

PAPER DETAILS

TITLE: İyonosfer Parametrelerinin Çok Katmanlı Algılayıcılar ile Kestirimi

AUTHORS: Muzaffer Can İBAN, Erman SENTÜRK

PAGES: 1480-1494

ORIGINAL PDF URL: <https://dergipark.org.tr/tr/download/article-file/1809312>



Makale / Research Paper

İyonosfer Parametrelerinin Çok Katmanlı Algılayıcılar ile Kestirimi

Muzaffer Can İBAN^{a*}, Erman ŞENTÜRK^b

^aMersin Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü. Mersin/TÜRKİYE

^bKocaeli Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü. Kocaeli/TÜRKİYE

caniban@mersin.edu.tr

Received/Geliş: 06.06.2021

Accepted/Kabul: 12.08.2021

Öz: İyonosferik parametrelerin değişimi, uzay iklimi, haberleşme ve seyrüsefer konularında oldukça önemli bir role sahiptir. Bu çalışmada, derin öğrenme yöntemlerinden olan Çok Katmanlı Algılayıcılar (ÇKA) regresyonu modelinin F2 Katmanlı Kritik Frekansı (foF2), Tepe Elektron Yoğunluğunun F2 Katmanlı Yüksekliği (hmF2) ve Toplam Elektron İçeriği (TEC) gibi iyonosfer parametrelerini kestirim performansı analiz edilmiştir. 01.01.2012 ile 31.12.2013 tarihleri arasında, ROME (RO041) digisonde istasyonunun saatlik foF2 ve hmF2 değerleri ile M0SE00ITA istasyon kodlu Uluslararası GNSS Servisi (IGS) istasyonunun saatlik TEC değerleri kullanılmıştır. Her iki istasyon da birbirine oldukça yakındır ve orta enlem bölgesinde bulunmaktadır. Eğitilecek girdi parametreler, verilerin gözlem periyotları, F10.7 güneş indeksi, jeomanyetik Ap indeksinin saatlik değerleri ve mevcut (t) zamanındaki foF2, hmF2 ve TEC değerleri ile bunların bir önceki güne ait (t-23) değerleri olarak seçilmiştir. Çıktı değişken, bu parametrelerin bir saat ileri (t+1) tahmin değerleridir. 2012 yılı verileri modelin eğitiminde kullanılmıştır. 2013 yılı verileri üzerinde gerçekleştirilen tahminin doğruluğu için Kök Karesel Ortalama Hata (KKOH) ve korelasyon değerleri hesaplanmış olup, bu değerler tüm yıl, yaz, kış ve ekinoks dönemleri için ayrı ayrı karşılaştırılmıştır. Sonuçlar, kestirim performansının genellikle kış döneminde daha yüksek, yaz döneminde ise diğer dönemlere göre düşük olduğunu göstermiştir. Ulaşılan istatistiksel sonuçlara göre, modelin çoklu iyonosferik parametrelerin tahmininde genel anlamda başarılı olduğu tespit edilmiştir.

Anahtar Kelimeler: İyonosferik parametre kestirimi; derin öğrenme; çok katmanlı algılayıcı

The Prediction of Ionospheric Parameters Using Multi-layer Perceptrons

Abstract: The variation of ionospheric parameters has crucial role in space weather, communication, and navigation. In this research, we analyze prediction performance of Multi-layer Perceptron (MLP) regression model, one of deep learning algorithms, for F2-layer Critical Frequency (foF2), F2-layer Height of the Peak Electron Density (hmF2), and Total Electron Content (TEC). Hourly foF2 and hmF2 values of ROME (RO041) digisonde and hourly TEC values of an International GNSS Service (IGS) station with site code M0SE00ITA were obtained for the period between 01.01.2012 and 31.12.2013. Both stations are located in mid-latitude region and are situated very close. The inputs to be trained are the observation periods of data, hourly values of solar index F10.7 and geomagnetic index Ap, present values of foF2(t), hmF2(t), TEC(t), and their values at t-23h. The output is the predicted values of parameters at t + 1. The 2012 values were used to train the model and they were predicted 1 hour in advance during 2013. Root Mean Square Error (RMSE) and correlation values between observed and predicted data were compared for the whole year, summer, winter, and equinox periods. The results showed that prediction performance of model is generally higher in winter period and partially lower in summer period than the others. The statistical results obtained show that the model was generally successful in forecasting multiple ionospheric parameters.

Keywords: Ionospheric parameter prediction; deep learning; multi-layer perceptron

Bu makaleye atıf yapmak için

İban, M.C., Şentürk, E., "İyonosfer Parametrelerinin Çok Katmanlı Algılayıcılar ile Kestirimi" El-Cezeri Fen ve Mühendislik Dergisi 2021, 8(3); 1480-1494.

How to cite this article

İban, M.C., Şentürk, E., "The Prediction of Ionospheric Parameters Using Multi-layer Perceptrons" El-Cezeri Journal of Science and Engineering, 2021, 8(3); 1480-1494.

ORCID ID: ^a0000-0002-3341-1338; ^b0000-0002-0833-7113

1. Giriş

Dünya'nın atmosferi, yükseklik, kimyasal ve termal özelliklere göre farklı katmanlardan oluşur. İyonosfer, Dünya yüzeyinin yaklaşık 60-1000 km yukarısında bulunan atmosfer tabakasıdır. İyonosferin kimyasal içeriği güneş ve kozmik radyasyona bağlı olarak değişmektedir. Bu katmandaki moleküller güneş ışığının enerjisine maruz kaldığında negatif elektronlar ve pozitif iyonlar ortaya çıkmaktadır. Bu iyonize gazlar, iyonosferi farklı yüksekliklerde üç katmana ayırmaktadır: D, E, F (F1 ve F2). D ve E katmanları Dünya yüzeyine daha yakındır ve 10-50 MHz aralığındaki radyo sinyallerini yansıtarak radyo iletişimini sağlar. F katmanı ise iyonosferin daha üst tarafında yer aldığı için, diğer tabakalara göre güneş ışınlarına daha fazla maruz kalmaktadır. Gündüz saatlerinde yüksek güneş ışınımı nedeniyle, F katmanı F1 ve F2 olarak ikiye ayrılmaktadır. Bu katmanlarda oluşan plazma, frekansı en az 50 MHz ve üzeri olan sinyallerin zayıflama etkisi ile birlikte uzay boşluğu ve Dünya arasında dolaşımını mümkün kılar [1]. F katmanı, özellikle de F2, Küresel Konum Belirleme Sistemi (Global Navigation Satellite Systems - GNSS) uygulamalarında önemli bir hata kaynağıdır. Kod gözlemlerinde gecikmeye ve faz gözlemlerinde hızlanmaya sebep olmaktadır. Bir başka deyişle, iyonize moleküllerden ayrılan serbest elektronların sayısı, bu gecikme ve hızlanma etkisinin derecesini belirler [2].

Taban alanı bir metrekaare olan silindirik bir hacimdeki serbest elektron miktarına 'Toplam Elektron İçeriği' (TEC) denir. TEC'in birimi TECU ise, bir metrekaareye düşen 10^{16} elektronun miktarına eşittir. Diğer önemli iyonosferik parametreler ise, F2 Katmanı Kritik Frekansı (f_0F2) ve Tepe Elektron Yoğunluğunun F2 Katmanı Yüksekliğidir (h_mF2). f_0F2 , iyonosferik F2 katmanı tarafından yansıtılan ya da bu katmandan nüfuz eden radyo frekansını tanımlamak için kullanılır. Bir radyo sinyali, frekansı f_0F2 değerinin üzerinde olduğunda yalnızca F2 katmanından geçebilir. h_mF2 ise, F2 katmanında maksimum elektron yoğunluğunun olduğu yüksekliği gösterir. Bu yükseklik, elektron içeriği ölçümleri için bölgesel tek katmanlı iyonosferik yüksekliği belirlemek adına önemlidir [3].

İyonosferik parametreler (f_0F2 , h_mF2 , TEC) saatlik, günlük, mevsimsel ve yıllık değişimler göstermektedir [4]. Ayrıca bu parametreler uzay iklimi, doğal ve insan kaynaklı olaylar esnasında da belirli mertebede değişiklikler gösterir [5], [6].

Elektromanyetik sinyallerde iyonosferik etki frekansa bağlı olduğundan, GNSS sinyallerinde iyonosferik gecikme/hızlanma etkisinden kaynaklı hata çift frekanslı alıcılarda giderilebilir. Bu cihazların maliyetinin yüksek olması nedeniyle araç takip, nesne coğrafi referanslama, hassas tarım vb. pratik uygulamalarda ucuz tek frekanslı alıcılar tercih edilmektedir. İyonosferik gecikme, tek frekanslı alıcılar için Klobuchar, NeQuick, IRI gibi çeşitli deneysel iyonosferik modellerle ortadan kaldırılmaya çalışılmaktadır. Gerçek zamanlı GPS seyrüsefer uygulamaları için en çok kullanılan model, GPS yayın efemeris (brdc) dosyalarında yer alan Klobuchar katsayılarıdır (4 alfa ve 4 beta katsayısı). Ancak bu model, iyonosferik hatanın sadece %50'sini ortadan kaldırabilir [7]. Özellikle olumsuz uzay iklimi koşullarında hatalar giderek artmaktadır. Bu nedenle, iyonosferik parametrelerin modellenmesi veya tahmin edilmesi, haberleşme ve seyrüsefer uygulamaları için önemli bir çalışma alanıdır. Gerçek zamanlı veya yakın-gerçek zamanlı iyonosferik veri setlerinin hazırlanması ve sunulmasında kestirilmiş parametrelerin önemi açık bir şekilde ortaya çıkmaktadır.

Önceki çalışmalarda birçok araştırmacı doğrusal ve doğrusal olmayan regresyon yöntemlerini kullanarak farklı uzay iklimi koşulları altında ve farklı lokasyonlarda iyonosferik parametreleri (f_0F2 , h_mF2 ve TEC) tahmin etmiş ve yöntemlerin performanslarını diğer deneysel ve tahmin modelleri ile karşılaştırmıştır. Altınay vd. [8], f_0F2 değerlerini bir saat önceden tahmin etmek için çok katmanlı algılayıcı tipi bir Yapay Sinir Ağı (YSA) modeli önermiştir. YSA modellerinin f_0F2 değerlerini, geleneksel olarak saatlik ortalamalarını almaya dayalı tahmin modeline nazaran iki kat daha doğru sonuçlar verdiğini öne sürmüşlerdir. Stanislawski ve Zbyszynski [9], [10] ise hem sakin

hem de hareketli iyonosferik koşullar esnasında tek bir noktaya ait f0F2 değerlerini tahmin etmek için oto-kovaryans yöntemini kullanmışlardır. Bu çalışmalar, uzun süreli jeomanyetik hareketlilik döneminde ve çok sakin koşullarda da kabul edilebilir bir doğruluk sağlamıştır. Chen vd. [11], [12] çalışmalarında, yüksek ve düşük güneş aktivitelerinde 1 ila 5 saat öncesinden Çin'deki yedi istasyon için f0F2 parametresinin değerlerini tahmin etmek için destek vektör makinesi regresyon yöntemini ortaya koymuşlardır. Bulgularını oto-korelasyon ve YSA modelleri ile karşılaştırmış ve otokorelasyona göre daha iyi, ancak YSA ile benzer performansa sahip sonuçlar elde etmişlerdir. Athieno vd. [13], kutup noktasına yakın tek bir istasyonda f0F2 değerlerini tahmin etmek için bir YSA modeli geliştirmiş ve sonuçlarını Uluslararası Referans İyonosfer (International Reference Ionosphere, IRI) - 2012 ile karşılaştırmıştır. Tahminler ve gözlemler arasındaki Kök Karesel Ortalama Hata (KKOH) değerleri, önerilen YSA modelinin düşük güneş aktivitesinin olduğu ekinokslar arası dönemde IRI - 2012 modelinden daha iyi performans ortaya koyduğunu göstermiştir. Fan vd. [14], Çin'in Wuhan istasyonunda bir saat ileriye yönelik f0F2 değerlerini tahmin etmek için parçacık sürü optimizasyonu ile Elman Sinir Ağı'nı (ESA) bütünleştirmiştir. KKOH değerleri geriye yayımlı YSA modelinden %8,92 daha düşük çıkan bu çalışmada, sonuçlar geleneksel ESA'ya göre %4,3 daha iyi performans sergilemiştir. Li vd. [15], f0F2 ve hmF2 değerlerini tahmin etmek için küresel iyonosferik modeller (GIPFM, GIPHM) oluşturmak adına genetik algoritmaları kullanan en yeni YSA tekniğini kullanmış ve bu modelleri 2009 ve 2013 yıllarında IRI modeli ile karşılaştırmışlardır. Önerilen modellerin KKOH değerleri, IRI modeline göre %20 ila %35 daha düşük çıkmıştır.

Bu çalışmada, zaman değişkenini bir girdi değişkeni olarak kullanmadan, birden fazla iyonosferik parametreyi tahmin etmek için derin öğrenme modellerinden olan Çok Katmanlı Algılayıcılar (ÇKA) regresyonu yönteminin performansı değerlendirilmiştir. Herhangi bir konudaki tahmin çalışmaları için evrensel olarak kabul edilmiş en iyi çalışan bir yöntem bulunmamaktadır. Bu araştırma, incelenen bu yöntemin zaman değişkenini kullanan otoregresif modellerden ya da çok fazla çeşitte girdi değişkeni ile eğitilen diğer YSA uygulamalarından çok daha iyi tahmin sonuçları vereceği hipotezi ile gerçekleştirilmemiştir. Aksine, mümkün olduğunca az sayıda girdi değişkeni çeşidi kullanarak, zaman değişkeninden bağımsız bir biçimde modelin eğitilmesine odaklanmaktadır. Aynı zamanda, farklı iyonosferik parametrelerin kestirimi için ÇKA regresyonu yönteminin potansiyel kullanımını desteklemeye çalışmaktadır.

Bu bağlamda, bir digisonde istasyonunun f0F2 ve hmF2 verileri ve orta enlem kuşağında bulunan bir GNSS istasyonunun TEC verileri işlenmiştir. İşlenen veri seti iki yıllık bir dönem kapsamaktadır. 2012 yılı verileri eğitim ve doğrulama amacıyla kullanılmış olup, 2013 yılı verileri üzerinde de tahmin çalışmaları gerçekleştirilmiştir. Tüm iyonosferik parametreler 1 saat önceden tahmin edilmiş olup, önerilen modelin tahmin performansı tüm yıl, yaz, kış ve ekinoks dönemlerinde tahmin edilen ve gözlemlenen veriler arasında KKOH değerleri hesaplanarak karşılaştırılmıştır.

2. Materyal ve Metot


Regresyon, bir model oluşturarak hem sayısal hem de kategorik veri değerlerini tahmin etmeyi amaçlar [16]. Bu çalışmada, çok katmanlı algılayıcılara dayalı regresyon algoritmasının uygulanması ve veri seti üzerinde analizlerin gerçekleştirilmesi için Python programlama dili kullanılmıştır. Python'un daha kolay komut oluşturma özelliği ve hızla olgunlaşan açık kaynaklı bilimsel kütüphaneleri sayesinde, hem denetimli hem de denetimsiz görevler için çok çeşitli modern derin öğrenme yöntemlerini uygulamak olanaklıdır [17]. Yapay öğrenme kütüphanelerinden biri olan Scikit-learn, yapay öğrenme süreçlerinin uygulanması için zengin bir ortam sağlamasının yanı sıra, daha iyi bir kullanıcı ara yüzüne sahip olmasıyla öne çıkmaktadır. Scikit-learn kütüphanesinde esas alınan nesne, bir girdi veri dizisi üzerinde model oluşturan tahmin edici (regresör) algoritmalarıdır [18], [19].

2.1. Çok Katmanlı Algılayıcılar

YSA, beynin çalışma işlevinden esinlenmiş yapılardır ve tahmin fonksiyonlarının kestirimi için bu ağlardan sıklıkla faydalanılır. Bu ağlar, veri seti içerisindeki ilişkilerden öğrenerek doğrusal veya doğrusal olmayan fonksiyonların yönetimini sağlar [20]. YSA, görüntü sınıflandırma ve konuşma örüntüsü tanıma çalışmalarında yüksek doğruluk sağlamasıyla birlikte [21] sınıflandırma, kümeleme ve tahmin problemlerinin çözümünde yaygınlık kazanmıştır [22]. Tıp [23], biyo-bilişim [24] ve finans [25] çalışmalarında belirli özelliklerin tahmininde ve çıkarımında bilgisayarların gücünden daha fazla faydalanılmasına katkı sağlamıştır.

Kullanımı oldukça yaygın olan ÇKA, doğrusal olmayan veri setlerinin modellemesi için oldukça yaygın bir şekilde kullanılan ve başarılı sonuçlar üreten bir YSA sınıfıdır [26]. ÇKA'nın da iklim parametrelerinin [27] ve kirlenici bileşenlerin kestirimi [28], belirli hastalıklara yatkınlığın tespit edilmesi [29] ve finansal varlıkların değişiminin öngörülebilmesi [30] çalışmalarında sıklıkla kullanıldığı literatürde gözlemlenmektedir. En büyük avantajı, belirli bir işlevsel form hakkında daha önceden bir bilginin (*a priori*) bulunmasına ihtiyaç olmamasıdır. İleri beslemeli ÇKA uygulamalarının çoğu, ilgili girdi ve çıktı (hedef) değişkenler arasındaki ilişkilerin tahminini yaparken, klasik yöntemlere kıyasla performansın üstünlüğü ile daha çok ilgilenmektedir. ÇKA uygulamaları, klasik YSA uygulamalarındaki gibi 'kara kutu' anlayışına sahip değildir. Sinir ağı içerisinde ne tür işlemler yapıldığını gözlemleyebilmek olanaklıdır. Dolayısıyla ÇKA algoritmasının, YSA modelleme çalışmalarındaki deneysel yapıyı geliştirebilmeye katkı sunduğu söylenebilir [31], [32].

ÇKA algoritması, denetimli öğrenme süreci üzerinde temellerini kurar. Ağ modeli oluşturulurken, değeri bilinen çıktı verilerin üzerinde örnekler kullanılarak eğitim işlemi gerçekleştirilir. ÇKA algoritmasının mimarisi, farklı katmanlardan oluşan ileri atımlı bir sinir ağından meydana gelmektedir. Bu ağda, doğrusal olmayan elemanlar (nöronlar) ardışık olarak sıralanan tabakaların üzerinde sıralanır. Girdi katman ile çıktı katman arasında bulunan gizli katmanlar aracılığıyla, birden çok doğrultu üzerinde bilgi akışı sağlanır. Bir katman üzerindeki herhangi bir noktanın (*node*), komşu katmandaki diğer noktalar ile bağlantısı sağlanır; ancak, bir katman üzerindeki noktalar arasında ya da geriye beslemeli bir bağlantı bu algoritmada söz konusu değildir. Girdi ve çıktı katmandaki eleman sayısı, problemde kullanılan girdi ve çıktı değişken sayısını temsil etmektedir. Gizli katmanlar, ağ içerisinde önemli bir parametredir ve tahmin fonksiyonunun sürekli bir şekilde değerlere yönelik yaklaşımda bulunması için bu ağ içerisinde rastgele sayıda gizli katman bulunmak zorundadır [33], [34].



Şekil 1. (a) İleri yayımlı sinir ağı şeması (b) tek bir algılayıcının şematik gösterimi

Şekil 1, bir nöronun bağlantılarıyla birlikte olan genel görünümünü temsil etmektedir. i nöronundan j nöronuna geçen her bir bağlantı, ağırlık ya da bağlantı kuvveti diye adlandırılan bir nicelik (w_{ij}) ile ilişkilendirilmiştir. Her bir nöron için aktivasyon olarak adlandırılan net girdi, tüm girdi değerlerinin ilişkili olduğu bağlantı ağırlıkları ile çarpımlarının toplamına karşılık gelir [35]:

$$a_j = \sum_i x_i w_{ji} + \theta_j \quad (1)$$

Burada i , bir önceki katmandaki toplam nöron sayısını, θ_j ise fonksiyonun düşey uzanımını etkileyen sapma miktarını (eşik değeri) temsil eder. Bir nöronun aktivasyonu hesaplandığında, çıktı değeri bir transfer fonksiyonu aracılığı ile belirlenebilir:

$$x_j = f(a_j) \quad (2)$$

Düzeltilmiş doğrusal birim fonksiyonu $f(x) = \max(0, x)$, hiperbolik tanjant fonksiyonu $f(x) = \tanh(x)$ veya sigmoid fonksiyonu gibi çok sayıda transfer fonksiyonu kullanılmaktadır. Doğrusal olmamasından ötürü sigmoid fonksiyonu genellikle tercih edilmektedir [36]:

$$x_j = f(a_j) = \frac{1}{1 + e^{-a_j}} \quad (3)$$

Ağ üzerinde sinyalin yayılımında ağırlıkların rolü oldukça önemlidir. Ağırlıklar, girdi örüntü ile bağlı olduğu çıktı örüntü arasında bir bağlantı kurarak, sinir ağının problem-çözüm ilişkisi hakkında bir bilgi üretmesine yardımcı olmaktadır.

İleri yayılım aşaması, girdi katmanına girdi değişkenlerin sunulması ile başlar ve aktivasyon hesaplamalarının gizli katmanlar üzerinde ileri yönlü olarak yayılması şeklinde devam eder. Her bir ardışık katmanda, tüm nöronlar girdi verileri toplar ve çıktısını hesaplamak için transfer fonksiyonunu çalıştırır. Ağın çıktı katmanı, nihai sonucu, bir diğer deyişle, hedef değişkenin tahmini değerini ortaya sunar.

Ağın ürettiği çıktı değeri hedef değer ile karşılaştırmak adına, ileri yayılımlı adımı takip eden geri yayılımlı bir adım daha bulunmaktadır ve k çıktı katmanındaki iki değer arasındaki hata miktarı (δ) hesaplanır [37]:

$$\delta_k = (t_k - x_k) f'(a_k) \quad (4)$$

Burada t_k hedef değer, x_k ağın ürettiği çıktı değeridir. f' , aktivasyon fonksiyonunun türevi, a_k girdi ağırlıklarının toplamı, $(t_k - x_k)$ ise hata miktarıdır. İfadenin türevli kısmı, a_k değerinin aktivasyon fonksiyonundaki eğrinin ani yükseldiği noktaya yakın olmasını durumunda daha güçlü bir düzeltme yapmak için gereklidir.

Bağlantı ağırlıklarının düzeltilmeleri, işlemin gerçekleştiği nöronun δ değerleri ile hesaplanır. Her bir ağırlık, bağlantıdan girdi veri alan hücrenin δ değerleri ile orantılıdır. Bu hesaplama şu şekilde yapılır:

$$\Delta w_{kj} = \eta \delta_k x_j \quad (5)$$

j nöronundan k nöronuna doğru hesaplanan ağırlık düzeltmesi (Δw_{kj}) üç faktöre bağlıdır: hedef nöronun hata değeri (δ_k), bağlantının kaynağının ürettiği çıktı değeri (x_j) ve ağın öğrenme hızı (η). Bu hız 0 ile 1 arasında bir değerdir. Kullanıcı tarafından sabit olarak seçilebilir ya da yazılım tarafından eğitim sürecinde en optimum hız en yüksekten başlayıp kademe kademe azaltılarak otomatik olarak uyarlanabilir [38].

Geri yayılım algoritması, hesaplanan bu hata yüzeyi üzerinde bir gradyan azalma optimizasyonu uygular ve her bir ağırlığı bulunduğu noktadaki gradyan değerine orantılı bir şekilde yeniden düzenler. Veriyi eğitirken en düşük hata değerinin elde edileceği global minimum noktalarını arayan bu algoritma, ağırlıkların yeniden düzenlenmesi işlemini genellikle momentum ifadesi olarak adlandırılan bir α parametresi ile gerçekleştirir. α parametresi de 0 ile 1 arasında bir değere sahiptir. $t + 1$ epogundaki ağırlığın düzeltme formülü şu şekildedir [38]:

$$\Delta w_{kj}(t + 1) = \eta \delta_k x_j + \alpha \Delta w_{kj}(t) \quad (6)$$

Öğrenme hızı (η) ve momentum ifadesi (α), geri yayımlı ağırlık öğrenme süreci için önemli bir role sahip hiper parametrelerdir. Bu parametrelerin hatalı seçimi durumunda, ağ fonksiyonu kararsız bir salınım gösterir ya da hata değerinin en yüksek olduğu lokal minimum noktalarda kalır.

Geri yayılım adımı, eğitim süreci kadar test sürecine de gereksinim duyar. Veri setinin bir bölümü ağırlık eğitimi için kullanılırken, kalan kısmı eğitimle elde edilen modelin doğruluğunu test etmek için kullanılır. Test sürecinde, ağırlık ürettiği çıktı değerler ile veri setindeki orijinal değerler karşılaştırılır. Eğitim-test verisi oranı, tipik bir derin öğrenme çalışmasında 1:1, 2:1, 3:1 ya da 4:1 şeklinde düzenlenebilir. Veri setinin karmaşıklığı, daha fazla eğitim verisinin kullanılmasını gerektirmektedir. Verinin bu şekilde parçalanması işlemine ‘k katlamalı çapraz geçerlilik işlemi’ adı verilir. Bu parçalama işlemi, veri setinin seçilmiş bir bölümü üzerinde yapılacağı gibi, rastgele seçilmiş veri örnekleri üzerinden de yapılabilir [39].

2.2. Kullanılan Veri Seti

41.9° K, 12.5° D coğrafi koordinatlarında bulunan ROME digisonde istasyonunun (URSI kodu: RO041) saatlik f0F2 ve hmF2 verileri bu çalışmada kullanılmıştır. Bu istasyon, DPS4 teknolojisine sahiptir ve Haziran 1997’den beri veri hizmeti vermektedir. Küresel digisonde istasyonlarının ham verileri, Amerikan Ulusal Jeofizik Veri Merkezi’nin (NGDC) Dosya Transfer Protokolü (File Transfer Protocol – FTP) adresinde (<ftp://ftp.ngdc.noaa.gov/ionosonde/>) ücretsiz erişime açıktır.

M0SE00ITA kodlu IGS istasyonunun TEC verileri de bu çalışmada kullanılmıştır. M0SE istasyonu 41.890° K, 12.490° D coğrafi koordinatlarında yer almaktadır ve ROME digisonde istasyonuna çok yakındır. İki istasyon arasındaki mesafe 950 metredir. İki istasyon arasındaki bu kadar küçük mesafe, aynı iyonosferik ve atmosferik koşullar altında birden fazla parametrenin davranışını incelemek için bir fırsat sağlamaktadır. TEC değerleri, ABD Boston College, Bilimsel Araştırma Enstitüsü tarafından geliştirilen GPS-TEC analiz uygulama yazılımı ile hesaplanmıştır. M0SE IGS istasyonunun günlük RINEX dosyaları, NASA’nın Uzay Jeodezi Verileri Arşivi’nden derlenmiştir (<https://cdis.nasa.gov/archive/gnss/data/daily/>).

Parametrelerin 2012 değerleri, önerilen ÇKA regresyon modelinin eğitimi ve doğrulaması için, 2013 değerleri ise tahminin doğruluğunu test etmek için kullanılmıştır. Bu yıllar, uzay iklimi açısından benzer koşullara sahiptir. Dolayısıyla her iki yıla ait parametrelerin varyasyonları, bazı mevsimsel farklılıklar olsa da benzer bir seyir izlemektedir (Şekil 2).

2.3. Girdi Değişkenler ve Çıktı Değerleri

Önerilen modelin girdi değişkenleri, f0F2, hmF2 ve TEC parametreleri ile ilişkili olduğu deneyimlenen parametrelere göre seçilmiştir. Bu çalışmada, bir optimizasyon modeli yerine gerçek bir derin öğrenme yaklaşımı önerildiği için, olabildiğince az sayıda girdi değişkeni seçilmeye çalışılmıştır. Derin öğrenme modelleri çok fazla girdi vektörü ile eğitilirse, elde edilen modellerin aşırı öğrenme (*overtraining*) ile karşılaşması olasıdır. Bu durum bir genelleme hatasının ortaya çıkmasına ya da daha uzun işlem süresi ile karşılaşılmasına neden olur. Bu nedenle, hangi girdi

değişkenlerin seçileceğine ilişkin titiz bir ön çalışma derin öğrenme uygulamaları için bir ön koşuldur. Az sayıda girdi değişkeni çeşidinin bulunması, boyutsallığı azaltmak adına da önemlidir. Boyutsallığın azalması, girdi verileri istatistiksel olarak daha anlamlı hale getirir [40].

Bu çalışmada kullanılan girdi değişkenler, adı geçen iyonosfer parametrelerinin zamansal değişimini baskın bir şekilde etkilemektedir. Oluşturulan tahmin modelin çıktıları ise, f_0F_2 , h_mF_2 ve TEC parametrelerinin $t+1$ değerleridir.

Günlük ve Mevsimsel Değişim: İyonosferik parametrelerdeki günlük ve mevsimsel değişimin etkisi evrensel saat ($0 \leq ES \leq 23$) ve gün sayısı ($1 \leq GS \leq 365$) ile ilişkilendirilmiştir. Bu girdilerin iki kareleme bileşeni aşağıdaki ifadelerde temsil edildiği şekilde kullanılmıştır [41]:

$$ESS = \sin(2\pi ES/24) \quad (7)$$

$$ESC = \cos(2\pi ES/24) \quad (8)$$

$$GSS = \sin(2\pi GS/365) \quad (9)$$

$$GSC = \cos(2\pi GS/365) \quad (10)$$

Uzay İklimi Etkisi: Güneş ve manyetik aktivitelerin iyonosferik varyasyon üzerinde güçlü bir etkisi vardır [42]. Güneş aktivitesinin seviyesini temsil etmek için en yaygın kullanılan indeksler güneş lekeleri sayısı (R) ve F10.7 güneş akısıdır. Şentürk ve Çepni [43], 14 yıllık TEC zaman serisi (2003-2016) ile F10.7 indeksi arasındaki korelasyonu 0.83, R indeksi ile olan korelasyonu ise 0.78 olarak bulmuşlardır. Bu bağlamda, bu çalışmada güneş aktivitesinin iyonosferik değişimler üzerindeki etkisinin temsili için saatlik F10.7 verileri kullanılmıştır. F10.7 indeksi, 2800 MHz frekans ile 10.7 cm dalga boyundaki mikrodalga akı yoğunluğu ile tanımlanmaktadır.

ÇKA regresyonunun diğer girdi verileri f_0F_2 , h_mF_2 ve TEC parametrelerinin mevcut gün (t) ve bir önceki gün (t-23) değerleridir. İyonosferin günlük değişimlerinden ötürü, önceki günün değerlerinin öteki günlerdeki değeri tahmin etmek için kullanımı önemlidir.


Bu çalışmada her bir parametre için toplamda altı adet girdi değişken kullanılmıştır (EES, ESC, GSS, GSC, F10.7 ve Ap indeksi). Bu araştırma, modelleri aşırı eğitmek adına çoklu zaman değerlerini (ara değerler ve türevleri) içermemektedir.

2.4. Veri Ön İşleme


Birçok veri seti, sinyaller kaydedilirken veya iletilirken bilinmeyen sebepler nedeniyle eksik veri değerleri içerir. İstatistiksel ve yapay öğrenme yaklaşımları, bu eksik değerler ile başa çıkamadığından, veri dosyalarında bu eksik değerlere sahip satırlar genellikle atlanır [44]. Bu atlama işlemi, diğer sütunlardaki kıymetli verilerin kullanılmamasına neden olabilir; dolayısıyla, tahmin modelini oluşturmadan önce eksik değerleri kestirmek (imputing) genel bir yaklaşımdır. Bununla birlikte, Farhangfar vd. [45] tarafından yürütülen bir çalışma, verinin %5 ila %20'sinin eksik olması durumunda eksik verilerin tahmin edilmesi ya da atlanması ile modelin ciddi bir doğruluk değişimi kaydetmediğini raporlamıştır. Bu çalışmada, h_mF_2 ve f_0F_2 değerlerinde 8760 satırdan 1261'i (%14.4) ve TEC değerlerinde 8760 satırdan 483'ü (%5.5) eksik (null) veri içermektedir. Eksik veri satırları, zamansal olarak ardışık değildir ve veri seti içinde rastgele dağınık olarak bulunmaktadır. Eksik veriler, derin öğrenme algoritması tarafından bir değer olarak kabul edileceği için, öğrenme sürecine bu eksik verilerle girilmesi yanlış tahmin modeli üretmeyi beraberinde getirecektir. Eksik veri yüzdesinin modelin doğruluğunu etkileyecek seviyenin altında

olmasından ötürü ve modelin yanlış tahminler üretmemesi adına eksik veriler öğrenme süreci öncesi veri setinden çıkarılmıştır.

Diğer bir veri ön işleme adımı ise, veri setindeki değişkenlerin çeşitliliğini normalleştirmeyi amaçlayan veri ölçekleme çalışmasıdır. Ölçekleme işlemi, değişken çeşitliliğini en aza indirir ve daha önceden tanımlanmış sınırlar arasına değerleri taşır [46].



Şekil 2. 2012 ve 2013 yıllarına ait iyonosfer parametrelerinin dağılımı, (a) f0F2, (b) hmF2, (c) TEC verilerini göstermektedir. Siyah çizgiler 2012 yılı verilerini, yeşil çizgiler ise 2013 yılı verilerini temsil etmektedir.



Şekil 3. F10.7 ve ap indekslerinin 2012 ve 2013 yıllarına ait dağılımı, (a) ap indeks, (b) F10.7 indeks. Siyah çizgiler ve noktalar 2012 yılı verilerini, yeşil çizgiler ve noktalar ise 2013 yılı verilerini temsil etmektedir.

Veri ölçekleme, modelin doğruluğunu belirli bir derece artırmaktadır. Aykırı ve tutarsız değerlerin yönetimine yardımcı olur [47], [48]. Bu araştırmada veri ölçekleme çalışması yapılmamıştır. Bunun iki nedeni bulunmaktadır: (1) TEC, hmF2 ve f0F2 değerlerinin genlikleri doğrusal olmayan bir şekilde değişir ve anormal genlikler bir güneş ve/veya jeomanyetik bir aktiviteyi temsil ettiği için gereksiz veri değildir, (2) bu çalışma, modelin anormal genlikleri de tahmin etme yeteneğini izlemeyi amaçlamaktadır. Son olarak, veri seti eğitim ve test verileri olarak ayrılmıştır. Bu ayrım, veri satırları arasında rastgele seçimle gerçekleştirilmiş olup, herhangi bir kural uygulanmamıştır. Bu çalışmada 5 katlı çapraz doğrulama yöntemi kullanılarak, veri setinin eksik olmayan %80'lik kısmı ağı eğitmek için, kalan %20'lik kısmı da ağın çıktı değerlerini orijinal veri ile karşılaştırarak test etmek için ayrılmıştır.

2.5. Doğruluk Tayini

Veriler üzerinde eğitilen ÇKA regresyon algoritmasının performanslarını değerlendirmek için 2012 verileri üzerinde çalışan regresörün doğruluk tayini R^2 regresyon skoru ile yapılmıştır:

$$R^2 = \frac{\sum (y - \hat{y})^2}{\sum (y - \bar{y})^2} \quad (11)$$

Burada y gözlemlenen değer, $\hat{y}$ tahmin edilen değer ve $\bar{y}$ gözlemlenen değerlerin ortalamasıdır. R^2 skorunun en iyi olası değeri 1'dir. 2012 verileri ile eğitilen ağ modelinin doğruluk tayininin 2013 verileri ile gerçekleştirilecek olması, veri setine oldukça bağlı olan R^2 skorunu kullanırmayı zorlaştıracaktır. Dolayısıyla, 2013 tahmin değerleri için Pearson korelasyon katsayısı (r) ve KKOH ölçütleri kullanılmıştır. Bu sayede, verinin birimine uygun hata hesaplamaları yapmak mümkündür. r ve KKOH formülleri sırasıyla aşağıdaki gibidir:

$$r = \frac{\frac{1}{n} \sum (x - \bar{x})(y - \bar{y})}{\sqrt{\frac{1}{n} \sum (x - \bar{x})^2 \frac{1}{n} \sum (y - \bar{y})^2}} \quad (12)$$

$$KKOH = \sqrt{\frac{1}{n} \sum (y - \hat{y})^2} \quad (13)$$

2.6. Hiper-parametrelerin Uyumlandırılması

Yapay öğrenme algoritmalarının doğruluğu, modelin eğitildiği hiper-parametreler ile doğrudan ilişkilidir. ÇKA regresyon algoritması için Scikit-learn kütüphanesi, hiper-parametre uyumlandırılmasına izin vermektedir [19]. Ancak hiper-parametrelerin seçimi çoğunlukla veri setinin doğasına göre farklılıklar göstermektedir. Dolayısıyla, hiper-parametrelerin seçiminde kütüphanenin sabit başlangıç değerlerini kullanmak yerine, bir optimizasyon çalışması gerekmektedir. ÇKA regresyon algoritmasında seçilen dört adet hiper-parametre bulunmaktadır: (1) aktivasyon fonksiyonu, (2) momentum ifadesi (α), (3) öğrenme hızı, (4) maksimum iterasyon sayısı. Her bir iyonosfer parametresi için, farklı hiper-parametrelerin kombinasyonu sonucu eğitilen ağ modellerinden elde edilen eğitim doğruluğu saptanmıştır.

Tablo 1. İyonosfer parametreleri için en iyi eğitim doğruluğunu veren hiper-parametreler


İyonosfer Parametresi	Aktivasyon Fonksiyonu	α	Öğrenme Hızı	Maksimum İterasyon Sayısı
f0F2	Tanh	0.0001	Uyumlu(Adaptive)	300
hmF2	tanh	0.0001	Uyumlu(Adaptive)	500
TEC	tanh	0.001	Sabit (Constant)	500

Bu sonuçlara göre, her bir iyonosfer parametresi için en iyi sonucu veren hiper-parametreler Tablo 1’de gösterilmektedir.


3. Bulgular

3.1. İyonosfer Parametrelerinin Kestirimi


Şekil 4’de f_0F_2 , Şekil 5’te h_mF_2 ve Şekil 6’da TEC verileri için, hem ÇKA regresyonu ile tahmin edilen 2013 değerlerin mutlak sapmalarının histogramları, hem de gözlemlenen ve tahmin edilen 2013 değerlerinin oluşturduğu saçılım grafikleri regresyon doğrusu ile birlikte gösterilmektedir. Bu gösterimde, hem tüm yıla ilişkin tahminler hem de mevsimsel tahminler (ekinoks, yaz, kış) gösterilmektedir.



Şekil 4. Tahmin edilen 2013 f_0F_2 değerleri ile orijinal f_0F_2 2013 verileri arasındaki mutlak sapmaların histogramları ve saçılım grafikleri. Sol üstteki histogram ve saçılım grafiği tüm yılı, sağ üstteki ekinoks dönemini, sol alttaki yaz dönemini, sağ alttaki ise kış dönemini göstermektedir.



Şekil 5. Tahmin edilen 2013 h_mF_2 değerleri ile orijinal h_mF_2 2013 verileri arasındaki mutlak sapmaların histogramları ve saçılım grafikleri. Sol üstteki histogram ve saçılım grafiği tüm yılı, sağ üstteki ekinoks dönemini, sol alttaki yaz dönemini, sağ alttaki ise kış dönemini göstermektedir.



Şekil 6. Tahmin edilen 2013 TEC değerleri ile orijinal TEC 2013 verileri arasındaki mutlak sapmaların histogramları ve saçılım grafikleri. Sol üstteki histogram ve saçılım grafiği tüm yılı, sağ üstteki ekinoks dönemini, sol alttaki yaz dönemini, sağ alttaki ise kış dönemini göstermektedir.

Şekil 4’de ÇKA regresyonunun tüm yıl için f_0F_2 değerlerinin % 97.9’unu 0 - 2 MHz değerleri arasındaki bir doğrulukla kestirebildiği görülmektedir. Bu değer ekinoks döneminde % 97.98, yaz döneminde % 97.2 ve kış döneminde %98.4 olarak bulunmuştur. Şekil 5’de ÇKA regresyonunun tüm yıl için h_mF_2 değerlerinin % 92.8’ini 0 - 40 km değerleri arasındaki bir doğrulukla kestirebildiği görülmektedir. Bu değer ekinoks döneminde % 94.3, yaz döneminde % 88.5 ve kış döneminde %94 olarak bulunmuştur. Şekil 6’da ÇKA regresyonunun tüm yıl için TEC değerlerinin % 85.4’ünü 0 - 4 TECU değerleri arasındaki bir doğrulukla kestirebildiği görülmektedir. Bu değer ekinoks döneminde % 81.3, yaz döneminde % 73.8 ve kış döneminde %91.9 olarak bulunmuştur. Şekil 4, 5 ve 6’da bulunan histogramlardaki her çubuğun üstünde, o mutlak sapma aralığına karşılık gelen çıktı veri yüzdesi bulunmaktadır. Regresyon grafiklerinde veriler arasındaki dağılım, karşılaştırılan değerler arasındaki ilişkinin gücünü ortaya koymaktadır. Grafiklerde yaz dönemindeki verilerin dağılımının diğerlerine görece daha yüksek bir saçılıma sahip olduğu görülmüştür. Tablo 3’deki korelasyon değerleri bu sonuçları doğrulamaktadır.

3.2. Karşılaştırmalı Analiz

Önerilen ÇKA regresyon algoritmasının performansı, R^2 , KKOH ve r istatistiksel göstergeleri kullanılarak incelenmiştir. Öncelikle R^2 ile eğitilen modelin iç (eğitim puanı) ve dış (test puanı) doğruluğu araştırılmıştır. Buna göre en iyi eğitim ve test R^2 skoru Tablo 2’de sunulmuştur.

Tablo 2. İyonosfer parametreleri için önerilen modelin 2012 yılına ait eğitim ve test performansı

İyonosfer Parametresi	Eğitim R^2 skoru	Test R^2 skoru
f_0F_2	0.8714	0.8703
h_mF_2	0.7457	0.7399
TEC	0.8740	0.8770

Tablo 2’ye göre, ÇKA regresyonu algoritması f_0F_2 ve TEC parametrelerinin tahmini için eğitilirken %85’in üstünde bir doğruluk elde edilmesini sağlamıştır. h_mF_2 parametresi için de, diğer parametrelere nazaran nispeten daha düşük bir doğruluk (%74) sağlamıştır. Aynı parametrelerde test verisi içinde benzer değerler tespit edilmiştir. R^2 değerleri tek başına modelin tahmin için

yeterli olup olmadığını veya tahminlerin yanlı olup olmadığını göstermez. Bu kapsamda saçılım grafikleri tahmin performanslarını değerlendirmek için incelenmesi gereken diğer bir göstergedir.

İyonosferik parametreler yılın farklı dönemlerinde farklı varyasyonlara sahiptir. Bu nedenle, mevsimsel tahmin performansları, mevsimsel eğilimleri elde etmek adına önemlidir. Bu amaçla, bir yıl üç farklı mevsimsel döneme ayrılmıştır: Yaz (Mayıs, Haziran, Temmuz, Ağustos), Kış (Ocak, Şubat, Kasım, Aralık) ve Ekinoks (Mart, Nisan, Eylül, Ekim). Tablo 3, her mevsimsel dönem için elde edilen tahmin doğruluğunu göstermektedir.

Tablo 3. İyonosfer parametreleri için önerilen modelin 2013 yılına ait tahmin performansı

	f0F2		hmF2		TEC	
	KKOH (MHz)	r	KKOH (km)	r	KKOH (TECU)	r
Bütün Yıl	0.7783	0.9322	22.61	0.8565	3.056	0.9347
Yaz	0.8558	0.8116	26.98	0.7932	3.694	0.8730
Kış	0.7384	0.9512	21.56	0.8725	2.616	0.9473
Ekinoks	0.7662	0.9340	20.59	0.8723	3.245	0.9138

Tablo 3’de düşük KKOH ve yüksek korelasyon değerleri en iyi tahmin performansını ortaya koymaktadır. Buna göre, önerilen yöntemin f0F2 parametresi için Kış döneminde en iyi tahmin performansına sahip olduğu görülmüştür. Bu dönemde KKOH değeri 0.74 Mhz ve r değeri 0.95 olarak tespit edilmiştir. hmF2 parametresi için önerilen yöntem Ekinoks döneminde en iyi tahmin performansına sahiptir. Bu dönemde KKOH değeri 20.6 km ve r değeri 0.87 olarak tespit edilmiştir. TEC parametresi için önerilen yöntem Kış döneminde en iyi tahmin performansına sahiptir. Bu dönemde KKOH değeri 2.6 TECU ve r değeri 0.95 olarak tespit edilmiştir. Tüm parametreler için Yaz dönemindeki tahmin değerleri diğer dönemlere görece daha düşük doğruluğa sahiptir.

4. Tartışma ve Sonuç

Bu çalışma, iyonosferin f0F2, hmF2 ve TEC parametrelerini tahmin etmek için derin öğrenme algoritmalarından olan çok katmanlı algılayıcı regresyonunun potansiyel kullanımını göstermeyi amaçlamıştır. Bu yöntemin kullanılmasının gerekçesi, derin öğrenme algoritmalarının literatürde kabul edilen diğer modeller gibi iyonosferik parametre kestirimi için kullanımını yaygınlaştırma hedefidir. Derin öğrenme yaklaşımının temel avantajı, bilinmeyen parametrelere ilişkin modeli tanımlamak için daha az girdi veriye gereksinim duyulmasıdır.

Bu araştırmada kullanılan denetimli öğrenme biçimini uygularken, girdi ve çıktı verileri arasında bir bağımlılığın bulunduğu varsayılmıştır. Algoritmanın en iyi tahmin sonuçlarının elde edilebilmesi için, algoritmanın doğasında bulunan hiper-parametrelerin doğru seçimi için optimizasyon çalışması yapılmıştır. Kullanılan doğruluk kriterine bağlı olarak, seçilen bu hiper-parametreler ile seçilen iyonosferik parametrelerin en yüksek doğrulukla tahmin edilmesi hedeflenmiştir.

Otoregresif modeller, önceki zamana ait verileri uyarlayarak tahmin yapar. Ancak, derin öğrenme yaklaşımı, bir modeli eğitim örneklerinden genelleştirme yeteneğine sahiptir. Her ne kadar bu modelin kusursuz olacağının garantisi olmasa da, modelin çok sayıda eğitim verisi ile beslenmesi ve iyi seçilmiş hiper-parametrelerin varlığı modelin genelleme başarısını artırmaktadır.

En uygun hiper-parametrelerle birlikte ÇKA regresyonu modelinin f0F2 parametresini ortalama %97’nin üzerinde bir başarıyla makul sınırlar içerisinde (0 - 2 MHz) kestirebildiği tespit edilmiştir. hmF2 parametresi yine kabul edilebilir sınırlar içerisinde (0 - 40 km) ortalama %92 ve üzeri bir

başarıyla kestirilmiştir. TEC değerlerinin kestiriminde 0 - 4 TECU değerleri arasında %83'ün üzerinde bir kestirim başarısı bulunmuştur. f_oF₂ ve TEC parametreleri için Kış döneminde, hmF₂ parametresi için Ekinoks döneminde en iyi kestirim sonuçlarına ulaşılmıştır. Tüm parametreler için Yaz dönemindeki kestirim performansının diğer dönemlere görece düşük olduğu tespit edilmiştir.

Önerilen yöntemin bir saate kadar olan tahmin performansı, iyonosferik parametrelerin varyasyonunun nispeten az olduğu orta enlem bölgesinde ve kuzey yarımkürede izlenmiştir. İlerleyen çalışmalarda, bu yöntemin düşük ve yüksek enlem bölgelerinde, farklı yarımkürelerde, güneş patlamaları ve jeomanyetik fırtına dönemlerinde uygulanabilirliğinin test edilmesi amaçlanmaktadır.

Yazarların Katkıları

MCİ: Modelin literatür araştırması, veri ön işleme, veri görselleştirme, modelleme ve tahmin, doğruluk analizi. EŞ: Konsept tasarım, iyonosfer parametrelerine ilişkin literatür araştırması, veri hazırlama, doğruluk analizi. Her iki yazar da makalenin son halini okudu ve onayladı.

Çıkar Çatışması

Yazarlar, çıkar çatışması olmadığını beyan eder.

Kaynaklar

- [1]. Davies, K., Ionospheric Radio, Peter Peregrinus, London (1990).
- [2]. Fayyaz, M., Naqvi, N. A., "The trends/ variations of Ionospheric parameters (hmF₂, foF₂) between observatory and International Reference Ionosphere web model values", Fourth International Conference on Aerospace Science and Engineering (ICASE), 1–4 (2015).
- [3]. Li, M., Yuan, Y., Zhang, B., Wang, N., Li, Z., Liu, X., Zhang, X., "Determination of the optimized single-layer ionospheric height for electron content measurements over China", Journal of Geodesy, 2018, 92 (2): 169–183.
- [4]. Vaishnav, R., Jacobi, C., Berdermann, J., "Long-term trends in the ionospheric response to solar extreme-ultraviolet variations", Annales Geophysicae, 2019, 37 (6): 1141–1159.
- [5]. Freeshah, M., Zhang, X., Şentürk, E., Adil, M.A., Mousa, B.G., Tariq, A., Ren, X., Refaat, M., "Analysis of Atmospheric and Ionospheric Variations Due to Impacts of Super Typhoon Mangkhut (1822) in the Northwest Pacific Ocean", Remote Sensing, 2021, 13 (4): 661.
- [6]. Şentürk, E., Arqim Adil, M., Saqib, M., "Ionospheric total electron content response to annular solar eclipse on June 21, 2020", Advances in Space Research, 2021, 67 (6): 1937–1947.
- [7]. Klobuchar, J., "Ionospheric Time-Delay Algorithm for Single-Frequency GPS Users", IEEE Transactions on Aerospace and Electronic Systems, 1987, 23 (3): 325–331.
- [8]. Altınay, O., Tulunay, E., Tulunay, Y., "Forecasting of ionospheric critical frequency using neural networks", Geophysical Research Letters, 1997, 24 (12): 1467–1470.
- [9]. Stanislawski, I., Zbyszynski, Z., "Forecasting of the ionospheric quiet and disturbed f_oF₂ values at a single location", Radio Science, 2001, 36 (5): 1065–1071.
- [10]. Stanislawski, I., Zbyszynski, Z., "Forecasting of ionospheric characteristics during quiet and disturbed conditions", Annals of Geophysics, 2002, 45 (1): 169–175.
- [11]. Chen, C., Wu, Z.-S., Ban, P.-P., Sun, S.-J., Xu, Z.-W., Zhao, Z.-W., "Diurnal specification of the ionospheric f_oF₂ parameter using a support vector machine", Radio Science, 2010, 45 (5).
- [12]. Chen, C., Wu, Z., Sun, S., Ban, P., Ding, Z., Xu, Z., "Forecasting the ionospheric f_oF₂ parameter one hour ahead using a support vector machine technique", Journal of Atmospheric and Solar-Terrestrial Physics, 2010, 72 (18):1341–1347

- [13]. Athieno, R., Jayachandran, P. T., Themens, D. R., “A neural network-based foF2 model for a single station in the polar cap”, *Radio Science*, 2017, 52 (6): 784–796.
- [14]. Fan, J., Liu, C., Lv, Y., Han, J., Wang, J., “A Short-Term Forecast Model of foF2 Based on Elman Neural Network”, *Applied Sciences*, 2019, 9 (14): 2782.
- [15]. Li, W., Zhao, D., He, C., Hu, A., Zhang, K., “Advanced Machine Learning Optimized by The Genetic Algorithm in Ionospheric Models Using Long-Term Multi-Instrument Observations”, *Remote Sensing*, 2020, 12 (5): 866
- [16]. Alpaydin, E., *Introduction to machine learning*, MIT Press, Cambridge (2020).
- [17]. Géron, A., *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems*. O'Reilly Media (2019).
- [18]. Kramer, O., *Machine Learning for Evolution Strategies*, Springer International Publishing (2016).
- [19]. Pedregosa, F. v.d., “Scikit-learn: Machine learning in Python”, *The Journal of Machine Learning Research*, 2011, 12: 2825–2830.
- [20]. Boden, M. A., *The Philosophy of Artificial Intelligence*. Oxford University Press (1990).
- [21]. Hinton, G. v.d., “Deep Neural Networks for Acoustic Modeling in Speech Recognition: The Shared Views of Four Research Groups”, *IEEE Signal Processing Magazine*, 2012, 29 (6): 82–97.
- [22]. Olden, J. D., Lawler, J. J., Poff, N. L., “Machine Learning Methods Without Tears: A Primer for Ecologists”, *The Quarterly Review of Biology*, 2008, 83 (2): 171–193.
- [23]. Shen, D., Wu, G., Suk, H.-I., “Deep Learning in Medical Image Analysis”, *Annual Review of Biomedical Engineering*, 2017, 19 (1): 221–248.
- [24]. Min, S., Lee, B., Yoon, S., “Deep learning in bioinformatics”, *Briefings in Bioinformatics*, 2016.
- [25]. Heaton, J. B., Polson, N. G., Witte, J. H., “Deep learning for finance: deep portfolios”, *Applied Stochastic Models in Business and Industry*, 2017, 33 (1): 3–12
- [26]. Palani, S., Liong, S.-Y., Tkalič, P., “An ANN application for water quality forecasting”, *Marine Pollution Bulletin*, 2008, 56 (9): 1586–1597.
- [27]. Choubin, B., Khalighi-Sigaroodi, S., Malekian, A., Kişi, Ö., “Multiple linear regression, multi-layer perceptron network and adaptive neuro-fuzzy inference system for forecasting precipitation based on large-scale climate signals”, *Hydrological Sciences Journal*, 2016, 61 (6): 1001–1009.
- [28]. Juhos, I., Makra, L., Tóth, B., “The behaviour of the multi-layer perceptron and the support vector regression learning methods in the prediction of NO and NO₂ concentrations in Szeged, Hungary”, *Neural Computing and Applications*, 2009, 18 (2): 193–205.
- [29]. Kurt, I., Türe, M., Kurum, A. T., “Comparing performances of logistic regression, classification and regression tree, and neural networks for predicting coronary artery disease”, *Expert Systems with Applications*, 2008, 34 (1): 366–374.
- [30]. Mahdi Pakdaman Naeini, Taremiyan, H., Homa Baradaran Hashemi, “Stock market value prediction using neural networks”, *International Conference on Computer Information Systems and Industrial Management Applications (CISIM)*, 132–136 (2010).
- [31]. Rosenblatt, F., “The perceptron: A probabilistic model for information storage and organization in the brain”, *Psychological Review*, 1958, 65 (6): 386–408.
- [32]. Hagan, M. T., Demuth, H. B., Jesús, O. De, “An introduction to the use of neural networks in control systems”, *International Journal of Robust and Nonlinear Control*, 2002, 12 (11): 959–985.
- [33]. Baum, E. B., “On the capabilities of multilayer perceptrons”, *Journal of Complexity*, 1988, 4 (3): 193–215.
- [34]. Tang, J., Deng, C., Huang, G.-B., “Extreme Learning Machine for Multilayer Perceptron”, *IEEE Transactions on Neural Networks and Learning Systems*, 2016, 27 (4): 809–821.
- [35]. Kişi, Ö., “Streamflow Forecasting Using Different Artificial Neural Network Algorithms”,

- Journal of Hydrologic Engineering, 2007, 12 (5): 532–539.
- [36]. Maier, H. R., Dandy, G. C., “Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications”, *Environmental Modelling & Software*, 2000, 15 (1): 101–124.
- [37]. Du, K.-L., Swamy, M. N. S., “Multilayer Perceptrons: Architecture and Error Backpropagation”, *Neural Networks and Statistical Learning*, Springer London (2014).
- [38]. Chien-Cheng Yu, Bin-Da Liu, “A backpropagation algorithm with adaptive learning rate and momentum coefficient”, *International Joint Conference on Neural Networks*, 1218–1223 (2002).
- [39]. Fushiki, T., “Estimation of prediction error by using K-fold cross-validation”, *Statistics and Computing*, 2011, 21 (2): 137–146.
- [40]. Schratz, P., Muenchow, J., Iturrutxa, E., Richter, J., Brenning, A., “Hyperparameter tuning and performance assessment of statistical and machine-learning algorithms using spatial data”, *Ecological Modelling*, 2019, 406: 109–120.
- [41]. Williscroft, L.-A., Poole, A. W. V., “Neural networks, foF2, sunspot number and magnetic activity”, *Geophysical Research Letters*, 1996, 23 (24): 3659–3662.
- [42]. Afraimovich, E. L., Astafyeva, E. I., “TEC anomalies—Local TEC changes prior to earthquakes or TEC response to solar and geomagnetic activity changes?”, *Earth, Planets and Space*, 2008, 60 (9): 961–966.
- [43]. Şentürk, E., Çepni, M. S., “Ionospheric temporal variations over the region of Turkey: a study based on long-time TEC observations”, *Acta Geodaetica et Geophysica*, 2018, 53 (4): 623–637.
- [44]. Shichao Zhang, Qin, Z., Ling, C. X., Sheng, S., “‘Missing is useful’: missing values in cost-sensitive decision trees”, *IEEE Transactions on Knowledge and Data Engineering*, 2005, 17 (12): 1689–1693.
- [45]. Farhangfar, A., Kurgan, L., Dy, J., “Impact of imputation of missing values on classification error for discrete data”, *Pattern Recognition*, 2008, 41 (12): 3692–3705
- [46]. Burdack, J., Horst, F., Giesselbach, S., Hassan, I., Daffner, S., Schöllhorn, W. I., “Systematic Comparison of the Influence of Different Data Preprocessing Methods on the Performance of Gait Classifications Using Machine Learning”, *Frontiers in Bioengineering and Biotechnology*, 2020, 8.
- [47]. Dey, S. K., Hossain, A., Rahman, M. M., “Implementation of a Web Application to Predict Diabetes Disease: An Approach Using Machine Learning Algorithm”, *21st International Conference of Computer and Information Technology (ICCIT)*, 1–5 (2018).
- [48]. Obaid, H. S., Dheyab, S. A., Sabry, S. S., “The Impact of Data Pre-Processing Techniques and Dimensionality Reduction on the Accuracy of Machine Learning”, *9th Annual Information Technology, Electromechanical Engineering and Microelectronics Conference (IEMECON)*, 279–283 (2019).