

Sihhiye Bölgesi Hava Kalitesi İndeksinin Aşırı Öğrenme Makineleri ve Yapay Sinir Ağları ile Tahmini

Burhan BARAN^{1*}

¹İnönü Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Malatya, Türkiye;
ORCID: [0000-0001-6394-412X](https://orcid.org/0000-0001-6394-412X) *Corresponding Author: burhanbaran@gmail.com

Received: 16 February 2022; Accepted: 29 March 2022

Reference/Atf: B. Baran, "Sihhiye Bölgesi Hava Kalitesi İndeksinin Aşırı Öğrenme Makineleri ve Yapay Sinir Ağları ile Tahmini", Researcher, vol. 02, no. 01, pp. 1-18, Jul. 2022, doi:10.55185/researcher.1074394

Özet



Bu çalışma ile Sihhiye bölgesindeki hava kalitesi indeksinin (HKİ) hem aşırı öğrenme makineleri (AÖM) hem de yapay sinir ağları (YSA) algoritmaları ile tahmin edilmesi amaçlanmıştır. Bu amaçla, HKİ'yi etkileyebilecek yedi adet parametre seçilmiştir. Bu parametreler PM₁₀, SO₂, CO, sıcaklık, nem, basınç ve rüzgâr hızıdır. İlk olarak, HKİ ile bu yedi parametre arasında korelasyon analizi yapılmıştır. Analiz sonucuna göre HKİ ile en güçlü ilişkinin atmosferik parametrelerden PM₁₀ ile, meteorolojik parametrelerden ise basınç ile olduğu sonucuna ulaşılmıştır. 2018 yılının Ağustos, Ekim, Kasım ve Aralık aylarına ait parametre değerleri eğitim verisi olarak belirlenmiştir. 2019 yılının Ocak ve Şubat aylarına ait ilk 14 günlük parametre verileri ise test verisi olarak belirlenmiştir. HKİ değerleri 1 ile 6 arasında matematiksel olarak sınıflandırılmıştır. Sınıflandırma çalışmaları hem ham veriler hem de normalize edilmiş veriler ile gerçekleştirilmiştir. Sınıflandırma sürecinde algoritmalarda farklı eğitim fonksiyonları ve gizli nöron sayıları kullanılmıştır. Sonuçların güvenilirliği için 3-kat çapraz doğrulama yapılmıştır. En yüksek performansa sahip aktivasyon fonksiyonları ve nöron sayıları gerçek test verilerine uygulanmıştır. Son olarak, HKİ'nin matematiksel sınıflandırma sonuçları ile tahmini sınıflandırma sonuçları karşılaştırılmıştır. Elde edilen sonuçlara göre hem ham hem de normalize veriler ile yapılan sınıflandırma çalışmalarında AÖM algoritmasının YSA algoritmasından daha başarılı sonuçlar elde ettiği görülmüştür. Başarım oranları ham verilerde %85.71, normalize verilerde %71.43 olarak gerçekleşmiştir.

Anahtar Kelimeler: hava kalitesi indeksi, aşırı öğrenme makineleri, yapay sinir ağları, sınıflandırma, korelasyon.

Prediction of Air Quality Index of Sihhiye Region by Extreme Learning Machines and Artificial Neural Networks

Abstract


With this study, it was aimed to estimate the air quality index (AQI) in the Sihhiye region with both extreme learning machines (ELM) and artificial neural networks (ANN) algorithms. For this purpose, seven parameters that could affect the AQI had been chosen. These parameters were PM₁₀, SO₂, CO, temperature, humidity, pressure and wind speed. Firstly, correlation analysis was performed between the AQI and these seven parameters. According to the results of the analysis, it was concluded that the strongest relation with the AQI were with PM₁₀ from the atmospheric parameters and the pressure from the meteorological parameters. The parameter values for August, October, November and December of 2018 year were determined as training data. The parameter values for the first 14 days of January and February of 2019 year were determined as test data. AQI values were classified mathematically between 1 and 6. Classification studies were applied to both raw data and normalized data. In the classification process, different training functions and hidden neuron numbers were used in algorithms. 3-fold cross-validation was performed for the reliability of the results. The activation function and neuron numbers with highest performance were applied to actual test data. Finally, mathematical classification results were compared with the predicted classification values of AQI. According to the results obtained, in the classification studies conducted with both raw and normalized data, it was observed that ELM algorithm achieved more successful results than ANN algorithm. The success rates were 85.71% in raw data and 71.43% in normalized data.

Keywords: air quality index, extreme learning machine, artificial neural networks, classification, correlation.

1. Giriş

Dünyanın hızla gelişmesine bağlı olarak kentleşme kaçınılmaz hale gelmiştir. Ancak, bu hem ekosistemler hem de insanlar için bir tehlike oluşturmaktadır. İnsanlar için oluşan tehlikelerden biri hava kirliliğidir [1]. Solunan kirli hava sağlığını doğrudan etkilemektedir. Bu nedenle, havanın kalitesini optimum seviyede tutmak büyük önem taşımaktadır [2]. Kentleşme ile birlikte, hava kirliliğinin bir diğer sebebi de sanayileşmedir. Özellikle hava kalitesi önlemlerinin bulunmadığı veya asgari düzeyde olduğu endüstriyel bölgelerde hava kalitesinin insan sağlığı üzerinde olumsuz etkisi bulunmaktadır. Bu nedenle, hava kirliliğinin derecesini objektif olarak değerlendirilmesi ve kirleticiler konsantrasyonlarını doğru şekilde tahmin edilmesi önem arz etmektedir. Bunun için bilimsel hava kalitesi izleme ve erken uyarı sistemleri oluşturulmalıdır [3]. Atmosferdeki hava kalitesi genel olarak hava kalitesi indeksi (HKİ) olarak bilinen bir parametre ile ölçülür. HKİ, havanın kirlilik derecesi hakkında bilgi verir. Hava kirliliği ise havadaki gazlar ve katı parçacıkların bir karışımı olarak tanımlanabilir. Araçlardan çıkan egzoz gazı, fabrikalardan çıkan kimyasallar, katı yakıt kaynaklı partiküller ve tozlar hava kirliliğine neden olan temel faktörlerdir. Atmosferde HKİ değerini etkileyen bazı kirleticiler partikül madde (PM₁₀), kükürt dioksit (SO₂) ve karbon monoksit (CO)'tir. PM₁₀, aerodinamik çapı 10 µm'den küçük partikül madde olarak tanımlanmaktadır. Hem dış hem de iç mekanlarda bulunabilir. Akciğer hastalıkları, kalp damar hastalıkları ve kalp krizine neden olabilmektedir [4]. Birçok sabit ve hareketli kaynaktan oluşabilmektedir. Küçük boyutlu olanların akciğerler üzerinde olumsuz etkileri olabilmektedir. SO₂, kömür ve fuel-oil gibi yakıtların yanması sonucu oluşmaktadır. İnsanların solunum fonksiyonlarını etkiler. Sülfürik asit oluşumuna ve sülfür dioksit birikmesine katkıda bulunmaktadır. Hem PM₁₀ hem de SO₂, özellikle kış aylarında kentsel hava kalitesi sorunları ile yakından ilişkilidir [5]. CO ise büyük miktarlarda solunduğunda zararlı olabilen bir gazdır. Renksiz ve kokusuzdur. Zehirlenmeye bağlı olarak bayılma ve ölümlere neden olabilmektedir. Dış havaya salınan en büyük CO kaynakları taşıtlardır [6].

Hava kirliliği insan sağlığını etkileyecek seviyelerin üzerine çıktığında hava kalitesi tahmin teknikleri geliştirilmektedir. Hava kalitesi tahmininde genellikle geleneksel yaklaşımlar, matematiksel ve istatistiksel teknikler kullanılmaktadır. Geleneksel tahmin modelleri temel olarak bilgisayar altyapısı gerektirmektedir. Çalışmalar HKİ'yi tahmin etmek için yeni modelleme yaklaşımlarını ortaya koymuştur. AÖM ve YSA ile sınıflandırma da bu yaklaşımlar kapsamındadır [7]. Ayrıca, hava kirleticilerinin dağılımı için rüzgâr hızı, sıcaklık, basınç, nem gibi meteorolojik faktörler de önemlidir. Bu parametrelerin hava kirliliği ve insan sağlığı açısından herhangi bir olumsuzluğu bulunmamaktadır. Ancak PM₁₀, SO₂ ve CO değerlerine yapacakları meteorolojik etkiler ile HKİ değerinin değişmesine neden olabilmektedirler. HKİ değerini etkileyen tüm bu parametrelerin temsili gösterimi Şekil 1'deki gibidir. Birçok ülke hava kirliliğini azaltmak için çalışmalar yapmaktadır. Bu ülkelerden biri de Türkiye'dir. Bu amaçla, ülke genelinde Çevre ve Şehircilik Bakanlığı tarafından kurulmuş Hava Kalitesi Ölçüm İstasyonları bulunmaktadır. Bu istasyonlar aracılığı ile kirleticiler ait veriler toplanmakta ve yine bu istasyonlarda analiz edilmektedir [8]. Analiz sonucunda istasyonun bulunduğu bölgenin hava kirliliği kalitesini gösteren HKİ değerleri hesaplanmaktadır. Çevre ve Şehircilik Bakanlığı Ulusal Hava Kalite İzleme Ağı web sitesinde kullanılan HKİ sınır değerleri şu şekildedir. İyi (0-50), orta (50-100), hassas (100-150), sağlıksız (150-200), kötü (200-300) ve tehlikeli (300-500).



Şekil 1: HKİ Değerini Etkileyen Parametrelerin Temsili Gösterimi

HKİ ve HKİ'yi etkileyebilecek parametrelerin tahminine yönelik makine öğrenmesi ve farklı algoritmalar kullanılarak çok sayıda çalışma yapılmıştır.

Sevinç (2022) tarafından yapılan çalışmada bir karar ağacı tahmincisi ve yeni bir parametre ayarlama süreci ile uyarlanabilir bir yükseltme algoritması kullanarak hastaların ciddiyetini tahmin etmek için geliştirilmiş bir öğrenme modeli önerilmiştir [9]. Cihan vd. (2021) tarafından yapılan çalışmada bir sanayi bölgesindeki PM₁₀ ve PM_{2.5} bileşenlerinin tahmini için uyarlamalı ağ tabanlı bulanık çıkarım sistemi, destek vektör regresyonu, sınıflandırma ve regresyon ağaçları, rastgele orman, k-en yakın komşuluk ve aşırı öğrenme makine yöntemleri kullanılmıştır. ANFIS modeli, diğer yöntemlere kıyasla PM₁₀ değerlerini tahmin etmede daha başarılı olmuştur [10]. Baran (2021) tarafından Beşiktaş'taki hava kalitesi indeksinin yapay sinir ağları ve k-en yakın komşuluk (kNN) algoritmaları ile tahmin edilmesi üzerine bir çalışma yapılmıştır [11]. Shishegaran vd. (2020) günlük HKİ tahmini için bir çalışma yapmışlardır. Dört tahmin modeli kullanılmışlardır. Modelleri karşılaştırmak için ise maksimum negatif ve pozitif hatalar, ortalama kesirli sapma, mutlak yüzde hata, kök ortalama kare hatası ve normalleştirilmiş kare hata yöntemlerini kullanılmışlardır. Elde edilen sonuca göre doğrusal olmayan topluluk modeli en iyi performansı göstermiştir [12]. Wang vd., (2020) yaptıkları çalışma ile günlük hava kalitesi tahmini için yenilikçi bir hibrit model önermişlerdir. Çalışmalarında aykırı nokta tespiti ve düzeltme algoritmasını benimsemişlerdir. Tahmin etkinliğini değerlendirmek için ise hipotez testi kullanılmıştır. Önerdikleri hibrit model diğer modellere göre daha yüksek tahmin seviyesine ulaşmıştır [13]. Baran (2019) tarafından yapılan çalışmada rüzgâr hızının ve buna bağlı olarak rüzgârdan elde edilebilecek enerjinin aşırı öğrenme makineleri algoritması tarafından tahmini yapılmıştır [14]. Liu vd. (2019) tarafından yapılan çalışma ile Pekin kenti için HKİ, İtalya için ise NO_x parametresinin tahmini amaçlanmıştır. Bu tahminler için destek vektör regresyonunu ve rastgele orman regresyonunu kullanılmışlardır. Regresyon modellerinin performansını değerlendirmek için ortalama karekök hatası ve korelasyon katsayısı kullanılmıştır. Yapılan deneysel çalışmalar neticesinde rastgele orman regresyonu modelin daha iyi performans gösterdiği, destek vektör regresyon modelin ise çok sayıda verinin işlenmesi yöntemlerine uygun olmadığı sonucuna ulaşılmıştır [15]. Sevinç (2019) tarafından yapılan çalışmada tek gizli katmanlı ileri beslemeli sinir ağları ile entegre yeni bir evrimsel öznetelik seçim algoritması önerilmiştir. Önerilen algoritma genetik algoritmaların evrimsel tekniğini birleştirmektedir. Aşırı öğrenme makineleri ile seçilen her bir özellik alt kümesinin uygunluk değerini hesaplanmıştır [16]. Zou vd. (2019), geçmişe ait hava kalitesi ve meteorolojik verilerin bir derin sinir ağı olan airQP-DNN modelinde kullanılmak suretiyle gelecekteki HKİ değerlerinin tahmini yapmışlardır. Bu tahmini HKİ verilerine göre de açık hava etkinlikleri için rota planlaması yapılmıştır. Çalışmada Pekin ve çevre kentlere ait bir yıllık veri seti kullanılmıştır. Elde ettikleri deneysel sonuçlara göre önerilen modelin diğer yaygın olarak kullanılan yöntemlerden daha iyi performans gösterdiği sonucuna ulaşılmıştır [17]. Bai vd. (2016) PM₁₀, SO₂ ve NO₂ içeren günlük hava kirliliği konsantrasyonlarını tahmin etmek için dalgacık tekniği ve geri yayılım sinir ağı modelini kullanarak bir W-BPNN modeli geliştirmişlerdir. Geliştirdikleri modeli, Çin'in Chongqing Nan'an Bölgesinde test etmişlerdir [18]. Baran (2019) tarafından yapılan çalışmada aşırı öğrenme makineleri algoritması ile hava kalitesi indeksinin tahmini gerçekleştirilmiştir [19]. Zhang ve Ding (2017) Hong Kong'un Sham Shui Po ve Tap Mun bölgelerindeki iki izleme istasyonunda altı yıllık veriler de dahil olmak üzere sekiz hava kalitesi parametresinden elde edilen verileri kullanarak AÖM algoritmasını eğitmişlerdir. Eğitilen AÖM algoritmasını kullanarak hava kirleticilerinin tahmini üzerine bir çalışma yürütmüşlerdir [20]. Sevinç (2018) tarafından yapılan çalışmada tek gizli katmanlı ileri beslemeli sinir ağlarında hesaplama parametrelerinin etkinliği incelenmiştir [21]. Zhu vd., (2017) yaptıkları çalışmada HKİ tahmininin doğruluğunu arttırmak için bölgesel hava kalitesi indeksi için bir tahmin modeli geliştirmişlerdir. Bu amaçla, ampirik mod ayrıştırma-EMD-SVR-Hibrit ve EMD-IMFs-Hibrit olarak adlandırılan iki hibrit model önermişlerdir [22].

Peng vd., (2017) doğrusal olmayan makine öğrenme yöntemleri kullanarak Kanada'da PM_{2.5}, O₃ ve NO₂ parametrelerine ait yoğunluk tahminleri yapmışlardır. Elde ettikleri verileri kullanmak suretiyle de HKİ değerinin tahminini yapmışlardır [23]. Jose (2017) Madrid kentindeki NO₂ kirliliğini tahmin etmek için olasılıksal tahmin tekniğini geliştirmişlerdir [24]. Patrico ve Ernesto (2016) Santiago kentindeki saatlik PM_{2.5} konsantrasyonunu tahmin etmek için ileri beslemeli bir sinir ağı modeli kullanılmışlardır [25]. Avşar (2015) tarafından yapılan çalışmada Burhaniye İlçesinde SO₂, NO_x, CO, O₃ ve VOC

parametrelerini içeren bir hava kalitesi analizi yapılmıştır [26]. Vong vd. (2014) PM₁₀ seviyesinin sınıfını tahmin etmek için AÖM algoritmasını kullanarak bir uyarı sistemi oluşturmuşlardır. Sonuçlarını destek vektör makineleri algoritmasının sonuçları ile karşılaştırmışlardır. Tahminleri iyileştirmek için önceden çoğaltma adı verilen dengesizlik stratejisini uygulamışlardır [27]. Moustiris vd. (2010) Yunanistan'ın Atina Bölgesi'nde 2001 ve 2005 yılları arasındaki eşik değer üzerindeki kirlilik değerlerinden en az birini dikkate almak suretiyle Avrupa Bölgesel Kirlilik Endeksi'nin maksimum günlük değerini tahmin etmek için YSA algoritmasını kullanmışlardır [28]. Biancofiore vd. (2017), PM₁₀ konsantrasyonu tahmin etmek için özyinelemeli sinir ağı modeli kullanmışlardır. Kullandıkları model % 95 oranında doğru tahmin yapmıştır [29]. Mekpariyup vd. (2020), tarafından yapılan çalışma ile Tayland'ın doğu bölgesinde bulunan sekiz hava izleme istasyonu tarafından ölçülen verilerin multi layer perceptron algoritmasına uygulanması suretiyle HKİ değerinin tahmini amaçlanmıştır. Yapılan analizler neticesinde HKİ tahmininde O₃ ve PM₁₀ parametrelerinin önemli rol oynadığı, NO₂, SO₂ ve CO parametrelerinin ise çok daha az önemli olduğu tespit edilmiştir. Ayrıca, HKİ değerinin yaz mevsimi sonunda düşük, yaz aylarında orta, kış aylarında yüksek olduğu tespit edilmiştir. Sınıflandırma tahmininde ise multi layer perceptron algoritması %90 oranında başarımla elde etmiştir [30]. Liu vd. (2017) Çin'in Pekin, Tianjin ve Shijiazhuang bölgelerindeki HKİ tahmini için mevcut makine öğrenme algoritmalarının tahmin hatasını en aza indirecek tahmin sonuçlarını elde etmek için destek vektör regresyon algoritmasını kullanmışlardır [31]. Ganesh vd. (2017) HKİ değerini tahmin etmek amacıyla YSA kullanmışlardır. YSA algoritmasını eğitmek için ise birçok yöntem kullanmışlardır. Bunlardan bazıları Elman sinir ağı, radyal temel fonksiyon sinir ağı, çok katmanlı algılayıcıdır. Çalışmalarında Houston ve Los Angeles bölgelerinde 2010-2016 yılları için NO₂, CO, O₃, PM_{2.5}, SO₂ ve PM₁₀ konsantrasyonları bağımsız, HKİ ise bağımlı değişken olarak kullanılmıştır [32]. Saatcioglu vd. (2011) tarafından çalışmada Marmaray Projesi ile otomobil kullanımının azaltılmasının 2015 ve 2030 yılları için İstanbul'daki hava kirliliğini nasıl etkileyeceğini değerlendirilmiştir. Elde edilen sonuçlara göre tüm kirlenici türleri için emisyonlardaki azalma oranının 2015 yılında %12.4 ve 2030 yılında %11.6 olacağı sonucuna ulaşılmıştır [33]. Dragomir (2010) tarafından k en yakın komşuluk algoritması ile HKİ değerinin tahminine yönelik bir çalışma yapılmıştır. Algoritmanın giriş parametreleri olarak SO₂, NO₂, O₃ ve CO parametrelerini kullanılmıştır. 2009 yılı Haziran ayının 29 günlük verileri ile bu çalışma yapılmıştır. K en yakın komşuluk algoritması ise Weka yazılımı aracılığı ile uygulanmıştır. K en yakın komşuluk algoritması tarafından 29 günden 19 tanesi doğru tahmin edilmiştir [34]. Jiao vd. (2019) tarafından yapılan çalışma ile HKİ değerinin tahmini amaçlanmıştır. Uzun kısa süreli bellek algoritması kullanılmıştır. PM_{2.5}, PM₁₀, SO₂, sıcaklık, rüzgâr yönü, NO₂, CO ve O₃ algoritmada kullanılan parametrelerdir. Çalışma sonucunda Uzun kısa süreli bellek algoritmasının HKİ değerini iyi derecede tahmin edebileceğine dair sonuçlara ulaşılmıştır [35]. Kadılar ve Kadılar (2017) ise mevsimsel otopregresif entegre hareketli ortalama yöntemi kullanarak Aksaray ilindeki hava kalitesini etkileyen SO₂ parametresinin tahmini üzerine bir çalışma yapmışlardır [36]. Avşar vd. (2010) tarafından yapılan çalışmada İstanbul'daki yol süpürme makinelerinden kaynaklanan gürültü seviyesinin ve PM₁₀ konsantrasyonunun etkisi incelenmiştir. Çalışma sonucunda bu araçlardan kaynaklanan PM₁₀ konsantrasyonunun 355 µg/m³'e ulaştığı ve bunun hem yayalara hem de operatöre yüksek oranda etki ettiği sonucuna ulaşılmıştır [37].

Geçmişte Sıhhiye bölgesi için en önemli kirlenici kaynaklar araç trafiği ve fosil yakıtlardır. Fosil yakıtlar nedeniyle SO₂ seviyesi yüksekti. Ancak, günümüzde ısıtmada doğalgazın kullanılmasına bağlı olarak SO₂ seviyesi düşmüştür. Bununla birlikte, hızla artan araç sayısı, PM değerinin yüksek çıkmasına sebep olabilmektedir. Bu çalışmada PM₁₀, SO₂, CO, sıcaklık, nem, basınç ve rüzgâr hızı parametreleri dikkate alınarak AÖM ve YSA algoritmaları tarafından HKİ değerlerine ait sınıflandırma tahminlerinin yapılması amaçlanmıştır. Elde edilen tahmini HKİ sınıflandırma sonuçları ile matematiksel HKİ sınıflandırma sonuçları karşılaştırılmıştır. Ayrıca, ham verilerin normalize edilmesi durumunda tahmin sonuçlarının nasıl etkileneceği de incelenmiştir. Tahmin çalışmalarında bağımsız giriş değişkenleri olarak PM₁₀, SO₂, CO, sıcaklık, nem, basınç ve rüzgâr hızı parametreleri kullanılmıştır. Bağımlı çıkış değişkeni ise HKİ'ye ait sınıflandırma değerleri olmuştur. HKİ değerlerini elde etmek için AQI Calculator [38] uygulaması kullanılmıştır. Bu uygulama PM₁₀, PM_{2.5}, SO₂, NO_x, CO, O₃ ve NH₃ gibi yedi adet kirlenicinin konsantrasyon değerlerine göre HKİ değerini hesaplamaktadır. Bu yedi parametreden en az üçü girilerek HKİ değeri hesaplanabilmektedir. Çalışmada 2018 yılının Ağustos, Ekim, Kasım ve Aralık aylarına ait 123 satırdan oluşan veriler eğitim verisi olarak kullanılmıştır. 2019

yılının Ocak ve Şubat aylarının ilk 14 günlük verileri ise test verisi olarak kullanılmıştır. Hem ham hem de normalize edilmiş veriler kullanılarak ayrı ayrı HKİ sınıflandırma değeri tahminleri yapılmıştır. AÖM ve YSA tarafından 2019 yılına ait bu iki farklı 14 günlük veriye ait HKİ sınıflarının doğru tahmin edilmesi amaçlanmıştır. En yüksek başarı oranında ve en kısa sürede doğru sonuçlar veren eğitim fonksiyonu ve nöron sayısı gerçek test verilerine uygulanmıştır. Elde edilen tahmin sonuçları karşılaştırılarak tahmin yöntemlerinin başarımları ölçülmüştür. Literatürdeki çalışmalar incelendiğinde genellikle PM₁₀, SO₂, CO parametreleri kullanılmışken bu çalışmada ek olarak sıcaklık, nem, basınç ve rüzgâr hızı parametreleri de HKİ değerinin belirlenmesinde giriş parametresi olarak dikkate alınmıştır. Ayrıca ham verilerin yanında normalize veriler ile de çalışmalar yapılmıştır. Bu bağlamda hem meteorolojik hem de atmosferik parametrelerin dikkate alındığı AÖM ve YSA algoritmaları ile yapılan bu tahmini sınıflandırma çalışmasının insan sağlığını olumsuz etkileyebilecek HKİ değerinin tahmin edilmesinde yol gösterici olacağı düşünülmektedir.

Çalışmanın bu aşamadan sonraki kısmı şu aşamalardan oluşmaktadır. İlk olarak HKİ değerini etkileyebilecek giriş parametreleri ile HKİ arasında korelasyon analizi yapılmıştır. Parametrelerin HKİ'yi hangi oranda etkilediğinin tespiti amaçlanmıştır. Ardından, AÖM ve YSA'ya ait teknik bilgiler verilmiştir. Daha sonra durum çalışmalarına yer verilmiştir. Giriş verilerinin hem ham hem de normalize edilmesi durumunda AÖM ve YSA ile elde edilen sonuçlara değinilmiştir. Sonuç bölümünde ise çalışmada elde edilen sonuçların karşılaştırması yapılmıştır.

2. İlgili Çalışmalar

2.1. HKİ Hesaplaması ve Sınır Değerler

HKİ günlük hava kalitesi indeksidir. Havanın kirlilik derecesi hakkında bilgi verir. Bu çalışmada kullanılan HKİ değerleri AQI Calculator uygulaması tarafından hesaplanmıştır. AQI Calculator PM₁₀, PM_{2.5}, SO₂, NO_x, CO, O₃ ve NH₃ parametrelerine ait değerlerin en az üç tanesinin girilmesi ile hava kalitesinin değerini hesaplayan excel tabanlı bir uygulamadır. Bu çalışmada PM₁₀, SO₂ ve CO parametrelerine ait değerler AQI Calculator uygulamasına girilerek HKİ değerleri elde edilmiştir. Elde edilen bu HKİ değerleri çalışma boyunca “hesaplanan HKİ” olarak adlandırılmıştır. AQI Calculator uygulaması tarafından elde edilen hesaplanan HKİ değerleri Çevre ve Şehircilik Bakanlığı Ulusal Hava Kalite İzleme Ağı web sitesindeki HKİ değerleri ile doğrulanmıştır [39]. Hava kirliliğinin kalitesini belirlemek için HKİ değerine belirli aralıklarla sınır değerler konulmuştur. Çevre ve Şehircilik Bakanlığı Ulusal Hava Kalite İzleme Ağı web sitesinde kullanılan HKİ sınır değerleri şu şekildedir. 0-50 (iyi), 50-100 (orta), 100-150 (hassas), 150-200 (sağlıksız), 200-300 (kötü) ve 300-500 (tehlikeli) olarak sınıflandırılmıştır. Bu çalışmada kullanılan sınır değerler ve atanan sınıf değerleri ise 0-50 (1. sınıf), 51-100 (2. sınıf), 101-150 (3. sınıf), 151-200 (4. sınıf), 201-300 (5. sınıf), 301-500 (6. sınıf) şeklindedir.

2.2. Eğitim Veri Seti

İlk olarak PM₁₀, SO₂ ve CO parametreleri AQI Calculator uygulamasına girilerek hesaplanan HKİ değerleri elde edilmiştir. Daha sonra, Ankara ili Sıhhiye bölgesine ait 2018 yılı Ağustos, Ekim, Kasım ve Aralık aylarındaki sıcaklık, nem, basınç ve rüzgâr hızı verileri www.timeanddate.com adlı web sitesinden alınmıştır [40]. Böylece, 7 adet giriş verisine karşılık 1 adet çıkış verisi olan hesaplanan HKİ verilerini içeren 123 satırlık eğitim veri seti oluşturulmuştur. Toplamda yedi adet olan meteorolojik ve atmosferik giriş parametresine göre elde edilen 123 adet hesaplanan HKİ değeri 1 ile 6 arasında matematiksel olarak sınıflandırılmıştır. Bu sınıflandırma işlemi sonucunda 1. sınıftan 45 adet, 2. sınıftan 66 adet, 3. sınıftan 8 adet ve 4. sınıftan 4 adet veri elde edilmiştir. Ancak, 5. ve 6. sınıflar için veri üretilmemiştir. Bunun nedeni, hesaplanan HKİ verileri içinde 201 ile 500 değerleri arasında hiçbir HKİ verisinin bulunmamasıdır.

2.3. Korelasyon Analizi

Korelasyon katsayısı (r), iki özellik arasındaki ilişkinin önemini ölçmede kullanılmaktadır. +1 ile -1 arasında değerler almaktadır ve birimi yoktur. r değeri sıfırdan büyük ise, parametreler arasında pozitif bir ilişki olduğu, sıfırdan küçük ise negatif bir ilişki olduğu sonucuna ulaşılmaktadır. Çıkan sonucun sıfıra eşit olması durumu ise, parametreler arasında doğrusal bir ilişki olmadığını göstermektedir. Pearson korelasyon katsayısı eşitlik 1 ile hesaplanmaktadır [41].

$$r = \frac{\sum xy - \frac{\sum x \sum y}{n}}{\sqrt{\left(\sum x^2 - \frac{(\sum x)^2}{n}\right) \left(\sum y^2 - \frac{(\sum y)^2}{n}\right)}} \quad (1)$$

Bu eşitlikte x ve y, iki sürekli yapının özelliklerini göstermektedir.

Korelasyon analizi, 2018 yılının Ağustos, Ekim, Kasım ve Aralık aylarına ait parametre değerleri ile hesaplanan HKİ değerleri karşılaştırılarak gerçekleştirilmiştir. Hesaplanan HKİ ile meteorolojik ve atmosferik parametreler arasında oluşan korelasyon grafikleri ve korelasyon katsayıları Şekil 2'deki gibidir.

2.4. Aşırı Öğrenme Makineleri

AÖM [42] tarafından geliştirilmiştir. İki katmandan oluşmaktadır. İkinci katmanı eğitilebilen ileri beslemeli bir yapay sinir ağıdır [43]. Klasik öğrenme algoritmaları ile karşılaştırıldığında yerel minimum, aşırı uyum gibi problemleri yaşamadan çok daha kısa sürede ve daha iyi performansta sonuçlar elde edilebilmektedir. AÖM, regresyon ve sınıflandırma gibi çalışmalarda kullanılmaktadır. N-gizli düğümü olan tek gizli katmanlı ileri beslemeli yapay sinir ağı eşitlik 2'deki gibi tanımlanmıştır [44].

$$f_N(x) = \sum_{i=1}^N B_i G(a_i, b_i, x), x \in R, a_i \in R \quad (2)$$

Burada, a_i ve b_i öğrenme parametreleridir. B_i , i. gizli düğümün ağırlığıdır. $G(x)$ ise aktivasyon fonksiyonudur.

2.5. Yapay Sinir Ağları

YSA'lar 1943 yılında McCulloch and Pitts tarafından geliştirilmişlerdir. Öğrenme yeteneğine sahip örüntü tanıma ve sınıflandırma tekniğidir. Biyolojik sinir ağlarını taklit eden sentetik yapılardır [45, 46, 8]. YSA'larda kullanılan ileri beslemeli geri yayılım sinir ağı algoritmaları, giriş vektörüne bağlı olarak çıkış vektörünü hesaplamada kullanılan algoritmalarlardır. Hem lineer olmayan hem de karmaşık problemleri çözme başarısından dolayı çoğunlukla tercih edilmektedir [47]. Yapay sinir ağları için ileri beslemeli toplama fonksiyonu ve transfer fonksiyonu sırasıyla eşitlik 3 ve eşitlik 4' te gösterilmiştir [48].

$$I_i = \sum_b W_{bi} x_b \quad (3)$$

$$y_i = f(I_i) \quad (4)$$

Bu çalışmadaki YSA çalışmasında ileri beslemeli geri yayılım sinir ağı algoritması kullanılmıştır. Kullanılan sinir ağı yedi adet giriş verisi, 123 adet gizli nöron ve 1 adet çıkış verisine göre tasarlanmıştır. Bu çalışmada kullanılan algoritmalar Matrix Laboratory (MATLAB) ortamında çalıştırılmıştır.

2.6. Normalizasyon

Yapay sinir ağlarında normalize edilmiş verilerle çalışmak daha hızlı sonuç vermektedir. Bu çalışmada ham verilerin normalize edilmesinde “min-maks normalizasyon” tekniği kullanılmıştır. Tüm eğitim ve test verileri dikkate alınarak 0 ile 1 arasında normalizasyon işlemi gerçekleştirilmiştir. Kullanılan normalizasyon denklemi eşitlik 5'teki gibidir [49].

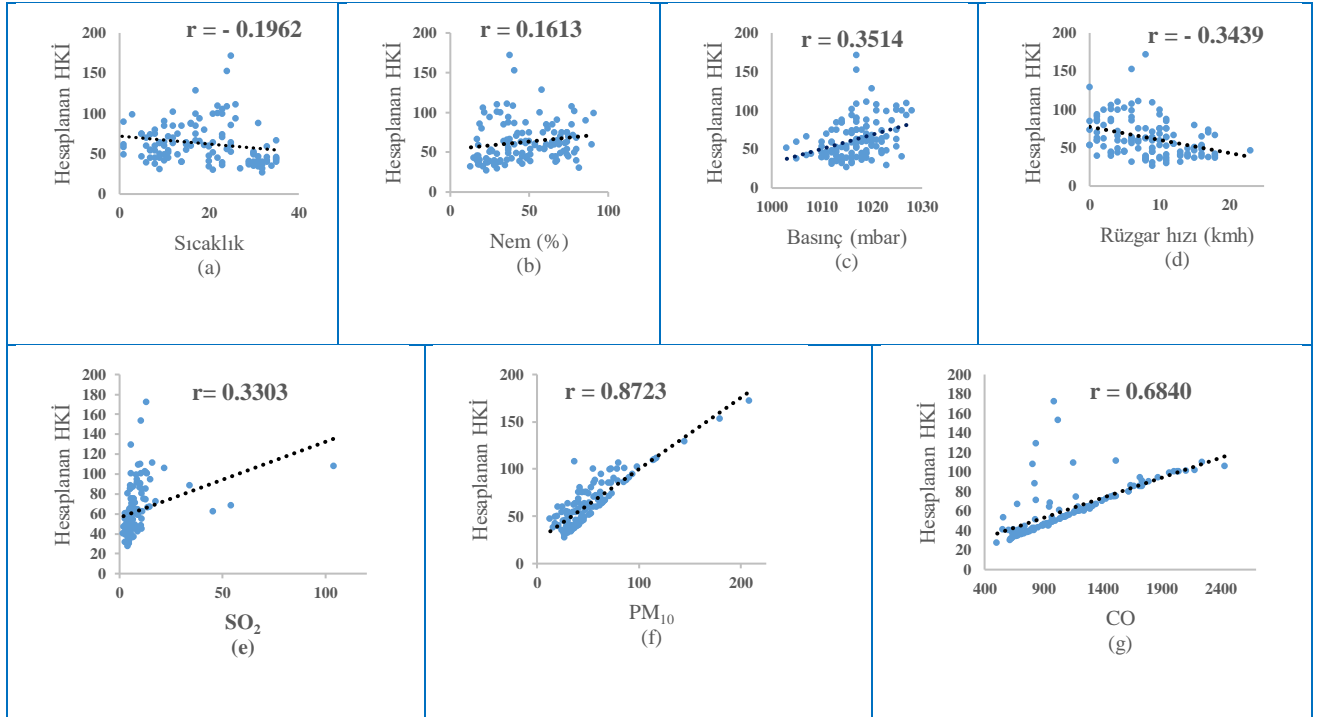
$$x' = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (5)$$

Burada, x' normalize edilmiş veriyi gösterirken x_i giriş verisi x_{max} giriş kümesindeki en büyük sayıyı, x_{min} ise giriş kümesindeki en küçük sayıyı göstermektedir.

3. Yapılan Çalışma ve Bulgular

3.1. Parametreler Arası Korelasyon Analizi

Korelasyon analizi, 2018 yılının Ağustos, Ekim, Kasım ve Aralık aylarına ait parametre değerleri ile hesaplanan HKİ değerleri karşılaştırılarak gerçekleştirilmiştir. Hesaplanan HKİ ile meteorolojik ve atmosferik parametreler arasında oluşan korelasyon grafikleri ve korelasyon katsayıları Şekil 2'deki gibidir.



Şekil 2: Hesaplanan HKİ ile Giriş Parametreleri Arasındaki Korelasyon Analizi

a) Sıcaklık b) Nem c) Basınç d) Rüzgâr hızı e) SO₂ f) PM₁₀ g) CO

Hesaplanan HKİ ve meteorolojik parametreler arasındaki ilişki incelendiğinde, HKİ ile nem ve basınç arasında pozitif ilişki olduğu görülürken, sıcaklık ve rüzgâr hızı ile arasında negatif ilişki olduğu görülmektedir. Meteorolojik parametreler ile olan en güçlü ilişki basınç ile, en zayıf ilişki ise nem ile olmuştur. Diğer taraftan, hesaplanan HKİ ile atmosferik parametrelerin tamamında pozitif ilişki olduğu görülmektedir. Atmosferik parametreler ile olan en güçlü ilişki PM₁₀ ile, en zayıf ilişki ise SO₂ ile olmuştur.

3.2. Ham Veriler ile AÖM Çalışması

AÖM algoritması ile yapılan sınıflandırma çalışmalarda *sinüs*, *sigmoidal* ve *hardlimit* aktivasyon fonksiyonları kullanılmıştır. Bu aktivasyon fonksiyonlarının test süreleri ve test doğruluk oranları karşılaştırılmıştır. Karşılaştırma sonucunda elde edilen değerler EK bölümündeki Tablo E1'de gösterilmiştir. Yapılan birinci karşılaştırmada kullanılan gizli nöron sayısı 50 olarak seçilmiştir. 50 gizli nöron seçilmesinin nedeni, AÖM algoritmasının ilk aşamada nasıl tepki verdiğini görmek ve diğer nöronların sayısını belirlemektir. AÖM algoritmasında, çıkış ağırlıkları analitik olarak hesaplanırken, giriş ağırlıkları rastgele hesaplanmaktadır. Bu nedenle, programın her çalışmasında elde edilen sonuçlar birbirine yakın fakat farklı değerler olabilmektedir. Bu sorunun üstesinden gelmek için AÖM algoritması ile yapılan değerlendirmede 3 kat çapraz doğrulama tekniği kullanılmıştır. Bu çalışmada maksimum 120 gizli nöron kullanılmıştır. Elde edilen sonuçlar test doğruluk oranları ve aktivasyon fonksiyonlarına göre incelendiğinde, en yüksek değer %76.42 test doğruluk oranı ve 0.000520 saniyelik test süresi ile *hardlimit* fonksiyonu tarafından karşılandığı görülmektedir. Hem *hardlimit* hem de *sine* ve *sigmoid* aktivasyon fonksiyonlarının farklı gizli nöron sayılarında nasıl tepki vereceğini incelemek için, bu üç aktivasyon fonksiyonunun 6 farklı nöron sayısına bağımlılığı incelenmiştir. Kullanılan gizli nöron sayıları tüm gizli nöronlara yakın ara değerlerden seçilmiştir. Bu doğrultuda elde edilen sonuçlar Tablo 1'de görülmektedir.

Tablo 1: Farklı Aktivasyon Fonksiyonu ve Nöron Sayısında Test Değerleri (Ham Veri)

Aktivasyon kodu - gizli nöron sayısı	Test Süresi (sn.)	Ortalama Test Doğruluğu (%)
sig-10	0.0003429	78.86
sin-10	0.0003433	33.33
hardlim-10	0.0004178	78.86
sig-25	0.0003677	79.68
sin-25	0.0003873	31.71
hardlim-25	0.0004554	66.67
sig-50	0.0004672	80.49
sin-50	0.0004997	34.15
hardlim-50	0.0004544	82.12
sig-75	0.0005035	65.85
sin-75	0.0005426	33.33
hardlim-75	0.0004760	85.37
sig-100	0.0005531	78.05
sin-100	0.0006763	37.40
hardlim-100	0.0004890	81.30
sig-120	0.0006389	72.36
sin-120	0.0006230	29.27
hardlim-120	0.0005296	82.93

Tablo 1'den görülebileceği gibi, en yüksek ortalama test doğruluğu oranı %85.37 oranında ve *hardlim-75* ile gerçekleşmiştir. Sonraki en yüksek test doğruluğu oranları ise sırasıyla *hardlim-120* ve *hardlim-50* ile ve %82.93 ve %82.12 ortalama doğruluk oranlarıdır. Bu sonuçlara göre en yüksek ortalama doğruluk oranına sahip olan *hardlim-75* aktivasyon fonksiyonu ve gizli nöron sayısı kullanılarak her biri 14 satırdan oluşan iki farklı test verisi üzerinde çalışmalar yapılmıştır. Test verileri, 14.01.2019-01.01.2019 ve 14.02.2019-01.02.2019 arasındaki verilerdir. Test verilerinin her satırında yedi adet giriş verisi ile bu giriş verilerine karşılık gelen HKİ değerleri bulunmaktadır. Ayrıca, HKİ değerlerine karşılık gelen ve bu çalışmada yapılan matematiksel sınıflandırma değerleri de bulunmaktadır. Bu değerler EK bölümündeki Tablo E2'de verilmiştir.

Buna göre en yüksek ortalama doğruluk oranına sahip olan *hardlim-75* aktivasyon fonksiyonu ve nöron sayısı 2019 yılının Ocak ayının ilk 14 günü verilerini içeren test verilerine uygulandığında elde edilen tahmini HKİ sınıflandırma değerleri Tablo 2'deki gibi olmuştur. Görüleceği üzere, 14 satırdan oluşan sınıflandırmanın 12 tane doğru sınıflandırmasına denk gelen %85.71'lik bir başarı elde edilmiştir. Bu oran yukarıda elde edilen %85.37 başarı oranına yakın bir değerdir. Test süresi 0.0004888 saniye

olarak elde edilmiştir. Bu sonuçlara göre, 14 adet sınıflandırma değerinin 12 tanesinin AÖM tarafından doğru tahmin edildiği görülmektedir.

Benzer şekilde, 2019 yılının Şubat ayının ilk 14 günlük test verileri kullanıldığında ise, AÖM yine % 85.71'lik bir başarımla elde etmiştir. Test süresi 0.0003357 saniye olarak elde edilmiştir. Her iki test verisi için, hem matematiksel HKİ sınıflandırma değerleri hem de AÖM tarafından yapılan tahmini HKİ sınıflandırma değerleri Tablo 2'de gösterilmektedir.

Tablo 2: AÖM Test Sonuçlarının Karşılaştırılması (Ham Veriler)

Tarih	Matematiksel Sınıflandırma	Tahmini AÖM Sınıflandırması	Tarih	Matematiksel Sınıflandırma	Tahmini AÖM Sınıflandırması
14.01.2019	2	2	14.02.2019	1	1
13.01.2019	2	2	13.02.2019	2	2
12.01.2019	2	2	12.02.2019	2	2
11.01.2019	2	2	11.02.2019	1	2
10.01.2019	2	2	10.02.2019	1	1
09.01.2019	1	1	09.02.2019	1	2
08.01.2019	2	2	08.02.2019	2	2
07.01.2019	2	2	07.02.2019	2	2
06.01.2019	1	2	06.02.2019	2	2
05.01.2019	2	2	05.02.2019	2	2
04.01.2019	2	1	04.02.2019	2	2
03.01.2019	1	1	03.02.2019	2	2
02.01.2019	2	2	02.02.2019	2	2
01.01.2019	1	1	01.02.2019	2	2

2019 yılı Ocak ayı test verilerinde iki adet yanlış HKİ sınıflandırma tahmini yapılmıştır. Matematiksel sınıflandırmaya göre 04.01.2019 tarihinde matematiksel HKİ sınıfı 2 iken, AÖM tarafından 1 olarak tahmin edilmiştir. 06.01.2019 tarihinde ise HKİ değeri matematiksel olarak 1. sınıfta iken, AÖM tarafından 2. sınıf olarak tahmin edilmiştir. Bunun nedeni, her iki tarihte hesaplanan HKİ değerlerinin sınır değer olan 50 değerine çok yakın olması ve AÖM algoritmasının bunu tahmin edememesidir. Aynı şekilde, 2019 yılı Şubat ayı test verilerinde de iki yanlış HKİ sınıflandırma tahmini yapılmıştır. Matematiksel sınıflandırma değerleri 09.02.2019 ve 11.02.2019 tarihlerinde 1 iken, AÖM tarafından 2. sınıf olarak tahmin edilmiştir.

3.3. Normalize Veriler ile AÖM Çalışması

Bu bölümde, normalize edilmiş verilerle HKİ sınıfının değerlerinin tahmin edilmesi amaçlanmıştır. Buna göre, normalize edilmiş verilerin 3 farklı aktivasyon fonksiyonuna ve 6 farklı gizli nörona bağımlılığı araştırılmıştır. Sonucun güvenilirliği için veriler kendi aralarında yine 3 kat çapraz doğrulama tekniğine tabi tutulmuşlardır. Elde edilen değerler Tablo 3'teki gibi olmuştur.

Tablo 3: Farklı Aktivasyon Fonksiyonu ve Nöron Sayısında Test Değerleri (Normalize Veri)

Aktivasyon kodu - gizli nöron sayısı	Test Süresi (sn.)	Ortalama Test Doğruluğu (%)
sig-10	0.0003916	73.98
sin-10	0.0004657	76.42
hardlim-10	0.0005113	43.09
sig-25	0.0004153	62.60
sin-25	0.0004465	85.37
hardlim-25	0.0004468	48.78
sig-50	0.0006831	61.79
sin-50	0.0006360	59.35
hardlim-50	0.0006188	59.35
sig-75	0.0006147	43.09
sin-75	0.0006132	50.41
hardlim-75	0.0005662	59.35
sig-100	0.0036135	46.34
sin-100	0.0006133	53.66
hardlim-100	0.0005662	57.72
sig-120	0.0007889	46.34
sin-120	0.0006365	47.15
hardlim-120	0.0005474	47.97

Tablo 3'ten görülebileceği gibi, en yüksek test doğruluğu oranı %85.37'lik başarı oranı ile sin-25'te elde edilmiştir. Bu doğrultuda, normalize edilmiş test verileri üzerinde yapılan çalışmada, sin-25 aktivasyon fonksiyonu ve gizli nöron sayısı kullanılmıştır. 14.01.2019-01.01.2019 ve 14.02.2019-01.02.2019 tarihleri arasındaki 7 adet normalize edilmiş giriş verisi ile bu giriş verilerine karşılık gelen HKİ değerleri ve matematiksel sınıflandırma değerleri EK bölümünde Tablo E3'te verilmiştir. 2019 yılı Ocak ayına ait normalize edilmiş 14 günlük test verileri için AÖM algoritması (sin-25) uygulandığında 0.0004551 saniyede %85.71 oranında başarı elde edilmiştir. 12 adet HKİ sınıflandırma değeri doğru tahmin edilmiştir.

Benzer şekilde, 2019 yılı Şubat ayına ait normalize edilmiş 14 adet test verisi kullanıldığında, AÖM algoritması (sin-25) %71.43'lük başarı göstermiştir. Tahmin süresi ise 0.0003926 saniye olmuştur. Sadece 10 adet HKİ verisi doğru olarak tahmin edilebilmiştir. Tablo 4, normalize edilmiş verilere karşılık gelen matematiksel HKİ sınıflandırma değerlerini ve AÖM tarafından yapılan HKİ sınıflandırma değerlerini göstermektedir.

Tablo 4: AÖM Test Sonuçlarının Karşılaştırılması (Normalize Veriler)

Tarih	Matematiksel Sınıflandırma	Tahmini AÖM Sınıflandırması	Tarih	Matematiksel Sınıflandırma	Tahmini AÖM Sınıflandırması
14.01.2019	2	2	14.02.2019	1	4
13.01.2019	2	2	13.02.2019	2	2
12.01.2019	2	2	12.02.2019	2	2
11.01.2019	2	2	11.02.2019	1	2
10.01.2019	2	2	10.02.2019	1	2
09.01.2019	1	1	09.02.2019	1	2
08.01.2019	2	2	08.02.2019	2	2
07.01.2019	2	2	07.02.2019	2	2
06.01.2019	1	2	06.02.2019	2	2
05.01.2019	2	2	05.02.2019	2	2
04.01.2019	2	1	04.02.2019	2	2
03.01.2019	1	1	03.02.2019	2	2
02.01.2019	2	2	02.02.2019	2	2
01.01.2019	1	1	01.02.2019	2	2

2019 yılı Ocak ayı normalize edilmiş test verilerinde de, ham verilerde olduğu gibi iki adet yanlış HKİ sınıflandırma tahmini yapılmıştır. Ham verilerle yapılan tahmin çalışmasında %85.71 oranında başarı elde edilirken, normalize edilmiş verilerle yapılan tahmin çalışmasında da % 85.71 oranında başarı elde edilmiştir. Bu başarımların süresi ham verilerle yapıldığında 0.0004888 saniye iken normalize edilmiş verilerle yapıldığında 0.0004551 saniye olmuştur. Bölüm 3.5'te de belirtildiği üzere verilerin normalize edilmesinin tahmin süresini kısmen de olsa azalttığı görülmektedir. 2019 yılı Şubat ayı normalize edilmiş test verileri ile yapılan tahmin çalışmasında AÖM algoritması 14 adet verinin 10 tanesini doğru tahmin ederek %71.43 oranında başarı elde etmiştir. Bu oran ham veriler ile yapılan tahmin çalışmasında %85.71 olarak elde edilmiştir.

3.4. Ham Veriler ile YSA Çalışması

Bu kısımda yapılan çalışmada da aynı eğitim ve test verileri kullanılmıştır. Yine 3 farklı eğitim fonksiyonu ve 6 farklı gizli nöron kullanılmıştır. Bu değerler EK bölümündeki Tablo E4'te verilmiştir. İlk karşılaştırma aşamasında kullanılan gizli nöron sayısı yine 50 olarak seçilmiştir. 50 nöron seçilmesinin nedeni, YSA algoritmasının ilk aşamada nasıl tepki verdiğini görmek ve asıl test verilerinde kullanılması gereken gizli nöron sayısını belirlemektir. Ortalama sonuçlar elde etmek için 3 kat çapraz doğrulama tekniği uygulanmıştır. Yapılan çalışma sonucunda elde edilen testin doğruluk oranları incelendiğinde, en yüksek doğruluk oranının %95.12 ile traincgp eğitim fonksiyonunda, daha sonra ise %92.68 doğruluk oranı ile trainbfg eğitim fonksiyonunda gerçekleşmiştir. Test doğruluğu oranı %90.24 olan iki eğitim fonksiyonu bulunmaktadır. Trainbr eğitim fonksiyonunun sonuca ulaşmada çok yüksek zaman gerektirmesinden dolayı aşağıdaki test çalışmalarında kullanılmamıştır. Bu doğrultuda çalışmalar en yüksek test doğruluğu oranına sahip olan traincgp, trainbfg ve traingd eğitim fonksiyonları ve bu fonksiyonların farklı gizli nöron sayılarında yapılmıştır. Yapılan çalışmalar sonucunda elde edilen değerler Tablo 5'teki gibidir.

Tablo 5: Farklı Eğitim Fonksiyonu ve Nöron Sayısında Test Değerleri (Ham Veri)

Aktivasyon kodu ve gizli nöron sayısı	Test Süresi (sn.)	Ortalama Test Doğruluğu (%)	Aktivasyon kodu ve gizli nöron sayısı	Test Süresi (sn.)	Ortalama Test Doğruluğu (%)
traincgp-10	0.1729	82.93	traincgp-75	0.2184	43.90
trainbfg-10	0.2642	85.37	trainbfg-75	2.6556	80.49
traingd-10	2.2404	95.12	traingd-75	3.5547	90.24
traincgp-25	0.3743	90.24	traincgp-100	0.6780	87.80
trainbfg-25	0.4836	90.24	trainbfg-100	6.5453	56.10
traingd-25	2.5513	97.56	traingd-100	0.1497	4.88
traincgp-50	0.1908	63.41	traincgp-120	0.2787	53.66
trainbfg-50	1.3862	82.93	trainbfg-120	18.8743	80.49
traingd-50	2.9794	92.68	traingd-120	2.0271	78.05

Tablo 5'te görülebileceği gibi, en yüksek test doğruluğu oranları traingd eğitim fonksiyonunun 10, 25 ve 50 gizli nöron sayılarında elde edilmiştir. En yüksek ortalama test doğruluğu oranları ise traingd-25 ile %97,56 oranında elde edilmiştir. Her iki test verisine ait tüm ham değerler EK bölümünde Tablo E2'de verilmiştir.

Buna göre, YSA algoritması traingd-25 aktivasyon fonksiyonu ve gizli nöron sayısında 123 satırdan oluşan eğitim verilerine ve 2019 yılı Ocak ayının ilk 14 günlük ham test verilerine uygulandığında %71.43 oranında başarı elde edilmiştir. Test süresi 2.4109 saniye olmuştur. Benzer şekilde, YSA algoritması aynı aktivasyon fonksiyonu ve nöron sayısında aynı eğitim verilerine ve 2019 yılı Şubat ayının ilk 14 günlük ham test verilerine uygulandığında ise %85.71 oranında başarı elde edilmiştir. Test süresi 2.5841 saniye olmuştur. Her iki test verisi için YSA tahmin sonuçları Tablo 6'daki gibidir.

Tablo 6: YSA Test Sonuçlarının Karşılaştırılması (Ham Veriler)

Tarih	Matematiksel Sınıflandırma	Tahmini YSA Sınıflandırması	Tarih	Matematiksel Sınıflandırma	Tahmini YSA Sınıflandırması
14.01.2019	2	1	14.02.2019	1	1
13.01.2019	2	2	13.02.2019	2	2
12.01.2019	2	2	12.02.2019	2	2
11.01.2019	2	2	11.02.2019	1	1
10.01.2019	2	2	10.02.2019	1	1
09.01.2019	1	2	09.02.2019	1	2
08.01.2019	2	2	08.02.2019	2	2
07.01.2019	2	2	07.02.2019	2	2
06.01.2019	1	1	06.02.2019	2	2
05.01.2019	2	2	05.02.2019	2	2
04.01.2019	2	1	04.02.2019	2	2
03.01.2019	1	2	03.02.2019	2	2
02.01.2019	2	2	02.02.2019	2	2
01.01.2019	1	1	01.02.2019	2	1

2019 yılı Ocak ayına ait 14 günlük ham test verilerine ait HKİ sınıflarının AÖM algoritması ile yapılan tahmin çalışmasında 0.0004888 saniyelik sürede %85.71'lik başarı oranı elde edilmişken, YSA algoritması ile yapılan tahmin çalışmasında 2.4109 saniyelik sürede %71.43'lik başarı elde edilmiştir. Aynı yılın Şubat ayına ait 14 günlük ham test verilerine ait HKİ sınıflarının AÖM algoritması ile yapılan tahmin çalışmasında ise 0.0003357 saniyelik sürede %85.71'lik başarı oranı elde edilmişken, YSA algoritması ile yapılan tahmin çalışmasında 2.5851 saniyelik sürede yine %85.71'lik başarı elde edilmiştir. Bu sonuçlara göre ham veriler ile yapılan sınıflandırma çalışmalarında AÖM algoritmasının daha başarılı olduğu sonucuna ulaşılabilmektedir.

3.5. Normalize Veriler ile YSA Çalışması

Bu bölümde, yine aynı verilerin normalize edilmesi durumunda YSA algoritmasının HKİ sınıfını tahmin etmesi üzerine bir çalışma yapılmıştır. Buna göre, normalize edilmiş verilerin 3 aktivasyon fonksiyonunun 6 farklı gizli nöron sayısına bağımlılığı araştırılmış ve Tablo 7 değerleri elde edilmiştir.

Tablo 7: Farklı Eğitim Fonksiyonu ve Nöron Sayısında Test Değerleri (Normalize Veriler)

Aktivasyon kodu ve gizli nöron sayısı	Test Süresi (sn.)	Ortalama Test Doğruluğu (%)	Aktivasyon kodu ve gizli nöron sayısı	Test Süresi (sn.)	Ortalama Test Doğruluğu (%)
traincgp-10	0.1734	63.41	traincgp-75	0.2647	68.29
trainbfg-10	0.2611	68.29	trainbfg-75	2.1783	70.73
traingd-10	2.4944	68.29	traingd-75	0.1590	0.00
traincgp-25	0.1443	26.83	traincgp-100	0.3978	68.29
trainbfg-25	0.4678	68.29	trainbfg-100	22.4158	75.61
traingd-25	1.7159	82.93	traingd-100	0.1317	0.00
traincgp-50	0.2588	78.05	traincgp-120	0.3530	68.69
trainbfg-50	1.8703	65.85	trainbfg-120	21.9830	63.41
traingd-50	3.5596	80.49	traingd-120	0.1367	0.00

Tablo 7'den görülebileceği gibi, en yüksek test doğruluğu oranı traingd-25 ile % 82.93 performans oranında elde edilmiştir. Ardından gelen en yüksek performans oranları ise traingd-50'de % 80.40 ve traincgp-50'de % 78.05 olmuştur. Traingd-25, 123 satırdan oluşan normalize edilmiş eğitim verilerine

ve 2019 yılı Ocak ayına ait normalize edilmiş test verilerine uygulandığında, 1.0494 saniye süre ile % 64.29 başarımla elde edilmiştir. Aynı şekilde, traingd-25 eğitim fonksiyonu ve nöron sayısı, normalize edilmiş eğitim verilerine ve 2019 yılı Şubat ayına ait 14 günlük normalize edilmiş test verilerine uygulandığında, 0.4575 saniyede % 42.86 başarımla elde edilmiştir. Her iki test verisi için elde edilen tahmin değerleri Tablo 8'de verilmiştir.

Tablo 8: YSA Test Sonuçlarının Karşılaştırılması (Normalize Veriler)

Tarih	Matematiksel Sınıflandırma	Tahmini YSA Sınıflandırması	Tarih	Matematiksel Sınıflandırma	Tahmini YSA Sınıflandırması
14.01.2019	2	2	14.02.2019	1	1
13.01.2019	2	2	13.02.2019	2	1
12.01.2019	2	2	12.02.2019	2	1
11.01.2019	2	2	11.02.2019	1	1
10.01.2019	2	2	10.02.2019	1	1
09.01.2019	1	2	09.02.2019	1	1
08.01.2019	2	1	08.02.2019	2	1
07.01.2019	2	2	07.02.2019	2	1
06.01.2019	1	0	06.02.2019	2	1
05.01.2019	2	2	05.02.2019	2	1
04.01.2019	2	1	04.02.2019	2	2
03.01.2019	1	2	03.02.2019	2	2
02.01.2019	2	2	02.02.2019	2	1
01.01.2019	1	1	01.02.2019	2	1

Bu sonuçlara göre AÖM algoritmasında olduğu gibi YSA algoritmasında da ham veriler ile yapılan çalışmaya ait başarımların normaliz edilmiş veriler ile yapılan başarımlardan daha yüksek olduğu görülmüştür. Bu bağlamda sadece ham veriler ile çalışma yapılmasının sonuçların tahminini yapmada yeterli olacağı sonucuna ulaşılmıştır.

2019 yılı Ocak ayına ait 14 günlük normalize edilmiş test verilerine ait HKİ sınıflarının AÖM algoritması ile yapılan tahmin çalışmasında 0.0004551 saniyelik sürede % 85.71'lik başarımla elde edilmişken, YSA algoritması ile yapılan tahmin çalışmasında 1.0494 saniyelik sürede % 64.29'luk başarımla elde edilmiştir. Aynı yılın Şubat ayına ait 14 günlük normalize edilmiş test verilerine ait HKİ sınıflarının AÖM algoritması ile yapılan tahmin çalışmasında ise 0.0003926 saniyelik sürede % 71.43'lük başarımla elde edilmişken, YSA algoritması ile yapılan tahmin çalışmasında 0.4575 saniyelik sürede yine % 42.86'lük başarımla elde edilmiştir. Bu sonuçlara göre ham veriler olduğu gibi normalize edilmiş veriler ile yapılan sınıflandırma çalışmalarında da AÖM algoritmasının daha başarılı olduğu sonucuna ulaşılabilmektedir.

Yukarıda literatür taraması yapılan kısımda belirtilen çalışmalar incelendiğinde genellikle PM₁₀, SO₂, CO parametreleri kullanılmışken bu çalışmada ek olarak sıcaklık, nem, basınç ve rüzgâr hızı parametreleri de HKİ değerinin belirlenmesinde giriş parametresi olarak dikkate alınmıştır. Meteorolojik parametrelerin HKİ değerini nasıl etkileyebileceğine dair analizler yapılmıştır. Analiz sonucuna göre HKİ ile en güçlü ilişkilerin atmosferik parametrelerden PM₁₀ ile, meteorolojik parametrelerden ise basınç ile olduğu sonucuna ulaşılmıştır. Ayrıca ham verilerin yanında normalize veriler ile de çalışmalar yapılmıştır. Farklı modeller kullanılan çalışmalarda Biancofiore vd. (2017), %95, Mekparıyup ve Saithanu (2020), %90 ve Dragomir (2010) %65.52 oranlarında başarımlar elde etmişlerdir. Zhang ve Ding (2017) tarafından yapılan çalışmada da atmosferik ve meteorolojik parametreler dikkate alınmıştır. AÖM ile FFANN-BP algoritmalarını karşılaştırılmıştır. AÖM'nin FFANN-BP algoritmasından daha başarılı sonucuna ulaşılmıştır. Bu çalışmada ise AÖM ile yapılan çalışmalarda ham veriler için %85.71, normalize veriler için %71.43 başarımla elde edilmiştir.

4. Sonuç

Bu çalışmada HKİ sınıf değerlerinin AÖM ve YSA algoritmaları ile tahmin edilmesi amaçlanmıştır. Elde edilen sonuçlara göre 2019 yılı Ocak ayına ait 14 günlük ham test verilerine ait HKİ sınıflarının AÖM algoritması ile yapılan tahmin çalışmasında %85.71'lik başarı oranı elde edilmişken, YSA algoritması ile yapılan tahmin çalışmasında %71.43'lik başarı elde edilmiştir. Aynı yılın Şubat ayına ait 14 günlük ham test verilerine ait HKİ sınıflarının hem AÖM hem de algoritması ile yapılan tahmin çalışmalarında ise %85.71'lik başarımlar elde edilmiştir. Bu sonuçlara göre ham veriler ile yapılan sınıflandırma çalışmalarında AÖM algoritması ile daha başarılı sonuçlar elde edilmiştir. 2019 yılı Ocak ayına ait 14 günlük normalize edilmiş test verilerine ait HKİ sınıflarının AÖM algoritması ile yapılan tahmin çalışmasında ise %85.71'lik başarı oranı elde edilmişken, YSA algoritması ile yapılan tahmin çalışmasında %64.29'luk başarı elde edilmiştir. Şubat ayına ait 14 günlük normalize edilmiş test verilerine ait HKİ sınıflarının AÖM algoritması ile yapılan tahmin çalışmasında ise %71.43'lük başarı oranı elde edilmişken, YSA algoritması ile yapılan tahmin çalışmasında %42.86'lik başarı elde edilmiştir. Sonuç olarak, bu çalışmada AÖM ile yapılan çalışmalarda ham verilerde %85.71, normalize verilerde %71.43 başarı gösterilmiştir. Hem meteorolojik hem de atmosferik parametrelerin dikkate alındığı AÖM ve YSA algoritmaları ile yapılan bu sınıflandırma çalışmasının insan sağlığını olumsuz etkileyebilecek HKİ değerinin tahmin edilmesinde yol gösterici olacağı düşünülmektedir.

Çıkar Çatışmaları

Yazar herhangi bir çıkar çatışması beyan etmemektedir.

Referanslar

- [1] Shaban, K.B., Kadri, A. and Rezk, E., 2016. Urban Air Pollution Monitoring System With Forecasting Models. *IEEE Sensors Journal*, 16 (8). DOI: 10.1109/JSEN.2016.2514378.
- [2] Yang, Z. and Wang, J., 2017. A new air quality monitoring and early warning system: Air quality assessment and air pollutant concentration prediction. *Environmental Research*, <https://www.sciencedirect.com/science/journal/00139351/158/supp/C158>, 105-117. <https://doi.org/10.1016/j.envres.2017.06.002>.
- [3] Karamchandani, S. and Gupta, D., 2016. Pervasive monitoring of carbon monoxide and methane using air quality prediction. 3rd International Conference on Computing for Sustainable Global Development (INDIACom).
- [4] Karacı, A., 2018. Akıllı Şehir Hava Takip Sistemi ve Astım Hastaları için PM2.5 Konsantrasyonu Ölçüm Aracının Geliştirilmesi, *Mühendislik Bilimleri ve Tasarım Dergisi*, 6:3, 418 – 425. <https://doi.org/10.21923/jesd.412665>.
- [5] Turaliöglu, F.S., 2005. An Assessment on Variation of Sulphur Dioxide and Particulate Matter in Erzurum (Turkey). *Environmental Monitoring Assessment*, 104, 119–130.
- [6] EPA, 2019. Birleşik Devletler Çevre Koruma Ajansı. Karbon monoksit Hava Kirliliği. <https://www.epa.gov/>.
- [7] Rao, K.S. Devi, G.L. and Ramesh, N., 2019. Air Quality Prediction in Visakhapatnam with LSTM based Recurrent Neural Networks. *International Journal of Intelligent Systems and Applications*, 2, 18-24. DOI: 10.5815/ijisa.2019.02.03.
- [8] Temiz, İ. and Turgut, D., 2015. Time Series Analysis and Forecasting For Air Pollution In Ankara: A Box-Jenkins Approach. *Alphanumeric Journal*, 3 (2), 131-138. <https://doi.org/10.17093/aj.2015.3.2.5000148347>.
- [9] Sevinç, E., 2022. An empowered AdaBoost algorithm implementation: A COVID-19 dataset study. *Computers & Industrial Engineering*, 165:107912. doi: 10.1016/j.cie.2021.107912.
- [10] Cihan, P., Ozel, H., & Ozcan, H. K. (2021). Modeling of atmospheric particulate matters via artificial intelligence methods. *Environmental Monitoring and Assessment*, 193 (5), 1-15. <https://doi.org/10.1007/s10661-021-09091-1>.
- [11] Baran, B., 2021. Air Quality Index Prediction in Besiktas District by Artificial Neural Networks and K Nearest Neighbours. *Journal of Engineering Sciences and Design*, 9(1): 52 – 63. DOI: 10.21923/jesd.671836.
- [12] Shishegaran, A., Saeedi, M., Kumar, A. and Ghiasinejad, H., 2020. Prediction of air quality in Tehran by developing the nonlinear ensemble model. *Journal of Cleaner Production*, 259, 120825. <https://doi.org/10.1016/j.jclepro.2020.120825>.
- [13] Wang, J., Du, P., Hao, Y., Ma, X., Niu, T. and Yang, W., 2020. An innovative hybrid model based on outlier detection and correction algorithm and heuristic intelligent optimization algorithm for daily air quality index forecasting. *Journal of Environmental Management*, 255, 109855. <https://doi.org/10.1016/j.jenvman.2019.109855>.
- [14] Baran, B., 2019. Aşırı Öğrenme Makineleri ile Rüzgar Hızına Bağlı Enerji Tahmini: Malatya Örneği. 1. Ulusal

- Mühendislik ve Teknoloji Kongresi (UMTK). 56-62.
- [15] Liu, H., Li, Q., Yu, D. and Gu, Y., 2019. Air Quality Index and Air Pollutant Concentration Prediction Based on Machine Learning Algorithms. *Applied Sciences*, 9 (4069), 1-9. <https://doi.org/10.3390/app9194069>.
- [16] Sevinç, E., 2019. A Novel Evolutionary Algorithm for Data Classification Problem With Extreme Learning Machines, *IEEE Access*, 7:122419-122427, doi: 10.1109/ACCESS.2019.2938271.
- [17] Zou, Z., Cai, T. and Cao, K., 2019. An urban big data-based air quality index prediction: A case study of routes planning for outdoor activities in Beijing. *Environment and Planning B: Urban Analytics and City Science*. <https://doi.org/10.1177/2399808319862292>.
- [18] Bai, Y., Li, Y., Wang, X., Xie, J. and Li, C., 2016. Air pollutants concentrations forecasting using back propagation neural network based on wavelet decomposition with meteorological conditions. *Atmospheric Pollution Research*, 7 (3), 557-566. <https://doi.org/10.1016/j.apr.2016.01.004>.
- [19] Baran, B., 2019. Prediction of Air Quality Index by Extreme Learning Machines. 2019 International Artificial Intelligence and Data Processing Symposium (IDAP), 1-8. doi: 10.1109/IDAP.2019.8875910.
- [20] Zhang, J. and Ding, W., 2017. Prediction of Air Pollutants Concentration Based on an Extreme Learning Machine: The Case of Hong Kong. *International Journal of Environmental Research and Public Health*, 14 (2), 114. doi: 10.3390/ijerph14020114.
- [21] Sevinç, E., 2018. Activation functions in single hidden layer feed-forward neural networks. *Selcuk University Journal of Engineering Sciences*, 1-13.
- [22] Zhu, S., Lian, X., Liu, H., Hu, J., Wang, Y.Y. and Che, Z., 2017. Daily air quality index forecasting with hybrid models: A case in China. *Environmental Pollution*, 231 (2), 1232-1244. DOI: 10.1016/j.envpol.2017.08.069
- [23] Peng, H., Lima, A.R., Teakles, A., Jin, J., Cannon, A.J. and Hsieh, W.W., 2017. Evaluating hourly air quality forecasting in Canada with nonlinear updatable machine learning methods. *Air Quality, Atmosphere, & Health*, 10 (2), 195-211.
- [24] Jose, L.A., 2017. Probabilistic forecasting for extreme NO2 pollution episodes. *Environmental Pollution*, 229, 321-328. <https://doi.org/10.1016/j.envpol.2017.05.079>.
- [25] Patricio, P. and Ernesto, G., 2016. Forecasting hourly PM2.5 in Santiago de Chile with emphasis on night episodes. *Atmospheric Environment*, 124, 22-27. <https://doi.org/10.1016/j.atmosenv.2015.11.016>.
- [26] Avşar, E., 2015. Balıkesir İli Burhaniye İlçesi (İskele Mahallesi) hava kalitesinin Değerlendirilmesi. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 4(1): 68-82. <https://doi.org/10.17798/beufen.40291>
- [27] Vong, C.M., Fai Ip, W., Wong, P.K. and Chiu, C.C., 2014. Predicting minority class for suspended particulate matters level by extreme learning machine. *Neurocomputing*, 128, 136-144. <https://doi.org/10.1016/j.neucom.2012.11.056>.
- [28] Moustiris, K.P., Ziomas, I.C. and Paliatsos, A.G., 2010. 3-Day-Ahead Forecasting of Regional Pollution Index for the Pollutants NO2, CO, SO2, and O3 Using Artificial Neural Networks in Athens, Greece. *Water, Air, & Soil Pollution*, 209 (1-4), 29-43.
- [29] Biancofiore, F., Busilacchio, M., Verdecchia, M., Tomassetti, B., Aruffo, E., Bianco, S., Di Tommaso, S., Colangeli, C., Rosatelli, G. and Di Carlo, P., 2017. Recursive neural network model for analysis and forecast of PM10 and PM2.5. *Atmospheric Pollution Research*, 8, 652-659. <https://doi.org/10.1016/j.apr.2016.12.014>.
- [30] Mekparyup, J. and Saithanu, K., 2020. Air Quality Index Prediction in the Eastern Regions of Thailand with Accuracy of Neural Networks. *International Journal of Applied Engineering Research*, 15 (5), 436-444.
- [31] Liu, B.C., Binaykia, A., Chang, P.C., Tiwari, M.K. and Tsao, C.C., 2017. Urban air quality forecasting based on multi-dimensional collaborative Support Vector Regression (SVR): A case study of Beijing-Tianjin-Shijiazhuang. *PLoS ONE*, 12 (7), e0179763. <https://doi.org/10.1371/journal.pone.0179763>.
- [32] Ganesh, S.S., Arulmozhivarman, P. and Tatavarti, R., 2017. Forecasting Air Quality Index Using an Ensemble of Artificial Neural Networks and Regression Models. *Journal of Intelligent Systems*. <https://doi.org/10.1515/jisys-2017-0277>.
- [33] Saatcioglu, T., Alp, K., Hanedar, A. and Avşar, E., (2011). Effect of the marmaray project on air pollution in Istanbul: An ıve model application, *Fresenius Environmental Bulletin*. 20 (9): 2340-2349,
- [34] Dragomir, E.G., 2010. Air Quality Index Prediction using K-Nearest Neighbor Technique. *Bulletin of PG University of Ploiesti, Series Mathematics, Informatics, Physics*, 62 (1), 103-108.
- [35] Jiao, Y., Wang, Z. and Zhang, Y., 2019. Prediction of Air Quality Index Based on LSTM. *IEEE 8th Joint International Information Technology and Artificial Intelligence Conference (ITAIC)*, Chongqing-China, 17-20. doi: 10.1109/ITAIC.2019.8785602.
- [36] Kadilar, G.O and Kadilar, C., 2017. Assessing air quality in Aksaray with time series analysis. *AIP Conference Proceedings*, 1833, 020112.
- [37] Avşar, E., Hanedar, A., Toroz, I., Alp, K. and Kaynak, B., (2010). Investigation of PM₁₀ Concentrations And Noise Levels of The Road Sweepers Operating In Istanbul-Turkey: A Case Study, *Fresenius Environmental Bulletin* 19 (9b).
- [38] AQI Calculator, 2018. Hava Kalitesi İndeksi Hesaplama Aracı. https://app.cpcbcr.com/ccr_docs/AQI%20-Calculator.xls.
- [39] YSAb, 2019. Yapay Sinir Ağları. <https://blogs.mathworks.com/loren/2015/08/04/artificial-neural-networks-for-beginners/>.

- [40] Time and Data, 2019. Ankara İli 2018-2019 Hava Durumu Bilgisi. <https://www.timeanddate.com/weather/turkey/ankara/historic>.
- [41] Taşdelen, B., 2019. Korelasyon ve Regresyon Analizi. Erişim adresi: <https://docplayer.biz.tr/47627312-Korelasyon-ve-regresyon-analizi-doc-dr-bahar-tasdelen.html>.
- [42] Huang, G.B., Zhu, Q.Y. and Siew, C.K., 2006. Extreme Learning Machine: Theory and Applications. *Neurocomputing*, 70, 489-501. <https://doi.org/10.1016/j.neucom.2005.12.126>.
- [43] Kaya, Y., 2014. A Fast Intelligent Diagnosis System For Thyroid Diseases Based On Extreme Learning Machine. *Bilim ve Teknoloji Dergisi A-Uygulamalı Bilimler ve Mühendislik*, 15 (1). <https://doi.org/10.18038/btd-a.89202>.
- [44] Baran, B., 2019. Sınır Değerler Arasında Kalan Evsel Atıksu Numune Analizi Sonucunun Aşırı Öğrenme Makineleri ile Sınıflandırılması. *Mühendislik Bilimleri ve Tasarım Dergisi*, 7 (1), 18 – 25. <https://doi.org/10.21923/jesd.457085>.
- [45] YSAa, 2019. Yapay Sinir Ağları. <http://kod5.org/yapay-sinir-aglari-ysa-nedir/>.
- [46] İnalpulat, M., Kızıl, Ü., Bilgücü, E. and Genç, L., 2016. E-Nose Identification of Milk Somatic Cell Count, *Çanakkale Onsekiz Mart Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 2:1, 22-35.
- [47] Saphioğlu, K., Küçükerdem Öztürk, T.S. and Şenel, FA., 2020. Eksik Hidrolojik Verilerin Simbiyotik Organizmalar Arama Algoritması ile Tahmini, *Çanakkale Onsekiz Mart Üniversitesi Fen Bilimleri Enstitüsü Dergisi Açık Erişim*, 6:1, 93-104. <https://doi.org/10.28979/comufbed.628846>.
- [48] FFBPNNa, 2019. Feed-forward Back Propagation Neural Network. <https://stackoverflow.com/questions/28403782/what-is-the-difference-between-back-propagation-and-feed-forward-neural-network>.
- [49] Yavuz, S. and Deveci M., 2012. İstatiksel Normalizasyon Tekniklerinin Yapay Sinir Ağın Performansına Etkisi. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 40 (2), 167-187.

EK

Bu çalışmaya ait ek veriler aşağıdaki gibidir.

Tablo E1: Farklı Aktivasyon Fonksiyonlarında Test Süresi ve Test Doğruluk Değerleri (50 nöron)

Aktivasyon Fonksiyonu	Test Süresi (sn.)	Test Doğruluğu (%)
sig	0.001073	71.54
sin	0.000582	30.90
hardlim	0.000520	76.42

Tablo E2: Parametreler ve Matematiksel Sınıflandırma Değerleri (ham veri / 14.01.2019-01.01.2019 ve 14.02.2019-01.01.2019)

14.01.2019 - 01.01.2019									14.02.2019 - 01.02.2019								
PM ₁₀	SO ₂	CO	Sıcaklık	Nem (%)	Basınç (mbar)	Rüzgar hızı (kmh)	Hesaplanan Hız	Matematiksel Sınıf	PM ₁₀	SO ₂	CO	Sıcaklık	Nem (%)	Basınç (mbar)	Rüzgar hızı (kmh)	Hesaplanan Hız	Matematiksel Sınıf
26.18	2.94	1360	6	77	1002	11	68	2	37.36	11.78	574	7	68	1014	20	37	1
48.53	5.16	1502	4	86	1005	3	75	2	56.06	12.38	1305	11	54	1017	10	65	2
35.06	5.85	1400	7	66	1010	6	70	2	53.58	11.33	1378	13	46	1015	15	69	2
47.35	10.05	1560	7	64	1018	9	78	2	31.67	9.05	978	9	57	1018	13	49	1
71.22	16.49	1956	1	60	1019	11	98	2	28.44	10.41	922	8	64	1018	9	46	1
18.16	10.19	977	-3	63	1017	9	49	1	30.85	10.9	1042	8	76	1015	6	50	1
40.45	8.47	1063	-1	62	1008	13	53	2	32.64	9.94	1116	8	85	1013	7	55	2
35.61	14.14	1280	-1	74	1013	4	64	2	40.16	12.37	1258	9	81	1012	12	63	2
32.57	8.86	983	-1	92	999	12	49	1	59.6	18.08	1353	11	68	1017	8	68	2
47.15	6.67	1389	2	87	1009	9	70	2	69.05	15	1340	16	37	1021	10	69	2
27.32	6.47	1014	5	55	1017	23	51	2	79.38	13.81	1816	16	37	1023	6	90	2
18.8	5.7	956	8	68	1010	11	48	1	66.74	10.87	1543	13	42	1022	4	77	2
49.42	10.94	1441	5	80	1009	3	72	2	50.84	14.1	1545	9	55	1021	6	78	2
31.33	9.38	936	-1	67	1019	18	47	1	16.93	10.49	1077	7	64	1016	31	54	2

Tablo E3: Parametreler ve Matematiksel Sınıflandırma Değerleri (normalize veri / 14.01.2019-01.01.2019 ve 14.02.2019-01.01.2019)

14.01.2019 - 01.01.2019									14.02.2019 - 01.02.2019								
PM ₁₀	SO ₂	CO	Sıcaklık	Nem (%)	Basınç (mbar)	Rüzgar hızı (kmh)	Hesaplanan Hızı	Matematiksel Sınıf	PM ₁₀	SO ₂	CO	Sıcaklık	Nem (%)	Basınç (mbar)	Rüzgar hızı (kmh)	Hesaplanan Hızı	Matematiksel Sınıf
0,07	0,011	0,442	0,237	0,810	0,103	0,003	68	2	0,125	0,097	0,035	0,263	0,696	0,517	0,645	37	1
0,18	0,032	0,516	0,184	0,924	0,207	0,007	75	2	0,220	0,103	0,413	0,368	0,519	0,621	0,323	65	2
0,11	0,039	0,463	0,263	0,671	0,379	0,012	70	2	0,208	0,093	0,452	0,421	0,418	0,552	0,484	69	2
0,18	0,080	0,546	0,263	0,646	0,655	0,021	78	2	0,096	0,071	0,244	0,316	0,557	0,655	0,419	49	1
0,30	0,143	0,751	0,105	0,595	0,690	0,022	98	2	0,079	0,084	0,215	0,289	0,646	0,655	0,290	46	1
0,03	0,082	0,244	0,000	0,633	0,621	0,020	49	1	0,091	0,089	0,277	0,289	0,797	0,552	0,194	50	1
0,14	0,065	0,288	0,053	0,620	0,310	0,010	53	2	0,101	0,079	0,316	0,289	0,911	0,483	0,226	55	2
0,12	0,120	0,401	0,053	0,772	0,483	0,016	64	2	0,139	0,103	0,389	0,316	0,861	0,448	0,387	63	2
0,10	0,069	0,247	0,053	1,000	0,000	0,000	49	1	0,239	0,159	0,439	0,368	0,696	0,621	0,258	68	2
0,17	0,047	0,457	0,132	0,937	0,345	0,011	70	2	0,287	0,129	0,432	0,500	0,304	0,759	0,323	69	2
0,07	0,045	0,263	0,211	0,532	0,621	0,020	51	2	0,340	0,117	0,678	0,500	0,304	0,828	0,194	90	2
0,03	0,038	0,233	0,289	0,696	0,379	0,012	48	1	0,275	0,088	0,537	0,421	0,367	0,793	0,129	77	2
0,19	0,089	0,484	0,211	0,848	0,345	0,011	72	2	0,194	0,120	0,538	0,316	0,532	0,759	0,194	78	2
0,09	0,074	0,223	0,053	0,684	0,690	0,022	47	1	0,020	0,085	0,296	0,263	0,646	0,586	1,000	54	2

Tablo E4. Farklı aktivasyon fonksiyonlarında test süreleri ve test doğruluk değerleri
(50 nöron-ham veri)

Aktivasyon Fonksiyonu	Test Süresi (sn.)	Test Doğruluğu (%)	Aktivasyon Fonksiyonu	Test Süresi (sn.)	Test Doğruluğu (%)
trainlm	0.3311	63.41	traincgf	0.2612	80.49
trainbr	24.8269	90.24	traincgp	0.5598	95.12
trainbfg	5.7137	92.68	trainoss	0.2690	75.61
trainrp	0.1815	65.85	traingdx	0.7939	87.80
trainscg	0.2217	87.80	traingdm	0.2008	39.02
traincgb	0.1998	78.05	traingd	3.6422	90.24