



## AB27 Ülkelerindeki Çimento Sektörünün Karbon Emisyonu Tahmini: Yapay Sinir Ağları ve ARIMA Yöntemleriyle Karşılaştırma

Zeliha Semra KILINÇ\*, Selim ŞANLISOY\*\*

### ÖZ

Çimento, dünya genelinde en çok kullanılan yapı malzemelerinden biri olup, üretim sürecindeki artış, küresel CO<sub>2</sub> emisyonlarının yükselmesine önemli ölçüde katkıda bulunmaktadır. Bu çalışmanın amacı, Avrupa Birliği (AB) ülkelerinde çimento sektörünün 2030 yılı itibarıyla yaratacağı karbon (CO<sub>2</sub>) emisyon miktarını tahmin etmek ve farklı yöntemlerle elde edilen sonuçları karşılaştırarak sektöre ilişkin olası ticari ve çevresel yükümlülükleri öngörmektir. Avrupa Yeşil Mutabakatı kapsamında uygulamaya konulan Sınırda Karbon Düzenleme Mekanizması (SKDM) ile çimento sektörü, emisyon azaltımının zorunlu kılındığı öncelikli sektörler arasında yer almıştır. Bu bağlamda çalışma, AB üyesi ülkelerde çimento sektörünün karbon emisyonlarının gelecekteki seyrini analiz ederek, uluslararası ticarete ortaya çıkacak ekstra maliyetlerin öngörülmesine katkı sağlamayı hedeflemektedir. Çalışmanın kapsamında, AB ülkeleri çimento sektörü odaklı olarak seçilmiş ve emisyon tahminleri 2030 yılına kadar yapılmıştır. Araştırmada zaman serisi analiz yöntemlerinden ARIMA modeli ile Yapay Sinir Ağları (YSA) kullanılmış, bu iki yöntemle elde edilen tahminler karşılaştırılmıştır. Sonuçlar, her iki yöntemin farklı değerler üretse de genel olarak çimento sektöründe belirgin bir emisyon azalımı beklenmediğini göstermektedir. Bu durum, sektörün SKDM kapsamında gelecekte önemli maliyetlerle karşılaşabileceğine ve karbon azaltım politikalarının güçlendirilmesi gerektiğine işaret etmektedir.

**Anahtar Kelimeler:** Karbon emisyon, ARIMA, Yapay Sinir Ağları

**JEL Sınıflandırması:** Q52, Q54

## The Carbon Emission Estimation of the Cement Sector in EU27 Countries: A Comparison with Artificial Neural Networks and ARIMA Methods

### ABSTRACT

Cement is one of the most widely used building materials worldwide and the increase in its production process contributes significantly to the increase in global CO<sub>2</sub> emissions. The aim of this study is to estimate the amount of carbon (CO<sub>2</sub>) emissions that will be generated by the cement sector in European Union (EU) countries by 2030 and to predict possible commercial and environmental liabilities for the sector by comparing the results obtained with different methods. With the Carbon Border Adjustment Mechanism (CBAM) introduced within the scope of the European Green Deal, the cement sector is among the priority sectors where emission reductions are mandated. In this context, the study aims to contribute to the prediction of extra costs that will arise in international trade by analyzing the future course of carbon emissions of the cement sector in EU member countries. Within the scope of the study, EU countries are selected with a focus on the cement sector and emission forecasts are made until 2030. ARIMA model and Artificial Neural Networks (ANN), one of the time series analysis methods, were used in the study and the forecasts obtained with these two methods were compared. The results show that although both methods produce different values, in general, no significant emission reduction is expected in the cement sector. This situation indicates that the sector may face significant costs in the future within the scope of CBAM and carbon mitigation policies should be strengthened.

**Keywords:** Carbon emission, ARIMA, Artificial Neural Network

**JEL Classification:** Q52, Q54

Geliş Tarihi / Received: 19.03.2025 Kabul Tarihi / Accepted: 25.04.2025

*Bu eser Creative Commons Atıf-Gayriticari 4.0 Uluslararası Lisansı ile lisanslanmıştır.*




\* Öğr.Gör.Dr., Aydın Adnan Menderes Üniversitesi, Yenipazar MYO, Finans, Bankacılık ve Sigortacılık Bölümü, z.kilinc@adu.edu.tr, ORCID:0000-0001-9837-1587.

\*\* Prof.Dr., Dokuz Eylül Üniversitesi, İİBF, İktisat Bölümü, selim.sanlisoy@deu.edu.tr, ORCID:0000-0002-0629-0905.

## 1. GİRİŞ

Küresel ısınma ve buna bağlı iklim değişikliğinin etkileri her geçen gün daha da belirginleşmektedir. Bu küresel sorunla mücadelede atılan ilk adım, 1972 yılında düzenlenen Birleşmiş Milletler İnsan Çevresi Konferansı ile başlamış, ardından 1992 yılında Rio de Janeiro'da imzalanan Birleşmiş Milletler İklim Değişikliği Çerçeve Sözleşmesi (UNFCCC) ile küresel ısınmaya karşı uluslararası bir hukuki çerçeve oluşturulmuştur. 1997 yılında imzalanan Kyoto Protokolü ile sanayileşmiş ülkelere sera gazı emisyonlarını azaltmaya yönelik bağlayıcı hedefler getirilmiş, ancak uygulamada esneklik mekanizmaları nedeniyle emisyon azaltımında beklenen başarı tam anlamıyla sağlanamamıştır. Bu süreci takiben 2015 yılında imzalanan Paris İklim Anlaşması ile sıcaklık artışının 1,5°C ile sınırlandırılması hedeflenmiş ve ülkeler sera gazı azaltım hedeflerini gönüllülük esasına göre belirlemişlerdir. Avrupa Birliği (AB) ise, Paris Anlaşması'nın ötesine geçerek 2021 yılında Avrupa Yeşil Mutabakatı'nı açıklamış ve bu doğrultuda Sınırlı Karbon Düzenleme Mekanizması'nı (SKDM) hayata geçirmiştir. SKDM, karbon kaçağını önlemeyi ve karbon yoğun sektörlerde emisyonları azaltmayı amaçlamaktadır. Bu mekanizma kapsamında demir-çelik, çimento, alüminyum, gübre ve enerji sektörleri öncelikli alanlar olarak belirlenmiş ve ülkelerin bu sektörlerdeki emisyon performansları her yıl Avrupa Çevre Ajansı tarafından izlenmeye başlanmıştır. 2026 yılından itibaren, belirlenen emisyon kotalarını aşan ülkeler aşım miktarı kadar parasal bedel ödemekle yükümlü olacaktır.



Şekil 1: Çimento Üretim Şeması

Kaynak: (Czigler vd., 2020).

Çimento sektörü, yüksek enerji tüketimi ve hammadde özellikleri nedeniyle sanayi kaynaklı karbon emisyonlarının önemli bir bölümünü oluşturmaktadır. Özellikle bir ton Portland çimentosu üretiminin yaklaşık bir ton CO<sub>2</sub> salımına neden olması, sektörü iklim değişikliği ile mücadelede kritik bir noktaya taşımaktadır. Fosil yakıt kullanımı ve kalker ayrışımı kaynaklı bu yoğun emisyonun önemli bir kısmı AB ülkelerinde gerçekleşmektedir. Bu bağlamda, SKDM kapsamındaki yükümlülükler çerçevesinde çimento sektörünün gelecekteki emisyon miktarlarının doğru şekilde tahmin edilmesi gerek politika yapıcılar gerekse sektör temsilcileri açısından büyük önem arz etmektedir.

Bu çalışmanın temel hipotezi, mevcut eğilimlerin devamı halinde AB ülkelerinde çimento sektörünün 2030 yılı itibarıyla SKDM tarafından belirlenen sınırların üzerinde CO<sub>2</sub> emisyonu gerçekleştireceğidir. Ek olarak, ARIMA ve Yapay Sinir Ağları (YSA) gibi farklı tahmin yöntemlerinin emisyon öngörülerinde farklı performanslar sergileyeceği varsayılmaktadır. Araştırmanın sınırları, yalnızca AB üyesi ülkelerde çimento sektöründen kaynaklanan CO<sub>2</sub> emisyonları ile sınırlıdır; diğer sera gazları ve dışsal politik/ekonomik değişkenler çalışmanın kapsamı dışında tutulmuştur. Literatür taraması sonucunda, Avrupa

Birliği özelinde çimento sektörüne ilişkin, SKDM düzenlemeleri ışığında ve hem ARIMA hem de YSA yöntemlerini kullanarak yapılan karşılaştırmalı emisyon tahminlerine rastlanmamıştır. Bu açıdan çalışma, önemli bir literatür boşluğunu doldurmayı ve mevcut bilgi birikimine özgün bir katkı sunmayı hedeflemektedir. Ayrıca, elde edilen sonuçların SKDM yükümlülükleri doğrultusunda ülkelere ve sektörde faaliyet gösteren firmalara rehberlik edecek nitelikte olması, çalışmanın pratikteki değerini artırmaktadır. Çalışma dört bölümden oluşmaktadır. İkinci bölümde iklim değişikliği, sera gazı emisyonları ve uluslararası çevre politikalarına ilişkin literatür taramasına yer verilmiştir. Üçüncü bölümde çalışmada kullanılan ARIMA ve Yapay Sinir Ağları (YSA) yöntemleri detaylı biçimde açıklanmıştır. Dördüncü bölümde AB ülkelerinde çimento sektörüne ilişkin 2030 yılı CO<sub>2</sub> emisyon tahmin sonuçları sunulmuş ve yöntemler karşılaştırılmıştır. Son bölümde ise elde edilen sonuçlar ışığında genel bir değerlendirme yapılmış, politika önerileri sunulmuş ve çalışmanın sınırlamaları ile gelecekte yapılabilecek araştırmalara yönelik öneriler tartışılmıştır.

## 2. LİTERATÜR TARAMASI

Küresel olarak yayılan ve insandan kaynaklanan karbon emisyonunun yaklaşık %5'i çimento sektörü tarafından gerçekleşmektedir (Mahasenan vd., 2003). Hem dünyada hem de AB ülkelerinde çimento sektörü karbon emisyonunu en yoğun yayan sektörlerin başında gelmektedir. AB iklim değişikliğine karşı attığı adımlar çimento sektöründe ciddi oranda karbon emisyonunu azaltması yönündedir (Mikulčić vd., 2013). Gelişen teknoloji dolayısıyla çimento sektöründe üretim hacmi günden güne artmakta ve üretim artışına bağlı olarak yaratılan emisyon miktarı da kirliliği artırmaktadır (Zimwara vd., 2012). Uluslararası literatür incelendiğinde çimento sektöründen kaynaklanan karbon emisyon miktarını ele alan çalışmalar genellikle çimento üretim sürecini irdelemektedir. Bunun yanı sıra literatürde karbon emisyonunun gelecekteki miktarını tahmin eden çalışmalar bulunmaktadır. Gelecekte yaratılacak emisyon miktarını tahmin eden çalışmalarda genellikle ARIMA ya da yapay sinir ağları metotları ile gerçekleştirilmiş ve bu metotların karbon emisyon tahmininde uygulanabilirliği test edilmiştir. ARIMA metodunun uygulanabilirliğini test eden bir çalışma örneğin Rehman vd., 2024 Hindistan'da 1990-2023 yılları arasındaki yaratılan karbon emisyon verileri kullanarak ARIMA metodu uygulanmış ve 2024-2038 yıllarının tahminini gerçekleştirmişlerdir. 2021-2023 yıllarını gerçek veriler ve tahmin edilen verilerle kıyaslayarak ARIMA metodunun karbon emisyonu tahmininde uygulanabilirliğini vurgulamaktadır. Öte yandan ARIMA metodu ile geleceği tahmin eden çalışmalardan Kour, 2023 Güney Afrika'da yaratılan karbon emisyonunun gelecekteki miktarı tahmin edilmiştir. Çalışmada 1980-2016 dönemine ait veriler kullanarak 2027 yılındaki emisyon miktarı tahmin edilmiştir. Sonuçlarda on yıl içinde emisyon miktarının sabit bir oranda artış göstereceği ortaya konulmuştur. Geleceği tahmin eden bir diğer çalışma Nyoni ve Bonga, 2019, Hindistan'a ait 1990-2017 verileri kullanarak 2018-2030 yılları arasındaki emisyon miktarı tahminlenmiştir. Sonuçlarda Hindistan'daki karbon emisyonunun artacağı ve önlem alınması gerektiği vurgulanmıştır. Literatürde yapay sinir ağlarıyla gelecekteki karbon emisyonunu tahmininde performansı ölçen çalışmalarda örneğin Acheampong ve Boateng, 2019 Avustralya, Brezilya, Çin, Hindistan ve ABD'de karbon emisyonu tahmini için 1980-2015 arası dönemde üçer aylık verileri kullanarak yapay sinir ağlarının gelecek tahmin başarısı araştırılmıştır. Sonuçlarda yapay sinir ağlarının güvenilir sonuçlar elde ettiği sonuçlarına ulaşılmıştır. Literatürde karbon emisyonunun gelecekteki miktarını araştıran çalışmalar kısıtlıdır. Ancak ekonometrik olarak ARIMA ve YSA yöntemlerinin performanslarının karşılaştırıldığı çalışmalar bulunmaktadır. Karşılaştırma çalışmalarında emisyon tahmin performansını karşılaştıran çalışmalar bulunduğu gibi aynı zamanda çimento sektöründe talep tahmininin performansını kıyaslayan çalışmalar da bulunmaktadır. Çimento sektöründe talep tahmin performansını kıyaslayan çalışmalardan örneğin, Liu ve diğerleri, 2008 çalışmasında Tayvan'da 1982- 1994 yılları arasındaki üçer aylık çimento talebi verileri kullanarak 2004-2005 yılları

arasındaki talep tahminlerini SARIMA ve YSA yöntemleriyle test etmişlerdir. Çalışmanın sonuçlarına göre YSA tahmin sonuçları daha doğru tahminler ürettiği sonucuna ulaşılmıştır. Benzer bir çalışma Frandinata ve diğerleri 2014 Aceh ilinde çimento talep tahminini diğer yöntemler ile ARIMA ve YSA modellerini kullanarak kıyaslamaktadır. Çalışmanın sonuçlarında ARIMA ve YSA yöntemlerinin diğer yöntemlere göre daha iyi olduğu sonucuna ulaşılmıştır. Öte yandan karbon emisyon tahmin performansını kıyaslayan çalışmalarda Li ve Zhang, 2023 Çin'deki karbon emisyonlarının gelecek tahmin performansını ölçmek için üç farklı istatistiki model ile araştırmışlardır. 1 Ocak 2020'den 30 Eylül 2022 tarihine kadar günlük verilerin kullanıldığı çalışmada üç farklı istatistiki metot ile altı farklı model denemeleri gerçekleştirilmiştir. Gri Tahmin, ARIMA ve SARIMAX ve üç makine öğrenimi metotları ile tahmin sonuçları kıyaslaması yapılmıştır. Sonuçlarda makine öğrenmesinin alt dallarından olan uzun kısa süreli bellek (LSTM) performansı diğer yöntem ve modellere göre karbon emisyonu tahmininde daha güçlü bir performansa sahip olduğu ortaya konulmuştur. Wen ve diğerleri, 2023 çalışmasında ise ARIMA ve LSTM birlikte kullanılarak 2000-2015 verileri ile 2018-2025 dönemleri arasındaki Çin'deki karbon emisyon miktarı tahmini gerçekleştirilerek uygulanan yöntemin başarısı ortaya konulmuştur. Janhuaton ve diğerleri, 2024 çalışmasında ise Tayland'da 1993-2013 yılları arasındaki veriler ile eğitilerek 2014-2022 arasındaki veriler ile test edilmiştir. 2030 yılının tahmin edildiği sonuç sonuçlarına göre emisyon miktarının azalarak 14.996,888 kilotona düşeceği ortaya konulmuştur. Enerji kullanımının en yoğun görüldüğü çimento sektöründe gelecekte ortaya çıkacak emisyon miktarının tahmin edilmesi ülkelerin emisyon miktarını azaltma önlemlerinde büyük önem arz etmektedir. Bu nedenle çalışmada çimento sektöründeki gelecek karbon emisyonunu YSA ve ARIMA modelleri ile tahminlemekte ve karşılaştırma yaparak literatüre katkı sağlamayı hedeflemektedir.

### 3. METODOLOJİ

#### 3.1. Veri Seti ve Yöntem

Çalışmada geçmiş karbon emisyon verisi kullanılarak gelecekteki karbon emisyon miktarı ARIMA ve YSA yöntemleriyle tahminlenmiş ve gelecekteki tahmin değerlerinin sonuçları ile modeller arası karşılaştırılması sağlanmıştır. Böylelikle modellerin tahmin gücü avantaj ve dezavantajlarıyla ortaya konulmuştur. Modellerin başarı performansları literatür araştırmalarında genellikle Ortalama Mutlak Hata Yüzdesi (MAPE) ve Hata Kareler Ortalaması (MSE) değerleri ile ölçülmekte (Zhang ve Hu,1998; Cho, 2003; De Lurgio, 1998) olup çalışmada da bu kriterler ile karşılaştırmalı olarak tablolarla verilmiştir.

Ortak karşılaştırma kriterlerinden olan MAPE ve MSE değerleri şu şekilde formüle edilerek hesaplanmaktadır:

$$MAPE = \frac{1}{N} \sum \left| \frac{e_t}{y_t} \right| * 100 \quad (1)$$

$$MSE = \frac{1}{T} \sum_{t=1}^T e_{t+k,t}^2 \quad (2)$$

Formüllerde gösterilen MAPE değerinin % 10 dan düşük olması tahmin modelinin güçlü performans derecesine sahip olduğunu gösterirken % 10 ve % 20 arasında olan değerlerde ise modelin sonuçlarının kabul edilebilir tahminler olduğu ifade edilebilmektedir (Kılınç ve Şanlısoy, 2024). Öte yandan MSE değerinde 0'a en yakın değer ve R değerinde 1'e en yakın değer performansın güçlü olduğunu göstermektedir.

Çalışmada kullanılan veri seti Avrupa Çevre Ajansının (EEA) her yıl sektörel bazda yayınladığı emisyon envanterinden derlenmiştir. 1990 yılından 2022 yılına kadar toplamda 33 yıllık çimento sektöründen kaynaklanan AB27 ülkelerinde toplam emisyon miktarı kullanılmıştır. ARIMA ve YSA modellerinde kullanılan yıl bazlı 33 veri ile 2023 yılından 2030 yılına kadar tahminleme gerçekleştirilmiştir. Verilere ait özet istatistikler tablosu aşağıdaki gibidir.

**Tablo 1: Özet İstatistikler**

| Emisyon           |           |
|-------------------|-----------|
| Ortalama          | 86033.65  |
| Medyan            | 89459.46  |
| Maksimum          | 106038.5  |
| Minimum           | 69794.91  |
| Std. Sapma        | 10789.19  |
| Çarpıklık         | -0.041107 |
| Kurtosis          | 1.616728  |
| Jarque-Bera       | 2.640276  |
| Olasılık          | 0.267098  |
| Toplam            | 2839111   |
| Toplam Std. Sapma | 3.73E+09  |
| Gözlem            | 33        |

### 3.2. ARIMA

Literatürde Box-Jenkins Yöntemi (B.J.) olarak da bilinen bu model George Box ve Gwilym Jenkins tarafından 1976'da ortaya konulmuştur (Goh ve Law, 2002). B.J. metodunun temeli tahminlenecek verilerin geçmişteki değerlerinin ve hataların bir kombinasyonu olarak modellenebilmesidir. Model şu şekilde ifade edilir (Amat, 2019):

$$\hat{y}_t = \mu + \alpha_1 y_{t-1} + \alpha_2 y_{t-2} + \dots + \alpha_p y_{t-p} - \beta_1 e_{t-1} - \beta_2 e_{t-2} - \dots - \beta_q e_{t-q} \quad (3)$$

Durağan serilerde sabit bir varyasyon aralığı bulunurken durağan olmayan serilerde bulunmamaktadır. Bu bağlamda ARIMA (p, d, q) modelleri zaman serisi tahminine bir yaklaşım sağlamakta ve verilerin otokorelasyonlarını tanımlamaktadır. ARIMA, otoregresif (p), fark (d) ve hareketli ortalama (q) oluşmaktadır (Alam ve AlArjani, 2021).

Yöntemde ilk koşul verilerin durağanlığının tespiti olup avantajlı tarafı hem durağan hem de durağan olmayan verilerle çalışılabilir olmasıdır. Durağanlık tespiti yapıldıktan sonra durağan olmayan bir seri ile çalışılıyorsa serinin farkı alınarak uygun model belirlenmektedir.

Otokorelasyon ve kısmi otokorelasyon değerlerine ve farkların derecesine göre AR ve MA bileşenlerinden oluşan modeller ile tahmin denemeleri gerçekleştirilmektedir. Çalışmada verilerin logaritması alınarak analiz gerçekleştirilmiştir.

### 3.3. ARIMA (1,1,1) Model


$$\hat{Y} = \phi_0 + Y_{t-1} + \phi_1 (Y_{t-1} - Y_{t-2}) - w_t \varepsilon_{t-1} \quad (4)$$

Modelde ifade edilen  $\hat{Y}$  zaman serisindeki tahmin edilen değerdir.  $Y_{t-1}$  ve  $Y_{t-2}$ ,  $t-1$  ve  $t-2$  zaman gecikmelerindeki yanıt değişkenleridir.  $t-1$  ve  $t-2$ , önceki zaman periyotlarındaki hataları da ifade etmektedir ve  $\phi_0, \phi_1, \phi_2, -1$  ve  $-2$ , tahmin edilecek katsayılarıdır.

**Tablo 2:** AR, MA, ARIMA Modelleri ve Özet Sonuçlar


| Model  | Akaike | Schwarz | Hannan Quinn | Durbin-Watson | R    | Prob.     |           |
|--------|--------|---------|--------------|---------------|------|-----------|-----------|
|        |        |         |              |               |      | AR        | MA        |
| AR1    | 4.71   | 4.61    | 4.68         | 1.50          | 0.84 | 0.00      |           |
| AR2    | 3.91   | 2.82    | 3.88         | 0.83          | 0.65 | 0.00      |           |
| MA1    | 3.89   | 3.80    | 3.86         | 0.83          | 0.64 |           | 0.00      |
| MA2    | 3.48   | 3.39    | 3.45         | 0.65          | 0.46 |           | 0.00      |
| AR1AR2 | 4.69   | 4.56    | 4.65         | 1.87          | 0.85 | 0.00-0.28 |           |
| MA1MA2 | 4.39   | 4.25    | 4.34         | 1.41          | 0.79 |           | 0.00-0.00 |
| AR1MA1 | 4.71   | 4.58    | 4.67         | 1.97          | 0.85 | 0.00      | 0.07      |
| AR1MA2 | 4.65   | 4.51    | 4.60         | 1.48          | 0.84 | 0.00      | 0.80      |
| AR2MA1 | 4.67   | 4.54    | 4.63         | 1.46          | 0.84 | 0.00      | 0.00      |
| AR2MA2 | 3.86   | 3.72    | 3.81         | 0.94          | 0.65 | 0.00      | 0.58      |

Tablo 2’de gösterilen modellerin sonuçlarında performans kriterlerine göre AR1MA1 modeli sonuçları prob. 0.00 ve 0.07 değerleriyle tahmin modeli olarak seçilmiştir. Seçilen AR1MA1 modeli ile gerçekleştirilen simülasyon sonucu Şekil 2’de gösterilmektedir.



Şekil 2: AR1MA1 Modeli Simülasyon Performansı

AR1MA1 modeli ile gerçekleştirilen tahmin benzetiminin sunulduğu Şekil 2’de 1990-2022 yıllarında gerçekleşen ve tahmin edilen değerleri optimum düzeyde gerçekleşmektedir.



Şekil 3: AR1MA1 Modeli ile Simülasyon Performans Güvenilirliği

AR1MA1 modeli ile gerçekleştirilen simülasyonun güvenilirliğinin gösterildiği Şekil 3’te simetrik MAPE değeri 0.33 değerinde güven aralığı içinde yer almaktadır. Öte yandan güvenilir performans sonucuna istinaden gelecek değerler tahmin edilerek Tablo 3’te sunulmaktadır.


**Tablo 3:** ARIMA1 Modeli ile Emisyon Tahmin Sonuçları

| Yıl  | Emisyon Tahmini |
|------|-----------------|
| 2023 | 73.206,32       |
| 2024 | 73.651,38       |
| 2025 | 74.048,30       |
| 2026 | 74.402,06       |
| 2027 | 74.717,16       |
| 2028 | 74.997,70       |
| 2029 | 75.247,35       |
| 2030 | 75.469,42       |

Tablo 3'te ARIMA1 modeli ile üretilen 2023-2030 yılları arasındaki tahmini emisyon miktarları sunulmaktadır. Tahminlenen sonuçlarda emisyon miktarının yıllar itibariyle artacağı 2030 yılına gelindiğinde 75.469,42 kilotona ulaşacağı sonucuna ulaşılmıştır. Sonuç sonuçları çimento üretim artışıyla paralel olduğunu göstermekte ve üretim artışıyla birlikte karbon emisyonunun artacağı söylenebilmektedir.

### 3.4. YSA

Yapay sinir ağları biyolojik canlıların sinir sisteminden esinlenerek 1943 yılında McCulloch ve Pitts, (1943) tarafından basitleştirilmiş nöronların tanıtılmasından sonra ortaya çıkmıştır. Tıpkı canlı organizmalarda olduğu gibi verilerin öğrenme, genelleme ve çok sayıda veriyle geleceği değerlendirebilme özelliğine sahiptir. YSA bu işlemleri yapay sinir hücreleri yoluyla ağ oluşturarak gerçekleştirmektedir. Yapay sinir hücresine verilen girdi, girdilerin işlenmesi esnasında ağırlıklar, bu ağırlıkların birleştirilmesi ve aktive edilmesi fonksiyonu ile çıkış işlemleriyle görevini yerine getirmektedir. Basit bir yapay sinir hücresi aşağıda gösterilmiştir.



**Şekil 4:** Yapay Sinir Hücresi

Kaynak: (McCulloch ve Pitts, 1943) uyarlanmıştır.

Çalışmada 33 yıllık verilerle ile gelecekteki emisyon oranının YSA modeliyle tahmin edilmesi işlemine geçilmeden önce ağ eğitilirken yüksek boyutlu veriler üzerindeki ciddi hesaplamalar yapılacak olması nedeniyle, veri setinin özelliklerine göre sırasıyla giriş ve çıkış verileri üzerinde standartlaştırma ve normalleştirme kullanılarak ölçeklendirilme yapılması gerekmektedir (Boateng vd., 2019). Normalleştirmede, ağın eğitim oranını artırmak için gözlemler 0-1 arasında dönüştürülmektedir. Bu nedenle çıktı değişkeni normalize edilmektedir ve bu sayede normalleştirme işlemi çıktı katmanı işlemini kolaylaştırmaktadır. Normalleştirme aşağıdaki formülle ifade edilmektedir (Acheampong ve Boateng, 2019).

$$\text{Lineer Dönüşüm } [0,1] : x_n = x_0 - x_{\min} / x_{\max} - x_{\min} \text{ (Zhang vd., 1998).} \quad (5)$$

Normalleştirilen veriler Matlab (2018b.) programına yüklenerek öğrenme algoritması belirlenerek ağı kurmadan önce veri setindeki değerlerin %70'i eğitim verisi, %20'si doğrulama ve %10'u ise test verisi olarak tanımlanmıştır. Ağı mimari tanımlamasında ise literatürde gelecek tahmini gerçekleştirilen çalışmalarda genellikle kullanılan ileri beslemeli ağlar tercih edilmiştir. Uygulamada en iyi tahmin sonucunu gerçekleştirecek ağa ulaşabilmek için öncelikle transfer fonksiyonu belirlenmiştir. Sabit katman ve farklı nöron sayılarıyla gerçekleştirilen transfer fonksiyonu belirleme denemeleri Tablo 4'te gösterilmiştir.

**Tablo 4:** Sabit Katman Farklı Nöron Sayıları ile Transfer Fonksiyonu Belirleme

| Deneme No | Transfer Fonksiyonu | Katman Sayısı | Nöron Sayısı | MSE  | R    | MAPE |
|-----------|---------------------|---------------|--------------|------|------|------|
| t1        | TANSIG              | 3             | 3            | 0.27 | 0.83 | 3.47 |
| u1        | TANSIG              | 3             | 5            | 0.24 | 0.96 | 2.71 |
| y1        | TANSIG              | 3             | 7            | 0.23 | 0.98 | 6.69 |
| z1        | LOGSIG              | 3             | 3            | 0.08 | 0.85 | 1.41 |
| w1        | LOGSIG              | 3             | 5            | 0.21 | 0.82 | 9.30 |
| x1        | LOGSIG              | 3             | 7            | 0.15 | 0.84 | 9.04 |
| T1        | PURELIN             | 3             | 3            | 0.17 | 0.70 | 9.07 |
| U1        | PURELIN             | 3             | 5            | 0.47 | 0.70 | 6.20 |
| Y1        | PURELIN             | 3             | 7            | 0.20 | 0.70 | 8.24 |

3 katmanlı farklı nöron sayılarıyla gerçekleştirilen denemeler sonucunda en düşük MAPE ve en yüksek R değeri 3 katmanlı 5 nöronlu TANSIG fonksiyonu ile gerçekleşmiştir. Transfer fonksiyonu belirlendikten sonra ikinci adımda farklı katmanlarda ve sabit nöron sayısı ile katman sayısı belirleme denemeleriyle devam etmiştir. Deneme sonuçları Tablo 5'te gösterilmiştir.

**Tablo 5:** Farklı Katman Sabit Nöron Sayıları ile Katman Sayısı Belirleme


| Deneme No | Transfer Fonksiyonu | Katman Sayısı | Nöron Sayısı | MSE  | R    | MAPE |
|-----------|---------------------|---------------|--------------|------|------|------|
| a1        | TANSIG              | 2             | 5            | 0.39 | 0.91 | 4.30 |
| b1        | TANSIG              | 3             | 5            | 0.16 | 0.92 | 3.19 |
| c1        | TANSIG              | 4             | 5            | 0.18 | 0.98 | 1.63 |
| d1        | TANSIG              | 5             | 5            | 0.00 | 0.99 | 0.98 |
| e1        | TANSIG              | 6             | 5            | 0.23 | 0.91 | 3.21 |
| f1        | TANSIG              | 7             | 5            | 0.22 | 0.88 | 4.46 |
| g1        | TANSIG              | 8             | 5            | 0.09 | 0.98 | 1.98 |

Katman sayısı belirleme deneme sonuçlarına göre 5 katmanlı 5 nöronlu ağ mimarisi belirlendikten sonra denemeler nöron sayısı belirleme çalışmasıyla devam etmiştir. Sabit 5 nöronlu ve farklı nöron sayılarıyla MAPE, MSE ve R kriterlerini en iyi sağlayan ağ mimarisi denemeleri devam etmiştir. Sonuçlar Tablo 6'da gösterilmiştir.

**Tablo 6:** Sabit 5 Katmanlı Farklı Nöron Sayıları ile Denemeler


| Deneme No | Transfer Fonksiyonu | Katman Sayısı | Nöron Sayısı | MSE  | R    | MAPE |
|-----------|---------------------|---------------|--------------|------|------|------|
| s1        | TANSIG              | 5             | 10           | 0.00 | 0.98 | 1.12 |
| h1        | TANSIG              | 5             | 9            | 0.34 | 0.97 | 2.14 |
| j1        | TANSIG              | 5             | 8            | 0.05 | 0.97 | 2.24 |
| k1        | TANSIG              | 5             | 7            | 0.00 | 0.98 | 1.38 |
| l1        | TANSIG              | 5             | 6            | 0.25 | 0.97 | 2.09 |
| d1        | TANSIG              | 5             | 5            | 0.05 | 0.99 | 0.98 |
| n1        | TANSIG              | 5             | 4            | 0.16 | 0.98 | 1.53 |
| o1        | TANSIG              | 5             | 3            | 0.09 | 0.98 | 1.04 |
| p1        | TANSIG              | 5             | 2            | 0.33 | 0.96 | 2.13 |
| r1        | TANSIG              | 5             | 1            | 0.05 | 0.92 | 3.59 |

Sabit 5 katman ve farklı nöron sayılarıyla gerçekleştirilen denemeler sonucuna göre 0.05 MSE, 0.98 MAPE ve 0.99 R değerinin en iyi sağlandığı 5 katman ve 5 nöronlu TANSIG fonksiyonu ile tahmin simülasyonu gerçekleştirilmiştir. Simülasyon çalışmasına göre 1990-2022 gerçek verilerle benzetim sonucu performansı Şekil 5'te gösterilmektedir.




**Şekil 5:** 5-5-1 Ağın Simülasyon Performansı

5 katmanlı 5 nöronlu ağın mimarisi Şekil 6'da gösterilmiştir.




Şekil 6: 5-5-1 Ağ Öğrenme Algoritması

Ağın mimarisinin gösterildiği Şekil 6’da en iyi performansa 1000 iterasyon sonucunda ulaşılmıştır. Tahmin performans kriterlerinden biri olan R değeri 0.99 oranında 1’e en yakın değerde gerçekleşmiştir.



Şekil 7: 5-5-1 Ağ Tahmin Performansı

MSE değerinin gösterildiği Şekil 8’de 1000 iterasyon sonucunda ulaşılan 0.0002 değeri ile ortalama karesel değerde en iyi değere sahiptir.



Şekil 8: 5-5-1 Ağın MSE Performansı

En iyi performansı gösteren 5-5-1 ağı ile gerçekleştirilen 2023-2030 arası tahmin sonuçları Tablo 8’de gösterilmektedir.

Tablo 8: YSA Tahmin Sonuçları

| Yıl  | Tahmin Emisyon |
|------|----------------|
| 2023 | 74.979,89      |
| 2024 | 74.981,26      |
| 2025 | 74.980,90      |
| 2026 | 74.980,60      |
| 2027 | 74.980,45      |
| 2028 | 74.980,38      |
| 2029 | 74.980,36      |
| 2030 | 74.980,34      |

Tablo 9: YSA ve ARIMA Tahmin Sonuçları Özet

| Yıl  | YSA       | ARIMA     |
|------|-----------|-----------|
| 2023 | 74.979,89 | 73.206,32 |
| 2024 | 74.981,26 | 73.651,38 |
| 2025 | 74.980,90 | 74.048,30 |
| 2026 | 74.980,60 | 74.402,06 |
| 2027 | 74.980,45 | 74.717,16 |
| 2028 | 74.980,38 | 74.997,70 |
| 2029 | 74.980,36 | 75.247,35 |
| 2030 | 74.980,34 | 75.469,42 |

Tablo 9’de paylaşılan YSA ve ARIMA tahmin değerleri incelendiğinde her iki yöntemde de birbirine yakın tahmin değerleri ürettiği görülmektedir. Ancak metotların tahmin güvenilirliğini ve performansını ölçen MAPE değerleri Tablo 10 incelendiğinde ARIMA metodunda 0.34 MAPE değeriyle daha güvenilir bir performans göstermektedir. Öte yandan Avrupa Çevre Ajansının yayımladığı en son 2022 yılı karbon emisyon verisinde Avrupa Birliği ülkelerinde çimento sektöründe emisyon miktarına yakın olan değer ARIMA metodunun tahmin ettiği değere yakındır. Örneğin Adebisi vd., 2014 çalışması iki metodun birbirine yakın değerler ürettiğini ve tahmin çalışmalarında güvenle tercih edilebileceği sonuçlarıyla makalenin sonuçlarını desteklemektedir.

**Tablo 10:** YSA ve ARIMA Tahmin Performansı Karşılaştırma

| Metot | YSA<br>(5-5-1) | ARIMA<br>(1,1,1) |
|-------|----------------|------------------|
| MSE   | 0.00           | 0.01             |
| MAPE  | 0.98           | 0.34             |
| R     | 0.99           | 0.85             |

#### 4. SONUÇ

Yapay sinir ağları ve ARIMA yöntemleriyle AB27 ülkelerinde gelecekteki çimento sektörünün yaratacağı emisyon miktarı tahminlenmesinin karşılaştırmalı olarak kıyaslandığı bu çalışmada, analiz sonuçları değerlendirilmiştir. YSA az sayıda veri ile güçlü tahminler üretmesi, korelasyon içeren verilerde bile tercih edilen bir yöntem olmasına olanak tanıırken, geleneksel ARIMA metodu da zaman serisi tahmin çalışmalarında sıklıkla kullanılabilmektedir. Literatürde Rehman vd. (2024) ve Kour (2023) gibi çalışmalar, ARIMA yönteminin karbon emisyonu tahmininde etkinliğini vurgulamışlardır. Ayrıca, Yapay Sinir Ağları'nın emisyon tahmininde güçlü bir performans sergilediği Acheampong ve Boateng (2019) tarafından da ortaya konulmuştur. Bu çalışmada yapılan analizlerde, kullanılan performans kriterlerine göre MSE değerlerinin birbirine oldukça yakın olduğu görülmekle birlikte, 0.34 MAPE değeriyle ARIMA metodunun tahminlerinin gerçek değerlere daha yakın olduğu bulunmuştur. Öte yandan her iki yöntem sonucunda da çimento sektöründe karbon emisyonunun artacağı öngörülmüştür. Bu sonuç, Nyoni ve Bonga (2019) ile Janhuaton vd. (2024) çalışmalarında gelecekte karbon emisyonunun artış eğilimi göstereceği yönündeki sonuçlarla da paralellik arz etmektedir. Üretim artışına bağlı olarak emisyon miktarındaki artış, literatürde Mikulčić vd. (2013) ve Zimwara vd. (2012) tarafından da vurgulanan çimento sektöründeki temel çevresel sorunlardan biridir. Bu durum, SKDM kapsamında çimento sektöründe üretim maliyetlerinin artacağı ve bu artışın dış ticarete rekabet dezavantajı yaratabileceği anlamına gelmektedir. Üretim maliyetlerindeki artışı dengelemek ve SKDM kaynaklı parasal yükümlülükleri azaltmak amacıyla temiz üretim teknolojilerine geçişin sağlanması hem politika yapımcılar hem de sektör firmaları açısından büyük önem taşımaktadır. Bu bağlamda, çalışmanın sonuçları, literatürdeki mevcut çalışmalarla uyumlu bir şekilde gelecekte karbon emisyon artışını önlemek için üretim süreçlerinde köklü değişiklikler yapılması gerektiğini vurgulamakta ve AB ülkeleri için yol gösterici nitelik taşımaktadır.

#### Araştırma ve Yayın Etiği Beyanı

Bu çalışma bilimsel araştırma ve yayın etiği kurallarına uygun olarak hazırlanmıştır.

#### Yazarların Makaleye Katkı Oranları

Yazar 1'in makaleye katkısı %60, Yazar 2'nin makaleye katkısı %40'dır.

## Çıkar Beyanı

Yazarlar açısından ya da üçüncü taraflar açısından çalışmadan kaynaklı çıkar çatışması bulunmamaktadır.

## KAYNAKÇA

- Acheampong, A. O., & Boateng, E. B. (2019). Modelling carbon emission intensity: Application of artificial neural network. *Journal of Cleaner Production*, 225, 833-856.
- Alam, T., & AlArjani, A. (2021). A Comparative Study of CO2 Emission Forecasting in the Gulf Countries Using Autoregressive Integrated Moving Average, Artificial Neural Network, and Holt-Winters Exponential Smoothing Models. *Advances in Meteorology*, 2021(1), 8322590.
- Amat Bernabéu, A. (2019). ARIMA and Artificial Neural Networks to forecast the CO2 emissions allowances price: application to the design of petrochemical supply chain under uncertainty.
- Boateng, E. B., Pillay, M., & Davis, P. (2019). Predicting the level of safety performance using an artificial neural network. In *Human Systems Engineering and Design: Proceedings of the 1st International Conference on Human Systems Engineering and Design (IHSED2018): Future Trends and Applications, October 25-27, 2018, CHU-Université de Reims Champagne-Ardenne, France 1* (pp. 705-710). Springer International Publishing.
- Cho, V. (2003). A comparison of three different approaches to tourist arrival forecasting. *Tourism management*, 24(3), 323-330.
- Czigler, T., Reiter, S., Schulze, P. & Somers, K., (2020). Laying the foundation for zero-carbon cement, <https://www.mckinsey.com/industries/chemicals/our-insights/laying-the-foundation-for-zero-carbon-cement#/>
- DeLurgio, S. A. (1998). *Forecasting principles and applications* (Vol. 49). New York: Irwin/McGraw-Hill.
- Fradinata, E., Suthummanon, S., Sirivongpaisal, N., & Suntiamorntuthq, W. (2014, August). ANN, ARIMA and MA timeseries model for forecasting in cement manufacturing industry: Case study at lafarge cement Indonesia—Aceh. In *2014 International Conference of Advanced Informatics: Concept, Theory and Application (ICAICTA)* (pp. 39-44). IEEE.
- Goh, C., & Law, R. (2002). Modeling and forecasting tourism demand for arrivals with stochastic nonstationary seasonality and intervention. *Tourism management*, 23(5), 499-510.
- Janhuaton, T., Ratanavaraha, V., & Jomnonkwao, S. (2024). Forecasting Thailand's Transportation CO2 Emissions: A Comparison among Artificial Intelligent Models. *Forecasting*, 6(2), 462-484.
- Kour, M. (2023). Modelling and forecasting of carbon-dioxide emissions in South Africa by using ARIMA model. *International Journal of Environmental Science and Technology*, 20(10), 11267-11274.
- Li, X., & Zhang, X. (2023). A comparative study of statistical and machine learning models on carbon dioxide emissions prediction of China. *Environmental Science and Pollution Research*, 30(55), 117485-117502.
- Mahasen, N., Smith, S., & Humphreys, K. (2003, January). The cement industry and global climate change: current and potential future cement industry CO2 emissions. In *Greenhouse gas control technologies-6th international conference* (pp. 995-1000). pergamon.
- Mikulčić, H., Vujanović, M., Markovska, N., Filkoski, R. V., Ban, M., & Duić, N. (2013). CO2 emission reduction in the cement industry. *Chemical engineering transactions*, 35, 703-708.
- Nyoni, T., & Bonga, W. G. (2019). Prediction of CO2 emissions in India using ARIMA models. *DRJ-Journal of Economics & Finance*, 4(2), 01-10.
- <https://www.mckinsey.com/industries/chemicals/our-insights/laying-the-foundation-for-zero-carbon-cement#/>
- Rehan, R., & Nehdi, M. (2005). Carbon dioxide emissions and climate change: policy implications for the cement industry. *Environmental Science & Policy*, 8(2), 105-114.
- Kılınç, Z., & Şanlısoy, S. Türkiye'nin AB 27 Ülkelerine Birincil Alüminyum İhracatının Sektörel Karbon Emisyonu Üzerine Etkileri. *İzmir İktisat Dergisi*, 39(4), 952-971.
- Zhang, G., & Hu, M. Y. (1998). Neural network forecasting of the British pound/US dollar exchange rate. *Omega*, 26(4), 495-506.
- Zhang, G., Patuwo, B. E. ve Hu, M. Y. (1998). Forecasting with artificial neural networks: The state of the art. *International journal of forecasting*, 14(1), 35-62.

Zimwara, D., Mugwagwa, L., & Chikowore, T. R. (2012). Air pollution control techniques for the cement manufacturing industry: A case study for Zimbabwe. *CIE42 proceedings*, 37, 1-13.

Wen, T., Liu, Y., he Bai, Y., & Liu, H. (2023). Modeling and forecasting CO2 emissions in China and its regions using a novel ARIMA-LSTM model. *Heliyon*, 9(11).

Worrell, E., Price, L., Martin, N., Hendriks, C., & Meida, L. O. (2001). Carbon dioxide emissions from the global cement industry. *Annual review of energy and the environment*, 26(1), 303-329.

## **Extended Summary**

### **The Carbon Emission Estimation of the Cement Sector in EU27 Countries: A Comparison with Artificial Neural Networks and ARIMA Methods**

Cement is one of the most widely used building materials in all developed and developing countries. Cement is a major contributor to global carbon emissions with the amount of carbon emissions it emits during production. Carbon emissions in the cement sector are mostly generated during production. The calcination process requires high heat and the type of energy used causes carbon emissions. The first step taken in the fight against climate change caused by global warming was the United Nations Conference on the Human Environment in 1972 and is one of the leading international initiatives. As a follow-up, the United Nations Framework Convention on Climate Change (UNFCCC), signed in Rio de Janeiro in 1992, was realized to provide an international framework to combat global warming and climate change. The Convention aimed to determine policies and measures to reduce greenhouse gas emissions, adaptation and absorption of greenhouse gases. With the Kyoto Protocol, which was signed in 1997 to reduce carbon emissions in the fight against climate change and entered into force in 2005, countries were given quantified emission reduction targets for the first time and a global emission trading system was established. According to the emissions trading system, firms can price carbon by purchasing certificates and unused certificates can be auctioned for sale. Although the aim of the emission trading system was to reduce carbon by pricing it, it failed to achieve its goal and only physically shifted the emission emitted. The emissions trading system, which is not a solution to reduce global emissions, has continued to be implemented but has been revised with regulations. Declared in 2021, the Border Carbon Adjustment Mechanism (CBAM) prepared within the scope of the European Green Deal can be considered as an extension of the emissions trading system. Within CBAM, five sectors that emit carbon intensively and are subject to foreign trade have been identified. These sectors are energy, cement, iron and steel, aluminum and fertilizer. The European Environment Agency (EEA) requires countries that have committed to carbon reductions in climate agreements to measure and report the amount of emissions in these priority sectors each year. The reports will play a role in determining the free emission allowances that will be granted to countries in the future. Scheduled to be officially implemented in 2026, the mechanism is binding on all countries exporting to EU countries. In essence, CBAM aims to protect producers within European borders in terms of competition. CBAM allocates countries limited emissions that they can create in production and obliges them to pay a price for the parts exceeding the allocation in exports and imports. The increase in emissions that countries create due to the increase in production and method will increase costs. It is important for countries not to lose their competitive advantage due to cost increase and to eliminate the negative effects of climate change by reducing the emissions created. In this context, the study aims to provide guidance to countries and firms by estimating the future amount of emissions created in the cement sector. In the study, firstly, in the introduction section, the steps taken internationally in the fight against climate change caused by global warming from the past to the present are given, and in the second section, the studies in the literature are mentioned. The third section presents the methodology and applications of the analyses used in the study. In the fourth and final section, the results of the analysis are shared and the conclusion is given. In this study, ARIMA and Artificial Neural Networks (ANN) methods are used to estimate the amount of carbon emissions from 2023 to 2030 using 33 years of carbon emission data for the period 1990-2022 from the UNFCCC report published annually by the European Environment Agency. The choice of two different methods allows us to compare the reliability of the forecasts. In the literature, both methods are used in carbon emission estimation. For example, in a study testing the applicability of the ARIMA method, Rehman et al., 2024 applied the ARIMA method using the carbon

emission data created in India between 1990-2023 and estimated the years 2024-2038. In the international literature, there are studies comparing both methods. In Liu et al. 2008, they forecasted cement demand in Taiwan for the period between 1982 and 1994. In the analysis conducted with 3-month data, SARIMA and ANN methods were compared in demand forecasts between 2004-2005. The findings of the study indicate that ANN method produces more accurate forecasts. Another study belongs to Frandinata et al., 2014. The study compares cement demand forecasting using ARIMA and ANN models with other methods. In the findings of the study, it was concluded that ARIMA and ANN methods are better than other methods. There is no study forecasting future emissions in the cement sector in EU27 countries with ARIMA and ANN methods. The study aims to contribute to the international literature with this feature. Although ARIMA method is a traditional forecasting tool, it allows working with non-stationary data by taking the difference in non-stationary series. On the other hand, in ANN method, it is not important whether the series are stationary or not. ANN can also make strong predictions even with data with a small number of observations. The fact that it can make strong forecasts even with a small number of data has enabled it to be preferred as one of the analysis methods to be used in the study. In this study, where the data between 1990-2022 is used as training data, the amount of emissions in the 2023-2030 periods is estimated. According to the findings, the ARIMA method estimated the amount of carbon emissions to be emitted in the cement sector in the EU27 countries in 2030 as 75,469.42 kilotons, while the ANN method produced an estimate of 74,980.34 kilotons. The results of the analyses in both methods similarly indicate that the amount of carbon emissions from the cement sector will increase in the EU27 countries in the future. The findings are not surprising. It is a known fact that increasing demand and production increase carbon emissions. In order to reduce the increase in emissions in the cement sector, changing the production method, creating alternatives in the raw materials used in production, changing the type of fuel used during production, and not preferring fossil fuels may be the preferred methods for reducing carbon emissions. As a continuation of the study, other priority sectors will be examined in other subsequent studies.