



Hava Kirliliği Tahmini: Yapay Sinir Ağları ve Regresyon Yöntemleriyle Bir Karşılaştırma

Air Pollution Forecast: A Comparison with Artificial Neural Networks and Regression Methods

İlayda AKBULUT^{1,*} , Burcu ÖZCAN² 

¹ Endüstri Mühendisliği, Kocaeli Üniversitesi, Kocaeli, Türkiye, **Orcid:** 0000-0002-1669-1817

² Endüstri Mühendisliği, Kocaeli Üniversitesi, Kocaeli, Türkiye, **Orcid:** 0000-0003-0820-4238

Araştırma Makalesi

Gönderilme Tarihi : 16/01/2020

Kabul Tarihi : 29/04/2020

Anahtar Kelimeler

Hava Kirliliği
Partikül Madde
Regresyon Analizi
Yapay Sinir Ağları

Research Paper

Received Date : 16/01/2020

Accepted Date : 29/04/2020

Keywords

Air Pollution
Particulate Matter
Regression Analysis
Artificial Neural Networks

Özet

Havanın doğal bileşimlerini farklılaştırıp, kirli bir hava olma niteliği kazandıran kirleticilerden kükürtdioksit (SO₂) ve partikül maddenin (PM₁₀) ölçülmesi, kirlilik seviyesine karar verebilme aşamasında Dünya Sağlık Örgütü (DSÖ) tarafından yeterli bulunarak tüm dünya ülkelerine önerilmiştir. Çalışmada, değerleri eksiksiz olarak elde edilebilen Türkiye'deki 31 il için veriler kullanılmıştır. Hava kirliliği, yapay sinir ağları (YSA) ve regresyon modelleri kullanılarak PM₁₀ miktarı tahmin edilerek ölçülmüş, iki yöntemin karşılaştırılması yapılmıştır. İlk olarak 2012-2018 yılları arasında ölçülen PM₁₀ miktarı bağımlı değişken olarak tanımlanarak onu etkileyebilecek 5 bağımsız değişken belirlenmiştir. Bağımlı değişken olan PM₁₀ miktarı 2018 yılı için regresyon ve YSA modelleri ile tahmin edilmiştir. Ayrıca bu tahminleme işlemi 4 ve 5 değişken için yapılarak nasıl bir farklılık olabileceği gözlenmiştir. Her iki yöntemde ve değişken sayısında, doğruluk oranını saptamak için ortalama mutlak hata (MAD), ortalama mutlak yüzde hata (MAPE), ortalama karesel hata (MSE), kök ortalama karesel hata (RMSE) değerleri hesaplanmıştır. Buna göre YSA yöntemi daha iyi uyum sağlayan model olarak seçilmiştir ve 2019 yılı için PM₁₀ değeri tahmini YSA yöntemiyle yapılmıştır.

Abstract

The measurement of sulfur dioxide (SO₂) and particulate matter (PM₁₀), which changes the natural composition of the air and gives it the characteristic of being a polluted air, has been proposed by the World Health Organization (WHO) to all countries in the world to determine the level of pollution. In this study, values obtainable data for exactly 31 provinces in Turkey are used. Air pollution was measured by estimating the amount of PM₁₀ using artificial neural networks (ANN) and regression models, and the two methods were compared. Firstly, the amount of PM₁₀ measured between 2013 and 2017 was defined as a dependent variable and 5 independent variables that could affect it were determined. The amount of the dependent variable PM₁₀ was estimated by regression and ANN models for 2018. In addition, it was observed that there could be a difference by making this estimation process for 4 and 5 variables. In both methods and number of variables, mean absolute error (MAD), mean absolute percent error (MAPE), mean square error (MSE), root mean square error (RMSE) values were calculated to determine the accuracy rate. Accordingly, the ANN method was chosen as a model that would fit better and PM value estimation for 2019 was made with the ANN method.

1. Giriş

Havanın doğal bileşimini farklılaştırıp bozan kirli hava özelliği kazandıran kirleticilerden, SO₂ ve PM₁₀ ölçümü,

kirlilik seviyesine karar verebilme aşamasında, DSÖ tarafından yeterli bulunarak tüm dünya ülkelerine önerilmiştir [1-4]. SO₂ kirliliği; kükürt bulunduran fosil yakıtların yanması ile kentsel ısınmada ve bazı endüstriyel proseslerin sonunda bacalardan çıkan kirliliklerden, partikül madde kirliliği ise genellikle sanayi bölgelerinden,

¹ Sorumlu Yazar (Corresponding Author): akbulut_ilyada@hotmail.com.tr



kısmen de kentsel ısınmada fosil yakıtlardan oluşmaktadır [5].

PM10 katı ya da sıvı olabilir, havada asılı halde bulunur PM10 içinde, pek çok organik ve inorganik kirlenici ile kanserojen özellikle ağır metalleri içerdiğinden SO₂'den daha önemlidir [2 – 4, 6].

Hava kirliliği toplumu her yönüyle etkilemekte sfesifik olarak çocuklar ve yaşlılarda etkilenme daha fazla olmaktadır. Dört yaşın altındakilerde pnömoni gibi göğüs rahatsızlıkları görülmekte ve pnömoni ölümleri artmakta, 55 yaş üstünde, kalp - akciğer hastalıkları ve hiper tansiyonlu hastaların durumlarında ağırlaşma, ağır hastalarda ise ölümlerde artma gözlenmektedir [1,4,7]. DSÖ, Avrupa Birliği (AB) ve Türkiye Hava Kalitesini Kontrol Yönetmeliği, hava kirliliğinin başladığı seviyeyi belirleyen standartlar ile kirleniciler için hedef sınır değerler belirlemiştir.

Çalışmanın amacı insan hayatını önemli ölçüde etkileyen hava kirlenici değerler için tahminleme yapmaktır. Bunun için Türkiye'de bulunan 31 il seçilerek 2013-2018 yılları arasında yapılan ölçümler sonucu elde edilen verilerden yararlanarak PM10 değerlerinin, belirlenen 5 bağımsız değişken ile arasındaki ilişkinin belirlenmesi, YSA ve regresyon analizi ile elimizde bulunan 2018 yılı için tahmin yapılarak yöntemlerin doğruluğunun tespiti için MAPE, MAD, MSE, RMSE değerleri hesaplanarak bir değerlendirme yapılması ve karşılaştırılmasıdır. Ve en iyi sonucu veren yöntem ile 2019 yılı için PM10 değerlerinin nasıl olacağını tahmin edilmesidir. Ayrıca tahminleme yapılırken değişken sayısı 4 ve 5 yapılarak işlemler tekrarlandığında nasıl bir farklılık göstereceğinin gözlemlenmesi amaçlanmıştır.

1.1. Literatür Araştırması

Sezer (2019) tezinde Zonguldak ilinin elektrik enerjisi yük tahmini, Regresyon, Geri Yayımlı Yapay Sinir Ağları (GYSA) ve Radyal Tabanlı Yapay Sinir Ağları (RTYSA) gibi metotlarla yapılmıştır. Tahmin metotlarında geliştirilen tüm modellerde aynı bağımsız değişkenler kullanılarak toplamda 8 farklı model kurularak analiz yapılmıştır. Tahmin metotları ile bulunan üç yıllık enerji tüketimi tahmini verileri kendi aralarında karşılaştırılmıştır. Bunun sonucunda en yüksek R² değeri ile hangi modelin en iyi tahmin sonucunu verdiği bulunmuştur [8].

Calp (2019) işletmeler için YSA kullanılarak günlük yemek talebini tahmin eden yapay zekâ tabanlı bir model önermiştir. Modelin performansı, regresyon değerleri, MAPE ve MSE dikkate alınarak belirlenmiştir. Deney sonuçları, modelin hata oranının düşük, performansının yüksek olduğunu ve talep tahmini için YSA kullanımının olumlu etkisini ortaya koymuştur [9].

Sönmez ve Zengin (2019) bir işletmenin satış tahmini için YSA ve çoklu regresyon modelleri kullanılarak günlük satışını tahmin edip ve iki modelin karşılaştırılması yapmışlardır. Her iki modelde başarı oranların yüksek olması talep tahmininde YSA ve çoklu regresyon kullanımının pozitif etkisini göstermiştir. YSA ile geliştirdiğimiz model çoklu regresyon modeline göre daha başarılı olduğu gözlemlenmiştir [10].

Dong, Fisman, Wang ve Xu (2019) çalışmalarında yatırım analistlerinin kurumsal saha ziyaretleri sırasında hava kirliliği ile müteakip kazanç tahminleri arasında negatif bir ilişki olduğunu ifade etmişlerdir [11].

Mutlu (2019) çalışmasında, Balıkesir il merkezinde bulunan toplam 24 kavşağı analiz ederek ve bu kavşaklardan geçen taşıt sayımları yaparak il merkezinde trafikten kaynaklanan hava kirliliği seviyelerini incelemiştir. Elde edilen veriler COPERT programı yardımı ile analiz edilerek, kirlenicilere ait trafik kaynaklı emisyonlar hesaplanmıştır [12].

Pimpin, Retat, Fecht, Preux, Sassi, Gulliver ve Webber (2018), İngiltere'deki ince partikül madde (PM_{2.5}) ve azot dioksit (NO₂) nedeniyle toplam sağlık ve ilgili Ulusal Sağlık Servisi (NHS) ve sosyal bakım maliyet yükünü ölçmektedir. Hava kirliliğine atfedilebilen yaklaşık 2.5 milyon koroner kalp hastası vakası, PM_{2.5} ve NO₂'nin mevcut seviyelerde kalması ve hava kirliliğini önemli bir halk sağlığı önceliği haline getirmesi durumunda 2035 yılına kadar tahmin edilmektedir [13].

Qiu, Tang, Lu, Huang ve Zhou (2018), 2014 yılında Wuhan'daki hava kirliliği kaynaklarının emisyon envanterine ve Wuhan'daki Kentsel Hava Kalitesi Uyum Planlamasının (2013-2017) verilerine göre bir İç İçe Hava Kalitesi Tahmin Modelleme Sistemi uygulanarak çevresel etki simülasyonu yapılmıştır [14].

Yücesan (2018) beyaz eşya sektöründe bulaşık makineleri, buzdolapları, küçük ev aletleri ve televizyonlar için çeşitli açıklayıcı değişken kullanarak satış tahmini modeli önermiş, en doğru tahminlerin, performans kriteri olan MSE karşılaştırıldığında YSA yöntemi kullanılarak elde edilmiştir [15].

Şahin (2018) YSA ile geleneksel tahmin yöntemlerinde ARIMA ile karşılaştırıldı. Çalışma örneklemini günlük kapanış fiyatları kullanılarak oluşturulmuştur. Bu çalışma sonucunda belli tarihler arasında yapay sinir ağları MPL (6-3-1) modeli ile tahmini fiyatların hem yönleri hem de değerleri, ARIMA (1.1.6) modelinden daha başarılı olmuştur [16].

Aydoğan ve Zırhhoğlu (2018) çalışmalarında, öğrencilerin başarı ölçülerini kestirebilen bir YSA'da bir modelin geliştirilmiştir. Sonucunda, Sınıflama (Kontenjans) Tabloları, Ki-kare testi, Basit Doğrusal Regresyon Analizi ve Korelasyon Analizi yöntemleri aracılığıyla doğrulanmış ve karşılaştırılmıştır. Bu sonuçlara

göre, kestirilen başarı ölçüleri ile gözlenen başarı ölçülerinin ve bu ölçülerle oluşan başarılı/başarısız şeklindeki başarı sınıflandırılmasının büyük oranda benzerlik gösterdiği görülmüştür [17].

Özden ve Öztürk (2018) zaman serileri ve YSA olmak üzere iki farklı yaklaşım kullanılarak Türkiye'deki bir endüstri bölgesi için enerji ihtiyaç tahmini üzerinde çalışılmış ve sonuçlar test edilmiştir. Daha önceki çalışmalardan farklı olarak, kısıtlı veri ile kısa dönem tahmini için basit bir model geliştirilmiştir. Zaman serileri yöntemi veri azlığı sebebiyle YSA'a göre daha kötü bir tahmin gerçekleştirmiştir [18].

Can ve Gerşil (2018) Manisa Tarım Borsasından yıllık pamuk fiyatlarını alarak zaman serisi ve YSA teknikleri kullanılarak 2017 yılına ait fiyatların değer tahminleri yapmışlardır. Yapılan tahminler MAD, MAPE ve RMSE değerleri üzerinden karşılaştırılarak YSA tekniğinin daha başarılı sonuçlar elde ettiği görülmüştür [19].

Taşar, Üneş, Demirci ve Kaya (2018) Cambridge Hazne ve havzası için buharlaşma miktarı tahmin edilmeye çalışmışlardır. YSA sonuçları, geleneksel Hargreaves-Samani, Ritchie ve Turc yöntemlerinin sonuçları ile karşılaştırılmıştır. Karşılaştırma, YSA modelinin buharlaşma miktarı tahmininde geleneksel yöntemlerden daha iyi performans ortaya koyduğu göstermiştir [20].

Feng, Chi, Wang, Li, Jiang ve Yang (2017), hava kirliliği modellerinin kritik bir bileşenini, sayısal olarak yapışkan kimyasal adi diferansiyel denklemlerle (ODE) Modified Backward-Euler (MBE), negatifliği korunmayan, verimli bir kimyasal çözücü MBE ile tasarlayıp, İç İç Hava Kalitesi Tahmin Modelleme Sistemine uygulayarak (NAQPMS) en popüler çözücü Adi Diferansiyel Denklemler için Livermore Çözücü (LSODE) arasında karşılaştırma yaparak, MBE'in hava kirliliği tahmini için daha iyi bir seçim olduğunu ortaya koymuşlardır [21].

Sammarco, Tse, Pau ve Marfía (2017), sosyal ağlarda coğrafi bir araştırmayı, yani hava kirliliği ile ilgili mesajlar hakkında bir jeososyal araştırmayı etkili hava kirliliği ölçümleri olarak kullanma fizibilitesini araştırmışlardır [22].

Miguel, de Blas ve Sipols (2017), kentsel yol fiyatlandırma sonuçlarının (Singapur, Londra, Stockholm ve Milano) yansıdığı gibi hava kirliliğini azaltmak için etkili bir araç olduğunu göstermek adına Madrid 'de varsayımsal bir kentsel yol fiyatlandırma sistemi kurulmasına dayalı bir anket yaparak sistemin hava kirliliğindeki bir azalmayı motive etme ve toplu taşıma kullanıcıları için daha sürdürülebilir bir davranış uygulama kapasitesinin yüksek olduğunu ortaya koymuşlardır [23].

Ekinci (2017), Hava kirliliğinin SO₂ (kükürtdioksit) konsantrasyonu üzerinden tahminleme modeli, Denizli il merkezinde 2005-2015 yılları arasında ölçülen SO₂, ve PM₁₀ konsantrasyonu ile sıcaklık, basınç, çiğ noktası,

rüzgar, yağmur gibi meteorolojik verilerle kurularak çok katmanlı sinir ağı ve çoklu doğrusal regresyon yöntemleri kullanılmıştır [24].

Özşahin, Eroğlu ve Pektezel (2016) Keşan şehrindeki hava kirliliğinin doğal ve beşeri coğrafya faktörleriyle ilişkisini araştırarak, kirliliğin neden ve sonuçları yorumlamışlardır. Sonucunda Keşan şehrindeki hava kirliliğinin kaynakları, kirliliğin azaltılması ve kontrol edilmesine yönelik önerilerde bulunmuşlardır [25].

Turgut ve Temiz (2015) çalışmalarında, PM₁₀ hava kirleticisi verilerine Box-Jenkins Metodolojisi uygulanarak zaman serileri analizi yapılmış ve PM₁₀ kirleticisinin gelecekte alacağı değerlerini tahmin etmişlerdir [26].

Kunt (2014), Konya ilindeki hava kirliliği seviyesinin tespiti ve insan sağlığına etki edecek konsantrasyonların tahminine yönelik SO₂ verileri ile meteorolojik veriler YSA ve Bulanık Mantık modelleri kullanılarak modellenmiştir [27].

Kaplan, Saray ve Azkeskin (2014) çalışmada, SO₂ ve PM₁₀ verileri kullanılarak YSA geri beslemeli ağ yapısı içinde Levenberg - Marquardt öğrenme algoritması ile tahminleme yapılmıştır [28].

Budak ve Erpolat (2012) bankaların kredi risklerini öngörmelerine yardımcı olması amacıyla, kredi talep eden müşterilerin ödeme alışkanlıklarının düzenli olup olmayacağını tahmin edilmesi için YSA ve lojistik regresyon analizi kullanılmışlardır. Çalışma sonucunda, YSA yönteminin müşterilerin ödeme alışkanlıklarının düzenli olup olmayacağını tahmin etme gücü lojistik regresyon modelinden daha üstün olduğu tespit edilmiştir [29].

Okkan ve Mollamahmutoğlu (2010) Gediz havzasında yer alan Yiğitler Çayına ait günlük akımların modellenmesi için kullanılacak bir YSA modeli hazırlanmış, modeli çoklu doğrusal regresyon modeli ile karşılaştırarak, YSA algoritması performansı regresyon modeline göre daha başarılı bulunmuştur [30].

Tolon ve Tosunoğlu (2008) YSA ile tatmin araştırmalarında sıklıkla kullanılan regresyon yöntemi ele alarak ve Ankamall müşterilerine yapılan uygulamayı karşılaştırmalı olarak analiz etmişlerdir [31].

Doğan ve Kitapçioğlu (2007) İzmir ilinde belirli bir zaman dilimindeki hava kirliliğini değerlendirmek ve hava kirliliği ölçümü ile ilgili olarak yapılan değişiklikler ile hava kirliliği değerleri arasındaki ilişkiler zaman serisi analizi ile analiz edilerek istatistiksel olarak anlamlı olduğu saptamışlardır [32].

Kunt (2007), Konya ilini ele alınarak YSA modelleri ile bazı meteorolojik parametreler kullanılarak hava kirliliği üzerine tahminleme çalışması yapmıştır [33].

Yapılan literatür araştırması sonrasında YSA ve regresyon analizi ile tahminleme üzerine pek çok farklı alan ve sektörde, farklı metot ve programlarla birlikte

yapılan çalışma olduğu görülmüştür. Bunlara elektrik enerjisi ihtiyacı, yemek talebi, farklı sektörlerde satış tahminleri, bölgesel olarak buharlaşma miktarı, tarımda pamuk fiyatları ve öğrencilerin başarı ölçüleri tahminleri gibi örnekler verilebilir. Hava kirliliği özelinde yapılan çalışmalara bakıldığında ise yatırım analistlerinin hava kirliliği ile müteakip kazanç tahminleri, lokal olarak bir ilde bulunan kavşak için taşıt sayısı ve taşıtların emisyon miktarları ile hava kirliliği seviyelerinin belirlenmesi, sosyal ağlarda yapılan paylaşımların hava kirliliği ile ilişkilendirilmesi, hava kirliliğinin sebep olabileceği hastalığa sahip hasta sayısı ile hava kirliliğinin ilişkilendirilmesi, tek parametre, meteorolojik veya topoğrafik parametreler ile hava kirliliğinin ölçülmesi ve tahminleme yapılması gibi birden fazla çalışma olduğu görülmüştür. Bu çalışmada ise hava kirliliğini arttıran veya azaltan beşeri parametreler ile hava kirliliğinin ilişkilendirilmesi ve tahmini yapılmıştır.

2. Malzeme ve Yöntem

Çalışmanın bu kısmında YSA ve regresyon analizi konuları kısaca açıklanmıştır.

2.1. Yapay Sinir Ağları

YSA, sinir hücrelerinden esinlenerek nöron yapısı dikkate alınarak modellenen ve zamanla kendi kendine öğrenme yeteneği olan bir metottur. YSA insan beyni gibi davranış farklılaştırma yöntemiyle yeni bilgiler üretebilme ve keşfedebilme gibi kabiliyetleri, yardım almadan kendiliğinden gelişen ve değişen makine öğrenmesi yöntemidir [34]. YSA'nın işleyişini esas teşkil eden en küçük yapılar yapay sinir hücresi veya işlem elemanı olarak adlandırılır. Şekil 1'de yapay sinir hücresinin yapısı gösterilmiştir. En basit yapay sinir hücresi şekil 2' de görüldüğü üzere YSA modelini giriş katmanı, gizli katman ve çıktı katmanı oluşturmaktadır. Gizli katman sayısı ve nöron sayıları yapılan çalışmalarda denemeler sonucu bulunabilir. Giriş katmanından herhangi işlem yapılmadan geçen veriler gizli katman ve çıkış katmanında bağlantıların ağırlık değerleri oranında çarpılarak gele veriler toplanır ve transfer fonksiyonuna aktarılır [35]. Çok katmanlı YSA sınıflandırma problemlerini çözmek için kullanılır. Sadece doğrusal problemlerin çözümünde tek nöron yeterli olabilir.

Şekil 2 incelendiğinde bir YSA modelinde katmanların dışında; girdiler, ağırlıklar, net fonksiyonu, aktivasyon fonksiyonu ve çıktılar olmak üzere 5 temel elemanın varlığı göze çarpmaktadır. Ağın girdi ve çıktı tabakasında probleme ait veriler bulunmaktadır. Girdi ve çıktı

tabakalarındaki hücre sayıları problemde tanımlanan bilgilere bağlı değişkenlik göstermektedir. Girdi tabakasındaki bilgilerin sistem içindeki etkinlikleri ve önemi ise ağırlıklarla sağlanmaktadır. Bilgi, bu ağırlıklarda saklanmakta olup; ağırlık zekâsı ve öğrenme performansı ağırlık değerlerinin doğru belirlenmesine bağlı olmaktadır. Ağırlıklı girdilerin toplamı olarak bulunan net fonksiyonu ile ise girdilerin bu hücre üzerindeki etkileri ifade edilmektedir.

2.2. Regresyon Analizi

Regresyon, istatistikte iki ya da daha çok değişken arasındaki ilişkinin modellenmesinde kullanılan bir tekniktir. Regresyon analizinde bağımlı değişken (açıklanan değişken, cevap değişkeni) Y ile, bağımsız değişkenler (açıklayıcı değişkenler) ise X_j ($j=1, \dots, m$) ile gösterilir. Burada amaç, bağımlı değişken ile bir ya da birden çok bağımsız değişken arasında kurulan modeldeki parametreleri tahmin ederek, bağımsız değişkenlerin bilinen değerleri için bağımlı değişkenin alacağı değeri tahmin etmektir. Yani bağımlı değişken ile bağımsız değişkenler arasındaki ilişki yapısını belirlemektir.


Y bağımlı değişkenini etkileyen m tane bağımsız değişken X_1, X_2, \dots, X_m olmak üzere çoklu regresyon modeli,

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_m X_m + \varepsilon \quad (1)$$

olarak tanımlanır. Burada β_0 ve β_j ($j=1, \dots, m$) parametreleri, X_i ($i \neq j$) bağımsız değişkenleri sabit tutulduğunda X_j 'deki bir birimlik değişim Y bağımlı değişkeni için beklenen değişim miktarını veren regresyon katsayıları ve ε hata terimidir. Model tahmininde amaç ε hata terimini minimum yapacak şekilde β_0 ve β_j katsayılarını tahmin etmektir.

Regresyon modelleri, tek tabakalı bir sinir ağı yapısına benzetilebilir. Bağımsız değişkenler sinir ağlarındaki girdilere, bağımlı değişken çıktılarına, β_j katsayıları da sinir ağlarındaki ağırlıklara dönüştürülebilir.

Katsayıları bulmak için, deney ve gözlemler yapılarak veri setinin oluşturulması gerekir. Bu, sinir ağlarında danışmanlı öğrenme süreci üzerindeki eğitim setine benzemektedir. Regresyon analizinde β_0 ve β_j katsayılarının bulunması amaçlanmıştır. YSA yaklaşımı, bir regresyon problemi gibi ele alındığında, burada da amaç, ağırlık katsayılarının bulunması olacaktır. YSA üzerindeki ağırlıkların bulunmasında geri yayılım algoritması kullanılabilir [31].




Şekil 1. Yapay sinir hücresi

3. Uygulama

Çalışma, hava kirliliğini ölçmek üzere 2012-2019 yılları arasındaki zaman diliminde Türkiye’de bulunan 31 il için yapılmıştır. Seçilen 31 il kullanılacak veriler açısından eksiksiz olduğu için seçilmiştir. İlk olarak hava kirliliği tespitinde kullanılacak olan PM10 değerleri TÜİK’den elde edilerek bağımlı değişken olarak tanımlanmıştır. Daha önceki çalışmalarda, hızlı nüfus artışının ve plansız kentleşmenin, yakıt tüketiminin, sanayi (endüstri) tesislerinin ve motorlu araçların hava kirliliğine yol açtığı tespit edilmiştir [36]. Ve bu görüş referans alınarak bağımlı değişken üzerinde etkisi olabileceği düşünülen “Nüfus sayısı”, “Taşıt sayısı”, “Orman ve Yarı Doğal Alan Miktarı”, “Sanayi Sitesinde Bulunan İşyeri Sayısı” ve “Termik Santral Katsayısı” bağımsız değişkenler olarak seçilmiştir. Nüfus sayısı, Taşıt sayısı, Orman ve Yarı Doğal Alan Miktarı değerlerinin verileri TÜİK’ten elde edilerek eksik yıllar ve değerler için Excel’in zaman serileri ile tahminleme özelliği kullanılarak oluşturulmuştur. Sanayi Sitesinde Bulunan İşyeri Sayısı değişkeni için eksik yılların tahmini Türkiye’nin büyüme oranları göz önüne alınıp hesaplandı. Termik Santral Katsayısı değişkeni için ise Türkiye’deki 27 termik santralin kurulu güçleri bulunup, bu santrallerin işlem yapılan ile olan uzaklığı ayrı ayrı tespit edilmiştir. Termik santrallerin kurulu güçleri tespit edilen uzaklıklara bölünmüş, bu değerler toplanarak işlem yapılan il için katsayı belirlenmiştir. Yıl bazlı değişen kurulu güçler göz önünde bulundurularak bu hesaplama 5 yıl ve 31 il için tekrarlanmıştır. Burada santral kurulu gücünün hava kirliliğini arttırdığı, ile olan mesafesinin ise azaltıcı etkide olduğu düşünülerek bu formül oluşturulmuştur [37]. Bağımsız değişkenler sırayla X_1 , X_2 , X_3 , X_4 ve X_5 olarak tanımlanmıştır. Ve bu veriler Excel’de Tablo 3’teki gibi düzenlenerek bir tablo haline getirilmiştir. Excel’de oluşturulan tabloda toplamda 186 satırlık veri olduğu için tablonun 2017 yılı verilerinin olduğu kısmı çalışmaya konulmuştur.

Regresyon ve YSA yöntemlerini karşılaştırmak için oluşturulan genel tablodan yararlanarak 2012-2018 yılları



Şekil 2. Çok tabakalı sinir ağı yapısı

arasındaki veriler seçilerek Excel’de bulunan “Veri analizi” komutu ile bulunan regresyon analizi seçeneği işaretlenerek regresyon katsayıları bulunmuştur. Bu işlem 4 değişken ve 5 değişken için ayrı ayrı yapılmıştır. Bu katsayıların değerleri Tablo 1 ve Tablo 2’de görülmektedir.

Tablo 1. 2018 yılı 4 değişken için yapılan regresyon analizi

	<i>Coefficients</i>	<i>Significance F</i>
Intercept	62,847838	0,0000005
X Variable 1	0,000027	
X Variable 2	0,0000002	
X Variable 3	-0,000017	
X Variable 4	0,001163	

Tablo 1’deki katsayılar kullanılarak 4 değişken için regresyon denklemi Eş. (2)’deki gibi oluşturulmuştur.

$$Y = 62,848 + X_1 * 0,0000274 + (X_2 * 0,000000249) + (X_3 * -0,000017) + (X_4 * 0,00116) \quad (2)$$

Eş. (2)’deki denklemde X_1 , X_2 ve X_4 bağımsız değişkenleri hava kirliliğini arttırıcı yöndeyken X_3 bağımsız değişkeni azaltıcı yöndedir. Sigma değerinden de regresyon katsayılarımızın (0,05’in altında) anlamlı olduğu görülmüştür.

Tablo 2. 2018 yılı 5 değişken için yapılan regresyon analizi

	<i>Coefficients</i>	<i>Significance F</i>
Intercept	52,759682	0,0000001
X Variable 1	0,000013	
X Variable 2	0,000003	
X Variable 3	-0,000015	
X Variable 4	0,001055	
X Variable 5	0,286256	

Tablo 2’deki katsayılar kullanılarak 5 değişken için regresyon denklemi Eş. (3)’teki gibi oluşturulmuştur.

$$Y = 52,759 + (X_1 * 0,0000129) + (X_2 * 0,00000294) + (X_3 * -0,0000145) + (X_4 * 0,00106) + (X_5 * 0,286) \quad (3)$$

Eş. (3)'teki denklemde de X_1 , X_2 , X_4 ve X_5 bağımsız değişkenleri hava kirliliğini arttırıcı yönde X_3 bağımsız değişkeni azaltıcı yöndedir. Sigma değerinden de


regresyon katsayılarımızın (0,05'in altında) anlamlı olduğu görülmüştür.

Bu denklemler kullanılarak 2018 yılı için regresyon modeli oluşturulmuştur. Oluşturulan regresyon modeli ile 2018 yılı PM10 için tahminleme yapılmıştır.


Tablo 3. Bağımsız ve bağımlı verilerin genel tablosunun excelde 2017 yılı için gösterilmesi

İller	Yıllar	Hava Kirliliği Değeri ($\mu\text{g}/\text{m}^3$) (1 saatlik)	Taşıt Sayısı (X_1)	Nüfus Sayısı (X_2)	Orman ve Yarı Doğal Alan Miktarı (X_3)	Sanayi Sitesinde Bulunan İşyeri Sayısı (X_4)	Termik Santral Katsayısı (X_5)
Adana	2017	62,00	614643	2216475	640031,20	1910	50,126
Adıyaman	2017	51,00	96191	615076	304913,92	912	33,203
Afyon	2017	82,00	208820	715693	637034,67	2536	42,573
Ağrı	2017	59,00	32524	536285	604552,71	612	16,288
Antalya	2017	51,00	980028	2364396	1457995,58	2169	29,286
Artvin	2017	24,00	35666	166143	642534,51	316	16,406
Aydın	2017	45,00	414296	1080839	378829,43	1476	45,871
Batman	2017	63,00	43425	585252	236389,70	400	21,205
Çanakkale	2017	26,00	211823	530417	525559,49	825	59,985
Çorum	2017	61,00	163806	528422	569668,55	1511	31,492
Denizli	2017	75,00	377025	1018735	656343,78	727	39,113
Diyarbakır	2017	49,00	120249	1699901	545898,22	1519	24,024
Elazığ	2017	61,00	112478	583671	570371,72	1251	29,747
Erzurum	2017	45,00	112904	760476	1696123,77	1154	19,219
Gaziantep	2017	54,00	471360	2005515	216584,69	4211	38,142
Hatay	2017	73,00	455684	1575226	231856,01	1829	50,564
Kahramanmaraş	2017	60,00	211806	1127623	897226,69	2168	46,127
Kayseri	2017	79,00	347919	1376722	742305,54	1610	40,257
Kocaeli	2017	55,00	361414	1883270	144707,43	960	55,141
Kütahya	2017	65,00	201824	572256	628586,66	817	68,558
Malatya	2017	53,00	156713	786676	757246,55	1246	40,488
Manisa	2017	77,00	554152	1413041	581739,18	2687	54,844
Mardin	2017	63,00	73545	809719	398722,99	544	22,253
Mersin	2017	72,00	568484	1793931	1051455,29	1814	36,522
Muğla	2017	67,00	457494	938751	929559,63	587	58,120
Sakarya	2017	63,00	265452	990214	195770,03	752	53,278
Sivas	2017	53,00	150197	621301	1677747,94	1348	36,660
Şanlıurfa	2017	73,00	252616	1985753	483765,92	1379	29,818
Tokat	2017	45,00	165091	602086	570530,36	1348	31,327
Trabzon	2017	62,00	174422	786326	268444,71	850	19,616
Van	2017	41,00	77930	1106891	1256636,93	1141	15,978

YSA ile 2018 yılı için tahminlemede Matlab2020a'da bağımsız değişkenler input (girdi) olarak, bağımlı değişken ise output (çıkıtı) olarak tanımlanmıştır. 2012-2018 yılları arasındaki veriler eğitim verisi, elimizde bulunan 2018 yılındaki gerçek verilerin bağımsız değişken değerleri test verisi olarak seçilip, Nntools modülü kullanılarak yapay sinir ağı oluşturulmuştur. Bu işlem 4 ve 5 bağımsız değişken için ayrı ayrı gerçekleştirilmiştir. Şekil 3'te 2018 yılı 4 değişken için Şekil 4'te de 2018 yılı 5 değişken için ağ modelinin yapısı gösterilmektedir.




Şekil 3. 2018 yılı 4 değişken için oluşturulan YSA yapısı




Şekil 4. 2018 yılı 5 değişken için oluşturulan YSA yapısı

Model oluşturulduktan sonra iterasyon sayısı güvenilirliğin artması için diğer çalışmalar dikkate alınarak ortalama bir iterasyon sayısı olan 10000 yapılarak değişken sayısı 4 ve 5 için sırasıyla Şekil 5 ve Şekil 6'da görüldüğü gibi eğitilir.



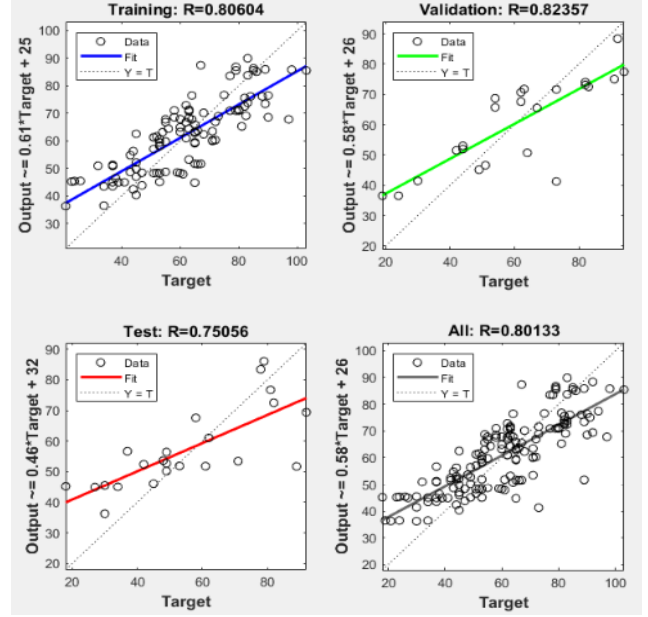
Şekil 5. Verilerin eğitilmesi (4 değişken)



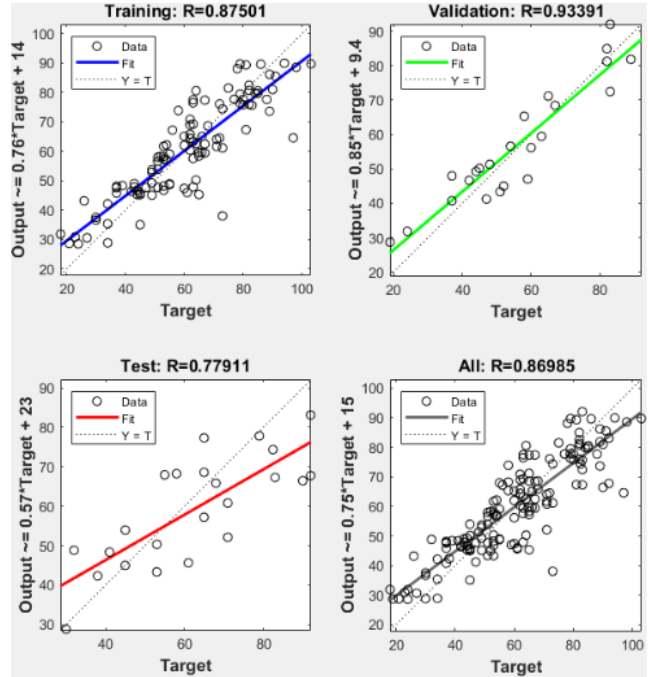
Şekil 6. Verilerin eğitilmesi (5 değişken)

Bu işlem bitince regresyon analizi yapılır. Şekil 7 ve Şekil 8'de bulunan regresyon analizleri sonuç grafiklerinde sırasıyla Training 0,806 ve 0,875 değerleriyle görüyoruz ki eğitimler yaklaşık %80 ve %87 oranında başarıyla tamamlanmıştır. All R değerleri için baktığımızda; data olarak gösterilen noktalar bizim bağımlı değişken verilerimizi ifade etmektedir. X eksenindeki Target değerlerin (bağımlı değişken değerleri) 60-100 aralığında tahminlenen değerlerden sapmasının daha fazla olduğu görülmüştür. Ayrıca $Y=T$ çizgisi tahminlenen değerleri gösterdiği için YSA'da tahminleme işleminin yüksek oranda doğruya yakın sonuçlar verdiğini görüyoruz. Eğer eğitim sayısı arttırılırsa YSA'nın öğrenmesinin arttığı ve

gerçeğe yakın sonuçlar verdiği de görülmüştür.



Şekil 7. 2018 yılı 4 değişken için YSA'da regresyon analizi



Şekil 8. 2018 yılı 5 değişken için YSA'da regresyon analizi

Daha sonra test verileri simule edilerek ağıın daha önce görmediği 2018 yılı için 4 ve 5 değişken için tahmini 2018 değerleri bulunmuştur. Regresyon analizi ve YSA için, 2018 yılı 4 ve 5 değişken için tahmini değerler ve gerçek veriler Tablo 4'te görülmektedir.

Tablo 4. 31 il için regresyon analizi ve YSA 2018 yılı tahmini değerleri

İller	Yıllar	Hava Kirliliği Değeri($\mu\text{g}/\text{m}^3$) (1 saatlik)	YSA ile Tahmin-4 Değişken	YSA ile Tahmin-5 Değişken	Regresyon ile Tahmin-4 Değişken	Regresyon ile Tahmin-5 Değişken
Adana	2018	61,00	61,41	60,72	72,19	74,63
Adıyaman	2018	46,00	53,43	55,78	61,51	61,88
Afyon	2018	74,00	84,76	77,69	60,88	63,28
Ağrı	2018	56,00	59,17	48,85	54,24	51,29
Antalya	2018	47,00	54,20	64,04	69,22	62,68
Artvin	2018	24,00	32,42	29,18	53,37	49,52
Aydın	2018	38,00	41,88	48,70	70,26	70,93
Batman	2018	45,00	71,55	70,64	60,65	58,19
Çanakkale	2018	37,55	33,17	50,77	61,07	69,17
Çorum	2018	53,00	45,35	40,81	59,53	58,81
Denizli	2018	74,00	84,15	82,80	63,63	63,52
Diyarbakır	2018	40,00	66,63	45,20	59,00	59,93
Elazığ	2018	60,00	44,12	43,42	57,90	57,56
Erzurum	2018	41,00	42,98	50,76	38,70	38,63
Gaziantep	2018	42,00	60,25	51,78	77,84	77,14
Hatay	2018	26,00	51,35	71,19	74,30	76,58
Kahramanmaraş	2018	125,00	64,11	56,44	56,44	61,44
Kayseri	2018	69,00	88,14	88,27	62,25	63,90
Kocaeli	2018	54,81	53,30	56,69	72,38	78,20
Kütahya	2018	80,00	67,18	76,66	58,81	68,59
Malatya	2018	60,00	63,48	47,19	56,08	59,13
Manisa	2018	94,00	78,16	80,39	72,02	74,64
Mardin	2018	56,00	75,12	78,48	58,96	57,37
Mersin	2018	84,00	60,00	67,76	63,68	62,81
Muğla	2018	73,00	61,34	79,79	61,14	65,75
Sakarya	2018	59,31	56,68	58,69	68,31	72,76
Sivas	2018	56,00	42,84	46,42	40,17	44,16
Şanlıurfa	2018	60,00	56,59	31,60	63,66	65,00
Tokat	2018	36,00	48,22	42,20	59,43	58,82
Trabzon	2018	42,00	53,18	62,70	64,55	60,19
Van	2018	43,00	49,21	53,96	45,25	44,66

Model ölçüm kriterleri, (MAD, MAPE, MSE, RMSE) tahminlenen değer ile gözlem değeri arasındaki farkı hesaplamak için kullanılmaktadır. Tahminlenen modelin ne kadar başarılı olduğunu test edebilmek için genellikle bu kriterler temel alınmaktadır [38].

Tablo 4'teki değerlerin 4 ve 5 değişken, 31 il için tümü kullanılarak MAD değerleri Eş. (4)'te, MAPE değerleri Eş. (5)'te, MSE Eş. (6)'te ve RMSE Eş. (7)'teki gibi hesaplanıp Tablo 5'teki hata oranları elde edilmiştir.

$$MAD = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{n}, (y_i \neq 0) \quad (4)$$

$$MAPE = \frac{\sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i}}{n} \times 100, (y_i \neq 0) \quad (5)$$

$$MSE = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n} \quad (6)$$

$$RMSE = \sqrt{MSE} \quad (7)$$

Burada, n gözlem sayısı, y_i gözlem değeri, \hat{y}_i tahminlenen değeri göstermektedir [39].

Tablo 5. Değişken sayısı ve yöntemsel olarak hata oranları

	YSA ile Tahmin-4 Değişken	YSA ile Tahmin-5 Değişken	Regresyon ile Tahmin-4 Değişken	Regresyon ile Tahmin-5 Değişken
MAPE	23,886	27,953	37,138	36,135
MAD	12,754	14,246	17,447	16,680
MSE	297,784	384,584	511,167	480,603
RMSE	17,256	19,611	22,609	21,923

Tablo 5'teki değerlere bakıldığında değişken sayısı farketmeksizin YSA değerlerinin daha düşük olduğu görülüyor. MAPE değeri düşük olan YSA yönteminin 4 değişkenli olan modeli daha iyi uyum sağlayan model olarak seçilmiştir. Daha sonra 2019 PM10 değerleri, bu kez 2012-2019 yılları arasındaki veriler kullanılarak YSA ile 2019 yılı tahmin değerleri Tablo 6'daki gibi bulunmuştur.

Tablo 6. 31 il için 5 değişken için YSA ile bulunan 2019 tahmin değerleri

İller	Tahmini 2019 PM10 Değerleri
Adana	52,06
Adıyaman	61,06
Afyon	70,90
Ağrı	40,65
Antalya	62,51
Artvin	36,21
Aydın	68,78
Batman	60,73
Çanakkale	56,20
Çorum	54,15
Denizli	73,52
Diyarbakır	61,59
Elazığ	51,38
Erzurum	38,39
Gaziantep	59,93
Hatay	63,20
Kahramanmaraş	74,56
Kayseri	90,20
Kocaeli	62,33
Kütahya	51,48
Malatya	61,69
Manisa	88,18
Mardin	56,37
Mersin	65,37
Muğla	77,15
Sakarya	62,77
Sivas	42,35
Şanlıurfa	56,19
Tokat	55,45
Trabzon	63,94
Van	44,99

4. Sonuçlar

Hava kirliliğinin insan hayatı üzerine olumsuz etkileri yadsınamaz bir gerçektir. İnsanların hayat kalitesini etkileyen bu durum için DSÖ tarafından PM10 değerlerinin ölçüldüğünde, hava kirliliği üzerine bir yorum getirilebilecek bir parametre olduğu belirtilmiştir.

Bu çalışmada, Türkiye'de seçilen 31 ilin hava kirliliği ölçümünde kullanılan PM10 değerleri üzerine regresyon ve YSA modeli uygulanmıştır. YSA'nın birçok modeli arasından, çokça kullanılan ve ortaya başarılı sonuçlar çıkaran bir model olması sebebiyle de ileri beslemeli geri yayımlı yapay sinir ağı kullanılmıştır. Yapılan hazırlık aşamasına göre, PM10 değeri, daha önceki çalışmalar referans alınarak ve üzerinde etkili olduğu düşünülen "Nüfus sayısı", "Taşıt sayısı", "Orman ve Yarı Doğal Alan Miktarı", "Sanayi Sitesinde Bulunan İşyeri Sayısı" ve "Termik Santral Katsayısı" değişkenler kümesi olarak 2 model için kullanılmıştır. Regresyon modeli ve YSA modellerinin sonuçları karşılaştırılmış ayrıca değişken sayısının değişmesinin nasıl bir farklılık ortaya çıkardığı araştırılmıştır.

En iyi uyumu veren modelin belirlenmesinde MAPE değerleri dikkate alınmıştır. Buna göre düşük MAPE değerine sahip model iyi model olarak dikkate alınmıştır. Çalışmada elde edilen performans değerlerine göre YSA modelinin regresyon analizinden daha etkin bir performans gösterdiği görülmektedir. Değişken sayısının artması regresyon analizinde modelin daha iyi olmasını sağlarken YSA'da modelin doğruluğunu düşürmüştür. Bu sonuç ile, YSA'nın regresyon analizine göre yüksek bir öngörü sağladığını ve daha az hataya sahip sonuçlar verdiği görülmektedir. Bu sebeple 2019 yılı için PM10 değerlerinin tahmini YSA'nın 4 değişkenli modeli ile yapılarak öngörülebilir bulunulup PM10 değerlerinin azaltılması üzerine çalışmaların yapılmasının gerekliliği ortaya konmuştur.

Çalışmada kurulan modelin yetersizlikleri, değişkenlerdeki eksik verilerin gerçek değerleri bulunup tamamlanarak, bağımsız değişkenlerin sayısı artırılarak, daha geniş zaman diliminde yapılarak geliştirilebilir. Bundan sonraki çalışmalarda, farklı sektör ve çalışma gruplarından toplanan; zaman, bağımlı değişken, bağımsız değişken vb. açıdan geniş ölçekli veriler ile tahmin araştırmalarında kullanılan diğer metotlarla YSA metodu karşılaştırmalı uygulamasının, regresyon analizinin etkinliğinin belirlenmesinde literatüre katkı sağlayacağı düşünülmektedir.

Kaynaklar

- [1] Air Quality Guidelines For Europe. World Health Organization Regular Office for Europe Copenhagen. Second Edition: WHO Regional Publications, European Series. No:1. <http://www.euro.who.int/document/e87950.pdf>
- [2] World Health Organization, 1972. Health Hazards of the Human Environment.
- [3] World Health Organization, 1987. Air Quality Guidelines For Europe.
- [4] Holman C., 1989. Air pollution and health. Friends Of The Earth, London.
- [5] Bayram, H., 2005. Türkiye’de Hava Kirliliği Sorunu: Nedenleri, Alınan Önlemler ve Mevcut Durum. Toraks Dergisi, 6, 159-165.
- [6] Başar P., Okyay P., Ergin F., Coşan S., Yıldız A., 2005. Aydın ili kent merkezinde hava kirliliği/1997-2004.
- [7] Elbir T., Müezzinoğlu A., Bayram A., 2000. Evaluation of some air pollution indicators in Turkey. Environment International 26, 5-10.
- [8] Sezer M. S., 2019. Yapay sinir ağları ve farklı tahmin yöntemleri ile uzun dönem yük tahmini: Zonguldak örneği, Yüksek Lisans Tezi, Kütahya Dumlupınar Üniversitesi, Fen Bilimleri Enstitüsü, Kütahya, Türkiye, 563912.
- [9] Calp, M. H., 2019. İşletmeler için personel yemek talep miktarının yapay sinir ağları kullanılarak tahmin edilmesi. Politeknik dergisi, 22, 675-686.
- [10] Sönmez O., Zengin K., 2019. Yiyecek ve İçecek İşletmelerinde Talep Tahmini: Yapay Sinir Ağları ve Regresyon Yöntemleriyle Bir Karşılaştırma. Avrupa Bilim ve Teknoloji Dergisi, Özel Sayı, 302-308.
- [11] Dong R., Fisman R., Wang Y., ve Xu N., 2019. Air pollution, affect, and forecasting bias: Evidence from Chinese financial analysts. Journal of Financial Economics, 134, 501-760.
- [12] Mutlu A., 2019. Balıkesir şehir merkezinde trafik kaynaklı hava kirliliği seviyelerinin analizi. Balıkesir Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 21, 152-168.
- [13] Pimpin L., Retat L., Fecht D., de Preux L., Sassi F., Gulliver J., ve Webber L., 2018. Estimating the costs of air pollution to the National Health Service and social care: An assessment and forecast up to 2035. PLoS medicine, 15.
- [14] Qiu P., Tang X., Lu M., Huang Y. ve Zhou J., 2018. Forecast of changing air pollution trends in Wuhan city. Nanjing Xinxing Gongcheng Daxue Xuebao, 10, 571-578.
- [15] Yücesan M., 2018. YSA, ARIMA ve ARIMAX Yöntemleriyle Satış Tahmini: Beyaz Eşya Sektöründe bir Uygulama. İşletme Araştırmaları Dergisi 10, 689-706.
- [16] Şahin E. E., 2018. Kripto Para Bitcoin: ARIMA ve Yapay Sinir Ağları İle Fiyat Tahmini. Fiscoeconomia 2, 74-92.
- [17] Aydoğan İ., Zirhlioğlu G., 2018. Öğrenci Başarılarının Yapay Sinir Ağları ile Kestirilmesi. Yüzüncü Yıl Üniversitesi Eğitim Fakültesi Dergisi, 15, 577-610.
- [18] Özden S., Öztürk A., 2018. Yapay sinir ağları ve zaman serileri yöntemi ile bir endüstri alanının (ivedik OSB) elektrik enerjisi ihtiyaç tahmini. Bilişim Teknolojileri Dergisi, 11, 255-261.
- [19] Can Ş., Gerşil M., 2018. Manisa Pamuk Fiyatlarının Zaman Serisi Analizi ve Yapay Sinir Ağı Teknikleri İle Tahminlenmesi ve Tahmin Performanslarının Karşılaştırılması. Yönetim ve Ekonomi: Celal Bayar Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 25, 1017-1031.
- [20] Taşar B., Üneş F., Demirci M., Kaya Y. Z., 2018. Yapay sinir ağları yöntemi kullanılarak buharlaşma miktarı tahmini. DÜMF Mühendislik Dergisi, 9, 543-551.
- [21] Feng F., Chi X., Wang Z., Li J., Jiang J. ve Yang W., 2017. A nonnegativity preserved efficient chemical solver applied to the air pollution forecast. Applied Mathematics and Computation, 314, 44-57.
- [22] Sammarco M., Tse R., Pau G. ve Marfia G., 2017. Using geosocial search for urban air pollution monitoring. Pervasive and Mobile Computing, 35, 15-31.
- [23] Miguel J. P. M., de Blas C. S. ve Sipols A. E. G., 2017. A forecast air pollution model applied to a hypothetical urban road pricing scheme: An empirical study in Madrid. Transportation Research Part D: Transport and Environment, 55, 21-38.
- [24] Ekinci M. E., 2017. Destek vektör regresyon ile hava kirliliği tahmini, Yüksek Lisans Tezi, Eskişehir Osmangazi Üniversitesi, Fen Bilimleri Enstitüsü, Eskişehir, Türkiye, 463905.
- [25] Özşahin E., Eroğlu İ., Pektez H., 2016. Keşan’da (Edirne) hava kirliliği. Selçuk Üniversitesi Sosyal Bilimler Enstitüsü Dergisi, 36, 83-100.

- [26] Turgut D. ve Temiz İ., 2015. Ankara'daki Hava Kirliliği İçin Zaman Serileri Analizi ve Tahmin: Box-Jenkins Yaklaşımı. *Alphanumeric Journal*, 3, 131-138.
- [27] Kunt F., 2014. Bulanık mantık ve yapay sinir ağları yöntemleri kullanılarak Konya il merkezi hava kirliliği modellenmesi, Doktora Tezi, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Konya, Türkiye, 380834 .
- [28] Kaplan Y., Saray U. ve Azkeskin E., 2014. Hava Kirliliğine Neden Olan PM10 ve SO₂ Maddesinin Yapay Sinir Ağı Kullanılarak Tahmininin Yapılması ve Hata Oranının Hesaplanması. *Afyon Kocatepe University Journal of Science & Engineering*, 14, 1-6.
- [29] Budak H., Erpolat S., 2012. Kredi Riski Tahmininde Yapay Sinir Ağları ve Lojistik Regresyon Analizi Karşılaştırılması. *AJIT-e: Online Academic Journal of Information Technology*, 3, 23-30.
- [30] Okkan U., Mollamahmutoğlu A., 2010. Yiğitler Çayı Günlük Akımlarının Yapay Sinir Ağları Ve Regresyon Analizi İle Modellenmesi. *Dumlupınar Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 23, 33-48.
- [31] Tolon M., Tosunoğlu N. G., 2008. Tüketici tatmini verilerinin analizi: yapay sinir ağları ve regresyon analizi karşılaştırması. *Gazi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 10, 247-259.
- [32] Doğan F., Kitapçıoğlu G., 2007. İzmir ilinde hava kirliliğinin yıllar itibariyle karşılaştırılması. *Ege Tıp Dergisi*, 46, 129-133.
- [33] Kunt F., 2007. Hava kirliliğinin yapay sinir ağları yöntemiyle modellenmesi ve tahmini, Doktora Tezi, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Konya, Türkiye, 212442.
- [34] Chehreh C. S., James C. H., Jorjani E., Mesroghli S., Bagherieh A. H., 2008. Prediction of coal grindability based on petrography, proximate and ultimate analysis using multiple regression and artificial neural network models. *Fuel Processing Technology*, 89,13-20.
- [35] Yongjae K., Sehun R., 2005. Arc sensor model using multiple-regression analysis and a neural network. *ProQ. Sci. J.*, 219, 431-447.
- [36] Özdemir M. A. ve Boyraz Z., 2002. Elazığ Şehir Merkezinde Hava Kirliliğini Doğuran Nedenler ve Kirlilik Parametrelerinin Zaman İçindeki Değişimine Coğrafi Yaklaşım. *Doğu Coğrafya Dergisi*, 7, 163-182.
- [37] http://sertifika.tema.org.tr/_Ki/CevreKutuphanesi/documents/Termik_Santrallerin_Hava_Kirliligi_Modellemesi.pdf (Erişim Tarihi: 22 Nisan 2020)
- [38] Wheelwright S., Makridakis S. ve Hyndman R. J., 1998. *Forecasting: methods and applications*. John Wiley & Sons, USA.
- [39] Bolzan A. C., Machado R. A. F. ve Piaia J. C. Z., 2008. Egg hatchability prediction by multiple linear regression and artificial neural networks. *Brazilian Journal of Poultry Science*, 10, 97-102.
- [40] <https://cevreselegostergeler.csb.gov.tr/illerin-cevre-gostergeleri-i-85803> (Erişim Tarihi: 22 Nisan 2020)
- [41] <https://evds2.tcmb.gov.tr/index.php?> (Erişim Tarihi: 22 Nisan 2020)