönüştürülmek istenen değer aralığına ait en küçük ve en büyük değerleri ifade etmektedir.

Şekil 2’de kurulan ÇKA modellerini temsil eden bir ağ mimarisi görülmektedir. En iyi sonucu veren ÇKA ağının oluşturulması için katman sayısı, her bir katmana ait nöron sayısı ve aktivasyon fonksiyonları gibi parametrelerin aldığı değerler döngüsel olarak değiştirilerek birçok deneme gerçekleştirilmiştir. Her bir sektöre ait en iyi ağ performansını veren parametreler ise bulgular kısmında gösterilmiştir. Şekil 2’de iki gizli katmandan (j, k) oluşan ve her gizli katmanda sırasıyla 5 ve 3 yapay nöron bulunan örnek bir ÇKA mimarisi görülmektedir. Girdi katmanında bir adet girdi değişkeni yer almaktadır. Öncelikle min-max normalizasyon işlemi ile tüm girdi değerleri aynı sayısal aralıkta ifade edilmiştir. Daha sonra birinci gizli katmandaki nöronların çıktı değerleri hesaplanmıştır. Bunun için girdilerin ve bias değerinin kendi ağırlık değerleri ile çarpımlarının birleştirme fonksiyonu ile toplamı, sigmoid aktivasyon fonksiyonundan geçirilmiştir. Bu değer aynı zamanda ikinci gizli katmanın girdi değerlerini oluşturmaktadır ve aynı işlem ikinci gizli katman içinde tekrarlanarak, ikinci gizli katmanın çıktı değerleri hesaplanmaktadır. İkinci gizli katmandaki çıktı değerleri ile çıktı katmanındaki ağırlık değerleri kullanılarak çıktı katmanının çıktı değeri hesaplanmaktadır. Bu aşamadan sonra hatanın hesaplanması ve geriye yayılım süreci gerçekleşir. Örnekte aktivasyon

fonksiyonu olarak sigmoid görülmektedir. Ancak uygulamalarda Relu aktivasyon fonksiyonu da denenmiştir. Katmanlar arasındaki ağırlık değerleri ve her bir katmandaki nöronlara ait bias ağırlık değerleri mimari üzerinde gösterilmiştir.

Makine öğrenmesi uygulamalarında veri setindeki örneklerin eğitim ve test olarak ayrılması gerekmektedir. Bu çalışmada veri setindeki örneklerin %70'i eğitim için, %30'u ise test için ayrılmıştır.



Şekil 2. Çok katmanlı algılayıcı mimarisi

3.3. Topluluk Öğrenme Yöntemlerine Ait Modellerin Oluşturulması

Topluluk yöntemlerinin temel fikri, tek bir öğrenciye ait tahmin hatalarının diğer öğrenciler tarafından telafi edilmesi sonucunda, tek bir öğrencinin tahmin performansından ziyade topluluğun genel tahmin performansının ön plana çıkarılmasıdır (Sagi & Rokach, 2018). Topluluk yöntemleri ile çoklu makine öğrenmesi yöntemlerinin performansları birleştirilerek daha güçlü tahmin yeteneğine sahip modeller geliştirilmesi amaçlanır. Topluluk yöntemlerine ait algoritmalar hem sınıflandırma problemlerinin hem de regresyon problemlerinin çözümünde kullanılabilirler. Topluluk yöntemlerinde bagging ve boosting gibi tekniklere dayanan çeşitli makine öğrenmesi algoritmaları geliştirilmiştir. Bagging yöntemini (Breiman, 1996) kullanan algoritmaların genel olarak yaptığı iş şöyle özetlenebilir. Kullanılan temel veri setinden örneklerin rastgele olarak seçilmesi koşuluyla yeni veri setleri elde edilir. Elde edilen yeni veri setleri ile temel veri seti aynı boyuttadır ve rastgele örnek seçiminin doğası gereği yeni veri setleri içerisinde tekrar eden örnekler yer alabilecektir. Ayrıca rastgele örnek seçimi temel veri setindeki tüm örneklerin yeni veri setlerinde olmasını garanti etmeyecektir (Harrington, 2012). Popüler bagging algoritmaları arasında Random Forest, Bagged Decision Tree ve Extremely Randomised Trees gibi ağaç tabanlı algoritmalar sayılabilir.

Bir diğer topluluk yöntemi ise Gradient Tree Boosting ve XGBoost gibi algoritmalara dayanan Boosting tekniğidir. Bu teknikte “weak” olarak ifade edilebilecek bir öğrencinin hatalı olarak tahmin ettiği örnekler daha fazla ağırlık değeri verilerek bir alt veri setinde toplanır. Daha sonra hatalı olarak tahmin edilen örnekleri içeren veri seti yeni öğrencilere verilir. Her yeni öğrenci bir önceki hatalı örneklere odaklandığı için başta “weak” olarak ifade edilen öğrencinin performansı nihai modelde tüm öğrencilerin bireysel tahminlerinin toplamı ya da ağırlıklı toplamı olarak “strong” bir tahmin performansına dönüşür (Julian, 2016).

3.4. Makine Öğrenmesi Modellerinin Performans Değerlendirmesi

Gerçekleştirilen çalışmada tahmin edilmesi arzulanan emisyon değerleri sürekli sayısal verilerden oluşmaktadır. Makine öğrenmesinde veri setinin tahmin edilecek olan özneliği eğer sürekli sayısal verilerden oluşuyor ise MSE (Ortalama Kare hata) ve MAE (Ortalama mutlak hata) gibi hata ölçütlerinin yanı sıra R^2 gibi veri setine ait örneklerin bir doğru ile ne ölçüde temsil edilebileceğini veren performans değerlendirme ölçütü de kullanılabilir (Al-Ghobari vd, 2018). Denklem 2, 3 ve 4 'de sırasıyla MSE, MAE ve R^2 ölçütlerinin matematiksel olarak gösterimi görülmektedir.

$$MSE(y, \hat{y}) = \frac{1}{n_{\text{örnekler}}} \sum_{i=0}^{n_{\text{örnekler}}-1} (y_i - \hat{y}_i)^2 \quad (2)$$

$$MAE(y, \hat{y}) = \frac{1}{n_{\text{örnekler}}} \sum_{i=0}^{n_{\text{örnekler}}-1} |y_i - \hat{y}_i| \quad (3)$$

$$R^2 = (y, \hat{y}) = 1 - \frac{\sum_{i=0}^{n_{\text{örnekler}}-1} (y_i - \hat{y}_i)^2}{\sum_{i=0}^{n_{\text{örnekler}}-1} (y_i - \bar{y})^2}, \quad \bar{y} = \frac{1}{n_{\text{örnekler}}} \sum_{i=0}^{n_{\text{örnekler}}-1} y_i \quad (4)$$

Denklemlerde \hat{y}_i ifadesi $i + 1$ 'nci örneğin tahmin değerini, \bar{y} ifadesi ortalama değeri ve y_i değeri ise $n_{\text{örnekler}}$ sayısı kadar veri seti örneğine karşılık gelen doğru değerleri ifade etmektedir.

4. Bulgular ve Tartışma

4.1. Çok Katmanlı Algılayıcı için Gerçekleştirilen Deneylere Ait Bulgular

Çok katmanlı algılayıcının eğitimi 3 adet gizli katman üzerinden gerçekleştirilmiştir. Algoritmanın iterasyon sayısı, gizli katmanlardaki nöron sayıları ve kullanılan aktivasyon fonksiyonlarına farklı değerler vererek en iyi performans değerleri elde edilene kadar eğitimler gerçekleştirilmiştir. İterasyon sayısı 1000 ile 50000 arasında belirlenmiş 20 farklı değer ile oluşturulmuştur. Aktivasyon fonksiyonu olarak Sigmoid ve Relu aktivasyon fonksiyonları kullanılmıştır. Nöron sayısı ise 2 ile 200 arasında belirlenmiş 30 farklı değer ile oluşturulmuştur. Tüm alternatif değerler ağı eğitimi üzerinde denenmiş ve test veri kümeleri denenerek elde edilen en dikkat çekici sonuçlar Tablo 2, 3, 4 ve 5'de verilmiştir.

Tablo 2'de, üretim sektörüne ait üç farklı sera gazı için oluşturulan ÇKA ağına ait bulgular yer almaktadır. Koyu renkli olarak ifade edilen satırlar en iyi performansı veren değerleri içermektedir. Buna göre, CH_4 , N_2O ve CO_2 gazlarına ait en iyi ÇKA modellerinin R^2 değerleri sırasıyla 0.86, 0.84 ve 0.81 olarak elde edilmiştir.

Tablo 2. Üretim sektörüne ait Emisyon verileri için kurulan ağ bilgileri ve elde edilen performans değerlendirme ölçütleri

	GK 1		GK 2		GK3		İ	MAE	MSE	R^2
	NS	AF	NS	AF	NS	AF				
CH_4	32	Relu	64	Relu	128	Relu	32000	0.11	0.01	0.86
	1024	Relu	256	Relu	512	Relu	32000	0.11	0.01	0.81
	32	Relu	64	Relu	128	Relu	4096	0.13	0.02	0.78
	100	Sigmoid	105	Sigmoid	64	Sigmoid	10000	0.13	0.02	0.77
	1000	Relu	1000	Relu	1000	Relu	10000	0.14	0.03	0.74
N_2O	64	Relu	128	Relu	256	Relu	4096	0.10	0.01	0.84
	64	Relu	128	Relu	256	Relu	16384	0.11	0.02	0.82
	30	Relu	60	Relu	90	Relu	12000	0.10	0.01	0.82
	8	Relu	16	Relu	32	Relu	4096	0.12	0.02	0.81
	32	Relu	64	Relu	128	Relu	4096	0.11	0.02	0.80
CO_2	30	Relu	18	Relu	20	Relu	9000	0.11	0.01	0.81
	40	Relu	18	Relu	20	Relu	10000	0.12	0.01	0.80
	30	Relu	18	Relu	20	Relu	10000	0.11	0.01	0.80
	256	Relu	512	Relu	1024	Relu	48000	0.11	0.01	0.79
	16	Relu	18	Relu	20	Relu	7000	0.13	0.02	0.74

GK: Gizli katman, **NS:** Nöron Sayısı, **AF:** Aktivasyon Fonksiyonu, **İ:** İterasyon

Tablo 3'de, enerji endüstrisi sektörüne ait üç farklı sera gazı için oluşturulan ÇKA ağına ait bulgular yer almaktadır. Buna göre, CH_4 , N_2O ve CO_2 gazlarına ait en iyi ÇKA modellerinin R^2 değerleri sırasıyla 0.92, 0.86 ve 0.93 olarak elde edilmiştir.

Tablo 3. Enerji endüstrisi sektörü emisyon verileri için kurulan ağ bilgileri ve elde edilen performans değerlendirme ölçütleri

	GK 1		GK 2		GK3		İ	MAE	MSE	R ²
	NS	AF	NS	AF	NS	AF				
CH ₄	6	Sigmoid	4	Sigmoid	2	Sigmoid	10000	0.07	0.007	0.92
	90	Sigmoid	90	Relu	95	Relu	1000	0.07	0.007	0.91
	16	Sigmoid	8	Sigmoid	4	Sigmoid	12000	0.07	0.008	0.91
	100	Relu	80	Relu	80	Relu	7000	0.07	0.009	0.90
	6	Sigmoid	8	Sigmoid	14	Sigmoid	12000	0.1	0.014	0.84
N ₂ O	12	Sigmoid	6	Sigmoid	4	Sigmoid	12000	0.10	0.01	0.86
	36	Sigmoid	16	Sigmoid	6	Sigmoid	20000	0.10	0.01	0.84
	16	Relu	8	Relu	4	Relu	8000	0.10	0.01	0.83
	48	Sigmoid	24	Sigmoid	4	Sigmoid	24000	0.11	0.01	0.82
	10	Relu	8	Relu	4	Relu	6000	0.11	0.01	0.81
CO ₂	16	Sigmoid	8	Sigmoid	4	Sigmoid	12000	0.07	0.006	0.93
	16	Sigmoid	8	Sigmoid	4	Sigmoid	16000	0.06	0.005	0.92
	16	Sigmoid	8	Relu	4	Sigmoid	18000	0.06	0.005	0.92
	50	Sigmoid	55	Relu	90	Relu	1000	0.09	0.01	0.86
	100	Relu	90	Relu	90	Relu	2000	0.10	0.01	0.81

GK: Gizli katman, **NS:** Nöron Sayısı, **AF:** Aktivasyon Fonksiyonu, **İ:** İterasyon

Tablo 4’de, yerleşim sektörüne ait üç farklı sera gazı için oluşturulan ÇKA ağına ait bulgular yer almaktadır. Buna göre CH₄, N₂O ve CO₂ gazlarına ait en iyi ÇKA modellerinin R² değerleri sırasıyla 0.73, 0.68 ve 0.91 olarak elde edilmiştir.

Tablo 4. Yerleşim sektörüne ait Emisyon verileri için kurulan ağ bilgileri ve elde edilen performans değerlendirme ölçütleri

	GK 1		GK 2		GK3		İ	MAE	MSE	R ²
	NS	AF	NS	AF	NS	AF				
CH ₄	64	Relu	128	Relu	256	Relu	48000	0.16	0.04	0.73
	10	Relu	16	Relu	20	Relu	10000	0.16	0.04	0.72
	20	Sigmoid	20	Sigmoid	20	Sigmoid	120000	0.18	0.05	0.71
	64	Relu	128	Relu	256	Relu	48000	0.16	0.04	0.71
	100	Sigmoid	100	Sigmoid	100	Sigmoid	24000	0.18	0.05	0.70
N ₂ O	16	sigmoid	18	sigmoid	20	sigmoid	18000	0.10	0.02	0.68
	60	sigmoid	30	sigmoid	15	sigmoid	18000	0.10	0.02	0.66
	10	sigmoid	12	sigmoid	16	sigmoid	12000	0.10	0.02	0.65
	12	sigmoid	14	sigmoid	16	sigmoid	12000	0.11	0.02	0.63
	24	Relu	18	Relu	12	Sigmoid	9000	0.09	0.02	0.63
CO ₂	8	Sigmoid	10	Sigmoid	14	Sigmoid	4000	0.10	0.01	0.91
	10	Sigmoid	12	Sigmoid	16	Sigmoid	10000	0.10	0.01	0.90
	10	Relu	12	Relu	16	Relu	10000	0.10	0.01	0.90
	6	Sigmoid	8	Sigmoid	10	Sigmoid	3000	0.12	0.02	0.85
	10	Relu	20	Relu	16	Sigmoid	10000	0.12	0.02	0.84

GK: Gizli katman, **NS:** Nöron Sayısı, **AF:** Aktivasyon Fonksiyonu, **İ:** İterasyon

Tablo 5’de ise, ulaşım sektörüne ait üç farklı sera gazı için oluşturulan ÇKA ağına ait bulgular yer almaktadır. Buna göre, CH₄, N₂O ve CO₂ gazlarına ait en iyi ÇKA modellerinin R² değerleri sırasıyla 0.95, 0.80 ve 0.91 olarak elde edilmiştir.

Tablo 5. Ulaşım sektörüne ait Emisyon verileri için kurulan ağ bilgileri ve elde edilen performans değerlendirme ölçütleri

	GK 1		GK 2		GK3		İ	MAE	MSE	R ²
	NS	AF	NS	AF	NS	AF				
CH ₄	16	Sigmoid	18	Sigmoid	20	Sigmoid	14000	0.05	0.003	0.95
	60	Relu	100	Relu	100	Relu	10000	0.05	0.003	0.94
	12	Sigmoid	8	Sigmoid	6	Sigmoid	14000	0.06	0.006	0.93
	200	Relu	80	Sigmoid	150	Relu	12000	0.05	0.006	0.93
	20	Sigmoid	15	Sigmoid	30	relu	4000	0.10	0.013	0.85
N ₂ O	32	Sigmoid	64	Sigmoid	128	Sigmoid	24000	0.11	0.02	0.79
	32	Sigmoid	64	Sigmoid	128	Sigmoid	24000	0.11	0.02	0.78
	32	Sigmoid	64	Sigmoid	128	Sigmoid	14000	0.12	0.02	0.77
	32	Sigmoid	64	Sigmoid	48	Sigmoid	30000	0.12	0.02	0.77
	6	Sigmoid	8	Sigmoid	10	Sigmoid	24000	0.09	0.01	0.91
CO ₂	6	Sigmoid	8	Sigmoid	10	Sigmoid	18000	0.10	0.01	0.88
	10	Sigmoid	12	Sigmoid	15	Sigmoid	10000	0.10	0.01	0.86
	16	Sigmoid	18	Sigmoid	20	Sigmoid	12000	0.10	0.01	0.86
	6	Sigmoid	8	Sigmoid	15	Sigmoid	7000	0.11	0.02	0.84

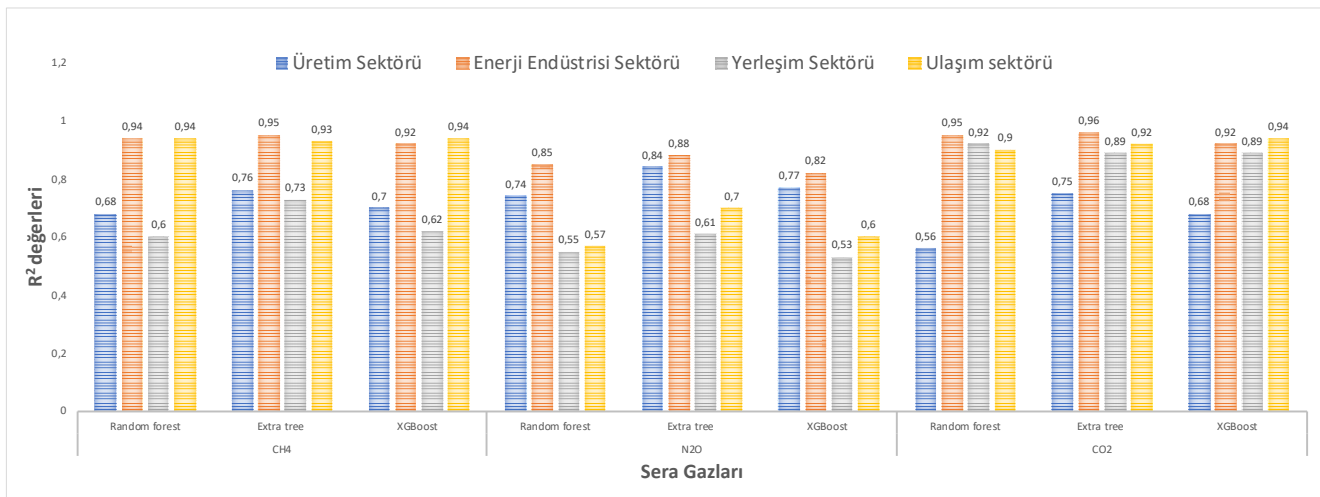
GK: Gizli katman, **NS:** Nöron Sayısı, **AF:** Aktivasyon Fonksiyonu, **İ:** İterasyon

Tüm sektörler için tüm emisyon verileri için elde edilen sonuçlar dikkate alındığında, en iyi R² tahmin performansının ortalama %90.1 değeri ile enerji endüstrisi sektörü deneylerinde elde edildiği görülmektedir. Tüm emisyon değerleri içerisinde en yüksek R² tahmin performansının ise ortalama % 89 değeri ile CO₂ gazına ait olduğu belirlenmiştir. Her bir gizli katman için kullanılan nöron sayısı ve aktivasyon fonksiyonunun yanı sıra iterasyon sayısının da farklı değerler verilerek gerçekleştirilen deneylerde bu parametrelerin aldığı değerlerin ağırlık performansı üzerine etkisi noktasında net bir yorum yapılamamaktadır.

4.2. Topluluk öğrenme yöntemleri için gerçekleştirilen deneylere ait bulgular


Bu çalışmada popüler topluluk öğrenme yöntemleri olan RFR, ERTR ve XGR teknikleri kullanılarak gerçekleştirilen deneyler neticesinde elde edilen performans değerleri sırasıyla Şekil 3, 4 ve 5’de verilmiştir. Şekil 3 incelendiğinde üretim, enerji endüstrisi ve yerleşim sektörüne ait veriler için en iyi R² performansı sırasıyla 0.79, 0.93 ve 0.74 ortalama değerleri ile ERTR ile elde edilmiştir. Ulaşım sektörü için en iyi performans değeri ise 0.94 ortalama değeri ile RFR ile elde edilmiştir.

Buna göre Şekil 3’deki R² değerlerinin kıyaslandığı grafik incelendiğinde, tüm sektörler ve sera gazları için Random forest, Extra tree ve XGBoost regresyon tekniklerinin ortalama değerleri sırasıyla 0.77, 0.82 ve 0.76 olarak elde edilmiştir.



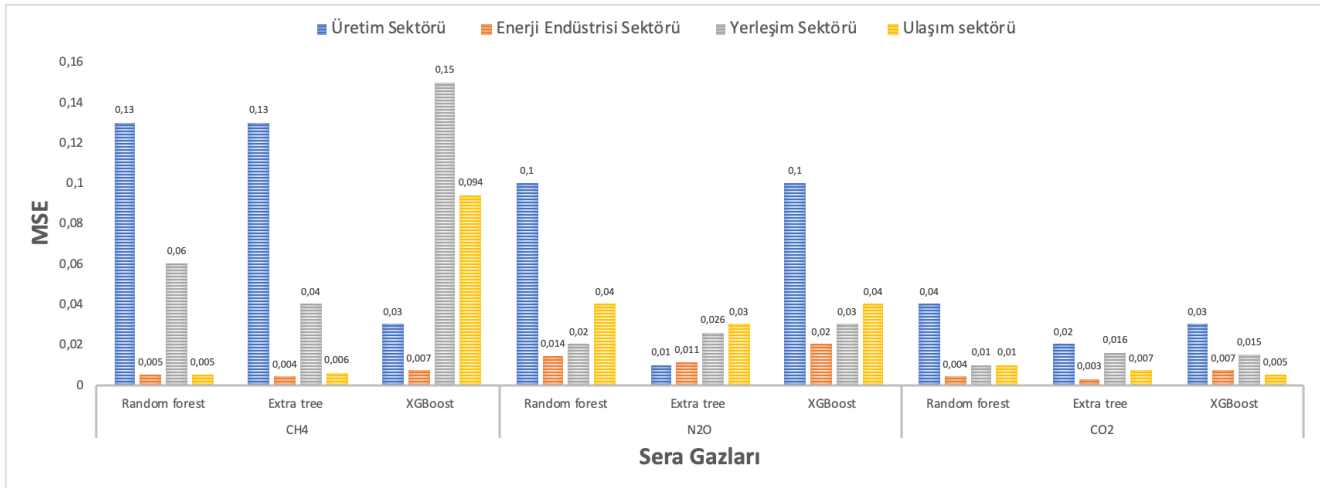
Şekil 3. Tüm sektörüne ait emisyon verileri için elde edilen R² değerleri

Şekil 4 incelendiğinde, tüm sektörler için seragazi emisyon değerlerinin ortalama mutlak hata bakımından kıyaslaması görülmektedir. Buna göre CH_4 ve CO_2 için enerji endüstrisi ve ulaşım sektörüne ait modellerin daha düşük hata değerine ulaştığı görülmektedir. N_2O için ise enerji endüstrisi ve yerleşim sektörlerinde daha düşük hata değerlerine ulaşılmıştır.



Şekil 4. Tm sektörüne ait emisyon verileri için elde edilen MAE deęerleri

Şekil 5'deki grafik Şekil 4'den farklı olarak tüm sektörler için seragazi emisyon değerlerinin ortalama kare hata bakımından kıyaslaması görülmektedir. Buna göre üretim sektörüne ait MAE deęerlerinin daha yüksek olması, dięer sektörler için daha az da olsa daha zayıf bir tahmin performansı gösterdiği yorumu yapılabilir.



Şekil 5. Tm sektörüne ait emisyon verileri için elde edilen MSE deęerleri

Tablo 6'da , 2020 yılı için ÇKA ve TÖY içinde en iyi ortalama performansı gösteren ERTR algoritmasının tahmin ettiği sera gazı emisyon deęerleri görülmektedir. ÇKA için sunulan deęerler Tablo 2, 3, 4 ve 5'de en yüksek performans deęerine sahip model kullanılarak elde edilmiştir.

Tablo 6. 2020 yılına ait tahmin edilen sera gazı emisyon deęerleri

	Üretim (Gg)	Enerji Endüstrisi (Gg)	Yerleşim (Gg)	Ulaşım (Gg)	
ÇKA	CH_4	4.5923	1.7531	95.813	14.1490
	N_2O	0.758	1.1382	1.1177	3.8472
	CO_2	76397	124026.6	54132.3	72193.9
Extra Tree	CH_4	5.4478	1.8211	116.102	16.8662
	N_2O	0.8644	0.0987	0.9596	3.8954
	CO_2	83241	130855	56141.3	78128.6

Gg: Gigagram

Tablo 7’de tüm modeller arasında en iyi sonucu veren ÇKA modeli ile geliştirilen 2020 yılında üretim, enerji endüstrisi, yerleşim ve ulaşım sektörleri tarafından doğaya salınacağı öngörülen sera gazı emisyon değerlerinin, 1990-2014 yılları arasında ortalama salınım değerlerinden ne ölçüde farklılık gösterdiği görülmektedir. Tablo 7’deki c sütunlarına ait değerler 2020 yılındaki emisyon değerlerinin yüzde kaçlık bir değişim gösterdiğini ifade etmektedir. Dört sektör arasında sadece yerleşim sektörüne ait tahmin değerlerinde geçmiş 14 yıllık döneme ait ortalamanın altında sonuçlar elde edildiği görülmektedir.

Tablo 7. 1990-2014 yılları arası ortalama salınım ile 2020 yılına ait tahmin edilen sera gazı emisyon değerlerinin kıyaslanması

	Üretim (Gg)			Enerji Endüstrisi (Gg)			Yerleşim (Gg)			Ulaşım (Gg)		
	a	b	c	a	b	c	a	b	c	a	b	c
CH ₄	3.3082	4.5923	38.8	1.0679	1.7531	64.1	120.55	95.813	-20.5	8.5822	14.1490	64.8
N ₂ O	0.5390	0.758	40.6	0.7065	1.1382	61.1	1.2352	1.1177	-9.5	2.6496	3.8472	45.1
CO ₂	58956	76397	29.5	74939	124026.6	65.5	33123	54132.3	63.4	40535	72193.9	78.1

a: 1990-2014 yılları arasında ortalama salınım değerleri b: 2020 yılına ait tahmin edilen salınım değeri c: Değişim (%)

5. Sonuç ve Öneriler

Küresel ısınmanın olumsuz etkileri artık günümüzde yaşanmaya başlanmış ve bir çok ülke küresel ısınmaya sebep olan sera gazlarına ait emisyon değerlerinin düşürülmesi için bazı önlemler almaya başlamıştır. Bir çok sektör sera gazı kaynaklı yüksek emisyon değerleri bakımından küresel ısınmaya tesir etmektedir. Ülkelerin sera gazı salınımlarının gelecek dönemler için tahmin edilmesi gerekli önlemlerin erken alınması bakımından önemlidir. Literatür araştırmalarında farklı tahmin modelleri ile ülke bazında emisyon değeri tahminine dönük çalışmalar yürütüldüğü görülmektedir.

Bu çalışmada Türkiye’deki üretim, enerji endüstrisi, yerleşim ve ulaşım sektörlerine ait 1990-2014 yılları arasındaki sera gazı emisyon değerleri kullanılarak yapay sinir ağı modellerinden olan ÇKA ve topluluk öğrenme yöntemlerinden olan ERTR, RFR ve XGR algoritmaları kullanılarak en iyi tahmin modelini oluşturmak için çeşitli deneyler gerçekleştirilmiştir. Çalışmanın en önemli kısıtı bazı sera gazı emisyon değerlerinin veri setinde yer almaması sebebiyle tüm sektörlerin ve sera gazı türlerinin çalışmaya dahil edilememesidir. Oluşturulan model ile bu sektörler tarafından doğaya salınımı yapılan CH₄, N₂O ve CO₂ gazlarının 2020 yılına ait değerleri tahmin edilmiştir. Avrupa Çevre Ajansından elde edilen veriler ön işleme aşamasından geçirildikten sonra normalizasyon işlemine tabi tutulmuştur. ÇKA ağının oluşturulması için katman sayısı, her bir katmana ait nöron sayısı ve aktivasyon fonksiyonları gibi parametrelerin aldığı değerler dögüsel olarak değiştirilerek birçok deneme gerçekleştirilmiştir. Sigmoid ve Relu aktivasyon fonksiyonları kullanılarak, nöron sayısı olarak 2 ile 200 arasında değişen 30 farklı değer için ağı eğitimi çalışmaları gerçekleştirilmiştir. Kurulan ÇKA modellerinin performansı ise MAE, MSE ve R² değerleri ile değerlendirilmiştir. Üç farklı sera gazı için kurulan modeller incelendiğinde elde edilen en yüksek R² değeri üretim, enerji endüstrisi, yerleşim ve ulaşım sektörleri için sırasıyla 0.86, 0.93, 0.91 ve 0.95 olarak bulunmuştur.

Çalışmada gerçekleştirilen TÖY’e dayanan algoritmalar da ise ortalama R² değerleri bakımından en iyi performansı ERTR algoritması ile kurulan model sağlamıştır. Hem ÇKA hem de TÖY yöntemleri ile elde edilen performans bakımından ise en iyi performans ÇKA tabanlı model ile elde edilmiştir.

2020 yılında bu sektörler tarafından doğaya salınacağı öngörülen sera gazı emisyon değerleri incelendiğinde, 14 yıllık geçmiş dönemi kapsayan salınım değerlerinin ortalamaları ile önemli farklılıklar olduğu görülmektedir. Buna göre 14 yıllık geçmiş döneme oranla üretim sektörü alanında ortalama % 36, enerji endüstrisi sektöründe % 64 ve ulaşım sektöründe % 63 oranında bir artış öngörülmektedir. Yerleşim sektöründe ise N₂O ve CH₄ gazlarının salınımlarında 2020 yılı için tahmin edilen değerde, 14 yıllık geçmiş döneme oranla ortalama %15’lik bir düşüş görülmektedir. Bu düşüşün nedeni olarak yerleşim sektöründe son yıllarda konutlarda doğalgaz kullanımının artışının etkili olduğu düşünülmektedir.

Gerçekleştirilen çalışma ile ortaya koyulan tahmin modellerinin Türkiye özelinde sera gazı emisyonları için alınacak önlemler bakımından önemli olduğu düşünülmektedir. Çalışmada kullandığımız veri seti 1990-2014 yılları arasındaki sera gazı emisyon değerlerini içermektedir. Tahmin modellerinin kurulduğu çalışmalarda özellikle zaman serisi temelli uygulamalarda veri aralığının çok olması daha iyi performans sonuçları alınmasını sağlamaktadır. Bu sebeple bu tür çalışmaların performansının daha da yüksek olabilmesi için güncel verilere ulaşım oldukça önemlidir. Bu çalışmada kullanılan makine öğrenmesi teknikleri ayrıca zaman serisine dayalı teknikler ya da recurrent ağlar kullanılarak da gerçekleştirilebilir. Yapılacak sonraki çalışmalarda farklı sektörler ve sera gazı türleri için zaman serisine ve recurrent ağlarına dayalı yeni çalışmalara odaklanılabilir.

Referanslar

- Abid, M. (2017). Does economic , fi nancial and institutional developments matter for environmental quality? A comparative analysis of EU and MEA countries. *Journal of Environmental Management*, 188(2), 183-194. <https://doi.org/10.1016/j.jenvman.2016.12.007>.
- Al-Ghobari, H. M., El-Marazky, M. S., Dewidar, A. Z., & Mattar, M. A. (2018). Prediction of wind drift and evaporation losses from sprinkler irrigation using neural network and multiple regression techniques. *Agricultural Water Management*, 195, 211-221.
- Ağaçayak, T., & Öztürk, L. (2017). Türkiye ' De Tarım Sektöründen Kaynaklanan Sera GazıEmisyonlarının. *İPM – MercatoPolitika Notu*, 3–15.
- Araabi, N. (2012). Prediction of Climate Change Induced Temperature Rise in Regional Scale Using Neural Network. *International Journal of Environmental Research*, 6(3), 677–688.
- Assareh, E., & Nedaei, M. (2018). A metaheuristic approach to forecast the global carbon dioxide emissions. *International Journal of Environmental Studies*, 75(1), 99–120. <https://doi.org/10.1080/00207233.2017.1374075>.
- Azid, A., Juahir, H., Toriman, M. E., Kamarudin, M. K. A., Saudi, A. S. M., Hasnam, C. N. C., ... Yamin, M. (2014). Prediction of the level of air pollution using principal component analysis and artificial neural network techniques: A case study in Malaysia. *Water, Air, and Soil Pollution*, 225(8). <https://doi.org/10.1007/s11270-014-2063-1>.
- Baghban, A., Ahmadi, M. A., & Shahraki, B. H. (2015). Prediction carbon dioxide solubility in presence of various ionic liquids using computational intelligence approaches. *Journal of Supercritical Fluids*, 98, 50–64. <https://doi.org/10.1016/j.supflu.2015.01.002>.
- Behrang, M. A., Assareh, E., Assari, M. R., & Ghanbarzadeh, A. (2011). Using bees algorithm and artificial neural network to forecast world carbon dioxide emission. *Energy Sources, Part A: Recovery, Utilization and Environmental Effects*, 33(19), 1747–1759. <https://doi.org/10.1080/15567036.2010.493920>.
- Bolanča, T., Strahovnik, T., Ukić, Š., Stankov, M. N., & Rogošić, M. (2017). Modeling of policies for reduction of GHG emissions in energy sector using ANN: case study—Croatia (EU). *Environmental Science and Pollution Research*, 24(19), 16172–16185. <https://doi.org/10.1007/s11356-017-9216-x>.
- Breiman, L. (1996). Bagging Predictors. *Machine Learning*, 24(421), 123–140. <https://doi.org/10.1007/BF00058655>.
- Buisson, L., Grenouillet, G., Casajus, N., & Lek, S. (2010). Predicting the Potential Impacts of Climate Change on Stream Fish Ass javascript :: emblages. *American Fisheries Society Symposium*, 5, 327–346.
- Change, I. P. O. C. (2007). Climate Change 2007: The Physical Science Basis: Summary for Policymakers. *Geneva: IPCC*, 996. <https://doi.org/10.1038/446727a>.
- Chen, D., Li, Y., Grace, P., & Mosier, A. R. (2008). N2O emissions from agricultural lands: A synthesis of simulation approaches. *Plant and Soil*, 309(1–2), 169–189. <https://doi.org/10.1007/s11104-008-9634-0>.
- Chen, X. (Michael), Zahiri, M., & Zhang, S. (2017). Understanding ridesplitting behavior of on-demand ride services: An ensemble learning approach. *Transportation Research Part C: Emerging Technologies*, 76, 51–70. <https://doi.org/10.1016/j.trc.2016.12.018>.
- Choi, S., & Hur, J. (2020). An ensemble learner-based bagging model using past output data for photovoltaic forecasting. *Energies*, 13(6). <https://doi.org/10.3390/en13061438>.
- Çoban, O., & Şahbaz Kılınç, N. (2014). Yenilenebilir enerji tüketimi ve karbon emisyonu ilişkisi: tr örneği *. *Sosyal Bilimler Enstitüsü Dergisi*, (38), 195–208.
- Collins, M. A. T. (2007). Ensembles and probabilities: A new era in the prediction of climate change. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 365(1857), 1957–1970. <https://doi.org/10.1098/rsta.2007.2068>.
- Cui, H. Z., Sham, F. C., Lo, T. Y., & Lum, H. T. (2011). Appraisal of alternative building materials for reduction of CO2 emissions by case modeling. *International Journal of Environmental Research*, 5(1), 93–100.

- Dam, M. M. (2014). Sera Gazı Emisyonlarının Makroekonomik Değişkenlerle İlişkisi: OECD Ülkeleri için Panel Veri Analizi. *Yüksek Lisans Tezi, Sosyal Bilimler Enstitüsü, Adnan Menderes Üniversitesi*, 1–159.
- Ergün, S., & Atay Polat, M. (2017). G7 Ülkelerinde CO2 Emisyonu, Elektrik Tüketimi ve Büyüme İlişkisi. *Siyaset, Ekonomi ve Yönetim Araştırmaları Dergisi*, (2).
- Ersoy, A. E. (2017). Türkiye'nin Hayvansal Gübre Kaynaklı Sera Gazı Emisyonları Durumu ve Biyogaz Enerjisi Potansiyeli. *Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, Hacettepe Üniversitesi*, 1–127.
- Fan, J. L., Zhang, X., Zhang, J., & Peng, S. (2015). Efficiency evaluation of CO2 utilization technologies in China: A super-efficiency DEA analysis based on expert survey. *Journal of CO2 Utilization*, 11(2015), 54–62. <https://doi.org/10.1016/j.jcou.2015.01.004>.
- Fu, W., Han, W., Xu, T., Kim, Y., Lyu, C., & Zheng, A. (2019). Exploring the Interconnection of Greenhouse Gas Emission and Socio-economic Factors. *SAR Journal*, 2(3), 115–120. <https://doi.org/10.18421/SAR23-05>.
- Güçlü, B. S. (2006). Kyoto protokolü ve türkiyede'nin protokol karşısında durumu. *Metalurji Dergisi*, 142, 1-4.
- Gurney, K. (2014). *An introduction to neural networks*. London and New York: CRC press. Retrieved from http://www.ghbook.ir/index.php?name=فرهنگ_و_رساله_های_نوین&option=com_dbook&task=readonline&book_id=13650&page=73&chkhask=ED9C9491B4&Itemid=218&lang=fa&tmpl=component.
- Hamzacebi, C., & Karakurt, I. (2015). Forecasting the energy-related CO₂ emissions of Turkey using a grey prediction model. *Energy Sources, Part A: Recovery, Utilization and Environmental Effects*, 37(9), 1023–1031. <https://doi.org/10.1080/15567036.2014.978086>.
- Harrington P (2012) Machine learning in action. *Manning Publications Co*.
- Hebb, D. O. (1949). *The Organization of Behavior A Neuropsychological Theory*. Central Institute of Education, New York: Wiley (Vol. 65). <https://doi.org/10.1901/jaba.1992.25-575>.
- IPCC. (2014). Climate Change 2014 Synthesis Report. *Contribution of Working Groups I, II and III to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change [Core Writing Team, R.K. Pachauri and L.A. Meyer (Eds.)]*. IPCC, Geneva, Switzerland, (1), 151. <https://doi.org/10.1177/0002716295541001010>.
- Işık, N. (2014). Sosyo Ekonomi Ulaştırma Sektöründe CO2 Emisyonu ve Enerji Ar-Ge Harcamaları İlişkisi. *Sosyoekonomi /*, 2014–2(December), 322–346.
- Jatmiko, W., Purnomo, D. M. J., Alhamidi, M., Wibisono, A., Wisesa, H., Mursanto, P., ... Addana, F. (2016). Algal growth rate modeling and prediction optimization using incorporation of MLP and CPSO algorithm. *2015 International Symposium on Micro-Nano Mechatronics and Human Science, MHS 2015*, (November), 1–8. <https://doi.org/10.1109/MHS.2015.7438293>.
- Julian, D. (2016). *Designing Machine Learning Systems with Python. PACKT Publishing open source community experience distilled* (Vol. 53).
- Kainuma, M., Matsuoka, Y., & Morita, T. (2000). The AIM/end-use model and its application to forecast Japanese carbon dioxide emissions. *European Journal of Operational Research*, 122(2), 416–425. [https://doi.org/10.1016/S0377-2217\(99\)00243-X](https://doi.org/10.1016/S0377-2217(99)00243-X).
- Kara, G., Yalınz, İ., & Sayar, M. (2019). Konya İli Hayvansal Gübre Kaynaklı Sera Gazı Emisyonları Durumu. *Ulusal Çevre Bilimleri Araştırma Dergisi*, 2(2), 57–60.
- Khan, M. J. U. R., & Awasthi, A. (2020). Machine learning model development for predicting road transport GHG emissions in Canada. *WSB Journal of Business and Finance*, 53(2), 55–72. <https://doi.org/10.2478/wsbjbf-2019-0022>.
- Khan, S., Rahmani, H., Shah, S. A. A., & Bennamoun, M. (2018). A Guide to Convolutional Neural Networks for Computer Vision. *Synthesis Lectures on Computer Vision*, 8(1), 1–207. <https://doi.org/10.2200/s00822ed1v01y201712cov015>.
- Khoshnevisan, B., Rafiee, S., Omid, M., Yousefi, M., & Movahedi, M. (2013). Modeling of energy consumption and GHG (greenhouse gas) emissions in wheat production in Esfahan province of Iran using artificial neural networks. *Energy*, 52, 333–338. <https://doi.org/10.1016/j.energy.2013.01.028>.

- Kolasa-Więcek, A. (2018). Neural Modeling of Greenhouse Gas Emission from Agricultural Sector in European Union Member Countries. *Water, Air, and Soil Pollution*, 229(6), 7–9. <https://doi.org/10.1007/s11270-018-3861-7>.
- Kovancılar, B. (2001). Küresel Isınma Sorununun Çözümünde Karbon Vergisi ve Etkinliği. *Yönetim ve Ekonomi*, 8(2), 10–13.
- Krstanoski, N. (2006). Defining The Policy For Reduction Of CO2 Emissions From The Road Transport Sector In Republic Of Macedonia, 1–15.
- Kumar, S., & Muhuri, P. K. (2019). A novel GDP prediction technique based on transfer learning using CO2 emission dataset. *Applied Energy*, 253(May), 113476. <https://doi.org/10.1016/j.apenergy.2019.113476>.
- Li, Y., Han, Y., Wang, J., & Zhao, Q. (2018). A MBCRF algorithm based on ensemble learning for building demand response considering the thermal comfort. *Energies*, 11(12). <https://doi.org/10.3390/en1123495>.
- Li, S., Zhou, R., & Ma, X. (2010). The forecast of CO2emissions in China based on RBF neural networks. *2010 2nd International Conference on Industrial and Information Systems, IIS 2010, 1*, 319–322. <https://doi.org/10.1109/INDUSIS.2010.5565845>.
- Liao, C. H., Lu, C. S., & Tseng, P. H. (2011). Carbon dioxide emissions and inland container transport in Taiwan. *Journal of Transport Geography*, 19(4), 722–728. <https://doi.org/10.1016/j.jtrangeo.2010.08.013>.
- Lu, I. J., Lewis, C., & Lin, S. J. (2009). The forecast of motor vehicle, energy demand and CO2 emission from Taiwan's road transportation sector. *Energy Policy*, 37(8), 2952–2961. <https://doi.org/10.1016/j.enpol.2009.03.039>.
- Mahesh, G. U. (2018). Prediction of Transportation Carbon Emission using Spatio-temporal Datasets and Multilayer Perceptron Neural Network. *International Journal of New Innovations in Engineering and Technology Prediction*, 8(2), 39–48.
- Mohammed, A. A., & Aung, Z. (2016). Ensemble learning approach for probabilistic forecasting of solar power generation. *Energies*, 9(12). <https://doi.org/10.3390/en9121017>.
- Nwulu, N. I., & Agboola, O. P. A. (2012). Modelling CO2 Emissions Using Artificial Neural Networks. *AWER Procedia Information Technology & Computer Science*, 2, 407–411.
- Özmen, M. T. (2009). Sera Gazı - Küresel Isınma ve Kyoto Protokolü. *Türkiye Mühendislik Haberleri*, 42–46.
- Pabuçcu, H., & Bayramoğlu, T. (2016). Yapay Sinir Ağları ile CO2 Emisyonu Tahmini: Türkiye Örneği. *Gazi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 18(3), 762–778.
- Parker, W. S. (2010). Predicting weather and climate: Uncertainty, ensembles and probability. *Studies in History and Philosophy of Science Part B - Studies in History and Philosophy of Modern Physics*, 41(3), 263–272. <https://doi.org/10.1016/j.shpsb.2010.07.006>.
- Priddy, K.L., & Keller, P.E., (2005). Artificial neural networks: An introduction. *SPIE- The International Society for Optical Engineering*, Washington, USA.
- Quesada-Rubio, J. M., Villar-Rubio, E., Mondéjar-Jiménez, J., & Molina-Moreno, V. (2011). Carbon dioxide emissions vs. allocation rights: Spanish case analysis. *International Journal of Environmental Research*, 5(2), 469–474. <https://doi.org/10.22059/ijer.2011.331>.
- Rosenblat, F. (1958). The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 386.
- Sagi, O., & Rokach, L. (2018). Ensemble learning: A survey.
- Saleh, C., Dzakiyullah, N. R., & Nugroho, J. B. (2016). Carbon dioxide emission prediction using support vector machine. *IOP Conference Series: Materials Science and Engineering*, 114(1). <https://doi.org/10.1088/1757-899X/114/1/012148>.
- Sangeetha, A., & Amudha, T. (2018). A Novel Bio-Inspired Framework for CO2 Emission Forecast in India. *Procedia Computer Science*, 125, 367–375. <https://doi.org/10.1016/j.procs.2017.12.048>.
- Solomon, S., Qin, D., Manning, M., Marquis, M., Averyt, K., Tignor, M. B., Chen, Z. H. (2007). *The Physical Science Basis. Contribution of Working Group I to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change*.

Cambridge University Press: Cambridge, United Kingdom and New York, NY, USA.
<https://doi.org/10.1017/CBO9781107415324.Summary>.

Theodoridis, S., & Koutroumbas, K. (2009). Pattern recognition. 2003. *Elsevier Inc.*

Uğuz, S. (2019). Makine öğrenmesi- Teorik yönleri ve Python uygulamaları ile bir yapay zeka ekolü. *Nobel akademik yayın*, 1,312.

Wang, T., Li, H., Zhang, J., & Lu, Y. (2012). Influencing Factors of Carbon Emission in China's Road Freight Transport. *Procedia - Social and Behavioral Sciences*, 43, 54–64. <https://doi.org/10.1016/j.sbspro.2012.04.077>.

Yan, X., & Crookes, R. J. (2010). Energy demand and emissions from road transportation vehicles in China. *Progress in Energy and Combustion Science*, 36(6), 651–676. <https://doi.org/10.1016/j.pecs.2010.02.003>.

Yılmaz, H., & Yılmaz, M. (2013). Forecasting Co₂ Emissions For Turkey By Using The Grey Prediction Method. *Journal of Engineering and Natural Sciences*, (444), 141–148.

Zhou, J., Yu, X., & Yuan, X. (2018). Predicting the carbon price sequence in the shenzhen emissions exchange using a multiscale ensemble forecasting model based on ensemble empirical mode decomposition. *Energies*, 11(7), 1–17. <https://doi.org/10.3390/en11071907>.

Zhou, Z. H. (2012). Ensemble methods: foundations and algorithms. *CRC press*.

Zhu, B. (2012). A novel multiscale ensemble carbon price prediction model integrating empirical mode decomposition, genetic algorithm and artificial neural network. *Energies*, 5(2), 355–370. <https://doi.org/10.3390/en5020355>.