



Yüzüncü Yıl Üniversitesi Fen Bilimleri Enstitüsü Dergisi

<https://dergipark.org.tr/tr/pub/yyufbed>



Araştırma Makalesi

Ampirik Mod Ayrıştırmasına Dayalı ARIMA Modeli Kullanılarak Van İli Hava Kirliliğinin Tahmini

Erdoğan ALADAĞ

Van Yüzüncü Yıl Üniversitesi, Mühendislik Fakültesi, Çevre Mühendisliği Bölümü, 65080, Van, Türkiye
Erdoğan ALADAĞ, ORCID No: 0000-0003-1354-0930
Sorumlu yazar e-posta: erdinicaladag@gmail.com

Makale Bilgileri

Geliş: 17.12.2022
Kabul: 01.02.2023
Online Ağustos 2023

DOI:10.53433/yyufbed.1220578

Anahtar Kelimeler

ARIMA,
DES,
EMD-ARIMA,
PM₁₀,
SO₂,
Van

Öz: Hava kirliliği, yaşam kalitesini doğrudan tehdit eden ana unsurlardan birisidir. Hava kirlenmelerindeki değişimlerin öngörülmesi, hava kirliliği kontrolünde ve yönetiminde önemli bir role sahiptir. Günümüzde kullanılan Çift Üstel Düzeltme (DES) ve Bütünleşik Otoregresif Hareketli Ortalama (ARIMA) gibi geleneksel yöntemler, hava kirliliğinin tahmin edilmesinde çoğu zaman yetersiz kalmaktadır. Bu nedenle, hava kalitesinin belirlenebilmesi için daha etkili tekniklerin üretilmesine ihtiyaç vardır. Bu araştırmanın temel amacı, yukarıdaki sorunları ele alarak doğruluğu yüksek bir hava kirliliği tahmin teorisi geliştirmektir. Önerilen yaklaşım, Ampirik Mod Ayrıştırması (EMD) algoritması ve ARIMA modelinin bir arada uygulandığı melez bir yöntemdir. EMD-ARIMA yönteminin tahmin becerisini belirlemek için Türkiye'nin Van şehir merkezindeki PM₁₀ ve SO₂ hava kirlenmelerine ait 2019-2020 kış dönemindeki veriler kullanılmıştır. MAE, MAPE, RMSE ve R² performans ölçütlerine göre EMD-ARIMA modeli ile PM₁₀ ve SO₂ için sırasıyla 7.25 µg/m³, %20.58, 8.84 µg/m³, 0.87 ve 7.58 µg/m³, %20.73, 8.96 µg/m³, 0.71 değerleri elde edilmiştir. Bulgular EMD-ARIMA yönteminin, geleneksel DES ve ARIMA tahmin modellerine göre daha hassas bir tahmin becerisine sahip olduğunu ortaya koymaktadır. Önerilen melez yaklaşım, hava kirliliğinin öngörülmesi ve azaltılmasına yönelik basit ve etkili bir yöntem olarak kullanılabilir.

Prediction of Air Pollution in Van Province Using ARIMA Model Based on Empirical Mode Decomposition

Article Info

Received: 17.12.2022
Accepted: 01.02.2023
Online August 2023

DOI:10.53433/yyufbed.1220578

Keywords

ARIMA,
DES,
EMD-ARIMA,
PM₁₀,
SO₂,
Van

Abstract: Air pollution is one of the main factors that directly threatens the quality of life. Predicting changes in air pollutants has an important role in air pollution control and management. Traditional methods such as Double Exponential Smoothing (DES) and Autoregressive Integrated Moving Average (ARIMA) used today are often insufficient for estimating air pollution. Therefore, more effective techniques are needed to determine air quality. The main purpose of this research is to develop a highly accurate air pollution prediction theory by addressing the above problems. The proposed approach is a hybrid method in which Empirical Mode Decomposition (EMD) algorithm and ARIMA model are applied together. To determine the estimation ability of the EMD-ARIMA method, data on PM₁₀ and SO₂ air pollutants in the city center of Van, Türkiye, in the winter period of 2019-2020 were used. According to MAE, MAPE, RMSE and R² performance criteria, values of 7.25 µg/m³, 20.58%, 8.84 µg/m³, 0.87 and 7.58 µg/m³, 20.73%, 8.96 µg/m³, 0.71 were obtained for PM₁₀ and SO₂ with EMD-ARIMA model, respectively. The findings reveal that the EMD-ARIMA method has a more sensitive estimation ability than traditional

DES and ARIMA estimation models. The proposed hybrid approach can be used as a simple and effective method for predicting and reducing air pollution.

1. Giriş

Hava kirliliği, dünyanın büyük bir bölümünü etkisi altına alan en önemli çevre ve sağlık sorunlarından birisidir (Kurt & Oktay, 2010). Son yıllardaki hızlı ekonomik kalkınma ve plansız kentleşme sonucunda şehir merkezlerindeki nüfus yoğunluğu dramatik bir şekilde artış göstermiştir. Evsel ısınma, yeterli baca bakımının yapılmaması, motorlu taşıtlar ve organize sanayi bölgeleri; dış ortam hava kalitesindeki belirgin azalmanın en büyük sebepleridir (Hao ve ark., 2018). Bu tür antropojenik kaynaklardan atmosfere salınan 10 µm'den küçük partikül madde (PM₁₀), kükürt dioksit (SO₂), azot dioksit (NO₂), karbon monoksit (CO) ve ozon (O₃) gibi birincil kirleticiler hava kirliliğinin ana bileşenleri arasında gösterilmektedir (Sheng & Tang, 2016). Ek olarak bölgenin coğrafi yapısı ve meteorolojik koşulları kent merkezlerindeki hava kalitesini etkileyen diğer önemli belirleyicilerdir (Varaprasad ve ark., 2021; Volna ve ark., 2021). Hava kirliliği, besin kaynaklarının zarar görmesi, asit yağmurlarının oluşması ve küresel ısınma gibi ciddi çevresel etkilerin yanı sıra yaşam kalitesinin düşmesi ve beklenen ömür süresinin kısalması gibi sağlık problemlerinden de sorumlu tutulmaktadır (Quah & Boon, 2003; Levy ve ark., 2013; Ostro ve ark., 2014).

Küresel çaptaki başlıca ölüm ve hastalık nedenlerinin belirlenmesine yönelik 204 ülkenin katılımıyla hazırlanan Küresel Hastalık Yüğü (The Global Burden of Disease) çalışmasına göre dış ortam hava kirliliği, tüm dünyada insan sağlığını tehdit eden altıncı risk faktörüdür (Murray ve ark., 2020). Aynı zamanda inme, kalp hastalıkları, akciğer kanseri ve astım gibi solunum yolu hastalıkları da dahil olmak üzere önde gelen diğer önemli ölüm nedenlerinin birçoğunu dolaylı yoldan etkilemektedir (WHO, 2022). Özellikle çocuklar, hamileler ve yaşlılar ile solunum yolu ve kardiyovasküler rahatsızlıkları olan hastalar da dahil olmak üzere nüfusun daha hassas ve savunmasız bireylerini tehdit eden ana unsurlardan birisi olarak görülmektedir (Sheng & Tang, 2016). Ayrıca Ekonomik Kalkınma ve İşbirliği Örgütü (OECD) ülkelerinde yapılan bir araştırmaya göre hava kirliliği gibi çevresel etkenlere bağlı sağlık harcamaları gayri safi yurtiçi hasılanın (GSYİH) yaklaşık onda birine karşılık gelmektedir (Mujtaba & Shahzad, 2021). Hava kirliliği, küresel sağlık sistemine getirdiği ek maliyetin yanında üretim ve işletme kapasitesini de olumsuz etkileyebilir. Hava kirliliğinin yol açtığı sağlık problemlerine bağlı olarak çalışanların hastalıklarının artması, üretim süreçlerinin yavaşlamasına ve finansal zarara neden olabilmektedir (Gautam & Bolia, 2020). Gelecek dönemlerdeki hava kalitesinin belirlenmesi, çevre kirliliği kaynaklı sağlık harcamalarının ve ekonomik kayıpların azaltılmasına yönelik çalışmaların yürütülmesine büyük katkı sağlayacağına inanılmaktadır.

Türkiye, diğer gelişmekte olan ülkeler gibi özellikle 1950'lerden sonra sanayileşme ve şehirleşme nedeniyle hava kirliliğinden en çok etkilenen ülkeler arasında yer almaktadır (Sümer, 2014). Ülkemizdeki hava kirliliği, çoğunlukla hane ısınmasında düşük kaliteli katı yakıt kullanımı ve motorlu araçlardan salınan yoğun egzoz dumanından kaynaklanmaktadır (Elbir ve ark., 2000; Akbostancı ve ark., 2009; Aladağ, 2023). Ayrıca kömür ile elektrik üreten termik santraller ve diğer endüstriyel faaliyetler de önemli etkiye sahiptir (Zeydan & Pekkaya, 2021). İlk olarak Ankara'da kurulan hava kalitesi izleme istasyonları, 1985 yılından itibaren ülke geneline yayılmıştır. Çevre Şehircilik ve İklim Değişikliği Bakanlığı tarafından geliştirilen ulusal ağ sistemi ile düzenli olarak hava kalitesi takibi gerçekleştirilmektedir (Bayram, 2005). Günümüzde 357 adet hava kalitesi izleme istasyonunda başlıca PM₁₀ ve SO₂ olmak üzere NO₂, CO, O₃ ve 2.5 µm'den daha küçük partikül madde (PM_{2.5}) ölçümü yapılmaktadır. Bu istasyonlardan elde edilen verilere göre 80 ilin havası Dünya Sağlık Örgütü (DSÖ) kriterlerine göre kirlidir (Alkan, 2018). 2019 yılında DSÖ tarafından belirlenen kılavuz değerlere uyulmadığı için hava kirliliğine bağlı sağlık problemleri sonucunda 30 binin üzerinde erken yaşam kaybı gerçekleşmiştir (Güzel & Özer, 2022). Bu yüzden, kent merkezlerindeki hava kalitesini tahmin çalışmaları, hava kirliliğinin kontrolüne ve insan sağlığı üzerine etkilerinin önlenmesine yönelik erken uyarı sistemlerinin geliştirilmesinde hayati bir rol oynamaktadır.

Günümüzde hava kirleticilerinin tahmin edilmesi için birçok istatistiksel ve matematiksel yöntemden yararlanılmaktadır. Bunlara bütünlük otoregresif hareketli ortalama (ARIMA), mevsimsel bütünlük otoregresif hareketli ortalama (SARIMA), çoklu doğrusal regresyon (MLR), yapay sinir

ağları (ANN), destek vektör makineleri (SVM), uzun kısa süreli bellek (LSTM), çok değişkenli uyarlanabilir regresyon eğrileri (MARS) ve aşırı gradyan artırma (XGBoost) gibi geleneksel veya yeni yöntemler örnek gösterilebilir (Cujia ve ark., 2019; Maleki ve ark., 2019; Wu & Lin, 2019; Leong ve ark., 2020; Gopu ve ark., 2021; Shams ve ark., 2021; Tırınk & Öztürk, 2022). Bu yöntemler, genellikle kaotik ve durağan olmayan bir yapıya sahip olan hava kirliliği parametrelerinin öngörülmesinde yetersiz kalmaktadırlar. Birçok çevresel ve içsel durumdan etkilenen hava kalitesindeki anlık ve beklenmedik değişimleri çoğu zaman yansıtamazlar (Zhang & Xia, 2022). ARIMA modelinin doğrusallık varsayımı ve yapay zekâ tabanlı modellerin “kara kutu” doğası kullanıcı müdahalesini sınırlar ve tahmin çalışmaları yüksek hata payı ile sonuçlanır (Wang ve ark., 2016). Bu yüzden, son yıllarda yapılan tahmin çalışmalarında dalgacık dönüşümü (WT), ampirik mod ayrışması (EMD) ve varyasyonel mod ayrışması (VMD) gibi zaman serilerini daha durağan serilere dönüştüren yenilikçi metotlardan faydalanılmaktadır. PM₁₀ tahmininde MODWT-ARIMA modeli kullanılan bir çalışmada geleneksel ARIMA modeline göre RMSE miktarında %90 azalma bildirilmiştir (Aladağ, 2021). PM₁₀ için SARIMA ile yapılan başka bir çalışmada %83 tahmin başarısı elde edilmiştir (Cujia ve ark., 2019). Hava kalite endeksi tahmini için önerilen VMD-SE-LSTM ile %87 tahmin performansı sağlanmıştır (Wu & Lin, 2019). EMD-SVR kullanılan başka bir çalışmada ise ARIMA modeline göre RMSE değerinin 208.6’dan 24.5’e kadar düştüğü rapor edilmiştir (Zhu ve ark., 2017).

Bu çalışmada hava kirleticilerinin tahmini için EMD algoritmasının ve ARIMA modelinin bir arada kullanıldığı yeni bir melez model geliştirilmiştir. Van kentindeki 2019-2020 kış mevsiminde ölçülen günlük PM₁₀ ve SO₂ konsantrasyonlarının geleneksel DES, ARIMA ve önerilen EMD-ARIMA melez yöntemi ile tahmin edilmesi amaçlanmıştır. Çalışma alanı olarak seçilen Van şehir merkezinin yüksek râkımdaki dağlarla çevrili coğrafik yapısı ve karasal iklim şartları nedeniyle özellikle sert geçen kış aylarında yoğun hava kirliliği yaşanmaktadır. Kentteki hava kalitesini olumsuz etkileyen başlıca kaynaklar arasında az gelişmiş sanayiden ziyade evsel ısınma ve yoğun trafik yer almaktadır (Öztürk & Bayram, 2019). 2020 yılında SO₂ ortalaması (22 µg/m³) en yüksek beşinci ildir ve yıllık PM₁₀ ortalaması (40 µg/m³) ise DSÖ tarafından belirlenen yıllık sınır değer (20 µg/m³) iki katıdır (THHP, 2021). Önerilen melez modelin uygulanabilmesi için öncelikle yüksek frekanslı ve durağan olmayan hava kirletici serileri EMD algoritması kullanılarak daha düşük frekanslı ve durağan alt zaman serilerine ayrıştırılmıştır. Daha sonra her bir alt IMF ve kalıntı serilerine yapılan ADF birim kök testi, ACF ve PACF analizlerine göre ARIMA modelleri oluşturulmuştur. Ardından tahmin edilen alt IMF serileri ve kalıntı serisi birleştirilerek hava kirleticilerinin günlük tahminleri gerçekleştirilmiştir. EMD-ARIMA melez yönteminin tahmin kabiliyeti, geleneksel DES ve ARIMA yöntemleri ile MAE, MAPE, RMSE ve R² performans ölçütlerine göre kıyaslanmıştır.

2. Materyal ve Yöntem


Bu bölümde çalışma alanı ve kullanılan verilerin kısa tanıtımı, ayrıştırma algoritması, geleneksel tahmin yöntemleri ve önerilen melez tahmin modeli ile ilgili gerekli tanımlara, açıklamalara ve tahmin modellerinin performans ölçütlerine yer verilmektedir.

2.1. Uygulama alanı ve veri toplama

Türkiye’nin Doğu Anadolu Bölgesinde yer alan Van ili, yaklaşık 1 milyon 150 bin kişinin yaşadığı bölgenin en kalabalık şehir merkezine ev sahipliği yapmaktadır. İl nüfusunun %54’ü Tuşba, İpekyolu ve Edremit merkez ilçelerinde yaşamaktadır. Şehrin kalbi sayılan Cumhuriyet-Bahçıvan ve Ali Paşa-Hafızıye hatları nüfus, trafik ve yapı yoğunluğu açısından en yoğun alanlardır (Bilik, 2021). Karasal iklim şartlarının hâkim olduğu ilde kış ayları karlı ve soğuk, yaz ayları ise kuru ve sıcaktır. Şahbağı, Musakent ve Erek dağlarıyla çevreli, 1730 râkımdaki şehir merkezinin batısında yer alan Van gölünün etkisiyle sıcaklık ve nem bölgeye göre nispeten daha yüksektir.

Van ilinde Çevre, Şehircilik ve İklim Değişikliği Bakanlığına ait bir adet hava kalitesi izleme istasyonu bulunmaktadır. Merkezi konumdaki ölçüm istasyonu ısınma ve trafik kaynaklı hava kirliliğini büyük ölçüde yansıtmaktadır. Bu istasyonda ölçülen saatlik PM₁₀ ve SO₂ konsantrasyon değerleri (µg/m³), Ulusal Hava Kalitesi İzleme Ağında (<http://www.havaizleme.gov.tr>) yayınlanmaktadır (ÇŞİDB, 2022). Çalışmada, 10 Kasım 2019 ile 15 Şubat 2020 tarihleri arasındaki günlük ortalama PM₁₀ ve SO₂ miktarları kullanılmıştır. Şekil 1’de hava kirleticilerinin zaman serilerine yer verilmiştir. PM₁₀

için 37 gün HKDYY tarafından belirlenen sınır değerini ($>50 \mu\text{g}/\text{m}^3$) üzerinde ölçüm yapılmıştır ve SO_2 için ise çalışma süresi boyunca sınır değeri ($>125 \mu\text{g}/\text{m}^3$) aşılmamıştır (HKDYY, 2008).



Şekil 1. PM_{10} ve SO_2 hava kirleticilerinin zaman serileri.

Çizelge 1'deki hava kirleticilerin betimleyici istatistiklerine göre PM_{10} ve SO_2 için ortalama değerler, sırasıyla, 47.67 ve $40.77 \mu\text{g}/\text{m}^3$ olarak hesaplanmıştır. En düşük PM_{10} değeri, 8 Şubat 2020 tarihinde $9.92 \mu\text{g}/\text{m}^3$ ve SO_2 değeri, 6 Aralık 2019 tarihinde $13.49 \mu\text{g}/\text{m}^3$ olarak ölçülmüştür. En yüksek PM_{10} miktarı, 21 Aralık 2019'da $131.51 \mu\text{g}/\text{m}^3$ ve SO_2 miktarı, 28 Ocak 2020'de $84.11 \mu\text{g}/\text{m}^3$ olarak ölçülmüştür. Her iki veri seti de hafifçe sola çarpıktır ve biraz basıktır. Zaman serilerinde sıklıkla tercih edilen Jarque-Bera normallik testine göre iki zaman serisi de normallik varsayımını ($p < 0.05$) reddeder (Ruchiraset & Tantrakarnapa, 2022).

Çizelge 1. Hava kirleticilerinin betimleyici istatistikleri

Seriler	Minimum	Maksimum	Medyan	Ortalama	Std. sapma	Aralık	Çarpıklık	Basıklık
PM_{10}	9.92	131.51	42.36	47.67	24.62	121.59	0.90	0.46
SO_2	13.49	84.11	39.15	40.77	16.57	70.62	0.61	-0.27

2.2. Tahmin yöntemleri

2.2.1. Çift üstel düzeltme (DES)

Üstel düzeltme hem deterministik hem de stokastik eğilime sahip olan tüm zaman serileri için uygulanabilen bir tahmin yöntemidir. Açık, anlaşılır ve şeffaf olmasının yanı sıra birçok farklı duruma başarı ile uyum sağlayabilmesi nedeniyle en sık kullanılan tahmin metodlarından birisidir (Yağimli & Ergin, 2017). Genellikle kısa vadeli tahminler için tercih edilir ve uzun vadeli tahminler için güvenilir olmayabilir. Hem basit ortalama hem de ağırlıklı hareketli ortalama yönteminin avantajlarına sahip olan üstel düzeltme, geçmiş kayıtların etki derecesini zayıflatır ama bu verilerden de tamamen vazgeçmez (Huang ve ark., 2012). Başka bir deyişle, yeni verilere daha fazla ağırlık verilirken önceki verilere üstel olarak azalan ağırlıklar verilir. Üstel düzeltme yönteminin temel eşitliği (Eşitlik 1) aşağıda gösterilmektedir.

$$S_t = \alpha y_t + (1 - \alpha)S_{t-1} \quad (1)$$

S_t , t dönemindeki tahmin edilen değeri, y_t , t dönemindeki gerçek değeri, S_{t-1} , $t-1$ dönemindeki tahmin edilen değeri ve α düzeltme faktörünü ($0 < \alpha < 1$) temsil eder.

Zaman serisinin eğilim ve mevsimsellik göstermediği durumlarda basit üstel düzeltme uygulanabilir. Tahmin eşitliğine (Eşitlik 2) aşağıda yer verilmiştir.

$$\hat{y}_{t+1} = \alpha y_t + (1 - \alpha)\hat{y}_t \quad (2)$$

Üstel düzeltme, eğilime sahip olan zaman serilerinde de tahmin yapılabilmesi için genişletilmiştir (Holt, 2004). Çift üstel düzeltme olarak ifade edilen bu yöntem, bir tahmin eşitliği (Eşitlik 3) ile seviye (Eşitlik 4) ve eğilim (Eşitlik 5) olmak üzere iki düzeltme eşitliği içerir. Bu eşitlikler aşağıdaki gibidir.

$$\hat{y}_{t+h} = l_t + hb_t \quad (3)$$

$$l_t = (1 - \alpha)l_{t-1} + \alpha x_t \quad (4)$$

$$b_t = (1 - \beta)b_{t-1} + \beta(l_t - l_{t-1}) \quad (5)$$

Burada l_t , t dönemindeki tahmin edilen seviyeyi, b_t , t dönemindeki tahmin edilen eğilimi ve h tahmin adımını gösterir. β ise eğilim ($0 < \beta < 1$) için düzeltme faktörüdür.

2.2.2. Bütünleşik otoregresif hareketli ortalama (ARIMA)

ARIMA, zaman serilerini tahmin etmek için otoregresyon ve hareketli ortalama modellerinin bir arada uygulandığı genelleştirilmiş bir yöntemdir. Otoregresyon modelinin (AR) derecesi p , hareketli ortalama modelinin (MA) derecesi q ve zaman serisini durağan hale getirmek için uygulanan fark alma işleminin (I) sayısı ise d ile ifade edilir (Box ve ark., 2015). Genel olarak ARIMA (p, d, q) modeline ait eşitlik aşağıdaki gibidir.

$$(1 - u)^d Y_t = \alpha + \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q} \quad (6)$$

Burada ϕ_i ve θ_i sırasıyla AR ve MA katsayılarını, u fark alma operatörünü, Y_t zaman serisini ve ε_t hata terimini göstermektedir.

ARIMA ile tahmin aşamasına geçilmeden önce zaman serilerinde önemli bir özellik olan durağanlığın mutlaka kontrol edilmesi gerekir. Bunun için serinin gecikmeli değerleri ile hesaplanan Genişletilmiş Dickey-Fuller (ADF) birim kök testi sıklıkla tercih edilmektedir. ADF birim kök testinde, t -istatistiğinin kritik değerlerden daha büyük olması, sıfır hipotezini reddederek birim kökün olmadığını göstermektedir (Zhang ve ark., 2018). Zaman serisinde birim kök olması durumunda ise ARIMA modelinin önemli bir varsayımı olan durağanlık sağlanana kadar fark işlemi uygulanmalıdır. Bir diğer yöntem ise eğer zaman serisi için uygunsa (yani sıfır veya negatif sayı içermiyorsa) logaritma almaktır. Daha sonra durağanlaştırılan zaman serisinde, AR (p) ve MA (q) modellerinde değişkenin önceki dönemlerle olan ilişkisinin saptanabilmesi için kullanılan otokorelasyon fonksiyonu (ACF) ve kısmi otokorelasyon fonksiyonu (PACF) incelenerek p ve q değerleri seçilir. Farklı derecelerdeki ARIMA (p, d, q) modellerinin göreceli olarak performansını belirlemek için genellikle Akaike bilgi kriterinden (AIC) faydalanılır (Cheng ve ark., 2019). Ayrıca Bayesci bilgi kriteri (BIC), Schwarz-Bayesci kriteri (SBC) veya Schwarz bilgi kriteri (SIC) de model kıyaslaması için kullanılabilir. Aşağıdaki eşitlik (Eşitlik 7) ile hesaplanan AIC değerinin daha küçük olması, modelin daha uygun olduğunu göstermektedir (Aladağ, 2021).

$$AIC = 2(p + q + k + 1) - 2 \log(L) \quad (7)$$

Eşitlikte, L modeli için olabilirlik fonksiyonunun maksimum değerini ve k ise modelde tahmin edilen parametre sayısını ifade etmektedir.

2.3. Ampirik mod ayırıştırma (EMD)

EMD, doğrusal ve durağan olmayan karmaşık zaman serilerini durağan olana kadar ayırıştırmak için uygulanan bir algoritmadır (Huang ve ark., 1998). EMD yöntemi ile orijinal zaman serisi, Hilbert-Huang dönüşümü ile belirli sayıdaki nispeten durağan olan içsel mod fonksiyonuna (IMF) ve bir kalıntı serisine ayrıştırılır. İçsel mod fonksiyonlarının iki şartı sağlaması gerekir. Bunlar: 1) Tüm veri kümesinde yerel ekstremumların ve sıfır geçişlerinin sayısı eşit olmalı veya en fazla bir noktada farklılık göstermelidir ve 2) Herhangi bir noktada yerel maksimumlar ve minimumlar tarafından tanımlanan zarfın ortalaması sıfır olmalıdır (Liu ve ark., 2021). Bir zaman serisi için uygulanan EMD algoritmasının adımlarına aşağıda yer verilmiştir.

1. Orijinal zaman serisinin (y_t) yerel maksimum ve yerel minimum değerleri belirlenir.
2. Yerel maksimum ve yerel minimum noktaları, kübik spline interpolasyon yöntemi ile birleştirilerek üst zarf ($e_{max,1}$) ve alt zarf ($e_{min,1}$) oluşturulur.

3. Üst zarf ve alt zarfın aritmetik ortalaması alınarak ortalama zarf ($e_{ort,1}$) hesaplanır.
4. Orijinal seriden ortalama zarf değerleri çıkarılarak fark serisi (d_t) bulunur.
5. Eğer fark serisi bir IMF ise, bir içsel mod fonksiyonu (c_t) olarak tanımlanır, değilse fark serisi yeni orijinal seri olarak kabul edilir ve IMF olana kadar ilk dört adım tekrarlanır.
6. IMF bulunduktan sonra bu seri, orijinal seriden çıkarılarak kalıntı serisi (r_t) elde edilir.
7. Kalıntı serisi, yeni orijinal seri olarak kabul edilir ve ilk altı adım tekrarlanır. Kalıntı serisi, monotonik bir fonksiyon olduğunda veya daha fazla IMF bileşeni elde edilemeyince EMD algoritması bitirilir.

Eşitlik 8’de gösterildiği gibi EMD algoritmasından sonra elde edilen IMF serilerinin ve kalıntı serisinin toplamı orijinal zaman serisine eşittir.

$$y_t = \sum_{i=1}^n IMF_i + r_n \quad (8)$$

Burada n toplam IMF serisinin sayısını ve r kalıntı bileşenini göstermektedir.

2.4. Önerilen melez EMD-ARIMA yöntemi

Hava kirleticilerinin tahmini için önerilen melez EMD-ARIMA modelinin hesaplama adımlarına aşağıda yer verilmiştir.

1. Hava kirleticilerine ait zaman serileri oluşturulur.
2. Zaman serileri, EMD algoritması ile IMF ve kalıntı alt serilerine ayrıştırılır.
3. Alt zaman serilerinin Sample Entropy miktarı hesaplanır ve serilerdeki entropi yeterince azaltılmışsa EMD sonlandırılır.
4. Alt serilere ADF birim kök testi uygulanır ve seriler logaritma ya da fark alma (d) işlemi ile durağanlaştırılır.
5. ACF ve PACF analizine göre ARIMA model parametreleri (p ve q) seçilir.
6. Alt serilerin ARIMA modelleri oluşturulur.
7. AIC istatistiğine göre en uygun model parametreleri seçilir.
8. Her bir alt seri için uygun ARIMA modeli ile tahmin yapılır.
9. Tahmini alt seriler birleştirilir.
10. Belirli bir zaman sonraki PM₁₀ ve SO₂ hava kirletici değeri için tahmin gerçekleştirilir.
11. Modelin performansı ölçülerek diğer modeller ile karşılaştırılır.

2.5. Performans değerlendirilmesi

Hava kirliliği tahmininde kullanılan modellerin performans ölçümü, korelasyon katsayısı (R^2), kök ortalama karesel hata (RMSE), ortalama mutlak hata (MAE) ve ortalama mutlak yüzde hata (MAPE) analiz yöntemleri ile gerçekleştirilmiştir. Bu çalışmada kullanılan R^2 , RMSE, MAE ve MAPE’ye ait eşitliklere, sırasıyla, Eşitlik 9, Eşitlik 10, Eşitlik 11 ve Eşitlik 12’de yer verilmiştir.

$$R^2 = \left(\frac{\sum_{i=1}^N (G_i - \bar{G})(T_i - \bar{T})}{\sqrt{\sum_{i=1}^N (G_i - \bar{G})^2 \sum_{i=1}^N (T_i - \bar{T})^2}} \right)^2 \quad (9)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (G_i - T_i)^2} \quad (10)$$


$$MAE = \frac{1}{N} \sum_{i=1}^N |G_i - T_i| \quad (11)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{G_i - T_i}{G_i} \right| \times 100 \quad (12)$$

Burada, N gözlem sayısını, G_i ve T_i sırasıyla i anındaki gözlem ve tahmin değerlerini, \bar{G} ve \bar{T} ise sırasıyla gözlem ve tahmin değerlerinin ortalamasını göstermektedir.

3. Bulgular ve Tartışma

Önerilen tahmin modelinin uygulanabilmesi için öncelikle PM_{10} ve SO_2 zaman serilerinin EMD yöntemi ile alt serilere ayrıştırılması gerekir. Şekil 2’de hava kirleticilerinin IMF ve kalıntı serileri gösterilmektedir. Şekil 2(k) ve Şekil 2(m)’de ise ayrıştırılan serilerin Sample Entropy grafikleri görülmektedir. Sample Entropy (SE), bir zaman serisinin karmaşıklığını gösterir (Ma ve ark., 2020). Her iki grafikte de açıkça görüldüğü gibi en yüksek SE değerleri, IMF₁ serilerindedir ve seriler ayrıştıkça entropi miktarları azalır. PM_{10} ve SO_2 zaman serileri için EMD algoritması ile elde edilen kalıntı serilerinin SE değerleri sıfıra çok yakındır. Dolayısıyla PM_{10} ve SO_2 zaman serileri için sırasıyla 4 ve 5 adet IMF ayrışmasının yeterli olduğu görülmektedir. Çizelge 2’de IMF ve kalıntı serilerine ait betimleyici istatistiklere yer verilmiştir.



Şekil 2. PM_{10} ve SO_2 zaman serilerinin ampirik mod ayrışımı.

Çizelge 2. IMF ve kalıntı serilerinin betimleyici istatistikleri

Alt seriler	Minimum	Maksimum	Medyan	Ortalama	Std. sapma	Aralık	Çarpıklık	Basıklık
PM ₁₀ .IMF ₁	-20.85	24.51	0.36	-0.09	9.78	45.36	0.03	-0.54
PM ₁₀ .IMF ₂	-34.30	44.41	1.22	-0.10	15.90	78.70	-0.04	-0.12
PM ₁₀ .IMF ₃	-25.30	24.53	-1.11	0.08	15.08	49.83	0.06	-1.22
PM ₁₀ .IMF ₄	-7.42	5.40	0.02	-0.04	3.87	12.82	-0.14	-1.25
PM ₁₀ .Kalıntı	42.82	52.51	47.89	47.81	3.05	9.62	-0.06	-1.34
SO ₂ .IMF ₁	-22.56	26.03	-1.44	-0.64	9.90	48.59	-0.03	-0.15
SO ₂ .IMF ₂	-19.18	23.33	-1.21	-0.94	9.46	42.51	0.21	-0.28
SO ₂ .IMF ₃	-15.15	11.93	-0.25	-0.21	7.81	27.07	-0.22	-0.95
SO ₂ .IMF ₄	-12.44	14.33	-6.55	-2.05	9.55	26.77	0.50	-1.34
SO ₂ .IMF ₅	-1.53	1.11	0.52	0.33	0.72	2.64	-0.77	-0.42
SO ₂ .Kalıntı	41.41	46.83	44.37	44.29	1.71	5.41	-0.11	-1.33


Bir zaman serisinde ARIMA ile tutarlı bir tahmin modeli oluşturabilmek için serinin durağan olması gerekir. Durağan olmayan zaman serileri fark alma ve/veya logaritma gibi işlemlerle durağanlaştırılır. ADF testi, zaman serilerinin durağanlığını belirlemek için yaygın olarak kullanılan bir yöntemdir. Çizelge 3'te PM₁₀ ve SO₂ zaman serilerinin ve birinci dereceden farklarının ($d = 1$) ADF testleri gösterilmektedir. Burada, sabit terimli ve doğrusal eğilimli ADF testi ve terimsiz ADF testi sonuçlarına göre her iki zaman serisinde de birim kök bulunmaktadır. Birinci dereceden farklarında ise birim kök yoktur ve seriler durağandır. Dolayısıyla PM₁₀ ve SO₂ serilerinin ARIMA modellerinde d değeri 1 olarak belirlenmiştir.

Çizelge 3. ADF testi

	ADF test	PM ₁₀	$d(\text{PM}_{10}, 1)$	SO ₂	$d(\text{SO}_2, 1)$
Sabit terimli	<i>t</i> -stat	-3.94	-9.29	-4.03	-9.88
	1%	-3.50	-3.50	-3.50	-3.50
	5%	-2.89	-2.89	-2.89	-2.89
	10%	-2.58	-2.58	-2.58	-2.58
	<i>p</i> -değeri	0.00	0.00	0.00	0.00
	Birim kök	yok	yok	yok	yok
	Sabit terimli ve doğrusal eğilimli	<i>t</i> -stat	-4.00	-9.23	-4.06
1%		-4.06	-4.06	-4.06	-4.06
5%		-3.46	-3.46	-3.46	-3.46
10%		-3.15	-3.15	-3.15	-3.15
<i>p</i> -değeri		0.01	0.00	0.01	0.00
Birim kök		var	yok	var	yok
Terimsiz		<i>t</i> -stat	-2.03	-9.34	-1.25
	1%	-2.59	-2.59	-2.59	-2.59
	5%	-1.94	-1.94	-1.94	-1.94
	10%	-1.61	-1.61	-1.61	-1.61
	<i>p</i> -değeri	0.04	0.00	0.19	0.00
	Birim kök	var	yok	var	yok

ARIMA modelinde AR (p) ve MA (q) bileşenlerindeki p ve q parametrelerinin belirlenebilmesi için ACF ve PACF analizleri yapılmıştır. PACF ve ACF testlerinde güven aralığının dışındaki gecikme sayısına göre sırasıyla p ve q değerleri seçilir. Şekil 3'te PM₁₀ ve SO₂ zaman serilerinin birinci dereceden farklarının ACF ve PACF grafiklerine yer verilmiştir. Her iki zaman serisinde p değeri PACF sonucuna göre 1 ve q değeri ACF sonucuna göre 2 seçilmiştir. Ayrıca her iki parametre için üçüncü dereceye

kadar ARIMA modelleri oluşturulmuş ve AIC değerleri incelenmiştir. Çizelge 4'te PM_{10} ve SO_2 hava kirlleticilerinin tahmin edilmesi için kurulan geleneksel ARIMA modellerinin AIC istatistiği gösterilmektedir. ARIMA parametreleri en düşük AIC değerine göre belirlenmiştir. Burada PM_{10} için en uygun ARIMA (p, q, d) modeli 2, 1, 1 ve SO_2 için en uygun model parametreleri 1, 1, 1 olarak hesaplanmıştır.



Şekil 3. PM_{10} ve SO_2 zaman serilerinin ACF ve PACF grafikleri.

Çizelge 4. ARIMA (p, q, d) modellerinin AIC istatistiği

PM_{10}	AIC	SO_2	AIC
2, 1, 1	822.81	1, 1, 1	760.27
1, 1, 2	823.44	1, 1, 2	760.96
3, 1, 1	824.50	2, 1, 1	760.99
1, 1, 3	824.70	1, 1, 3	762.80
2, 1, 2	825.35	2, 1, 2	762.92
2, 1, 3	826.50	2, 1, 3	764.96
3, 1, 3	828.59	3, 1, 3	767.38
0, 1, 0	828.83	0, 1, 0	767.95
0, 1, 3	830.30	0, 1, 3	768.06
0, 1, 1	830.44	0, 1, 2	768.75
1, 1, 0	830.50	2, 1, 0	769.90
2, 1, 0	831.76	0, 1, 1	769.91
0, 1, 2	831.93	1, 1, 0	769.93
1, 1, 1	832.36	3, 1, 0	771.80
3, 1, 0	832.69	3, 1, 1	773.83
3, 1, 2	833.37	3, 1, 2	775.90

Önerilen EMD-ARIMA yönteminde de her bir IMF ve kalıntı serisi geleneksel ARIMA modeline benzer şekilde oluşturulmuştur. EMD ile elde edilen alt serilerin durağanlık analizleri, ACF, PACF ve AIC sonuçlarına göre Çizelge 5'te gösterilen p , d ve q değerleri seçilmiştir. Daha sonra EMD-ARIMA modeli ile hava kirleticilerinin tahmin edilmesi için tahmin edilen IMF ve kalıntı alt serileri birleştirilmiştir.

Çizelge 5. EMD serileri için seçilen ARIMA (p , q , d) parametreleri


Hava kirleticileri	IMF ₁	IMF ₂	IMF ₃	IMF ₄	IMF ₅	Kalıntı
PM ₁₀	3, 0, 0	2, 0, 5	2, 1, 4	5, 1, 2	-	3, 1, 5
SO ₂	0, 0, 1	3, 0, 2	2, 0, 4	5, 1, 0	2, 1, 0	4, 1, 3

Çizelge 6'da DES, ARIMA ve EMD-ARIMA modellerinin tahmin performanslarına yer verilmiştir. DES modelinde α ve β katsayıları, sırasıyla, PM₁₀ için 1.17575 ve 0.01432, SO₂ için 1.19898 ve 0.00803 olarak hesaplanmıştır. En yüksek MAE değerleri sırasıyla DES ve ARIMA modellerinde ölçülürken en düşük MAE değeri ise EMD-ARIMA modelinde PM₁₀ için 7.25 $\mu\text{g}/\text{m}^3$ ve SO₂ için 7.58 $\mu\text{g}/\text{m}^3$ olarak elde edilmiştir. En yüksek MAPE değeri, DES modelinde PM₁₀ için %31.15 ve SO₂ için %25.96 ve en düşük EMD-ARIMA modelinde sırasıyla, %20.58 ve %20.73 olarak hesaplanmıştır. En düşük RMSE değeri de diğer performans ölçütlerine benzer biçimde önerilen EMD-ARIMA modelinde elde edilmiştir. RMSE hata miktarı, PM₁₀ için ARIMA modeline kıyasla %49.97 ve SO₂ için %29.5 azalmıştır. Hava kalitesi endeksi tahmini için VMD ile kullanılarak ayırıştırma yapılan LSTM modelinde MAE, MAPE ve RMSE için sırasıyla %11.97 %9.09 ve %15.10 oranlarında performans artışı bildirilmiştir (Wu & Lin, 2019). Aylık PM₁₀ tahmininde WT-ARIMA ile ARIMA modeline göre RMSE değeri 18 $\mu\text{g}/\text{m}^3$ 'den 2 $\mu\text{g}/\text{m}^3$ 'e kadar azalmıştır (Aladağ, 2021).

Çizelge 6. DES, ARIMA ve EMD-ARIMA tahmin modellerinin performans sonuçları

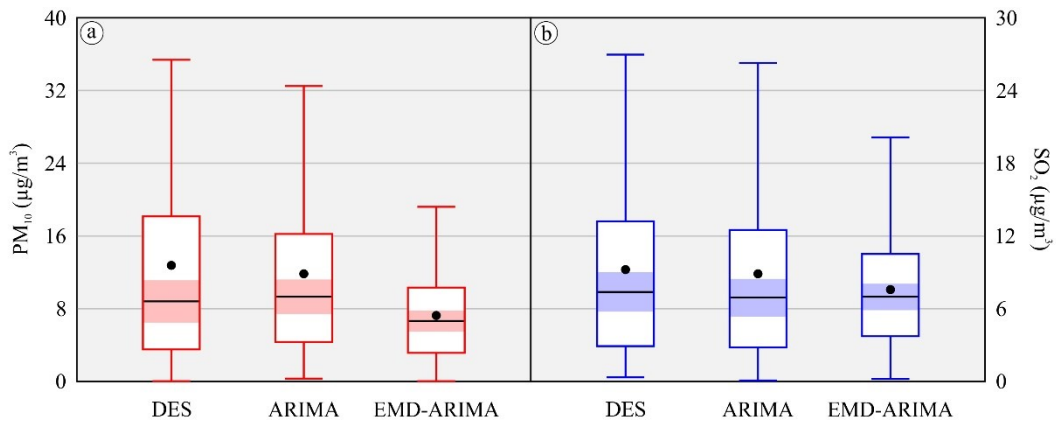
Parametre	Model adı	MAE ($\mu\text{g}/\text{m}^3$)	MAPE (%)	RMSE ($\mu\text{g}/\text{m}^3$)	R ²
PM ₁₀	DES	12.77	31.15	17.67	0.56
	ARIMA	11.84	29.68	15.49	0.59
	EMD-ARIMA	7.25	20.58	8.84	0.87
SO ₂	DES	9.22	25.96	12.71	0.53
	ARIMA	8.87	25.02	11.52	0.51
	EMD-ARIMA	7.58	20.73	8.96	0.71

Şekil 4'te DES, ARIMA ve EMD-ARIMA modellerinden elde edilen değerler ile gözlemlenen değerler arasındaki korelasyon grafikleri gösterilmektedir. Grafiklerdeki kırmızı düz çizgiler mükemmel korelasyonu ($R^2 = 1$) ve kesikli mavi çizgi ise örneklemin ölçülen korelasyonunu göstermektedir. En yüksek R² değerleri, EMD-ARIMA modelinde PM₁₀ için 0.87 ve SO₂ için 0.71 olarak hesaplanmıştır. En düşük R² değerleri ise PM₁₀ için sırasıyla DES ve ARIMA, SO₂ için sırasıyla ARIMA ve DES modellerinde elde edilmiştir. Ayrıca her iki modelde de özellikle orta ve yüksek değerlerdeki hata miktarı belirgin bir şekilde artmaktadır. EMD-ARIMA modelinde ise yüksek değerlerde PM₁₀'a göre SO₂ zaman serisinde daha fazla sapma gözlemlenmiştir. Yıllık PM_{2.5} tahmini yapılan bir çalışmada cdEMD-SVM-ARIMA melez modelinde R² değeri 0.84 olarak hesaplanmıştır (Zhang & Xia, 2022). Tahran'daki SO₂ miktarının öngörülmesinde kullanılan MLP modeli ile 0.9 R² değeri elde edilmiştir (Shams ve ark., 2021).



Şekil 4. DES, ARIMA ve EMD-ARIMA tahmin modellerinin korelasyon grafikleri.

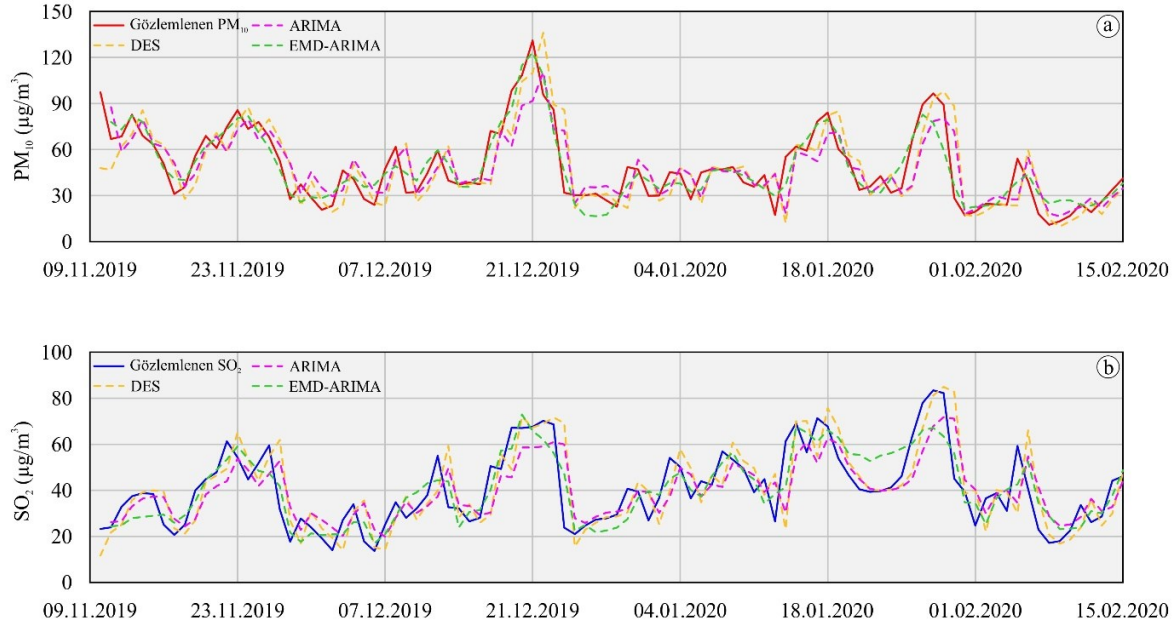
Şekil 5'te DES, ARIMA ve EMD-ARIMA modellerinden elde edilen tahmin değerleri ile gözlemlenen değerler arasındaki hata miktarlarının (solda) PM₁₀ ve (sağda) SO₂ için kutucuk grafikleri gösterilmektedir. Kutucuk grafiği bir seri hakkında aynı anda birçok bilginin bir arada görülmesine imkân tanır. Kutucukların ucundaki yatay eksene paralel aşağı ve yukarı yönlü çizgiler, sırasıyla, aykırı değerler dışında kalan en yüksek ve en düşük değerleri gösterir. Kutucuğun alt ve üst kenarları ise sırasıyla hata miktarının yüzde yirmi beşlik (ilk çeyrek) ve yetmiş beşlik (üçüncü çeyrek) kısmını ifade eder. Kutucuğun içindeki yatay eksene paralel çizgi ortanca değeri ve kalın nokta ortalama değeri gösterir. Buna göre her iki hava kirleticisi için EMD-ARIMA yönteminden elde edilen hata miktarındaki değişim oranları ve ortalamaları DES ve geleneksel ARIMA modellerine kıyasla daha azdır.



Şekil 5. DES, ARIMA ve EMD-ARIMA model hatalarının kutucuk grafikleri.

Şekil 6'da hava kirleticilerinin gözlemlenen değerleri ve tahmin modellerinin uyum grafiklerine yer verilmiştir. DES ve ARIMA modellerinde hava kirleticilerinin uç (pik) değerlerinde kaymalar görülmektedir ve gecikmeli bir düzelme söz konusudur. EMD-ARIMA modelinde ise PM₁₀ ve SO₂ miktarlarındaki değişimler daha az kayma ile yakalanmıştır. Bu durum, EMD algoritmasından elde

edilen alt serilerin belirli bir hareketi takip etme doğasından kaynaklanır ve ARIMA modelinin doğrusal tahmin yeteneğinin sonuçlarla örtüşmesiyle açıklanabilir (Zhu ve ark., 2017).



Şekil 6. DES, ARIMA ve EMD-ARIMA modellerinin gözlemlenen değerlerle uyumu.

Hava kirliliği tahmin modellerinin değerlendirilebilmesi için bir diğer önemli ölçüt de günlük hava kalite endeksinin doğru aralıkta tahmin edilebilmesidir. Hava kalite endeksi (AQI), atmosferik kirlleticilerin insan sağlığı üzerine etkilerine göre sınıflandırılmasını sağlar. PM₁₀ için 0-54 µg/m³ arası “iyi”, 55-154 µg/m³ arası ise “orta” ve SO₂ için 0-35 µg/m³ arası “iyi”, 36-75 µg/m³ arası “orta”, 76-185 µg/m³ arası “sağlıksız” AQI seviyesine işaret eder (EPA, 2022). Çalışma süresi boyunca hava kirleticisi verileri daha üst seviyelere ulaşmadığı için AQI karşılıklarına burada yer verilmemiştir. PM₁₀ konsantrasyonuna göre toplam 33 gün orta seviyede AQI gözlemlenmiştir. Bu günler için DES ve ARIMA modelleri ile 25 gün, EMD-ARIMA modeliyle ise 29 gün doğru tahmin yapılmıştır. SO₂ konsantrasyonuna göre toplam 57 gün orta ve 3 gün sağlıksız AQI seviyesine ulaşılmıştır. Orta AQI için DES ile 19 gün, ARIMA ile 14 gün ve EMD-ARIMA modeli ile 23 gün doğru tahmin yapılmıştır. Sağlıksız AQI görülen günleri ise üç model de doğru tahmin etmeyi başaramamıştır.

4. Sonuç

Hava kirliliği yaşam kalitesini olumsuz yönde etkileyen önemli çevresel bileşenlerden birisidir. Düşük hava kalitesinin gözlemlendiği kent merkezlerinde, hava kirliliğine bağlı solunum yolu rahatsızlıklarında kayda değer bir artış meydana gelir ve toplum sağlığı bu durumdan olumsuz etkilenir. Hava kirliliğinin öngörülmesi, atmosferik kirleticilerin salınımının önlenmesinde ve halk sağlığına olası etkilerinin azaltılmasında kilit rol oynamaktadır. Hava kirliticilerine ait zaman serileri genellikle durağan olmayan kaotik bir yapıdadır. Bu yüzden hava kirliliği için tutarlı tahminlerde bulunmak oldukça zordur. Geleneksel tahmin modelleri, hava kirliticilerindeki beklenmedik artışların öngörülmesinde çoğu zaman yetersiz kalmaktadır. Bu çalışmada bu sorunun üstesinden gelmek için EMD algoritmasını ve ARIMA tahmin yöntemini içeren melez bir yaklaşım olan EMD-ARIMA modeli önerilmiştir.

Türkiye'nin Van şehir merkezindeki hava kirliliği gözlem istasyonundan toplanan 2019-2020 kış dönemine ait PM₁₀ ve SO₂ verileri, önerilen EMD-ARIMA melez modelinin tahmin becerisinin ölçülebilmesi için kullanılmıştır. Önerilen melez model, DES ve geleneksel ARIMA modelleri ile karşılaştırıldığında daha yüksek tahmin hassasiyetine sahiptir. EMD-ARIMA modeli ile MAE, MAPE, RMSE ve R² performans ölçütlerine göre PM₁₀ ve SO₂ için sırasıyla 7.25 µg/m³, %20.58, 8.84 µg/m³, 0.87 ve 7.58 µg/m³, %20.73, 8.96 µg/m³, 0.71 sonuçları elde edilmiştir. Ampirik bulgular, zaman

serilerini daha düşük frekanslı ve nispeten daha durağan alt serilere ayırıştırarak EMD algoritması ile ARIMA modelinin birleştirilmesinin hava kirletici miktarlarındaki değişimlerin öngörülmesinde uygun bir melez yöntem olduğunu açıkça ortaya koymaktadır. Bu nedenle, EMD-ARIMA yöntemi, hava kirliliği kontrolü ve yönetimi için etkili ve basit bir araç olarak uygulanabilir. Gelecekteki çalışmalarda, diğer hava kirleticilerini de ele alan bölgenin topografik yapısını, demografik özelliklerini ve mevsimsel değişimlerini kapsayan daha geniş ölçekli hava kirliliği tahmin teorilerinin geliştirilmesi beklenmektedir.

Kaynakça

- Akbostancı, E., Türüt-Aşık, S., & Tunç, G. İ. (2009). The relationship between income and environment in Turkey: is there an environmental Kuznets curve?. *Energy policy*, 37(3), 861-867. doi:10.1016/j.enpol.2008.09.088
- Aladag, E. (2023). The influence of meteorological factors on air quality in the province of Van, Turkey. *Water, Air, & Soil Pollution*, 234(4), 259. doi:10.1007/s11270-023-06265-0
- Aladağ, E. (2021). Forecasting of particulate matter with a hybrid ARIMA model based on wavelet transformation and seasonal adjustment. *Urban Climate*, 39, 100930. doi:10.1016/j.uclim.2021.100930
- Alkan, A. (2018). Hava kirliliğinin ciddi boyutlara ulaştığı kentlere bir örnek: Siirt. *Bitlis Eren Üniversitesi Sosyal Bilimler Dergisi*, 7(2), 641-666.
- Bayram, H. (2005). Türkiye’de hava kirliliği sorunu: Nedenleri, alınan önlemler ve mevcut durum. *Toraks Dergisi*, 6(2), 159-165.
- Bilik, M. B. (2021). Deprem tehlikelerine karşı Van kent merkezinin sosyo-mekansal zarar görebilirliği. *Resilience*, 5(1), 67-92. doi:10.32569/resilience.886414
- Box, G. E., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time series analysis: Forecasting and control*. Hoboken, USA: John Wiley & Sons.
- Cheng, Y., Zhang, H., Liu, Z., Chen, L., & Wang, P. (2019). Hybrid algorithm for short-term forecasting of PM_{2.5} in China. *Atmospheric Environment*, 200, 264-279. doi:10.1016/j.atmosenv.2018.12.025
- Cujia, A., Agudelo-Castañeda, D., Pacheco-Bustos, C., & Teixeira, E. C. (2019). Forecast of PM₁₀ time-series data: A study case in Caribbean cities. *Atmospheric Pollution Research*, 10(6), 2053-2062. doi:10.1016/j.apr.2019.09.013
- ÇŞİDB. (2022). *Ulusal Hava Kalitesi İzleme Ağı*. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı. <http://www.havaizleme.gov.tr> Erişim tarihi: 11.10.2022.
- Elbir, T., Müezzinoğlu, A., & Bayram, A. (2000). Evaluation of some air pollution indicators in Turkey. *Environment International*, 26(1-2), 5-10. doi: 10.1016/S0160-4120(00)00071-4
- EPA. (2022). *Air quality index (AQI) basics*. Çevre Koruma Ajansı. <https://airnow.gov/index.cfm?action=aqibasics.aqi> Erişim tarihi: 03.12.2022.
- Gautam, D., & Bolia, N. B. (2020). Air pollution: Impact and interventions. *Air Quality, Atmosphere & Health*, 13(2), 209-223. doi:10.1007/s11869-019-00784-8
- Gopu, P., Panda, R. R., & Nagwani, N. K. (2021). *Time series analysis using ARIMA model for air pollution prediction in Hyderabad city of India*. 3rd International Conference on Soft Computing and Signal Processing, Hyderabad. doi:10.1007/978-981-33-6912-2_5
- Güzel, Ş., & Özer, P. (2022). Türkiye’de hava kirliliği ve sağlık harcamaları. *Sağlık ve Sosyal Refah Araştırmaları Dergisi*, 4(2), 186-202. doi:10.55050/sarad.1138629
- Hao, Y., Peng, H., Temulun, T., Liu, L.-Q., Mao, J., Lu, Z.-N., & Chen, H. (2018). How harmful is air pollution to economic development? New evidence from PM_{2.5} concentrations of Chinese cities. *Journal of Cleaner Production*, 172, 743-757. doi:10.1016/j.jclepro.2017.10.195
- HKDYY. (2008, 6 Haziran). T. C. Başbakanlık, Hava Kalitesi Değerlendirme ve Yönetimi Yönetmeliği. *Resmi Gazete (Sayı: 26898)*. Erişim adresi: <https://www.mevzuat.gov.tr/mevzuat?MevzuatNo=12188&MevzuatTur=7&MevzuatTertip=5>
- Holt, C. C. (2004). Forecasting seasonals and trends by exponentially weighted moving averages. *International Journal of Forecasting*, 20(1), 5-10. doi:10.1016/j.ijforecast.2003.09.015
- Huang, N. E., Shen, Z., Long, S. R., Wu, M. C., Shih, H. H., Zheng, Q., ... & Liu, H. H. (1998). The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time

- series analysis. *Proceedings of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences*, 454(1971), 903-995. doi:10.1098/rspa.1998.0193
- Huang, J., Li, C., & Yu, J. (2012). *Resource prediction based on double exponential smoothing in cloud computing*. 2nd International Conference on Consumer Electronics, Communications and Networks, Yichang. doi:10.1109/CECNet.2012.6201461
- Kurt, A., & Oktay, A. B. (2010). Forecasting air pollutant indicator levels with geographic models 3 days in advance using neural networks. *Expert Systems with Applications*, 37(12), 7986-7992. doi:10.1016/j.eswa.2010.05.093
- Leong, W. C., Kelani, R. O., & Ahmad, Z. (2020). Prediction of air pollution index (API) using support vector machine (SVM). *Journal of Environmental Chemical Engineering*, 8(3), 103208. doi:10.1016/j.jece.2019.103208
- Levy, H., Horowitz, L. W., Schwarzkopf, M. D., Ming, Y., Golaz, J.-C., Naik, V., & Ramaswamy, V. (2013). The roles of aerosol direct and indirect effects in past and future climate change. *Journal of Geophysical Research: Atmospheres*, 118(10), 4521-4532. doi:10.1002/jgrd.50192
- Liu, M.-D., Ding, L., & Bai, Y.-L. (2021). Application of hybrid model based on empirical mode decomposition, novel recurrent neural networks and the ARIMA to wind speed prediction. *Energy Conversion and Management*, 233, 113917. doi:10.1016/j.enconman.2021.113917
- Ma, Z., Chen, H., Wang, J., Yang, X., Yan, R., Jia, J., & Xu, W. (2020). Application of hybrid model based on double decomposition, error correction and deep learning in short-term wind speed prediction. *Energy Conversion and Management*, 205, 112345. doi:10.1016/j.enconman.2019.112345
- Maleki, H., Sorooshian, A., Goudarzi, G., Baboli, Z., Tahmasebi Birgani, Y., & Rahmati, M. (2019). Air pollution prediction by using an artificial neural network model. *Clean Technologies and Environmental Policy*, 21(6), 1341-1352. doi:10.1007/s10098-019-01709-w
- Mujtaba, G., & Shahzad, S. J. H. (2021). Air pollutants, economic growth and public health: Implications for sustainable development in OECD countries. *Environmental Science and Pollution Research*, 28(10), 12686-12698. doi:10.1007/s11356-020-11212-1
- Murray, C. J., Aravkin, A. Y., Zheng, P., Abbafati, C., Abbas, K. M., Abbasi-Kangevari, M., Abd-Allah, F., Abdelalim, A., Abdollahi, M., & Abdollahpour, I. (2020). Global burden of 87 risk factors in 204 countries and territories, 1990–2019: A systematic analysis for the Global Burden of Disease Study 2019. *The Lancet*, 396(10258), 1223-1249. doi:10.1016/S0140-6736(20)30752-2
- Ostro, B., Malig, B., Broadwin, R., Basu, R., Gold, E. B., Bromberger, J. T., ... & Green, R. (2014). Chronic PM_{2.5} exposure and inflammation: Determining sensitive subgroups in mid-life women. *Environmental Research*, 132, 168-175. doi:10.1016/j.envres.2014.03.042
- Öztürk, D., & Bayram, T. (2019). Van ili kent merkezinde hava kirliliği. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 8(3), 1142-1153. doi:10.17798/bitlisfen.529099
- Quah, E., & Boon, T. L. (2003). The economic cost of particulate air pollution on health in Singapore. *Journal of Asian Economics*, 14(1), 73-90. doi:10.1016/S1049-0078(02)00240-3
- Ruchiraset, A., & Tantrakarnapa, K. (2022). Association of climate factors and air pollutants with pneumonia incidence in Lampang province, Thailand: Findings from a 12-year longitudinal study. *International Journal of Environmental Health Research*, 32(3), 691-700. doi:10.1080/09603123.2020.1793919
- Shams, S. R., Jahani, A., Kalantary, S., Moeinaddini, M., & Khorasani, N. (2021). The evaluation on artificial neural networks (ANN) and multiple linear regressions (MLR) models for predicting SO₂ concentration. *Urban Climate*, 37, 100837. doi:10.1016/j.uclim.2021.100837
- Sheng, N., & Tang, U. W. (2016). The first official city ranking by air quality in China—A review and analysis. *Cities*, 51, 139-149. doi:10.1016/j.cities.2015.08.012
- Sümer, G. Ç. (2014). Hava kirliliği kontrolü: Türkiye’de hava kirliliğini önlemeye yönelik yasal düzenlemelerin ve örgütlenmelerin incelenmesi. *Uluslararası İktisadi ve İdari İncelemeler Dergisi*, 13, 37-56. doi:10.18092/ulikidince.232135
- THHP. (2021). *Kara Rapor: Hava kirliliği ve sağlığa etkileri*. Temiz Hava Hakkı Platformu. <https://www.temizhavahakki.org/wp-content/uploads/2021/09/KaraRapor2021.pdf> Erişim tarihi: 21.11.2022.

- Tırınk, S., & Öztürk, B. (2022). Evaluation of PM₁₀ concentration by using Mars and XGBOOST algorithms in Iğdır Province of Türkiye. *International Journal of Environmental Science and Technology*, 20, 5349–5358. doi:10.1007/s13762-022-04511-2
- Varaprasad, V., Kanawade, V., & Narayana, A. (2021). Spatio-temporal variability of near-surface air pollutants at four distinct geographical locations in Andhra Pradesh State of India. *Environmental Pollution*, 268, 115899. doi:10.1016/j.envpol.2020.115899
- Volna, V., Blažek, Z., & Krejčí, B. (2021). Assessment of air pollution by PM₁₀ suspended particles in the urban agglomeration of Central Europe in the period from 2001 to 2018. *Urban Climate*, 39, 100959. doi:10.1016/j.uclim.2021.100959
- Wang, H., Liu, L., Dong, S., Qian, Z., & Wei, H. (2016). A novel work zone short-term vehicle-type specific traffic speed prediction model through the hybrid EMD–ARIMA framework. *Transportmetrica B: Transport Dynamics*, 4(3), 159-186. doi:10.1080/21680566.2015.1060582
- WHO. (2022). *Ambient (outdoor) air pollution*. Dünya Sağlık Örgütü. [https://www.who.int/news-room/fact-sheets/detail/ambient-\(outdoor\)-air-quality-and-health](https://www.who.int/news-room/fact-sheets/detail/ambient-(outdoor)-air-quality-and-health) Erişim tarihi: 03.12.2022.
- Wu, Q., & Lin, H. (2019). Daily urban air quality index forecasting based on variational mode decomposition, sample entropy and LSTM neural network. *Sustainable Cities and Society*, 50, 101657. doi:10.1016/j.scs.2019.101657
- Yağımlı, M., & Ergin, H. (2017). Türkiye’de iş kazalarının üssel düzeltme metodu ile tahmin edilmesi. *Marmara Fen Bilimleri Dergisi*, 29(4), 118-123. doi:10.7240/marufbd.305236
- Zeydan, Ö., & Pekkaya, M. (2021). Evaluating air quality monitoring stations in Turkey by using multi criteria decision making. *Atmospheric Pollution Research*, 12(5), 101046. doi:10.1016/j.apr.2021.03.009
- Zhang, L., Lin, J., Qiu, R., Hu, X., Zhang, H., Chen, Q., ... & Wang, J. (2018). Trend analysis and forecast of PM_{2.5} in Fuzhou, China using the ARIMA model. *Ecological Indicators*, 95, 702-710. doi:10.1016/j.ecolind.2018.08.032
- Zhang, Z., & Xia, D. (2022). An improved PM_{2.5} forecasting method based on correlation denoising and ensemble learning strategy. *International Journal of Environmental Science and Technology*, 20, 8641–8654. doi:10.1007/s13762-022-04525-w
- Zhu, S., Lian, X., Liu, H., Hu, J., Wang, Y., & Che, J. (2017). Daily air quality index forecasting with hybrid models: A case in China. *Environmental Pollution*, 231, 1232-1244. doi:10.1016/j.envpol.2017.08.069