T.C.
HARRAN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

DERİN ÖĞRENME YÖNTEMİ İLE İYONOSFERİK TEC DEĞİŞİMLERİNİN TAHMİN EDİLMESİ

İsmail DEMİRYEGE

HARİTA MÜHENDİSLİĞİ ANABİLİM DALI

ŞANLIURFA
2021

İÇİNDEKİLER

Sayfa No

ÖZET i
ABSTRACT ii
TEŞEKKÜR iii
ŞEKİLLER DİZİNİ iv
ÇİZELGELER DİZİNİ v
SİMGELER ve KISALTMALAR DİZİNİ vi
1. GİRİŞ 1
1.1 Tezin Amacı 3
2. ÖNCEKİ ÇALIŞMALAR 4
3. MATERYAL ve YÖNTEM 13
3.1. Materyal 13
3.1.1. GPS Gözlemlerinden TEC Elde Edilmesi 13
3.2. Yöntem 17
3.2.1. Karesel ortalama hata 17
3.2.2. Yapay sinir ağı 18
3.2.3. Yapay sinir ağlarında kullanılan aktivasyon fonksiyonları 22
3.2.4. Uzun kısa süreli bellek 24
3.2.4.1. Momentumlu stokastik gradyan inişi (SGDM) optimizasyonu 26
3.2.4.2. Uyarlanabilir moment (ADAM) optimizasyonu 27
4. ARAŞTIRMA BULGULARI ve TARTIŞMA 30
4.1. SURF İstasyonu GPS-TEC Tahmini 31
4.2. ANTL İstasyonu GPS-TEC Tahmini 40
4.3. GEME İstasyonu GPS-TEC Tahmini 48
4.4. HEND İstasyonu GPS-TEC Tahmini 56
5. SONUÇLAR ve ÖNERİLER 65
KAYNAKLAR 67

ÖZET

Yüksek Lisans Tezi

DERİN ÖĞRENME YÖNTEMİ İLE İYONOSFERİK TEC DEĞİŞİMLERİNİN TAHMİN EDİLMESİ

İsmail DEMİRYEGE

Harran Üniversitesi
Fen Bilimleri Enstitüsü
Harita Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Mustafa ULUKAVAK
YIL: 2021, Sayfa: 74

İyonosfer tabakası, Küresel Konumlandırma Sistemi (GPS) uydularının radyo dalgalarının frekanslarına bağlı olarak zaman gecikmesi oluşturan aktif bir ortam olarak tanımlanmaktadır. İyonosferik çalışmaların birçoğu, GPS sinyallerinden elde edilen toplam elektron içeriği (TEC) değişiklikleri kullanılarak gerçekleştirilir. Günümüzde iyonosferin fiziksel yapısı üzerine yapılan çalışmalar, uzay iklimi koşullarının tahmini, konumlandırma, navigasyon ve iletişim gibi birçok alanda devam etmektedir. Bu çalışmanın amacı, iyonosferik TEC'nin kestirimi için derin öğrenmenin bir çeşidi olan uzun kısa vadeli bellek yönteminin en uygun ağ modelini oluşturmaktır. Tasarlanan model ve ilgili özellikleri, MATLAB® ortamında özelleştirilmiş Derin Öğrenme Araç Kutusu kullanılarak hazırlanmıştır. Bu çalışmada, Türkiye'nin farklı bölgelerinde bulunan ve Türkiye Ulusal Sabit GPS Ağı (TUSAGA-Aktif)'na kayıtlı olan SURF, GEME, HEND ve ANTL isimli istasyonların 2016-2019 yılları arasında iki saat çözünürlüklü GPS gözlemleri kullanılmıştır. 2019 yılının ilk altı ayı için iyonosferik TEC değişimlerini tahmin etmeyi amaçlayan bu çalışmada, her bir istasyon için optimum parametreler araştırılmıştır. Tahmini yapılan TEC'lerin, Momentumlu Stokastik Gradyan İnişi (SGDM) ve Uyarlanabilir Moment (ADAM) optimizasyonlarıyla karesel ortalama hataları (KOH) elde edilmiş ve birbirleriyle kıyaslanmıştır.

ANAHTAR KELİMELER: Derin öğrenme, TEC, uzun kısa süreli bellek, ADAM, SGDM

ABSTRACT

MSc Thesis

FORECASTING OF IONOSPHERIC TEC VARIATIONS BY DEEP LEARNING METHOD

İsmail DEMİRYEGE

Harran University
Graduate School of Natural and Applied Sciences
Department of Geomatic Engineering

Supervisor: Assist. Prof. Dr. Mustafa ULUKAVAK
Year: 2021, Page: 74

The ionosphere layer is defined as an active medium that creates a time delay depending on the frequencies of the radio waves of the Global Positioning System (GPS) satellites. Most ionospheric studies are performed using changes in total electron content (TEC) obtained from GPS signals. Today, studies on the physical structure of the ionosphere continue in many areas such as the prediction of space climate conditions, positioning, navigation and communication. The aim of this study is to create the most appropriate network model of the long-short-term memory (LSTM) method, which is a type of deep learning, for the estimation of ionospheric TEC. The designed model and its related features have been prepared in the MATLAB® environment using the Deep Learning Toolbox. In this study, two-hour resolution GPS observations of the stations named SURF, GEME, HEND and ANTL where are located in different regions of Turkey and registered to the Turkey National Constant GPS Network (TUSAGA-Aktif) were used between 2016-2019. In this study, which aims to predict ionospheric TEC changes for the first six months of 2019, optimum parameters were investigated for each station. The mean-square errors (RMSE) of the predicted-TECs were obtained from Momentum Stochastic Gradient Descent with Momentum (SGDM) and Adaptive Moment (ADAM) optimizations and compared with each other.

KEY WORDS: Deep learning, TEC, LSTM, SGDM, ADAM

TEŞEKKÜR

Bu çalışma boyunca her zaman bana destek olan ve bilgi birikimini esirgemeyen kıymetli hocam Dr. Öğr. Üyesi Mustafa ULUKAVAK'a teşekkür ederim.

Tez çalışmam boyunca sempozyum ve konferanslara katılmamda bana maddi ve manevi desteklerini esirgemeyen ve en zor zamanlarımda bana her türlü imkânı sağlayan saygıdeğer ağabeylerim Naim BUCAK'a, Sabri BUCAK'a ve Ömer POLAT'a teşekkür ederim.

Bana öğrenmenin güzelliğini keşfettiren, yaşamını bize adayarak yaşamımıza anlam katan ilk öğretmenim anneme ve diğer aile bireylerime teşekkür ederim.

İçimi ısıtan sevgisiyle bana güç verip, hayatlarımızın kesişmesine her daim şükredeceğim, can yoldaşım, hayat arkadaşım, eşim Leyla'ya sonsuz teşekkürlerimi sunarım.

Eğitim hayatım boyunca emekleriyle bugünlere gelmeme yardımcı olan bütün hocalarıma ve kıymetli dostlarıma teşekkürü borç bilirim.

ŞEKİLLER DİZİNİ

Sayfa No

Şekil 3. 1. Biyolojik sinir hücresi ve yapay sinir ağı hücresi 19
Şekil 3. 2. Yapay sinir hücresi/yapay nöron 20
Şekil 3. 3. LSTM Ağı Mimarisi 24
Şekil 3. 4. LSTM Bloğu Çalışma Prensibi 26
Şekil 3. 5. Optimizasyonların örnek uygulaması 29
Şekil 4. 1. Çalışmada kullanılan TUSAGA-Aktif istasyonları 31
Şekil 4. 2. SURF istasyonunun 2 saatlik çözünürlüklü VTEC değişimleri 32
Şekil 4. 3. SURF istasyonunda eğitilecek ve test edilecek VTEC değerleri 33
Şekil 4. 4. SURF istasyonunda tahmini ve gözlemlenen VTEC değerleri 33
Şekil 4. 5. İlk tahmin verileriyle SGDM ve ADAM optimizasyon çözümleri 34
Şekil 4. 6. SURF istasyonunda tahmine yapılan güncelleme 35
Şekil 4. 7. ADAM optimizasyonuyla güncellenen yeni KOH değerleri 36
Şekil 4. 8. SGDM optimizasyonuyla güncellenen yeni KOH değerleri 36
Şekil 4. 9. ADAM ve SGDM optimizasyonlarının duyarlılıkları 37
Şekil 4. 10. ANTL istasyonunun 2 saatlik çözünürlüklü VTEC değişimleri 40
Şekil 4. 11. ANTL istasyonunda eğitilecek ve test edilecek VTEC değerleri 41
Şekil 4. 12. ANTL istasyonunda tahmini ve gözlemlenen VTEC değerleri 41
Şekil 4. 13. İlk tahmin verileriyle SGDM ve ADAM optimizasyon çözümleri 42
Şekil 4. 14. ANTL istasyonunda tahmine yapılan güncelleme 43
Şekil 4. 15. ADAM optimizasyonuyla güncellenen yeni KOH değerleri 44
Şekil 4. 16. SGDM optimizasyonuyla güncellenen yeni KOH değerleri 44
Şekil 4. 17. ADAM ve SGDM optimizasyonlarının duyarlılıkları 45
Şekil 4. 18. GEME istasyonunun 2 saatlik çözünürlüklü VTEC değişimleri 48
Şekil 4. 19. GEME istasyonunda eğitilecek ve test edilecek VTEC değerleri 49
Şekil 4. 20. GEME istasyonunda tahmini ve gözlemlenen VTEC değerleri 49
Şekil 4. 21. İlk tahmin verileriyle SGDM ve ADAM optimizasyon çözümleri 50
Şekil 4. 22. GEME istasyonunda tahmine yapılan güncelleme 51
Şekil 4. 23. ADAM optimizasyonuyla güncellenen yeni KOH değerleri 52
Şekil 4. 24. SGDM optimizasyonuyla güncellenen yeni KOH değerleri 52
Şekil 4. 25. ADAM ve SGDM optimizasyonlarının duyarlılıkları 53
Şekil 4. 26. HEND istasyonunun 2 saatlik çözünürlüklü VTEC değişimleri 56
Şekil 4. 27. HEND istasyonunda eğitilecek ve test edilecek VTEC değerleri 57
Şekil 4. 28. HEND istasyonunda tahmini ve gözlemlenen VTEC değerleri 57
Şekil 4. 29. İlk tahmin verileriyle SGDM ve ADAM optimizasyon çözümleri 58
Şekil 4. 30. HEND istasyonunda tahmine yapılan güncelleme 59
Şekil 4. 31. ADAM optimizasyonuyla güncellenen yeni KOH değerleri 60
Şekil 4. 32. SGDM optimizasyonuyla güncellenen yeni KOH değerleri 60
Şekil 4. 33. ADAM ve SGDM optimizasyonlarının duyarlılıkları 61

ÇİZELGELER DİZİNİ

Sayfa No

Çizelge 3. 1. ANN'de kullanılan bazı aktivasyon fonksiyonları ve özellikleri 23
Çizelge 4. 1. Tahmini yapılacak istasyonlara ait özellikler..... 30
Çizelge 4. 2. İstasyonlara ait istatistiksel özellikler ve tasarlanan ağın özellikleri 30
Çizelge 4. 3. SURF istasyonunda ilk tahmindeki optimizasyonlarının duyarlılıkları 38
Çizelge 4. 4. SURF istasyonunda güncellenen tahmindeki optimizasyonlarının duyarlılıkları 39
Çizelge 4. 5. ANTL istasyonunda ilk tahmindeki optimizasyonlarının duyarlılıkları 46
Çizelge 4. 6. ANTL istasyonunda güncellenen tahmindeki optimizasyonlarının duyarlılıkları 47
Çizelge 4. 7. GEME istasyonunda ilk tahmindeki optimizasyonlarının duyarlılıkları..... 54
Çizelge 4. 8. GEME istasyonunda güncellenen tahmindeki optimizasyonlarının duyarlılıkları..... 55
Çizelge 4. 9. HEND istasyonunda ilk tahmindeki optimizasyonlarının duyarlılıkları 62
Çizelge 4. 10. HEND istasyonunda güncellenen tahmindeki optimizasyonlarının duyarlılıkları 63
Çizelge 4. 11. Her istasyonda yapılan tahminlere optimizasyonların etkisi..... 64

SİMGELER ve KISALTMALAR DİZİNİ

ADAM	: Uyarlanabilir Moment
ANN	: Yapay Sinir Ağları
CNN	: Konvolüsyonel Sinir Ağı
DAE	: Derin Oto-Kodlayıcı
DBN	: Derin İnanç Ağı
DCBs	: Diferansiyel Kod Farkı
Dst	: Jeomanyetik Aktivite İndisi
GA	: Genetik Algoritma
GISTM	: GPS İyonosferik Sintilasyon ve TEC Monitör
GPS	: Küresel Konumlama Sistemleri
IPP	: İyonosferin Delindiği Nokta
IRI	: Uluslararası Referans Iyonosfer
KOH	: Karesel Ortalama
Kp	: Jeomanyetik Fırtına İndisi
LSTM	: Uzun Kısa Süreli Bellek
NNAR	: Sinir Ağı Otoregresyonu
PD	: Yüzde Sapma Oranı
RBM	: Sınırlı Boltzman Makinesi
RBF	: Radyal Temel Fonksiyon
RINEX	: Alıcıdan Bağımsız Veri Formatı
RNN	: Tekrarlayan Sinir Ağları
SGDM	: Momentumlu Stokastik Gradyan İnişi
SNN	: Güneş Lekesi Sayısı
SST	: Deniz Yüzeyi Sıcaklığını
STEC	: Eğik Toplam Elektron İçeriği
SVM	: Destek Vektör Makinesi
TEC	: Toplam Elektron İçeriği
TECU	: Toplam Elektron İçeriği Birimi
TUSAGA	: Türkiye Ulusal Sabit GPS Ağı
VTEC	: Dikey Toplam Elektron İçeriği

1. GİRİŞ

Küresel konumlandırma sistemi (Global Position System - GPS) uydu teknolojisine dayalı konumlandırma ve navigasyon sistemidir. GPS, hava, deniz ve kara navigasyonu gibi çeşitli alanlarda çok yaygın bir şekilde kullanılmakla birlikte günlük yaşam, endüstri, araştırma ve eğitim için de bir araç vazifesi görmektedir. Elektronik, yörünge mekaniği, atmosfer bilimi, jeodezi, görelilik teorisi, matematik ve filtreleme ile yazılım mühendisliği bilgilerini içerir (Xu, 2007). Konumlandırma da karşımıza çıkan atmosferik etkilerin büyük bir kısmı GPS sinyalleri üzerindeki iyonosferik etkilerden kaynaklanmaktadır. İyonosferde~~ki~~ meydana gelen bozulmalar; özellikle uzay iklim koşullarının meydana getirdiği değişimlerin, radyo iletişim sistemine ve yayılımına zarar vermektedir (Tan, 2008). Bu nedenle iletişim, navigasyon, radar gibi radyo sinyallerinin iletişimini olumsuz yönde etkileyebilir (~~S.~~ Tan ve ark., 2011). İyonosfer radyo iletişiminde önemli bir rol oynadığından dolayı yapılacak uygulamalar iyonosferik şartlar dikkate alınarak gerçekleştirilmelidir.

Toplam Elektron İçeriği (Total Electron Content - TEC), GPS uydularından GPS alıcısına gelen sinyal yolu boyunca 1 metrekarelik kesit alanında elde edilen toplam elektron sayısı (10^{16}el/m^2) olarak tanımlanır ve toplam elektron içeriği birimi (Total Electron Content Unit - TECU) olarak temsil edilmektedir (Abdullah ve ark., 2009). TEC, serbest elektronlar aracılığıyla düzeltilmiş GPS sinyallerinden elde edilen iyonosferik değişkenliğin bir belirtisidir (Yaacob ve ark., 2010). TEC, iyonosferdeki bozukluklar hakkında bilgi sağlayan önemli bir parametredir (Chakraborty ve ark., 2014). Jeomanyetik alan ve güneş aktiviteleri arasındaki karmaşık fiziksel etkileşimler, iyonosferik etkilerin modellenmesini ve tahmin edilmesini zorlaştırır (Xu, 2007). GPS aracılığıyla yapılan gözlemler, navigasyon ve konumlandırma uygulamalarıyla birlikte iyonosferik uzay iklim koşullarının etkilerinin araştırılmasını kullanılmaktadır (Hofmann-Wellenhof ve ark., 1993).

Bu çalışmada Yapay Sinir Ağları (Artificial Neural Networks - ANN) modelleri GPS ile ölçülen TEC zaman serileri kullanılarak iyonosferik TEC farklılıklarının modellenmesi ve tahmini için kullanılacaktır. ANN'ler istatistiksel yöntemlerden daha iyi performans gösterse de uzun yılların TEC örneklerini içeren büyük girdili eğitim verilerinin gerekliliği ve eğitim sürecinde sinaptik ağırlıkların belirlenmesindeki karmaşıklık ve kısa süreli TEC tahmini için ANN modelinin uygulanmasını sınırlayan standart matematiksel arka plan eksikliği belirlenmiştir (Leandro ve Santos, 2007; Tulunay ve ark., 2006). Bu sebepten dolayı tekrarlayan sinir ağları (Recurrent Neural Network - RNN) derin öğrenmede zaman serileri için tasarlanmıştır.

Uzun Kısa Süreli Bellek (Long Short-Term Memory - LSTM), zaman serilerini ve uzun menzilli bağımlılıklarını modellemek için tasarlanmış ve özelleştirilmiş bir RNN mimarisidir. Bir LSTM ağı, RNN ağ modellerinden farklı olarak LSTM birimleri içerir. LSTM birimi, kısa veya uzun zaman aralıklarını belleğinde tutar. Bu sebeple, depolanan bilgi tekrarlı olarak değiştirilmez ve bu zaman diliminde geri yayılımla eğitildiğinde bilgi kaybı olmaz. Ağın eğitimi esnasında oluşturulan öğrenmenin kompleks hale gelmesinden dolayı güncelleme yapılamamakta ve eğitim sonlanabilmektedir. RNN yapısındaki geri yayılım problemine, LSTM yapısında bir bellek birim hücresi RNN yapısına katılmasıyla çözüm olarak sunulmuştur. Bu bellek birim hücresi ile daha önce kullanılan bilgi alınabilmekte ve bir sonrakine aktarılabilmektedir. Bu nedenle LSTM mimarileri yaygın olarak kullanılmaya başlanmıştır (Hochreiter ve Schmidhuber, 1997; Olah, 2019; Ni ve ark., 2019).

TEC değerlerinden oluşan geçmiş zaman serileri verilerinden, ileriye yönelik GPS-TEC tahminleri LSTM ağ modeli ile yapılabilmektedir. Kısaca ileriye yönelik zaman serileri ve bu seriler arasındaki ilişki bulunabilmektedir. Bu tez çalışmasında, LSTM ağ modeli, 24. güneş döngüsü sırasında 3.5 yıllık GPS-TEC sıralı verilerinin işlenmesi uygulanmaktadır. TEC zaman serisi tahmini için yukarıda bahsedilen

GPS-TEC veri seti kullanılacak ve LSTM Tahmini TEC modelinin performansı karesel ortalama hata (KOH) değerlerine göre ölçülecektir.

Bu yüksek lisans tezi çalışması kapsamında derin öğrenme alanında ki birçok disiplin tarafından da kullanılmakta olan LSTM'nin tahmin kabiliyeti uyarlanabilir moment (Adaptive Moment - ADAM) ve momentumlu stokastik gradyan inişi (Stochastic Gradient Descent with Momentum - SGDM) olmak üzere iki farklı optimizasyon ile ele alınacaktır. Bu optimizasyonların doğrulukları bu çalışma kapsamında değerlendirilecektir.

Tez kapsamında, birinci bölümde teze giriş yazısı ve tezin amacı anlatılmıştır, ikinci bölümde literatürde günümüze kadar yapılan derin öğrenme yapılan tahmin modelleri ve LSTM tahmin modellerinin örnekleri ele alınmıştır, üçüncü bölümde derin öğrenmenin bir yöntemi olan LSTM'nin geniş bir tanımına, hangi parametlerin kullanıldığına, matematiksel bağıntılarına, kullanılacak verilere ve optimizasyonlarına değinilecektir, dördüncü bölümde araştırma bulguları ve tartışma kısmına yer verilmiştir. Son bölüm olan beşinci bölümde ise sonuçlar ve öneriler aktarılarak çalışma tamamlanmıştır.

1.1. Tezin Amacı

GPS sinyalleri ile yapılan ölçümlerin daha iyi bir konumlandırma hizmeti verebilmesi için bu sinyalleri etkileyen iyonosferik TEC değerlerinin derin öğrenme ortamında tahmininin yapılması bu tez çalışmasınn amacını ve hedefini belirlemede önemli bir rol oynamıştır.

2. ÖNCEKİ ÇALIŞMALAR

Derin öğrenme ile tahmin yapmak günümüze kadar gelen literatür kapsamında birçok çalışma içerisinde konu olarak seçildiğini görmekteyiz. Derin öğrenme çalışmalarına konu olan örnek literatür çalışmalarına aşağıda yer verilmiştir.

Xenos ve diğerleri (2003), Floransa'dan saatlik ve günlük (1 saat, 1 gün, 2 gün ve 7 gün aralığında) Faraday dönüklüğünden türetilmiş TEC ölçümlerini kullanarak klasik sinir ağ modelleri yardımıyla tahmin yapmışlardır. İncelenen veri kümesi için tahmin doğruluğu, zaman aralığı arttığında bozulmasına rağmen, diğer iyonosferik TEC modellerinden her zaman yüksek olduğunu göstermiştir. Aslında, ±%10'luk tahmin hata sınırı göz önüne alındığında, buna dahil edilen veri yüzdesi genelde %55'in üzerinde olmuştur. Sonuçların mevsime ve veri kümesi zenginliğine büyük ölçüde bağlı olduğu bulunmuştur.

Srivani ve diğerleri (2005), Hindistan'ın Bengaluru istasyonu (16.26° Kuzey, 80.44° Doğu) üzerindeki iyonosferik gecikmeleri tahmin etme kabiliyetini değerlendirmek için LSTM tahmin tekniğini araştırmış ve sekiz yıllık (2009-2016) GPS-TEC değerlerini kullanılarak LSTM modelinin performansını değerlendirmişlerdir. LSTM tahmin modeli, Uluslararası Referans İyonosfer - 2016 (International Reference Ionosphere - IRI2016) modeliyle mukayese edilmiştir. Yapılan tahmin sonuçlarıyla istatistiksel analizler yapılmış olup, önerilen LSTM modelinin GPS-TEC ile 0.99'luk bir korelasyon sağladığını ve 1-2 TEC hassasiyetinde bir tahmin hatası olduğunu belirlemişlerdir.

Habarulema ve diğerleri (2007), Güney Afrika GPS-TEC'den mevsimsel değişim, günlük değişkenlik, güneş lekesi sayısı (Sun Spot Numbers – SSN) ve manyetik aktivite endeksi kullanılarak yapay sinir ağı yöntemini kullanmıştır. Öngörülen TEC değerleri, IRI-2001 ve GPS-TEC'den elde edilen TEC ile

karşılaştırılmıştır. Sonuç olarak, ANN, Güney Afrika'daki IRI-TEC modelinden GPS-TEC'yi daha doğru tahmin ettiğini, ancak iyonosferin mevsimsel değişimini doğru bir şekilde göstermek için daha fazla GPS verisinin gerekli olduğu belirtilmiştir.

Abhishek ve diğerleri (2012), Hindistan'ın Karnataka ili üzerinde ortalama yağış tahmin etme olasılığını ANN modelleri ile analiz etmişlerdir. ANN tabanlı tahmin modellerinin formüle edilmesinde üç katmanlı geri yayılımlı bir ağ oluşturulmuştur. İncelenen modeller gizli katman sayısında farklıdır. Eğitim için %70'lik veri seti kullanılmış olup, %30'luk test verisinin ortalama yağış tahmini gerçekleşmiştir.

Watthanasangmechai ve diğerleri (2012), Tayland'da sabit bir ekvatoral enlem GPS istasyonu olan Chumphon üzerindeki TEC tahmini için geri yayılım algoritmasına sahip tek gizli katman ileri beslemeli bir ağ ile ANN uygulaması gerçekleştirmişlerdir. İncelenen dönem, 2005'ten 2009'a kadar düşük güneş aktivitesi dönemindeki mevcut verilere dayanmaktadır. ANN'nin giriş verileri; gün sayısını, saat sayısını ve güneş lekesi numarasını içermiştir. TEC'yi sinir ağları tahmininden (ANN TEC), gözlemlenmiş TEC (GPS-TEC) ve IRI-2007 modelinden TEC (IRI-2007 TEC) ile karşılaştırarak bir analiz yapılmıştır. TEC tahmini için optimum ANN'yi elde etmek için, KOH değerleri dikkate alınmıştır. ANN'nin performansını ölçmek için, ANN-TEC'nin normalleştirilmiş KOH değeri, ANN-TEC ve GPS-TEC arasındaki farktan hesaplanmıştır. KOH ve normalize KOH hem ANN modeli hem de IRI-2007 modeli için karşılaştırmalar açıklanmıştır. Sınırlı miktarda mevcut veri olmasına rağmen, elde edilen sonuçlar önerilen ANN-TEC'in GPS-TEC'yi ekvatoral enlem istasyonu üzerinde oldukça iyi tahmin edebileceğini göstermiştir. Optimum ANN'yi elde etmek için, her biri gizli katmanda 6 ila 12 hücreli nöronların KOH değerlerinin karşılaştırması yapılmıştır. ANN işlemlerinde kullanılan tüm veriler 2005'ten 2009'a kadar olan 4 yıllık verilerdir. Eğitimli ağın başarısı sadece girdi parametrelerinin seçimine değil, aynı zamanda başlangıç

ağırlıklarına da bağlı olduğu için ilk rastgele ağırlıklar kullanılmıştır. En iyi ANN modelini seçmek için her ANN ağını farklı parametrelerle on kez çalıştırarak gizli katman sayısının 9 seçildiği modelin, çalışılan süre boyunca Chumphon istasyonu için KOH değeri ±2.27 TECU ve normalize edilmiş KOH değeri ±0.16 TECU ile en iyi ANN modeli olarak elde etmiştir.

Huang ve Yuan (2014), 30 dakika çözünürlüklü iyonosferik TEC verilerinin tahmininde kullanılmak üzere Gauss karışım modeli ile radyal temel fonksiyon (RBF) sinir ağı geliştirmiştir. Gelişmiş ağ modelinin farklı enlemlerde yer alan istasyonlara tepkisi hakkında daha fazla bilgi edinmek için, GPS yer istasyonlarının (BJFS, WUHN ve KUNM) 2011 yılında 6 ay boyunca eğitim veri seti, radyal temel fonksiyon (Radial Basis Function – RBF) ağ modelinin veri ve test veri setinin doğrulanması için kullanılmıştır. Eğitilmiş modelin performansı bazı kriterle değerlendirilmiştir. Sonuçlar, tahmin edilen TEC'nin ortalama hatası yaklaşık %9 ve KOH değeri ±5 TECU'dan az olduğu saptanmıştır.

Homam (2014), Malezyadaki Parit Raja GPS istasyonundan, İyonosferin saatlik TEC değerlerinin tahminini 2 ağ modeli oluşturarak yapmıştır. İlk ağdaki eğitimde 2005 yılının Ocak-Kasım arasındaki verileri ve testlerde Aralık 2005 verileri kullanılarak, ikinci ağdaki eğitimde ise 2005 Ocak-Ekim arasındaki verileri ve testlerde Kasım 2005 verileri kullanılmıştır. Genel olarak testlerdeki KOH ±3-7 TECU, ±2-5 TECU mutlak hatası ve %9-20 bağıl hata ile sonuçlanmıştır. TEC değişimlerinin düşük güneş aktivitesi sırasında olan Kasım 2005'teki tahmini, nispeten daha yüksek güneş aktivitesi sırasında olan Aralık 2005'e kıyasla daha iyi sonuçlar vermiştir.

Sompotan ve diğerleri (2015), Endonezya'da gerçekleşen bir depremin merkez üssünü belirlemek amacıyla iyonosferik TEC haritasını derin öğrenmenin kriging yöntemiyle tahmin etmiş ve 2.5° × 5° hassasiyetinde iyonosferik TEC haritası elde etmişlerdir.

Homam (2016), bir nöral ağ kullanarak düşük ila orta güneş aktivitesi sırasında 6 yıllık (2005- 2010) bir GPS İyonosferik sintilasyon ve TEC Monitör (GPS Ionospheric Scintillation TEC Monitor - GISTM) alıcısından elde edilen verileri kullanarak, saatlik VTEC tahminini sunmuştur. Nöron sayısının ve gizli katmanların etkisini gözlemlemek için çeşitli ağ parametreleri araştırılmıştır. Birkaç ağ modeli tasarımı için genel eğitim sonucunda KOH değeri ±3-7 TECU, mutalak hata ±2-6 TECU ve %8 ile %28 göreceli hata bulunmuştur. Nisan 2010- Kasım 2010 verileri kullanılarak yapılan eğitim sonucunda KOH değeri ±2.95-3.88 TECU, mutlak hata ±2.39-3.09 TECU ve bağıl hata %8.11 - %16.18 olarak elde edilmiştir. Ayrıca gizli katman sayılarına göre de KOH karşılaştırmaları yapılmıştır.

Akir ve diğerleri (2017) Malezya'da bulunan UKM isimli GPS istasyonundan GISTM verileri kullanılarak TEC tahmini yapmışlardır. TEC tahmini için Matlab ortamında özelleştirilmiş parametrelerle bir yapay sinir ağı modeli tasarlamışlardır. İyonosferik aktiviteden çeşitli tiplerde giriş verileri ve veri gösterimleri, seçilen ileri-geri yayılma yöntemi ile eğitilen ve seçilen test verileri üzerinde test edilen üç katmanlı bir algılayıcı olan ağ yapısı için kullanılmıştır. Optimum KOH değeri 10 gizli katman sayısı ile ±1.35 TECU olarak elde edilmiştir. İncelenen dönem için GISTM UKM istasyonu için en iyi ANN modeli olarak 10 düğüm ile oluştuğu sonucuna varılmıştır. Ölçülen TEC'den, Tahmini TEC değişimlerinin analizi yapılmış daha sona da IRI-düzeltme modeliyle karşılaştırmak için bir analiz yapılmıştır. Sonuçlar, ANN modelinin %9.96 bağıl hata ile tahmin ettiğini göstermiştir. TEC tahmininin daha büyük veri setiyle daha başarılı bir şekilde gerçekleştirilme potansiyeline sahip olduğu anlaşılmıştır.

Sun ve diğerleri (2017), Pekin'deki iyonosferik düşey TEC'yi tahmin etmek için uzun kısa süreli bellek (LSTM) tabanlı bir model önermişlerdir. Modelin girişi, günlük TEC'lerin vektöründen ve diğer ilgili parametrelerden oluşan bir zaman dizisidir. Çıktı 24 saat gelecekteki TEC'lerdir. Sonuç, test verilerinin karesel ortalama (KOH) hatasının 3.50'ye ulaşabileceğini ve düşük güneş aktivitesi

süresince KOH hatasının bu sayıdan az olduğunu göstermiştir. Çok katmanlı algılayıcı yapay sinir ağları ile karşılaştırıldığında, LSTM'nin iyonosferik TEC değişimlerini tahmin etmede daha güvenilir olduğu saptanmıştır. İyonosferin TEC tahminine dayanan bir LSTM RNN modeli sunulmuştur. Deneysel sonuçlar, önerilen modelin daha kararlı yakınsama eğilimi, duyarlılığı daha iyi KOH hata ile mevcut yöntemleri geride bıraktığını ve farklı koşullarda iyi bir öngörü sağlayabileceğini göstermiştir.

Venkata ve diğerleri (2017), iyonosferik TEC değerlerini tahmin etmek için yapay zekanın bir alt birimi olan bulanık mantık tabanlı bir gradyan iniş yöntemi önermiştir. Bu teknikte üyelik fonksiyonları, indirgeme tahmini değerlerine göre ayarlanmıştır. Önerilen algoritma, (Guntur, Hindistan, KL Üniversitesi) düşük enlem istasyonundaki iki jeomanyetik fırtınanın TEC verileri ile test edilmiştir. Gradyan iniş yönteminin iyi performans gösterdiği ve tahmin edilen TEC değerlerinin orijinal TEC ölçümlerine yakın olduğu elde edilmiştir.

Zhang ve diğerleri (2017), Çin'in kıyı denizlerinin deniz yüzeyi sıcaklığını (SST) tahmin etmek amacıyla LSTM yöntemini önermiştir. Önerilen ağ mimarisi LSTM katmanı ve tam bağlı yoğun katman olmak üzere iki tür katmandan oluşmuştur. LSTM katmanı, zaman serisi ilişkisini modellemek için kullanılmıştır. Tam bağlı katman, LSTM katmanının çıktısını olası bir tahmine eşlemek için kullanılmıştır. Deneylerle bu mimarinin en uygun parametreleri araştırılmış ve önerilen yöntemin performansını ölçmek amacıyla Çin'in kıyı denizlerinin deniz yüzeyi sıcaklığının tahmini, gerçeğe yakın bir doğrulukla tahmin edilmiştir.

Song ve diğerleri (2018), Çin üzerindeki iyonosferik TEC için bölgesel bir tahmin modeli geliştirilmesinde yapay sinir ağlarının uygulamasını araştırmıştır. Geleneksel ANN tabanlı modelin neden olduğu 'yerel minimum' etkisinden kaçınmak için, ANN'nin başlangıç ağırlıklarını optimize etmek için bir genetik algoritma (Genetic Algorithm - GA) kullanılmıştır. ANN'nin iyonosferik

parametrelerde değişikliklere neden olduğu bilinen iyonosferik günlük değişimler, mevsimsel bilgiler, güneş döngüsü, jeomanyetik faaliyetler, coğrafi koordinatlar ve sapma gibi parametreler kullanılmıştır. Çıkış parametresi, Çin'deki 43 sabit GPS istasyonundan ölçülen günlük, saatlik VTEC'lerdir. 2012-2014 yılları arasında veri setleri ağı eğitmek için kullanılmıştır ve 2015 veri setleri modelin performansını doğrulamak için test verisi olarak seçilmiştir. GA tabanlı ANN (GA-ANN) modeli, geri yayılım tabanlı (Back Propagation – BP) ANN modeli ve Uluslararası Referans İyonosfer-2012 (IRI2012) modelinden yapılan tahminler, Çin'deki 12 GPS istasyonundan gözlemlenen TEC ile karşılaştırılmıştır. Sayısal analize göre, GA-ANN modelinin KOH değeri ±5.21 ile 8.48 TECU arasında değişmektedir, karşılık gelen yüzdelik sapma değeri (Percent Deviation - PD) %8.78–12.30'dur ve korelasyon katsayısı 0.80-0.95'dir. BP-ANN modelinin KOH değeri ±6.30 ile 12.15 TECU arasında değişmektedir, PD %10.17 ile %14.16 arasındadır ve korelasyon katsayısı 0.72–0.94 aralığındadır. IRI2012 modeli için karşılık gelen aralıklar sırasıyla ±6.55–11.79 TECU, PD %11.01-14.07 ve korelasyon katsayı değerleri 0.73-0.91'dur. Bu, TEC'in günlük değişimlerinin karşılaştırılması ile birleştiğinde, GA-ANN modelinin BP-ANN ve IRI2012 modellerinden çok daha iyi performans gösterdiğini açıklamıştır. Ayrıca, mevsimsel ve yerel özelliklerin değişimi GA-ANN modeli ile de doğrulanmaktadır. Sonuçlar GA-ANN modelinin iyonosferik çalışmalardaki uygulamalar için daha kullanışlı olduğunu göstermiştir.

Okoh (2018), GPS-TEC değişimlerinin Nijerya üzerinden uzayda ve zaman içinde bir sinir ağı modeli geliştirmek için Nijerya'daki 14 GPS istasyonundan dikey toplam elektron içeriği (VTEC) verilerini kullanarak, 2011 yılı ile 2016 arasındaki dönemi kapsayan belirli bir çizim yapmıştır. Geliştirilen modelden alınan örnek simülasyonlar: Modelin, günlük, mevsimsel, yıllık, boylamsal ve enlemsel değişkenler açısından VTEC değişkenlik modellerini tahmin etmede doğru olduğunu göstermektedir. Yapay sinir ağı tahminleri ile IRI-Plus ve NeQuick gibi diğer modellerin karşılaştırmalı analizi, sinir ağı modelindeki tahminlerin ağırlıklı olarak daha güvenilir olduğunu göstermiştir. Nijerya üzerinden bölgesel bir VTEC modeli,

2011-2016 yıllarını kapsayan 14 istasyondan derin öğrenme ortamında oluşturulmuş sinir ağları modeli ve GPS-TEC verileri kullanılarak geliştirilmiştir. Toplam 7 giriş katmanı (Yıl, Gün, Saat, Jeomanyetik Boylam, Jeomanyetik Enlem, SSN ve manyetik fırtına endeksleri) çalışılan çıktıyı (GPS-TEC) öğrenmek için kullanılmıştır. Farklı gizli katmanlı modelde 20 farklı ağı simüle ederek, 6 gizli katmanlı ağda KOH değeri minimuma ulaşmıştır. Tasarlanan sinir ağ modelinin, günlük değişimler, mevsimsel değişimler, uzun vadeli güneş döngüsü değişimleri ve Nijerya'daki mekansal değişimler açısından VTEC değişkenlik modellerini tahmin etmede yetkin olduğu gösterilmiştir. İki popüler küresel iyonosferik modelle (NeQuick ve IRI-Plus) karşılaştırıldığında, tasarlanan sinir ağı modelinden tahminlerin GPS-TEC değerlerine yakınlık açısından daha doğru olduğu görülmüştür. Tasarlanan yapay sinir ağı modeli tahminleri için KOH'lar, ±1.3–10.8 TECU, ortalama ise ±5.6 TECU. IRI-Plus modeli için, KOH'lar ±8.5–12.4 TECU arasında ve ortalama ±11.2 TECU. NeQuick için KOH'lar ±2.8 ila 11 TECU arasında ve ortalama ±6.7 TECU olarak belirlenmiştir.

Sabzehee ve diğerleri (2018), 2006-2010 zaman aralığında, TEC modellemesi için bir girdi parametreleri ve ANN mimarisinin geliştirilmesinde İran'da 5 bölge tanımlamış ve kullanmışlardır. Girdi alanı olarak; gün sayısı (mevsimsel değişim), saat (günlük değişim), güneş lekesi sayısı (güneş aktivitesinin bir ölçüsü) ve manyetik indeksi (manyetik aktivitenin bir ölçüsü) içermiştir. Elde edilen sonuçlara göre, ANN-TEC modeli ve tahmininde kabul edilebilir bir yetenek ve esneklik göstermiştir. Uluslararası Referans İyonosferin (IRI-TEC) IRI-2012 versiyonundan elde edilen TEC ve ANN-TEC tarafından tahmin edilen TEC, ekinokslar ve gündönümü esnasında karşılaştırılmıştır. Bu karşılaştırmaya göre ANN'nin GPS TEC değişimlerinin İran üzerindeki IRI'dan daha doğru tahmin ettiğini göstermiştir. IRI-2012 modelinin TEC değişimlerini İran üzerinden sağlamak için uygun bir yöntem olmadığı sonucuna varılmıştır.

İnyurt ve Şekertekin (2019), 2015 yılında ANKR (Enlem: 39.85596, Boylam: 32.84603) GPS istasyonundan elde edilen GPS-TEC gözlemleri ile yapay sinir ağını kullanarak mevsimsel iyonosferik TEC modellemesi ve tahmini yapmıştır. Yılın Günü (DOY), saat, F10.7 cm indeksi (güneş aktivitesi), Kp indeksi ve DsT indeksi (manyetik fırtına indeksi) ağ için giriş parametreleri olarak kabul edilmiştir. ANN modellerinin performansları, her mevsim için KOH ve R istatistiksel ölçümleri kullanılarak değerlendirilmiştir. Tahmin sonuçlarına bakıldığında, ANN, sırasıyla KOH ±3.92 TECU ve ±3.97 TECU ile kış ve sonbahar aylarında TEC değerlerinin yaz ve ilkbahardan daha başarılı tahminlerini sunmuştur. Öte yandan, kış veri setinin (0.74) R değeri, sonbahardaki veri setinden (0.88) düşükken, KOH değerleri zıt olmuştur. Bu sonuçlar, tasarlanan ANN modelinin GPS-TEC değişkenlerini ANKR istasyon verileri için gerçeğe yakın bir öngörü saptanmıştır.

Kim ve Kim (2019), GIM-TEC verilerini güneş ve jeomanyetik parametrelerle hesaplamak için bir destek vektör makinesi (Support Vector Machine-SVM) önermektedir. SVM algoritmasını eğitmek için Güney Kore'deki sabit GPS istasyonundan elde edilen bir yıllık iyonosferik gecikme haritası verileri kullanılmıştır. Daha sonra, giriş veri bölgesi dışındaki 1 aylık iyonosferik gecikme verilerinin hesaplandığı tahmin edilmektedir. Güneş ve jeomanyetik çevresel parametrelere ek olarak, iç veri bölgesinden gelen iyonosferik gecikme verileri, dış bölge için iyonosferik gecikme verilerini tahmin etmek için kullanılmıştır. Doğruluk değerlendirmesi, iç veri bölgelerinin dışında 5°, 10° ve 15° aralığında üç seviyede gerçekleştirilmiştir. Ekstrapolasyon hataları, 5 bölge için ±0.33 TECU ve 15 bölge için ±1.95 TECU'dur. Bu değerler GPS Klobuchar model hata değerlerinden önemli ölçüde düşüktür. Başka bir makine öğrenmesi ekstrapolasyon yöntemi ile karşılaştırıldığında, sinir ağı %26.7'ye kadar önemli bir gelişme göstermektedir.

Kaselimi ve diğerleri (2019), iyonosferik gecikmelerin GNSS uydu sinyalleri üzerindeki olumsuz etkilerinin giderilmesi için uygun iyonosfer modelini tahmin edecek bir LSTM ağı geliştirmişlerdir. LSTM ağlarını kullanarak GPS ağ

istasyonlarının farklı konumlarındaki iyonosferik gecikmeyi tahmin etmek için uygun yapılandırma parametrelerini seçerek, ağın performansını artırmak için de bir Bayes optimizasyonu yöntemi ile çalışmışlardır.

Pala ve Atıcı (2019), 25.Güneş Döngüsü'nü tahmin etmek için, 1749-2018 yılları arasında düzenli olarak ölçülen güneş lekesi sayısı (SSN)'lerden oluşan değerleri kullanarak bir zaman serisine dönüştürmüşlerdir. 10 yıllık bir tahmin, derin öğrenme algoritmaları yardımıyla yapılmıştır. Tahmin sonuçları, LSTM ve sinir ağı otoregresyonu (Neural Network AutoRegression - NNAR) gibi algoritmaların geleneksel birçok algoritmadan daha iyi performans gösterdiği saptanmıştır. Geniş bir zaman serisi tahmin sürecinde R programlama dili kullanılarak, 2022 ve 2023 arasında 25.Güneş Döngüsü'nün maksimum genliğine ulaşacağını da tahmin etmişlerdir.

3. MATERYAL ve YÖNTEM

3.1. Materyal

3.1.1. GPS gözlemlerinden TEC elde edilmesi

Yapay İyonosferik TEC değişimleri GPS sinyallerinin kod (P) veya taşıyıcı faz (Φ) gözlemlerinin geometriden bağımsız kombinasyonu yardımıyla elde edilebilir (Inyurt ve ark., 2017; Schmidt ve ark., 2008). TEC değerleri TECU biriminde, GPS uyduları ile yeryüzündeki GPS alıcısı arasında ortaya çıkan sinyal yolu boyunca atmosferin 1 metrekare taban alanına sahip silindir ile iyonosfer tabakasının belirli bir yüksekliğinde bu silindir ile oluşan arakesitinde ölçülen elektron miktarıdır ve 1 TECU yaklaşık 10^{16} elektron/m^2'dir. Her bir GPS alıcısı ve GPS uydusu arasındaki eğri sinyal yolu boyunca belirlenen Eğik Toplam Elektron İçeriği (Slant Total Electron Content - STEC) değeri, uydu ve alıcı sistemine bağlı f_1 ve f_2 frekans aralığındaki sinyal gecikmelerinin diferansiyel kod ölçüsü farkları (Differantial Code Bias-DCBs) GPS gözlemlerinden elimine ederek belirlenebilmektedir (Ulukavak, 2017).

GPS alıcıları, GPS uydularından yayılan sinyalleri özel bir alıcı bağımsız değişim (Receiver Independent Exchange-RINEX) formatında belleğe kaydederler. İki farklı frekansa sahip (f_1=1575.42 MHz ve f_2=1227.60 MHz) psoydo-range kayıtlarının modeli;

$$P_{1,u}^{m} = \rho_u^m + c(\delta t_u - \delta t^m) + d_{\mathrm{trop,u}}^{m} + d_{ion1,\mathrm{u}}^{m} + c(\varepsilon_1^m + \varepsilon_{1,u}) \quad (1)$$

$$P_{2,u}^{m} = \rho_u^m + c(\delta t_u - \delta t^m) + d_{\mathrm{trop,u}}^{m} + d_{ion2,\mathrm{u}}^{m} + c(\varepsilon_2^m + \varepsilon_{2,u}) \quad (2)$$

biçiminde oluşturulur (Ulukavak, 2017). Burada, P, psoydo-range gözlemini; ρ, uydu ve alıcı arasındaki uzunluğu, $\delta t_u - \delta t^m$, uydu ile alıcı

arasında oluşan zamansal gecikme hatalarını, d_{trop} ve d_{ion}, troposfer ve iyonosfer tabakasından etkilenen sinyalin kod gecikmeleri, ε^m ve ε_u, frekansa dayalı uydu ve alıcı farklarını; c, uzayda süzülen ışık hızını; u, alıcı indisini ve m, uydu indisini göstermektedir (Dach ve ark., 2007; Leick, 2004). Psoydo-range ölçüleri (P), geometriden bağımsız olan doğrusal kombinasyon, uydu ve alıcı arasında katedilen uzunluk (ρ) ve sinyalin troposferik (d_{trop}) gecikmelerini elimine eder. Geometriden bağımsız doğrusal kombinasyon, cebirsel işlemle eşitlik 2, eşitlik 1'den çıkarılarak;

$$P_{4,u}^m = P_{1,u}^m - P_{2,u}^m = d_{ion1,\mathrm{u}}^m - d_{ion2,\mathrm{u}}^m + c(\varepsilon_1^m + \varepsilon_2^m) + c(\varepsilon_{1,u} + \varepsilon_{2,u}) \quad (3)$$

elde edilir (Liao, 2000). Frekansa dayalı uydu ve alıcı arasında oluşan diferansiyel kod farkları (DCBs);

$$DCB^m = \varepsilon_1^m + \varepsilon_2^m \quad (4)$$

$$DCB_u = \varepsilon_{1,u} + \varepsilon_{2,u} \quad (5)$$

olarak tanımlanmaktadır. Burada, DCB^m uydu, DCB_u ise alıcı için diferansiyel kod farklarını temsil eder. Aynı denklemler faz gecikme gözlemlerini temsil etmek için yazılırsa;

$$L_{1,u}^m = \lambda_1 \Phi_{1,u}^m = \rho_u^m + \mathrm{c}(\delta \mathrm{t}_u - \delta \mathrm{t}^{\mathrm{m}}) + \lambda_1 \Phi_{trop,u}^m + \lambda_1 \Phi_{ion1,u}^m + c(\varepsilon_1^m + \varepsilon_{1,u}) + \lambda_1 \mathrm{N}_1^m \quad (6)$$

$$L_{2,u}^m = \lambda_2 \Phi_{2,u}^m = \rho_u^m + \mathrm{c}(\delta \mathrm{t}_u - \delta \mathrm{t}^{\mathrm{m}}) + \lambda_2 \Phi_{trop,u}^m + \lambda_2 \Phi_{ion1,u}^m + c(\varepsilon_2^m + \varepsilon_{2,u}) + \lambda_2 \mathrm{N}_2^m \quad (7)$$

elde edilir (Dach ve ark., 2007). Burada, λ_1 ve λ_2, dalga boylarını; $\Phi_{1,u}^m$ve $\Phi_{2,u}^m$, uydu ile alıcı arasında kaydedilen faz gecikmelerini; $\Phi_{ion1,u}^m$ve $\Phi_{ion2,u}^m$, iyonosferik faz gecikmelerini; $\Phi_{trop,u}^m$, troposferik faz gecikmelerini; N_1^m ve N_2^m ,

sinyal yolu boyunca meydana gelen ilk faz belirsizlikleri göstermektedir. Faz ölçüleri için geometriden bağımsız doğrusal kombinasyon cebirsel işlemle eşitlik 7, eşitlik 6'dan çıkartılarak;

$$L_{4,u}^{m} = \lambda_1 \Phi_{1,u}^{m} - \lambda_2 \Phi_{2,u}^{m} = \lambda_1 \Phi_{ion1,u}^{m} - \lambda_2 \Phi_{ion2,u}^{m} - \mathrm{c}(DCB^{m} + DCB_u) + \Delta \mathrm{N}^{m} \quad (8)$$

elde edilir. Burada $\Delta \mathrm{N}^{m}$;

$$\Delta \mathrm{N}^{m} = \lambda_1 \mathrm{N}_1^{m} - \lambda_2 \mathrm{N}_2^{m} \quad (9)$$

olarak tanımlanmaktadır (Dach ve ark., 2007; Liao, 2000). İyonosferik kod ve faz gecikmeleri arasında;

$$d_{ion,u}^{m} = -\Phi_{ion,u}^{m} \frac{c}{f} \approx A \frac{STEC_u^{m}}{f^2} \quad (10)$$

şeklinde bir yaklaşım elde edilebilir. Burada, A = 40.3 m^3/s^2 ve $STEC_u^{m}$, alıcı (u) ve (m) uydu arasındaki sinyal yolu boyunca STEC değerlerini temsil etmektedir. Eşitlik (3)'teki $d_{ion,u}^{m}$ ve eşitlik (8)'deki $-\Phi_{ion,u}^{m} \frac{c}{f}$ değerleri yerine eşitlik (10)'daki $A \frac{STEC_u^{m}}{f^2}$ yerine konulursa geometriden bağımsız doğrusal kombinasyon kod ve faz gözlemleri;

$$P_{4,u}^{m} = A \left(\frac{f_1^2 - f_2^2}{f_1^2 f_2^2} \right) STEC_u^{m} - \mathrm{c}(DCB^{m} + DCB_u) \quad (11)$$

$$L_{4,u}^{m} = A \left(\frac{f_1^2 - f_2^2}{f_1^2 f_2^2} \right) STEC_u^{m} - \mathrm{c}(DCB^{m} + DCB_u) + \Delta \mathrm{N}^{m} \quad (12)$$

elde edilmiş olur. (Dach ve ark., 2007; Liao, 2000)

DCB'ler f_1 ve f_2 frekanslar aralığındaki sinyaller için uydu ve alıcı donanımlarına bağlı olarak farklı değerler alırlar (Komjathy, 1997). Fakat TEC hesaplama çalışmalarında bu farklı değerlerin nasıl kullanılacağını gösteren herhangi bir yöntem yoktur (Warnant, 1997; Komjathy, 1997; Makalea ve ark., 2001). Kod ölçüleri kullanılarak yapılan STEC belirleme çalışmalarında yaygın olarak;

$$STEC_u^m(n) = \frac{1}{A}\left(\frac{f_1^2 f_2^2}{f_1^2 - f_2^2}\right)[P_{4,u(n)}^m + \mathrm{c}(DCB^m + DCB_u) \quad (13)$$

eşitliği kullanılır. Burada, n, 1'den N'ye kadar kaydedilen veri sayısını göstermektedir. Elde edilen STEC değerleri iyonosferik ince tabaka modeline göre eşitlik 14'deki $M(z)$ izdüşüm fonksiyonu kullanılarak Düşey Toplam Elektron İçeriği (VTEC) değerine dönüştürülür (Şentürk ve Çepni, 2018).

$$M(z) = \frac{1}{cosz'} \quad (14)$$

Burada z′, uydu ile GPS alıcısı arasındaki sinyal yolu boyunca ince kabuk modeline göre tanımlanan iyonosfer tabakasının delindiği noktanın (Ionosphere Pierce Point - IPP) zenit açısı olarak kullanılmaktadır. VTEC değerleri eşitlik 15'de verilen denklem kullanılarak GPS alıcıları ile her bir GPS uydusu arasındaki sinyal yolu boyunca elde edilir (İnyurt ve ark.,2020).

$$VTEC = STEC * M(z) \quad (15)$$

Bu tez çalışmasında, kullanılan VTEC değişimleri GPS sinyallerinden elde edilen 30 saniyelik RINEX verilerinden oluşturulmuştur. Bu 30 saniyelik VTEC değişimlerine ikinci dereceden eğri yüzeyleri geçirilerek 2 saat çözünürlüklü VTEC değişimleri elde edilmiştir. Gün boyunca, her bir sabit GPS

istasyonu üzerindeki IPP'de kalibre edilmiş 30 saniyelik VTEC değerlerinden 2 saatlik VTEC değişimleri, ikinci dereceden eğri yüzeyi geçirme yöntemiyle (Durmaz ve Karslioglu, 2014);

$$VTEC(\varphi_{IPP}, s_{IPP}) = \alpha_0 + \alpha_1\varphi_{IPP} + \alpha_2 s_{IPP} + \alpha_3{\varphi_{IPP}}^2 + \alpha_4\varphi_{IPP}s_{IPP} + \alpha_5{s_{IPP}}^2 \quad (16)$$

eşitliğinden elde edilmiştir. Burada φ_{IPP} ve s_{IPP} IPP'nin güneş sabit referanslı küresel koordinatlarını; $\alpha_0, \alpha_1, \alpha_2, \alpha_3, \alpha_4$ ve α_5 geçirilen eğri yüzeyinin katsayılarını göstermektedir. Eğri yüzey katsayılarının 2 saatlik elde edilmesi için kullanılan veri penceresi 240 ölçü sayısına ayarlanmıştır (öncesi ve sonrası 120 epok). Eşitlik (16)'daki bilinmeyen 2 saatlik eğri yüzeyine ait katsayılar lineer cebir işlemlerle elde edilmiştir. SURF, ANTL, GEME ve HEND istasyonlarının güneş sabit küresel koordinatları, belirlenen yüzey eğrisinde yerine koyularak 2 saat çözünürlüklü istasyon üstü VTEC değerleri elde edilmiştir (Schaer, 1999).

Bu tez çalışmasının tamamında bahsi geçen iyonosferik TEC değişimleri, kalibre edilmiş STEC değişimlerinden hesaplanan VTEC değişimleri olduğu bilinmelidir.

3.2. Yöntem

3.2.1. Karesel ortalama hata

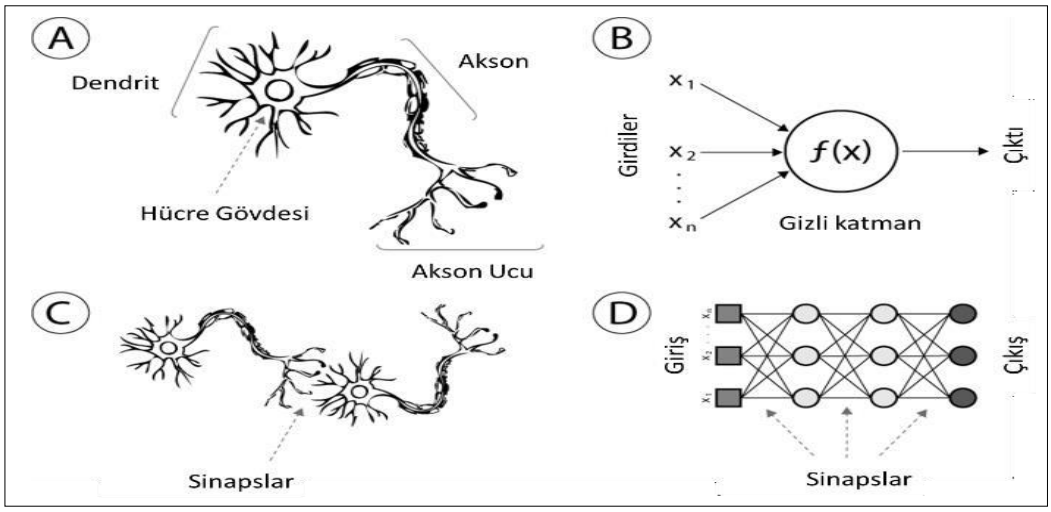
Karesel ortalama hata (KOH) bir veri setinde bulunan ölçülerin doğruluğu istatiksel anlamda güvenilir bir çıktı verir. Tahmini yapılacak değerlere ait hataların kareleri alındığı için sayısal anlamda sonuç sürekli pozitif olacağından, elde edilen verilerin doğruluğu hakkında sağlıklı yorumlar yapılabilecektir. Bu yüzden, yukarıda bahsi geçen VTEC verileri üzerinden yapılacak tahminler sonucunda elde edilecek tahmini-VTEC verilerinin doğruluğu KOH yöntemi ile belirlenecektir. KOH, gözlemlenmiş ve öngörülmüş değerlerin arasındaki farkının karelerinin toplamının, uygulamaya giriş yapan toplam veri sayısına

bölünmesiyle bulunan değerdir (Wang ve Xu, 2004). Matematiksel bağıntısı aşağıdaki eşitlik (16)'de gösterilmiştir. Burada N veri sayısı, y_i tahmin edilen değer ve y_i' ise gözlemlenen değeri temsil etmektedir.

$$\text{KOH} = \sqrt{\frac{1}{N}\sum_{i=1}^{N}|y_i - y_i'|^2} \tag{17}$$

3.2.2. Yapay sinir ağı

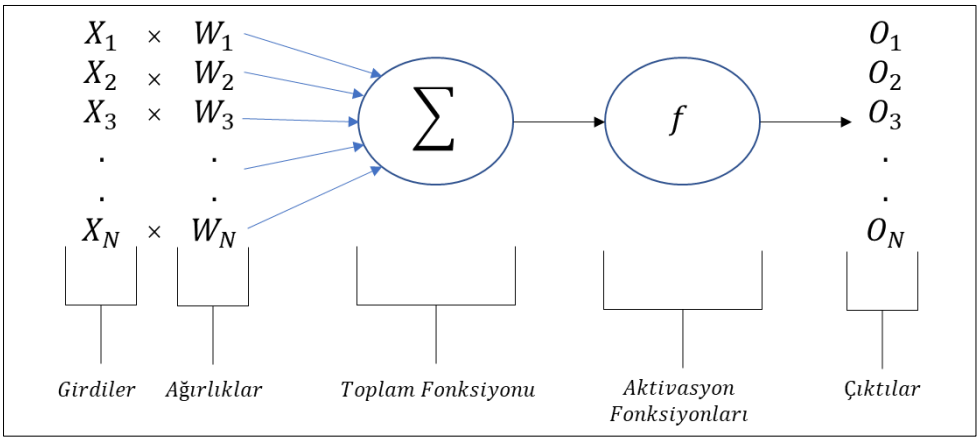
Yapay Sinir Ağı (ANN), insanı beyninin çalışma işleminden esinlenerek oluşturulan bir yöntemdir (Karahan, 2015). ANN, insan beynine iki farklı biçimde benzerlik göstermektedir (Gülpınar, 2013; Ataseven, 2013). İlk olarak ANN'de işlenecek olan veri, öğrenme işlemiyle ağ tarafından oluşturulur, ardından ANN, nöronlar arasındaki bağın bilgisini hafızada tutmak için kullanır. ANN'nin genel amacı öğrenme aşamasıdır. ANN insan beynine benzer biçimde eğitilerek ve geçmiş deneyimleriyle bilgiyi öğrenir (Karymshakov ve Abdykaparov, 2012). ANN; bilgiyi öğrenme, öğrendiği bilgiyi kendi belleğinde kaydetme ve bilgiler arasındaki bağı meydana çıkarma yeteneğine sahiptir (Özkan, 2012). İnsan beyninin çalışma yapısına benzerlik gösteren ANN; deneyimlerinden öğrenme, eksik veri ile işlemlerine devam etme, bilgiler arasında bağ kurma, türlere göre ayırma ve optimizasyon süreçlerinden birini veya birkaçını yapma gibi önemli yeteneklere sahiptir (Öztemel, 2006; Aydemir ve ark, 2014). Bir ANN hücresi ile biyolojik sinir hücresine ait benzerlik şekil 3.1'de detaylı olarak görülmektedir.



Şekil 3. 1. Biyolojik sinir hücresi ve ANN hücresi (Goncalves ve ark., 2013'ten değiştirilerek)

Şekil 3.1.'de A, insan sinir sistemine ait nöron; B, yapay sinir ağı nöronu veya gizli katman; C, biyolojik bağlantı sinapsı ve D, ANN ise sinapsları temsil etmektedirler. ANN matematiksel bir model olmakla birlikte ilişkili hücrelerin bulunduğu tabakalardan oluşmaktadır (Tosunoğlu ve Benli, 2012; Benli ve Yıldız, 2014). ANN'nin zaman serilerini istatistiksel modelleme ve tahmin uygulamalarındaki hedefi, bir bilgi setine bağlı olarak bu bilgieri elde eden istatistiksel işlemi tasarlamak ve oluşacak yeni bilgilerle gerçeğe yakın tahminler elde edebilmektir (Akın, 2001). Yapay sinir hücresi (nöron), ANN'nin genel işlemlerinde rol alan temel elemanı veya temel birimidir. Bu birim Şekil 3.2.'de şematik olarak gösterilmiştir. (Aydemir ve ark., 2014).

Şekil 3.2.'de ağ modeline giriş yapan veriler x_1, x_2, x_3, …, x_n ile, ağ modelinin ağırlıkları w_1, w_2, w_3, …, w_n, toplam fonksiyonu Σ ile, aktivasyon fonksiyonu f ile ve çıktı değerleri ise O ile gösterilmektedir. Yapay sinir hücrelerinde çıktı verilerinin oluşma süreci, tasarlanan ağdaki ağırlıklık değerlerinin ağa giriş yapan veriler ile cebirsel olarak çarpılması ve bu çarpımların toplanması ($w_1x_1 + w_2x_2 + \cdots + w_nx_n$) ile meydana gelen değişken fonksiyon ile başlar. Bu işlemin ardından değişken fonksiyon, aktivasyon fonksiyonundan geçirilerek çıktı değerleri elde edilir (Tüzüntürk ve ark., 2016).



Şekil 3. 2. Yapay sinir hücresi/yapay nöron (Tüzüntürk ve ark., 2016'ten değiştirilerek)

Yapay sinir ağları içerisinde oluşturulan modeller;

- Tek katmanlı algılayıcılar
- Çok katmanlı algılayıcılar
- İleri beslemeli yapay sinir ağları
- Geri beslemeli yapay sinir ağları

olmak üzere 4 farklı kategoride incelenmektedir (Öztürk ve Şahin, 2018).

Derin öğrenme yöntemi ise bu 4 modelin kullanıldığı yapay sinir ağlarının bir alt kümesidir. Derin öğrenme yöntemleri;

- Evrişimsel (Konvolüsyonel) Sinir Ağları (Convolutional Neural Network-CNN)
- Tekrarlayan Sinir Ağları (Recurrent Neural Network - RNN)
- Uzun Kısa Süreli Hafıza Ağları (Long Short Term Memory - LSTM)
- Sınırlı Boltzman Makineleri (Restricted Boltzman Machine-RBM)
- Derin İnanç Ağları (Deep Belief Network-DBN)
- Derin Oto-Kodlayıcılar (Deep Auto Encoder-DAE)

olmak üzere 6 grupta incelenebilir (Şeker ve ark., 2017).

CNN, çok katmanlı algılayıcılar aracılığıyla ileri beslemeli bir modelin oluşturulduğu derin öğrenme yöntemidir (Fukushima, 1980). CNN; görüntü işlemede (Karpathy ve Fei-Fei, 2017), anlamsal olarak ayırt etmede (Grefenstette ve ark., 2015), bir veri setinde sorgulama yapmada (Shen ve ark., 2014), sözel cümlelerin modellemesinde (Kalchbrenner ve ark., 2014), sınıflandırmada (Kim, 2014) ve öngörme problemlerinde (Collobert ve Weston, 2008) kullanılmıştır.

RNN ise modele input olarak girilen verilerin arasındaki ilişkilerin yönlendirilmiş bir döngü oluşturduğu derin öğrenme türüdür. Bu döngü aracılığıyla farklı zamansal davranış göstermesine fırsat sunan bir ağ durumu yaratılmıştır. İleri beslemeli sinir ağlarının aksine, RNN'ler kendi giriş hafızasını ağa girilen verilerin rastgele dizilerini işlemek için kullanırlar (Mikolov ve ark., 2010).

LSTM, RNN yapısının daha iyileştirilmiş bir türü olup son zamanlarda derin öğrenme çalışmalarında sıkça kullanılan en önemli yöntemlerinden biri olmuştur. RNN yönteminde ağa giriş yapan verilerin bir önceki bilgiyi kullanma işlemine bağlı bir yaklaşımı vardır. Girilen veriler arasındaki boşlukların artmasıyla RNN modelinin geçmişten gelen bilgileri kendi belleğinde kaydetmesi ve kullanması zor bir hale gelmektedir (Bengio ve ark., 1994). Bu problemi çözmek için, uzun vadeli veri girdilerinin aralarındaki bağını öğrenebilen, bellek konusunda RNN'ye göre daha gelişmiş bir model olan LSTM ağları Hochreiter ve Schmidhuber tarafından literatüre eklenmiştir (Hochreiter ve Schmidhuber, 1997).

RBM, ağa girilen verilerin olasılık dağılımını öğrenebilen kullanışlı bir derin öğrenme yöntemidir. RBM'ler, boyut indirgemede (Hinton ve Salakhutdinov, 2006), sınıflandırmada (Larochelle ve Bengio, 2008), filtreleme problemlerinde (Salakhutdinov ve ark., 2007), özellik öğreniminde (Coates ve

Ark., 2011) ve konu modelleme (Salakhutdinov ve Hinton 2009) gibi çeşitli disiplinlerde kullanılarak güvenilir çıktıların elde edildiği bir metottur.

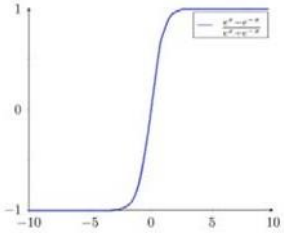
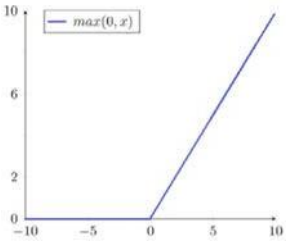
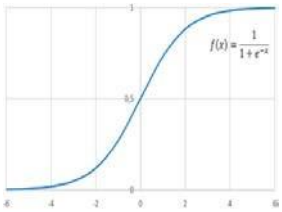
DBN ise RBM'lerin özel bir biçimi olup son gizli katmanında bulunan softmax aktivasyon fonksiyonunu yardımıyla türlere ayırma veya denetimsiz bir öğrenme için çok boyutlu mantıksal kümeleme özelliğine sahip yöntemdir (Hinton ve Salakhutdinov, 2006). DBN yöntemi, işlenilen görüntüyü tanıma ve üretme disiplinlerinde sıklıkla kullanılmaktadır (Ranzato ve ark., 2007).

DAE, denetimsiz öğrenme için kullanılan bir derin öğrenme yöntemidir (Liou ve ark., 2014). Bu yöntem, ağa girilen veri setlerinin sıkıştırılmış görünümünden en iyi özelliklerin başarılı bir şekilde öğrenilmesini hedefleyen, ileri beslemeli sinir ağlarından oluşur (Krizhevsky ve Hinton, 2011). DAE, anomali ve aykırı değer belirlenmesi gibi farklı disiplinlerde nispeten başarılı çıktılar elde etmektedir (Yadav ve Subramanian, 2016).

3.2.3. Yapay sinir ağlarında kullanılan aktivasyon fonksiyonları

Bir ANN hücresindeki giriş verisinin değeri ($-\infty$, $+\infty$) aralığında olabileceğinden dolayı hücre, verideki gerçek değerin sınırlarını bilemez. ANN'de kullanılan aktivasyon fonksiyonları modelin hücredeki çıktılarını sonraki tabakalara aktarırken kullanır ve bu çıktıların, diğer tabakalara aktarılıp aktarılmayacağına karar verebilmek için sınır aralığının belirlenmesi gerekir. Bu nedenle, hücrenin etkin olup-olmamasına karar verebilmesi için aktivasyon fonksiyonları yapay sinir ağlarının vazgeçilmezi haline gelmiştir. Aktivasyon fonksiyonlarıyla bir hücre tarafından elde edilen çıktılar kontrolü sağlanacak ve dış bağlantıların hücresi etkin olarak görüp-görmeyeceği sonucuna varılabilecektir (Sharma, 2017).

Çizelge 3. 1. ANN'de kullanılan bazı aktivasyon fonksiyonları ve özellikleri

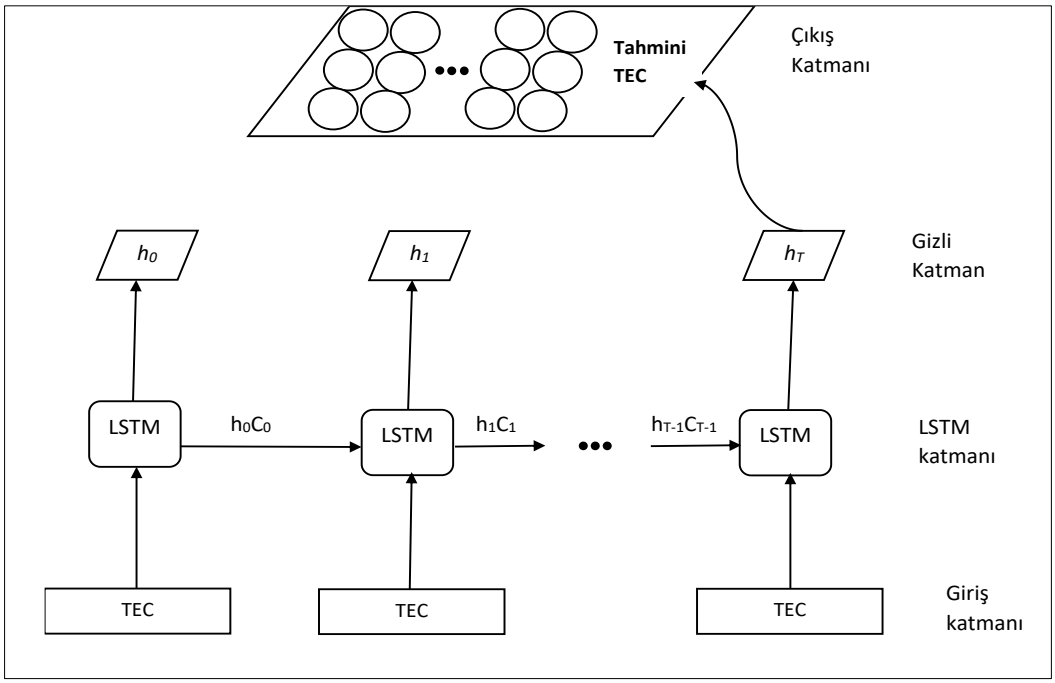
Aktivasyon Fonksiyonları	Grafik	Açıklama
Tanh		Hiperbolik tanjant fonksiyonu ağa giriş yapan değerlerin her birini -1 ile +1 aralığında değere eşitler (Nwankpa ve ark., 2018). $$f(x) = \left(\frac{e^x - e^{-x}}{e^x + e^{-x}}\right)$$
Rectified Linear (ReLU)		Doğrultulmuş lineer fonksiyonda girdi değeri negatif iken çıktı değerini sıfıra eşitler. Girdi değeri pozitif olduğunda ise çıktı değerini girdi değerine eşitler böylece bağımlı değişkenle doğrusal bir bağ oluşmaktadır (Anonim, 2018b). $$f(x) = max(0,1)$$ $$Eğer\ x \geq 0\ ise \quad x \mid Eğer\ x \leq 0\ ise\ 0$$
Sigmoid		Sigmoid aktivasyon fonksiyonu, ağdaki giriş kümesindeki verilerin her biri için 0 ile 1 arasında bir değer üretir (Nwankpa ve ark., 2018). $$f(x) = \left(\frac{1}{1 + exp^{-x}}\right)$$

ANN'ler genellikle doğrusal olmayan sınıflandırma uygulamalarında kullandıldığı için aktivasyon fonksiyonu daha çok lineer olmayan bir fonksiyon seçilir. Tasarlanan ağ modeli, öğrenme sürecinde geriye doğru bir yayılım yolu izlerken, aktivasyon fonksiyonunun türevi de kullanılacağından dolayı türevi kolay hesaplanabilen bir aktivasyon fonksiyonunun seçilmesi işlemin çalışma hızına etki edecektir (Şengöz, 2017; Kutlu, 2018). Bazı aktivasyon fonksiyonlarına ait özellikler Çizelge 3.1.'de verilmiştir (Ser ve Batı, 2019). Bu tez çalışmasında, LSTM ile yapılan tahminde sigmoid ve hiperbolik tanjant aktivasyon fonksiyonları kullanılmıştır.

3.2.4. Uzun kısa süreli bellek

LSTM ağları, girişleri uzun süre hatırlamayı sağlayan, geçitli hücreler olarak bilinen genişletilmiş bellek hücrelerinden oluşan derin öğrenmenin genişletilmiş RNN'lerdir. LSTM kapılı hücresinin hafızasındaki bilgiler, verilen algoritma tarafından ağırlıklar önemle karar verilebilecek şekilde saklanabilir veya silinebilir, yani zaman içinde bilginin önemini öğrenir (Zhang ve ark., 2017).

TEC zaman serilerinin tahmini için önerilen LSTM ağ mimarisi, girdi katmanları, LSTM katmanları, gizli katmanlar ve çıktı katmanlar olmak üzere 4 katmandan oluşmaktadır (Şekil 3.3.). Giriş katmanının her bir elemanı TEC değerlerinden elde edilen vektörlerdir.



Şekil 3. 3. LSTM Ağı Mimarisi

.

LSTM bloğunda giriş kapısı, boşaltma kapısı ve çıkış kapısı gibi üç ana kapı vardır. Giriş kapısı, yeni girişe izin verilip verilmeyeceğini belirler.

Boşaltma kapısı, kullanışlı olmayan bilgilerin silinip silinmeyeceğine karar verir. Eğer boşaltma kapısının çıktısı 1 ise, bilgi hücre durumunda tutulur ve boşaltmak için belirtilen 0 değerine yakın tutulur. Çıkış geçidi, girişin boşaltma geçit noktasından geçerli zaman adımında çıktıyı etkilemesine izin vermeye karar verir ve her birimin etkinliğinin ne kadarının korunacağını belirler. LSTM, zamansal farklılıkları ve uzun vadeli bağımlılıklarını içeren sıralı verileri modellemek için tasarlanmıştır (Sun ve ark., 2017).

Bir LSTM katmanının giriş sırasını X_t = (x_1, x_2, x_3, …, x_n) gizli bir çıktı h_t= (h_1, h_2, h_3 …, h_n) sırasına eşler. Bu işlemlerin süreci aşağıda verilen denklemlerdeki sıralamada yapılmaktadır.

$$i_t = \sigma(W_{ix}X_t + W_{ih}h_{t-1} + b_i) \quad (17)$$

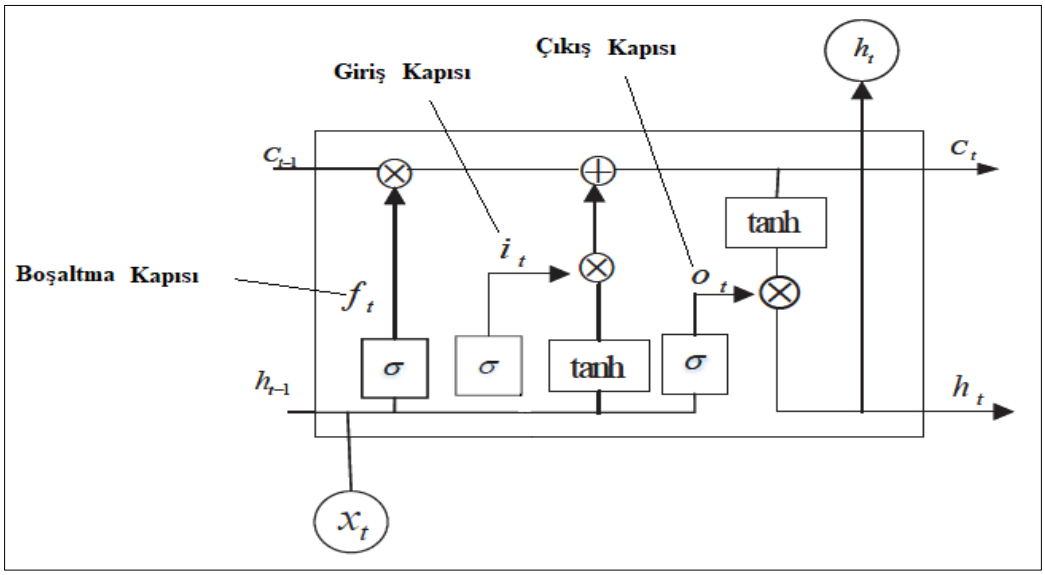
$$f_t = \sigma(W_{fx}X_t + W_{fh}h_{t-1} + b_f) \quad (18)$$

$$o_t = \sigma(W_{ox}X_t + W_{oh}h_{t-1} + b_o) \quad (19)$$

$$C_t = f_t C_{t-1} + i_t \tanh\,(W_{ox}x_t + W_{ch}h_{t-1} + b_c) \quad (20)$$

$$h_t = o_t \tanh\,(C_t) \quad (21)$$

Eşitliklerdeki t indisi iterasyon sayısını temsil etmektedir. Eşitlik 17'deki i, her gizli birime girişin ne kadarının iç durum vektörüne (C_t) yazıldığını kontrol eden giriş kapısıdır. f_t, önceki iç durumun (C_{t-1}) ne kadarının korunduğunu belirleyen boşaltma kapısıdır. Yazma ve boşaltma kapılarından oluşan kombinasyon, ağın her adımda hangi bilgilerin saklanması ve üzerine yazılması gerektiğini kontrol etmesini sağlamaktadır. o çıkış kapısıdır ve her bir birimin güncellenmesinin ne kadarının korunacağını kontrol etmektedir ve LSTM hücresinin alakalı olmayan bilgilerinin saklanmasında görev almaktadır. C_t zaman serisi verilerinin uzun bağımlılıklarını öğrenen hücredir. Son gizli durum h, zaman serisi verilerimizin tahmini değerlerin temsili olmaktadır (Sun ve ark., 2017).



Şekil 3. 4. LSTM Bloğu Çalışma Prensibi (Kızrak ve Bolat, 2019)

LSTM bloğu sigmoid ve hiperbolik tanjant (tanh) gibi iki etkileştirme fonksiyonuna sahiptir. Sigmoid fonksiyonu, gerekli bilgilerin güncellenmesine karar verir ve yalnız başına sadece bellek ekler ancak belleği boşaltamaz. Tanh ağ üzerinden geçen değerleri düzenler ve hücre yolunun hafızayı boşaltmasını sağlar. Bu hesaplamalarda, σ kapı aktivasyon fonksiyonunu ifade eder. Hesaplama fonksiyonu, varsayılan olarak, verilen aktivasyon fonksiyonlarını kullanır (Şekil 3.4.) (Hochreiter ve Schmidhuber, 1997; Zhang ve ark., 2017).

3.2.4.1. Momentumlu stokastik gradyan inişi (SGDM) optimizasyonu

Derin öğrenme ile yapılacak tahmin çalışmalarında, öğrenme sürecinin duyarlılığını artırmak için hata fonksiyonunun mutlak değerinin minimuma yakın olması gerekmektedir. Optimizasyon yöntemleri, yapay sinir ağının meydana getirdiği çıktı değerleri ile gözlemlenmiş değerler arasındaki farkı yani hatayı azaltmak için kullanılan tekniklerdir. Ağ modellerinin optimizasyonu için literatürde en çok kullanılan tekniklerden biri momentumlu gradyan inişi yöntemidir (Kurt, 2018). Optimizasyon işlemlerinde öğrenme katsayısının belirlenmesi ağ modelinin eğitiminde önemli bir görev üstlenmektedir. Fakat, her

optimizasyon işlemi ile ağın modeldeki öğrenme katsayısını net bir biçimde belirlemek mümkün değildir. Bu sorunu ortadan kaldırabilmek için optimizasyon yöntemlerinin farklı çözümleri tavsiye edilmiştir. (Li, 2017).

Jelassi ve Defazio (2020), momentumlu stokastik gradyan inişinde gerçek gradyan vektörünü stokastik bir tahmini ile değiştirmiştir. Özellikle bir ANN için, stokastik tahmin tek bir veri noktasının kaybının gradyanı anlamına geldiğini belirtmiştir. SGDM, mevcut gradyanı $\frac{\partial \mathrm{L}}{\partial \mathrm{Wt}}$, eğitimden önce belirlenen öğrenme katsayısı (α) ile çarparak ağın mevcut ağırlığını sürekli olarak $(\mathrm{W}t)$ güncellemektedir (Akca, 2020; Yazan ve Talu., 2017). Böylece örnekler arasındaki gereksiz bilgileri önlemeye çalışır. Bunun matematiksel ifadesi aşağıdaki eşitliklerde verilmiştir (McRae ve ark, 2021).

$$W_{t+1} = W_t - \alpha \frac{\partial \mathrm{L}}{\partial \mathrm{Wt}} \tag{22}$$

$$W_{t+1} = W_t - \alpha m_t \tag{23}$$

$$m_t = \beta m_{t-1} + (1-\beta) \frac{\partial \mathrm{L}}{\partial \mathrm{Wt}} \tag{24}$$

β, 0 ile 1 arasında değer alan geçmiş gradyanların hangi oranda işleme dahil edileceğini ayarlayan bir sönümleme faktörüdür. m_t tasarlanan ağ modelinde momentum değişikliklerini ifade eder ve başlangıçtaki değeri 0'dır. (Alpaydın, 2018; Karim, 2018)

3.2.4.2. Uyarlanabilir moment (ADAM) optimizasyonu

SGDM şu anda birçok derin öğrenme problemi için en iyi optimizasyon yöntemi olarak belirlenmiş olsa da, literatürde adaptif adı verilen metotlar da bulunmaktadır. Bu metotlar, SGDM'nin çözüm getiremeyeceği özellikle zaman serisi gibi çoklu verilerin işleneceği problemler için kullanılır (Defazio ve Jelassi., 2021).

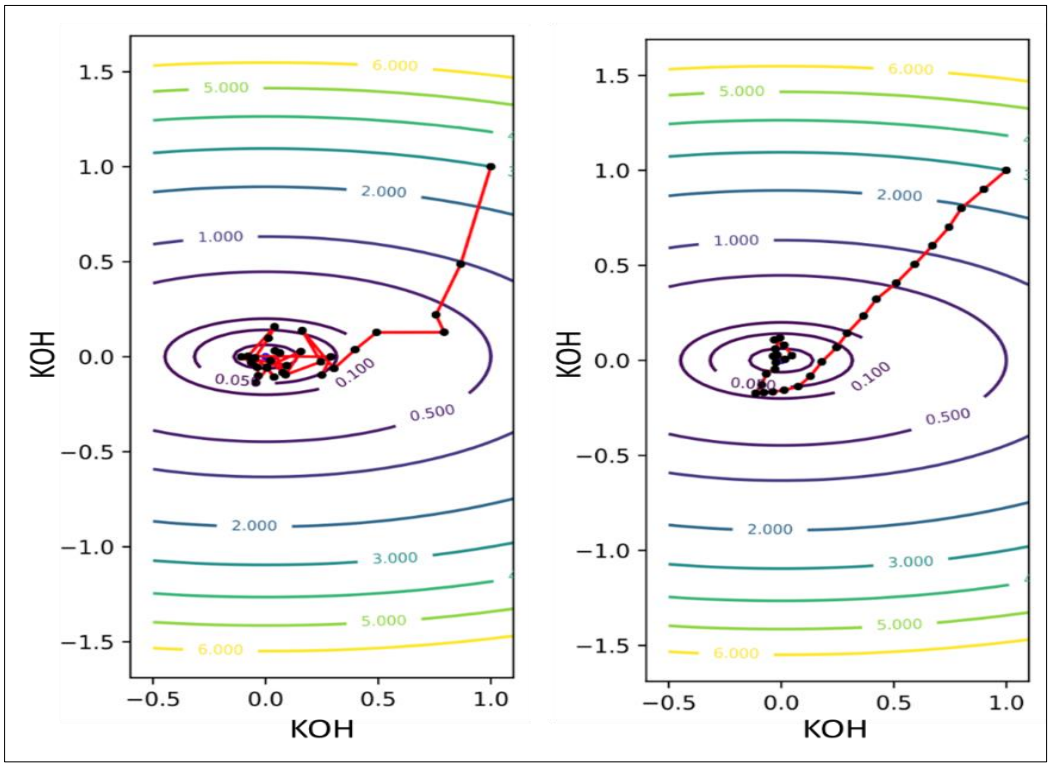
Bu yöntemde momentum güncellemesi gradyanın karesinin üstel hareketli ortalaması alınarak yapılır ve 0 ile 1 arasında değer alan sönümleme faktörü β ile uğraşırken öğrenme oranını değiştirmeye gerek duyulmaz. Matematiksel ifadesi şu şekildedir; γ, küresel öğrenme oranını, m_t, tasarlanan ağ modelinde momentumun üstel hareketli ortalamasını, ϵ, sıfıra bölünme hatalarından kurtulmak için (10^{-7} veya 10^{-8}) sabit bir değer, V_{t+1} ise 2. moment tahminini, f_i sürekli ve türevlenebilir olduğu varsayılan tarafsız bir tahminleyici fonksiyonunu, $\nabla f_i(W_t)$ ise f_i'nin gradyanı ifade eder (McRae ve ark, 2021).

$$m_{t+1} = \beta m_t + (1-\beta)\nabla f_i(W_t) \quad (25)$$

$$V_{t+1} = \alpha V_t + (1-\alpha)\nabla f_i(W_t)^2 \quad (26)$$

$$W_{t+1} = W_t - \gamma \frac{m_t}{\epsilon + \sqrt{V_{t+1}}} \quad (27)$$

Üstel hareketli ortalama, zaman serisinde değişebilecek bir değerin ortalamasını gözetlemek için kullanılan bir matematiksel işlemdir. Böylece daha fazla bilgi sağlayan verilerin ağırlıkları da daha fazla olacaktır. Daha az bilgi sağlayan veriler için de 0 ile 1 aralığında değer alan bir α sabiti ile her iterasyonda azalacak şekilde ağırlıklandırılacaktır. Bu sayede önemsiz bilgilerin ağ modeline olan etkisi üstel hareketli ortalamanın etkisiyle azaltılmış olacaktır (Candes ve ark., 2006)



Şekil 3.5. Optimizasyonların örnek uygulaması: Sol resim (SGDM), sağ resim (ADAM) (Defazio, 2020)

Yapay sinir ağlarının eğitimine başlarken SGDM genellikle tahmin edilecek değerlerden uzaklaşırken, ADAM gerçek değere doğru hareket eder. Bunun yanısıra, ADAM da SGDM gibi yararsız verilerden etkilenebilir, yani yararsız verilerden etkilendiğinde doğruluk en düşük seviyeye geldiğinde optimumun etrafında yaptığı hatalı sıçramalar kritik sonuçlara yol açabilmektedir. Bunun örneğini Şekil 5'ten yorumlayabiliriz.

4. ARAŞTIRMA BULGULARI VE TARTIŞMA

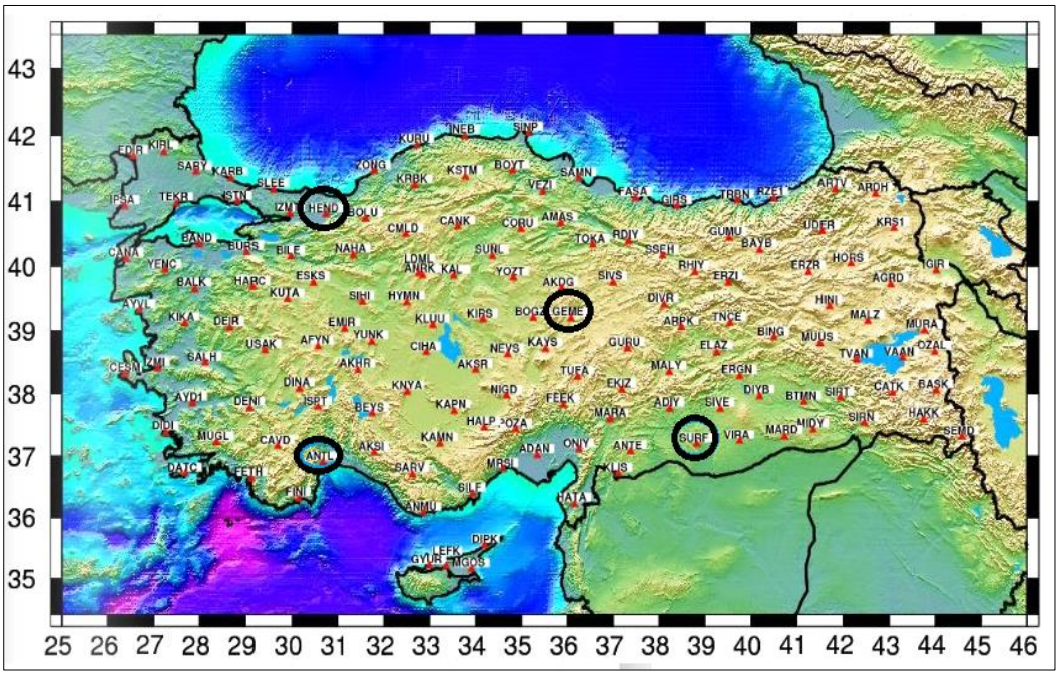
Bu tez kapsamında, LSTM ağ modelinin yanında SGDM ve ADAM optimizasyonları kullanılarak Türkiye'nin farklı bölgelerinde bulunan ve Türkiye Ulusal Sabit GPS Ağı (TUSAGA-Aktif)'na kayıtlı olan SURF, GEME, HEND ve ANTL isimli istasyonlara ait özellikler Çizelge 4.1.'de verilmiş olup, 2016-2019 yılları arasında iki saat çözünürlüklü VTEC gözlem verileriyle 6 aylık bir tahmin yapılmıştır.

Çizelge 4. 1. Tahmini yapılacak istasyonlara ait özellikler

İstasyonlar	Enlem (°Kuzey)	Boylam (°Doğu)	Eğitilecek Veri Sayısı (%86)	Test Edilecek Veri Sayısı (%14)	Veri setindeki En Küçük Değer (±TECU)	Veri setindeki En Büyük Değer (±TECU)
SURF	37.19184	38.81802	13,152	2,172	4.4	39.6
ANTL	36.88845	30.66642	13,152	2,172	4.4	40
GEME	39.18513	36.08084	13,152	2,172	4	37.3
HEND	40.79499	30.74075	13,152	2,172	4	36.8

Çizelge 4. 2. İstasyonlara ait istatistiksel özellikler ve tasarlanan ağın özellikleri

İstasyonlar	Eğitim Verilerinin Ortalaması	Eğitim Verilerinin Standart Sapması	Başlangıç Öğrenme Oranı	Gizli Katman Sayısı	İterasyon Sayısı
SURF	12.8485	4.7192	%5	1-50	100
ANTL	12.8231	4.8381	%5	1-50	100
GEME	12.2265	4.4252	%5	1-50	100
HEND	12.1971	4.4623	%5	1-50	100



Şekil 4. 1. Çalışmada kullanılan TUSAGA-Aktif istasyonları (Özdemir, 2016)

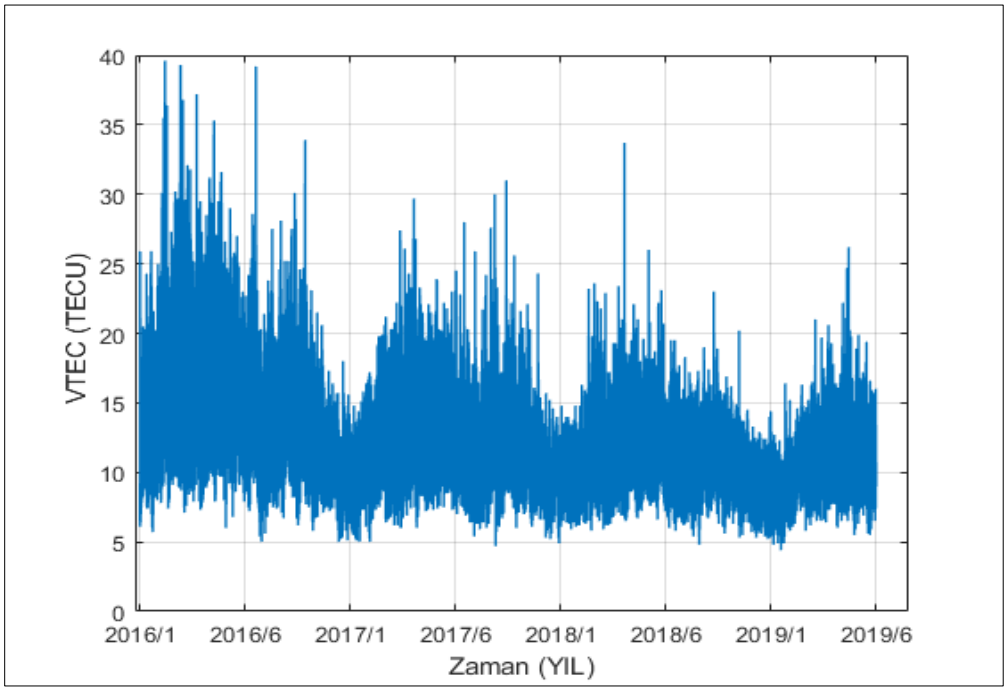
Çalışmanın yapıldığı istasyonlarda (Şekil 4.1) başlangıç öğrenme oranı, gizli katman sayısı, kayıp fonksiyonu ve iterasyon sayıları gibi ağ parametleri aynı seçilmiştir (Çizelge 4.1 ve Çizelge 4.2). Her istasyonda toplam veri sayısı 15324'tür. Bu verinin yaklaşık %86'i (13,152 veri) eğitim verisi olarak ve yaklaşık %14'ü (2,172 veri) ise test verisi olarak seçilmiştir. Daha çok girdili verilerle daha az veriyi test etmek başarıyı artırabilecektir.

Bu tez çalışmasında, MATLAB kütüphanesinde tasarlanan LSTM ağındaki uygulamalarda kullanılan bilgisayar sistemi, Intel i7-7700HQ işlemci, 24 GB hafıza, 1 terabayt sabit disk ve NVidia GeForce 950M performansına sahip GPU'den oluşmuştur.

4.1. SURF İstasyonu GPS-TEC Tahmini

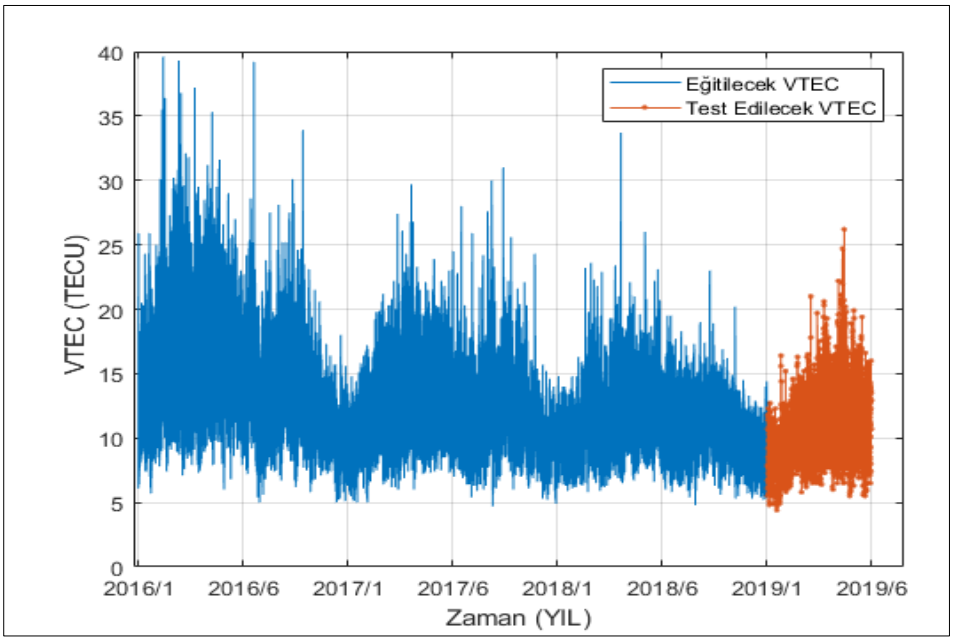
Şanlıurfa İli'nde bulunan ve TUSAGA-Aktif sistemine kayıtlı olan SURF istasyonuna (Enlem: 37.19184° Kuzey, Boylam: 38.81802° Doğu) ait 2 saat

çözünürlüklü VTEC değişimlerini (Şekil 4.2) içeren 3.5 yıllık veri seti eğitime tabii tutulmuş ve 6 aylık bir VTEC tahmini yapılmıştır. Daha sonra bu tahmini VTEC'in doğruluğu KOH yöntemi kullanılarak saptanmıştır.

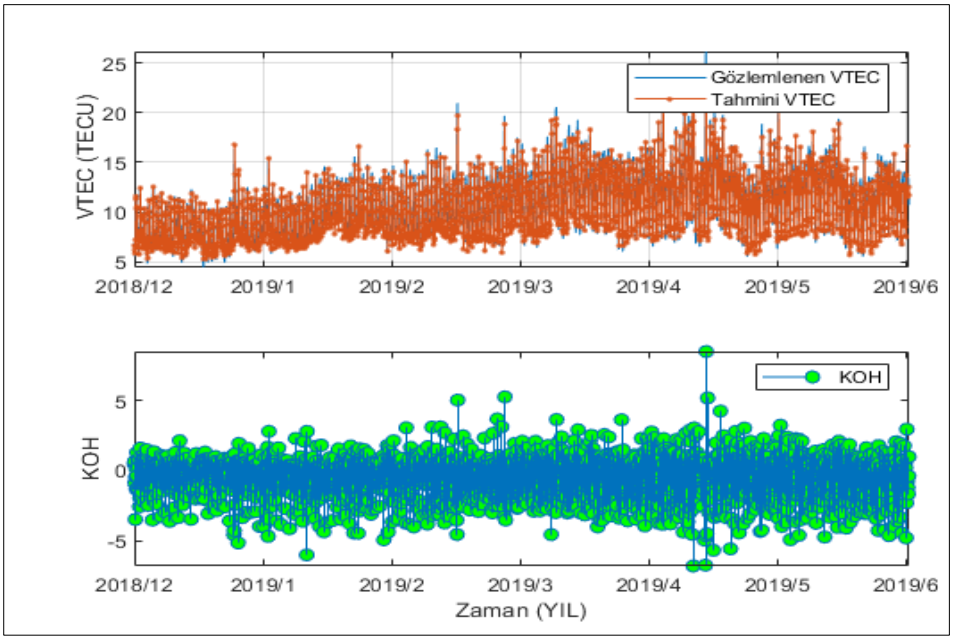


Şekil 4. 2. SURF istasyonunun 2 saatlik çözünürlüklü VTEC değişimleri

Literatürdeki çalışmalar (Pala ve Atıcı, 2019; Srivani ve ark., 2019) dikkate alınarak, gizli katman sayısı 50 ve iterasyon sayısı 100 olacak şekilde LSTM ağı tasarlanmıştır. SURF istasyonuna ait GPS-TEC gözlemlerinin ilk 3 yıllık veri seti önerilen bu ağa girdi olarak eklenmiştir. Daha sonra son 6 aya ait veriler ise test verisi olarak seçilmiştir (Şekil 4.3.).



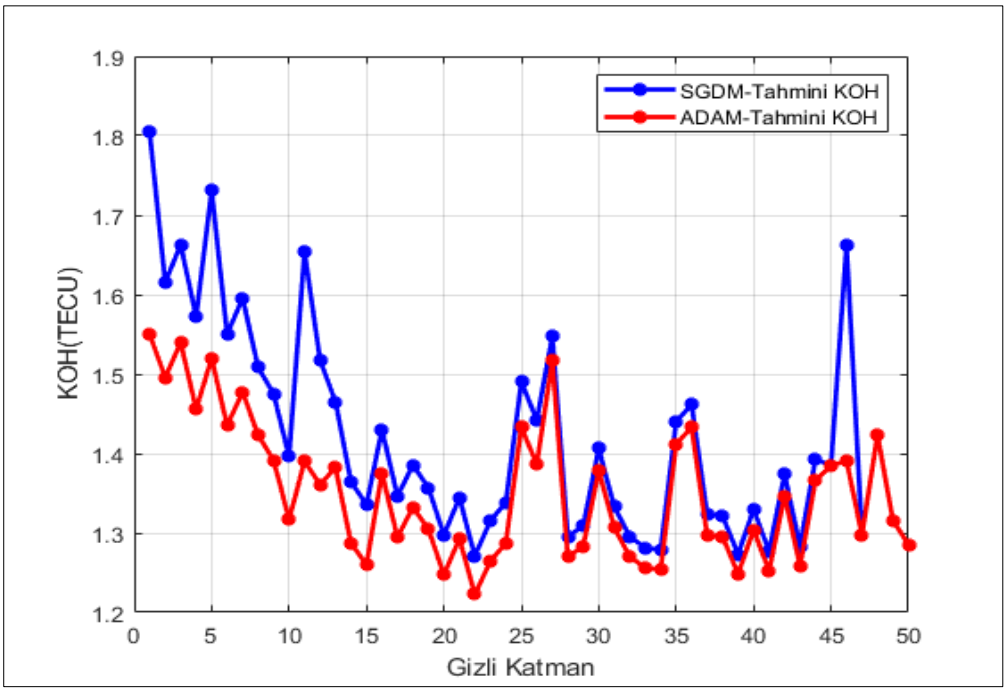
Şekil 4. 3. SURF istasyonunda eğitilecek ve test edilecek VTEC değerleri



Şekil 4. 4. SURF istasyonunda tahmini ve gözlemlenen VTEC değerleri (üst), KOH (alt)

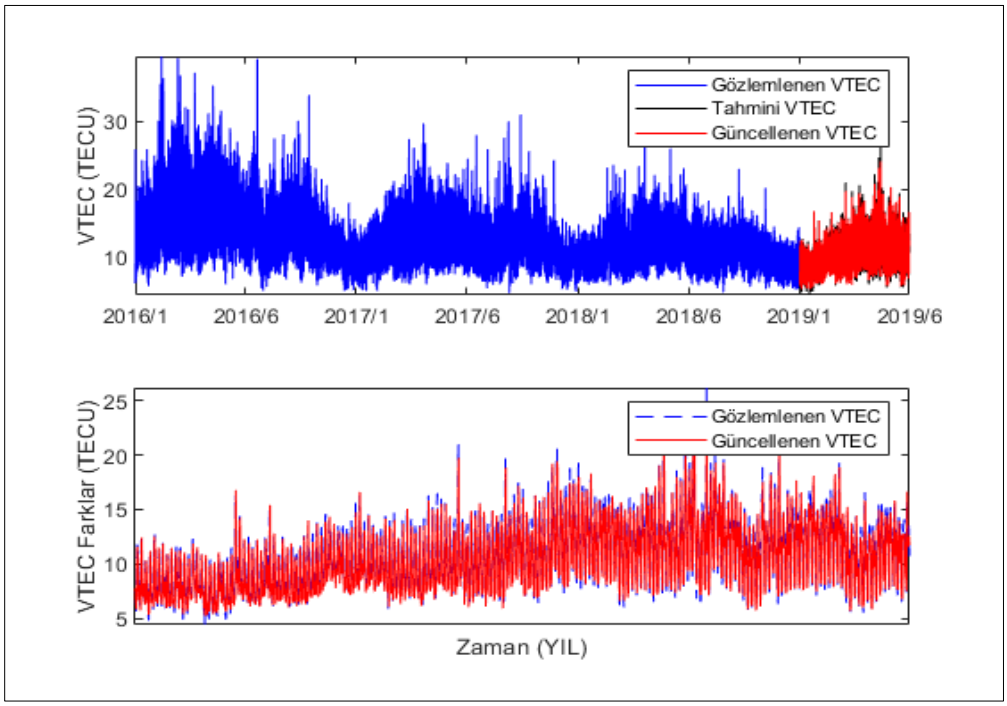
Daha sonra tasarlanan LSTM ağında ilk tahmin yapılmış ve bu ilk tahmine ait KOH değeri ±3.43 TECU olarak elde edilmiştir (Şekil 4.4.). İlk tahmin

yapıldıktan sonra, SGDM ve ADAM optimizasyonlarıyla da her gizli katmanda elde edilen KOH değerleri ayrı ayrı elde edilmiştir (Şekil 4.5.).



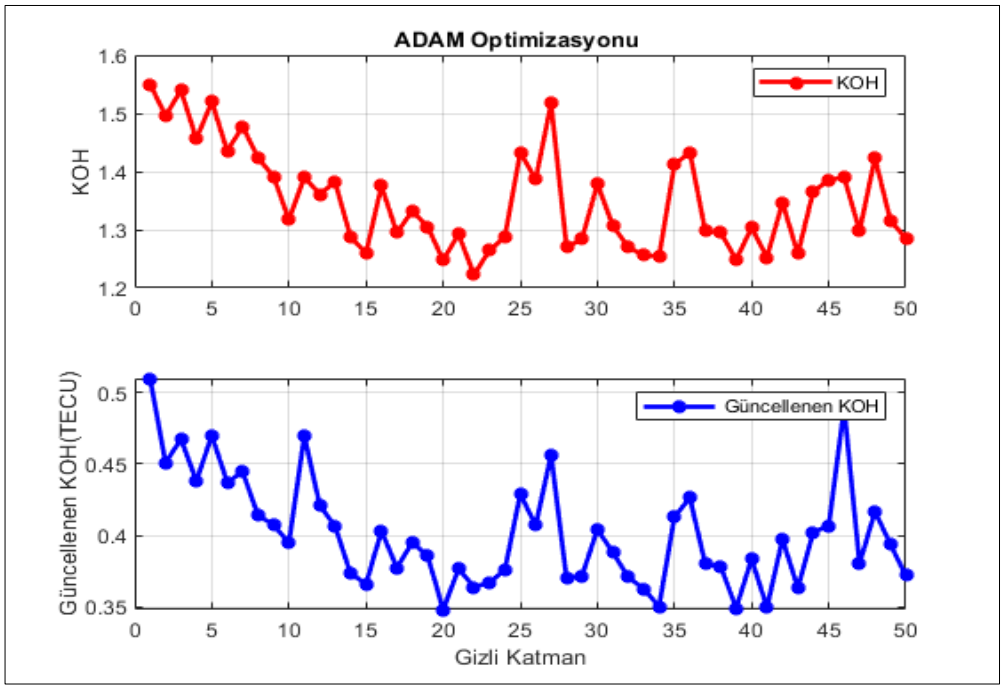
Şekil 4. 5. İlk tahmin verileriyle SGDM ve ADAM optimizasyon çözümleri

Yapılan ilk tahmin neticesinde, SGDM optimizasyonuyla gizli katman sayısı 1 seçildiğinde KOH değeri en yüksek ±1.81 TECU, gizli katman sayısı 22 seçildiğinde ise ±1.27 TECU olarak saptanmıştır. ADAM optimizasyonunda ise gizli katman sayısının 1 seçildiği durumda KOH değeri en yüksek ±1.55 TECU, gizli katman sayısının 20 seçildiği durumda ise ±1.24 TECU olarak elde edilmiştir. Her 2 optimizasyon yönteminde de gizli katman sayılarının 1-5 aralığında seçildiği modelde tahmin doğruluğunun az olduğu görülmektedir.

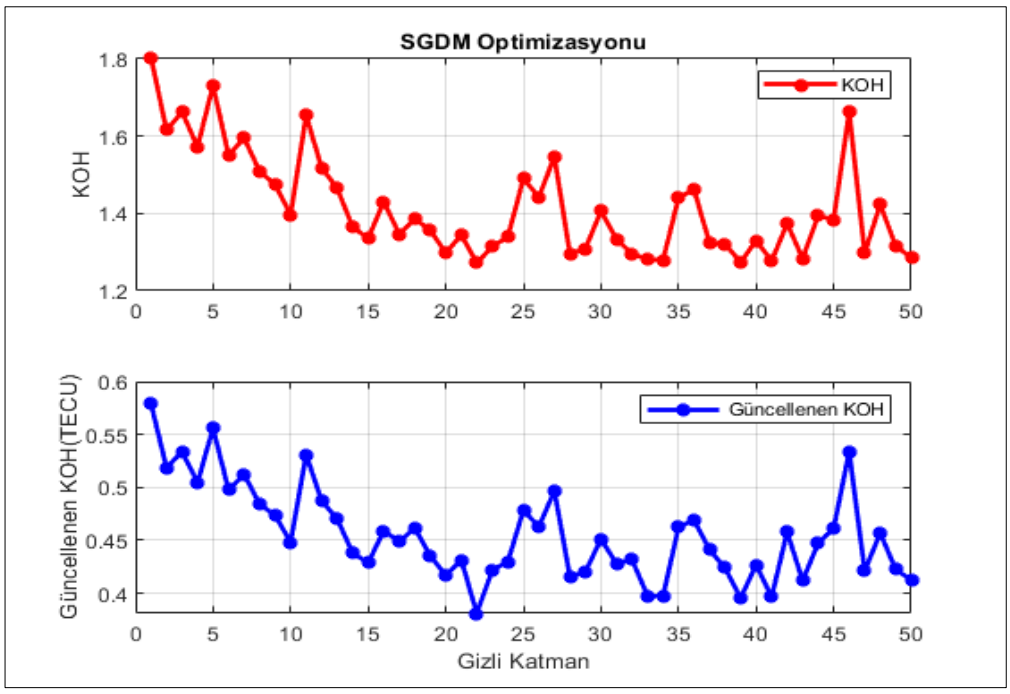


Şekil 4. 6. SURF istasyonunda tahmine yapılan güncelleme

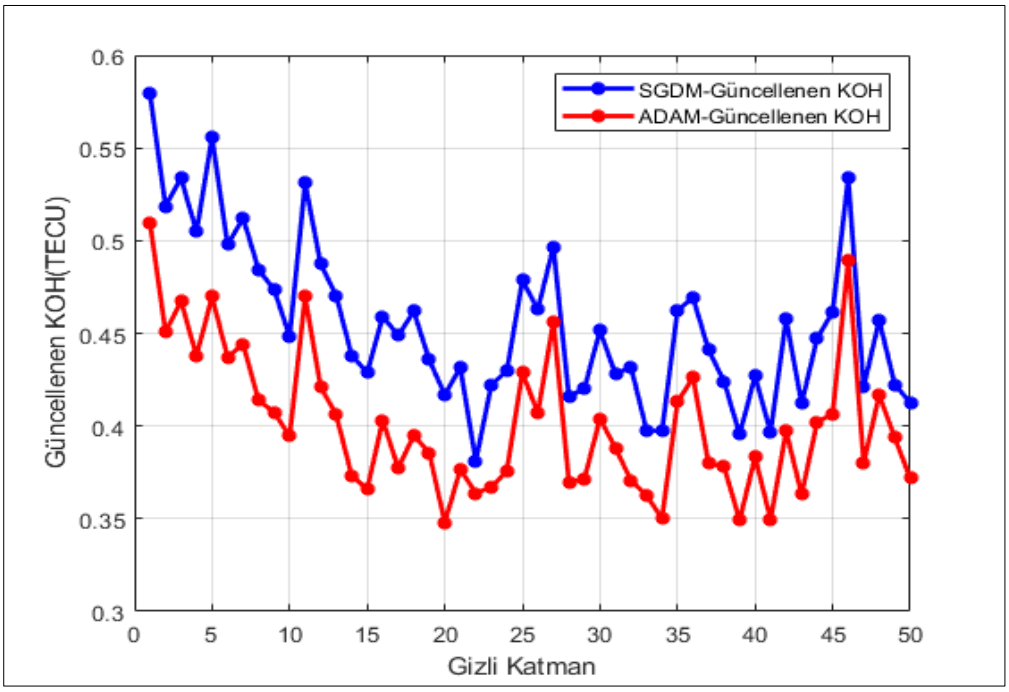
İlk tahminlerin ardından güncelleme faktörü (gradyan) ile tahminlerde güncellenme yapılmış (Şekil 4.6) ve KOH değeri ±2.92 TECU olarak elde edilmiştir. Ardından tasarlanan ağ tekrardan optimizasyon çözümleriyle ele alınmış ve gerçeğe yakın değerler elde edilmiştir. Şekil 4.7'de güncellenen tahmine uygulanan ADAM optimizasyonu işleminde gizli katman sayısı 1 seçildiğinde en yüksek KOH değeri ±0.51 TECU, gizli katman sayısı 20 seçildiğinde ise KOH değeri en düşük ±0.35 TECU olarak saptanmıştır. Şekil 4.8'de ise güncellenen tahmine SGDM optimizasyonu uygulanmış ve gizli katman sayısının 1 seçildiği durumda en yüksek KOH değeri ±0.58 TECU, gizli katman sayısının 22 seçildiği parametrede ise en düşük KOH değeri ±0.38 TECU olarak belirlenmiştir. Şekil 4.9'da ise bu 2 farklı optimizasyon çözümleri karşılaştırılmıştır.



Şekil 4. 7. ADAM optimizasyonuyla güncellenen yeni KOH değerleri



Şekil 4. 8. SGDM optimizasyonuyla güncellenen yeni KOH değerleri



Şekil 4. 9. ADAM ve SGDM optimizasyonlarının duyarlılıkları

Bu çözümlemelerin ardından SURF istasyon verilerinde ADAM optimizasyonunun hem ilk tahmin iyileştirmesinde hem de güncellenmiş tahmin üzerinden yapılan iyileştirmede SGDM optimizasyonuna göre daha başarılı olduğu ortaya konmuştur.

Çizelge 4. 3. SURF istasyonunda ilk tahmindeki optimizasyonlarının duyarlılıkları

Gizli Katman Sayısı	ADAM (±TECU)	SGDM (±TECU)	Gizli Katman Sayısı	ADAM (±TECU)	SGDM (±TECU)
1	1.5502	1.8041	26	1.3865	1.4420
2	1.4958	1.6154	27	1.5170	1.5473
3	1.5395	1.6627	28	1.2701	1.2955
4	1.4558	1.5722	29	1.2833	1.3090
5	1.5200	1.7312	30	1.3787	1.4062
6	1.4353	1.5502	31	1.3069	1.3331
7	1.4773	1.5955	32	1.2702	1.2956
8	1.4233	1.5087	33	1.2561	1.2812
9	1.3915	1.4750	34	1.2536	1.2787
10	1.3173	1.3964	35	1.4121	1.4403
11	1.3908	1.6539	36	1.4329	1.4615
12	1.3611	1.5179	37	1.2973	1.3232
13	1.3822	1.4651	38	1.2951	1.3210
14	1.2872	1.3644	39	1.2484	1.2733
15	1.2603	1.3356	40	1.3039	1.3300
16	1.3752	1.4302	41	1.2521	1.2772
17	1.2946	1.3464	42	1.3469	1.3738
18	1.3323	1.3856	43	1.2583	1.2835
19	1.3047	1.3569	44	1.3663	1.3936
20	1.2476	1.2975	45	1.3843	1.3843
21	1.2925	1.3442	46	1.3911	1.6625
22	**1.2225**	**1.2714**	47	1.2971	1.2972
23	1.2645	1.3151	48	1.4236	1.4235
24	1.2872	1.3387	49	1.3151	1.3153
25	1.4329	1.4902	50	1.2855	1.2853

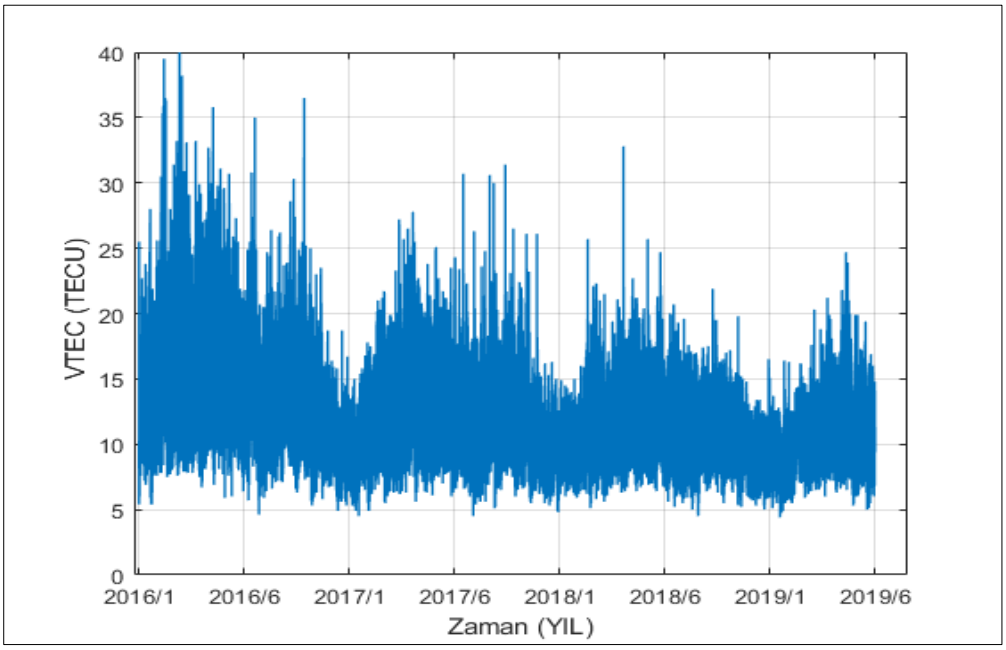
Çizelge 4. 4. SURF istasyonunda güncellenen tahmindeki optimizasyonlarının duyarlılıkları

Gizli Katman Sayısı	ADAM (±TECU)	SGDM (±TECU)	Gizli Katman Sayısı	ADAM (±TECU)	SGDM (±TECU)
1	0.5097	0.5792	26	0.4069	0.4629
2	0.4508	0.5186	27	0.4564	0.4968
3	0.4673	0.5338	28	0.3698	0.4159
4	0.4380	0.5048	29	0.3715	0.4203
5	0.4697	0.5558	30	0.4041	0.4515
6	0.4372	0.4977	31	0.3881	0.4280
7	0.4442	0.5122	32	0.3707	0.4319
8	0.4139	0.4844	33	0.3626	0.3979
9	0.4074	0.4736	34	0.3501	0.3971
10	0.3945	0.4483	35	0.4129	0.4624
11	0.4697	0.5310	36	0.4262	0.4692
12	0.4210	0.4873	37	0.3798	0.4411
13	0.4061	0.4704	38	0.3782	0.4241
14	0.3732	0.4380	39	0.3490	0.3954
15	0.3660	0.4288	40	0.3833	0.4270
16	0.4030	0.4592	41	0.3495	0.3966
17	0.3773	0.4488	42	0.3973	0.4579
18	0.3949	0.4619	43	0.3631	0.4121
19	0.3855	0.4356	44	0.4022	0.4474
20	**0.3480**	0.4169	45	0.4064	0.4614
21	0.3766	0.4316	46	0.4891	0.5337
22	0.3638	**0.3811**	47	0.3800	0.4212
23	0.3669	0.4222	48	0.4167	0.4570
24	0.3758	0.4298	49	0.3937	0.4224
25	0.4288	0.4784	50	0.3718	0.4126

Çizelge 4.3 ve 4.4'ten yola çıkarak gizli katman sayısının 1 seçildiği durumlarda tahmin doğruluğunun en az olduğu görülmektedir. Bu durum tüm çözümlerde aynı olmuştur.

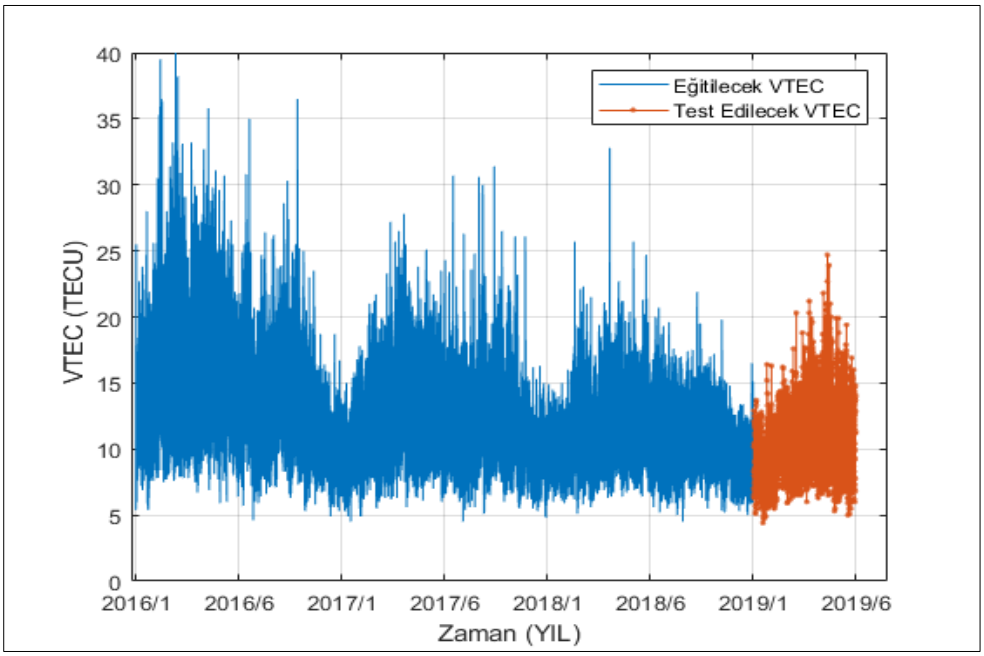
4.2. ANTL İstasyonu GPS-TEC Tahmini

Antalya İli sınırlarında bulunan ANTL istasyonuna (Enlem:36.88845◦ Kuzey, Boylam:30.66642◦ Doğu) ait 2 saat çözünürlüklü VTEC değişimlerini (Şekil 4.10) içeren 3.5 yıllık veri seti eğitilmiş ve 6 aylık bir VTEC tahmini belirlenen parametrelere göre yapılmıştır. Yapılan tahminin doğruluğu KOH yöntemi kullanılarak saptanmıştır.

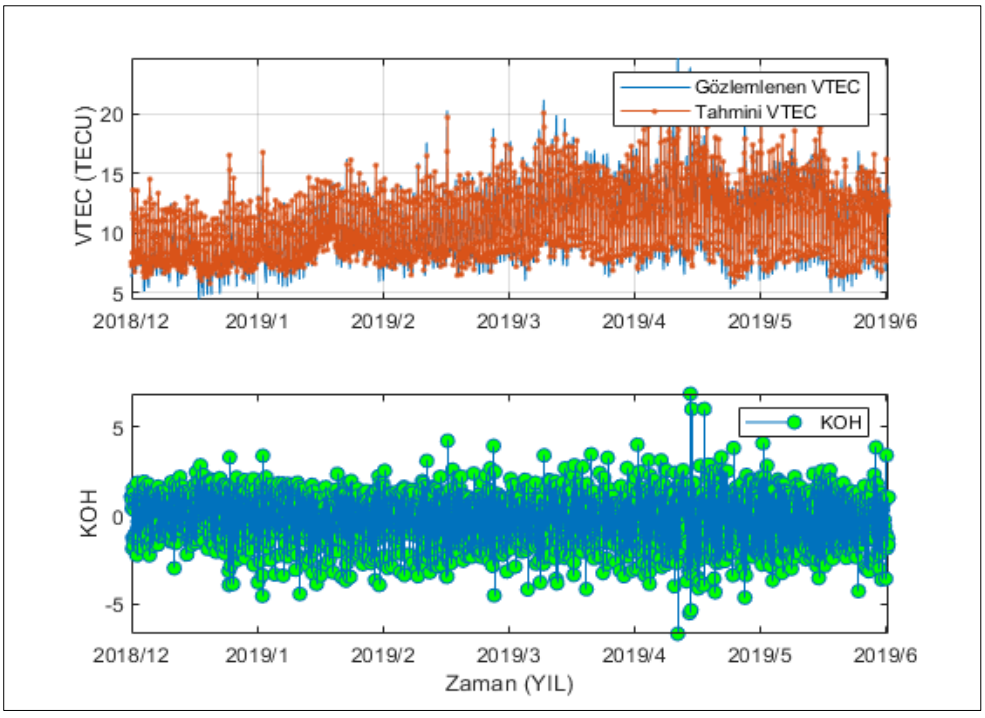


Şekil 4. 10. ANTL istasyonunun 2 saatlik çözünürlüklü VTEC değişimleri

Literatürdeki çalışmalar (Pala ve Atıcı, 2019; Srivani ve ark., 2019) dikkate alınarak, gizli katman sayısı 50 ve iterasyon sayısı 100 olacak şekilde LSTM ağı tasarlanmıştır. ANTL istasyonuna ait GPS-TEC gözlemlerinin ilk 3 yıllık veri seti önerilen bu ağa girdi olarak eklenmiştir. Daha sonra son 6 aya ait veriler ise test verisi olarak seçilmiştir (Şekil 4.11.).

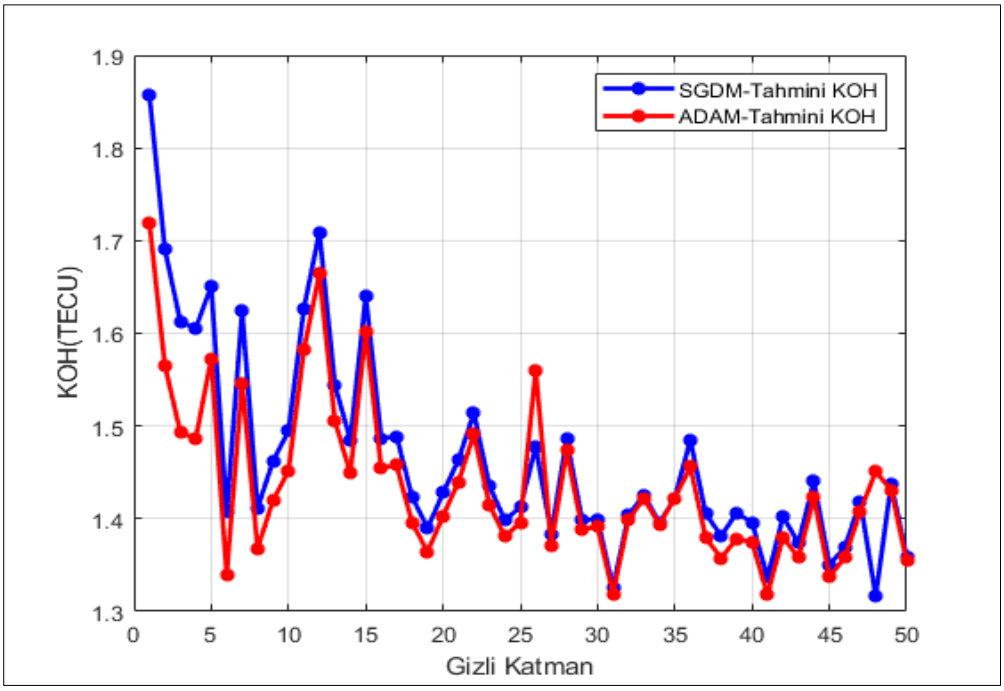


Şekil 4. 11. ANTL istasyonunda eğitilecek ve test edilecek VTEC değerleri



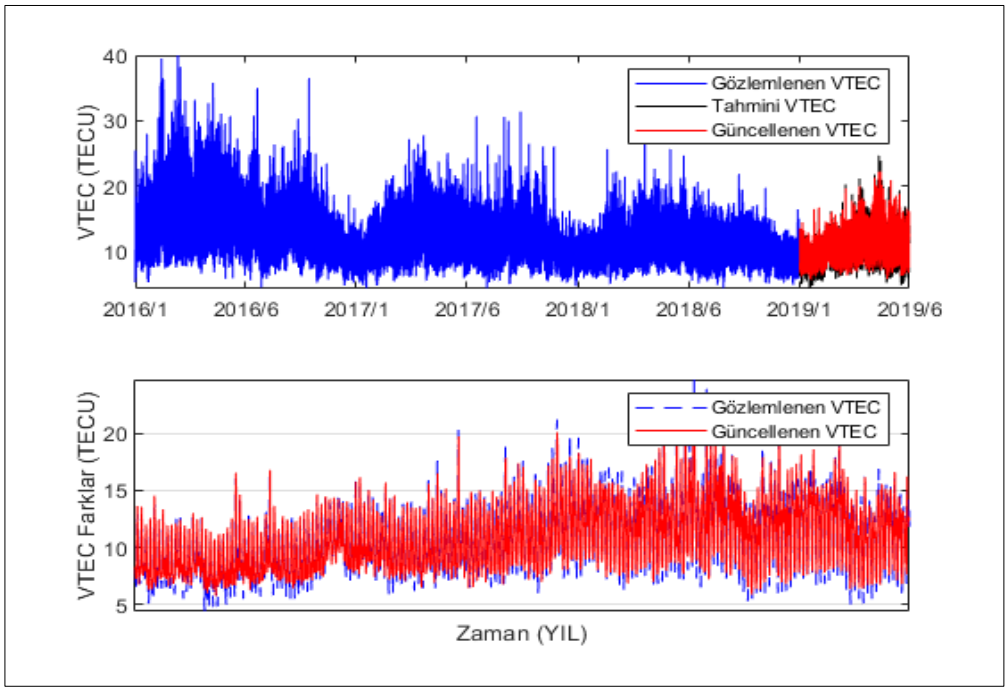
Şekil 4. 12. ANTL istasyonunda tahmini ve gözlemlenen VTEC değerleri (üst), KOH (alt)

Daha sonra tasarlanan LSTM ağında ilk tahmin yapılmış ve bu ilk tahmine ait KOH değer ±3.29 TECU olarak elde edilmiştir (Şekil 4.12). İlk tahmin yapıldıktan sonra da SGDM ve ADAM optimizasyonlarıyla da her gizli katmanda elde edilen KOH değerleri ayrı ayrı bulunmuştur (Şekil 4.13).



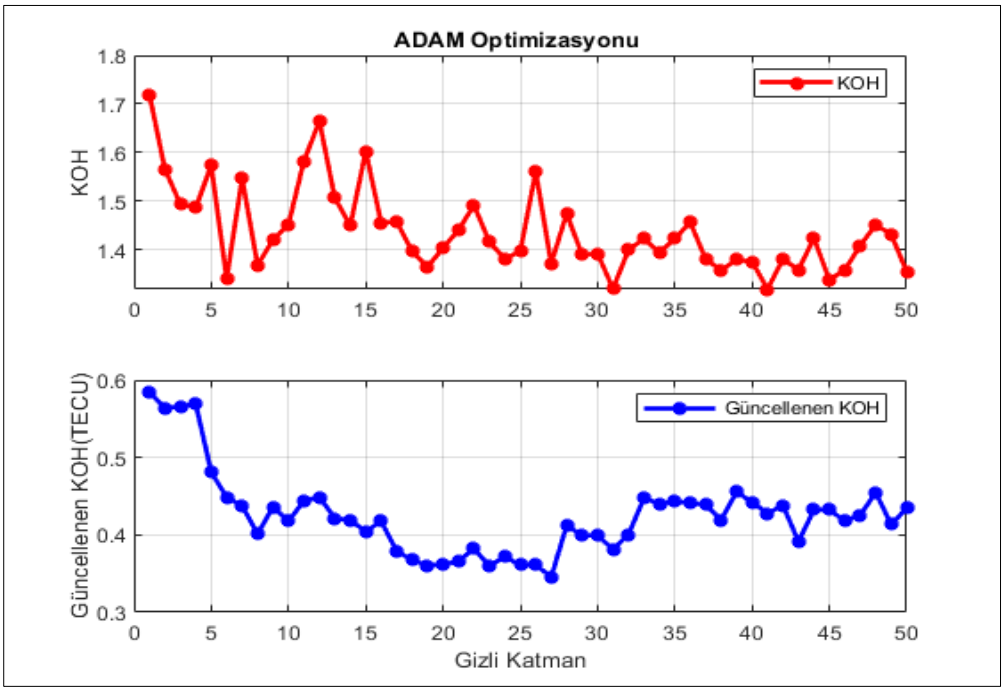
Şekil 4. 13. İlk tahmin verileriyle SGDM ve ADAM optimizasyon çözümleri

Yapılan ilk tahmin neticesinde, SGDM optimizasyonuyla gizli katman sayısı 1 seçildiğinde KOH değeri en yüksek ±1.86 TECU, gizli katman sayısı 48 seçildiğinde ise ±1.32 TECU olarak saptanmıştır. ADAM optimizasyonunda ise gizli katman sayısının 1 seçildiği durumda KOH değeri en yüksek ±1.72 TECU, gizli katman sayısının 41 seçildiği durumda ise ±1.32 TECU olarak elde edilmiştir.

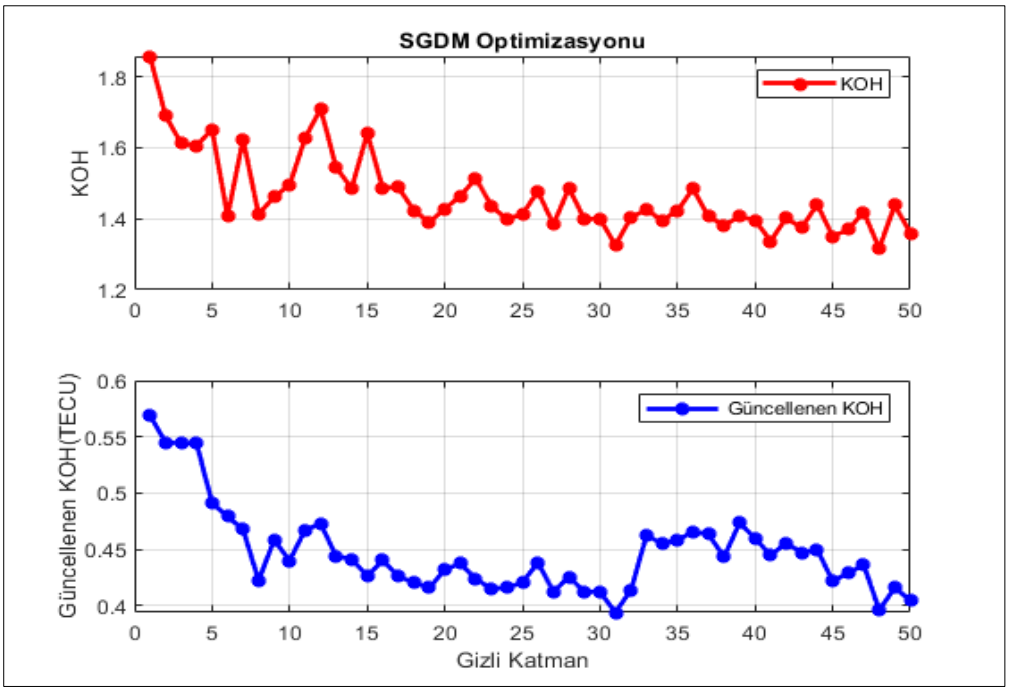


Şekil 4. 14. ANTL istasyonunda tahmine yapılan güncelleme

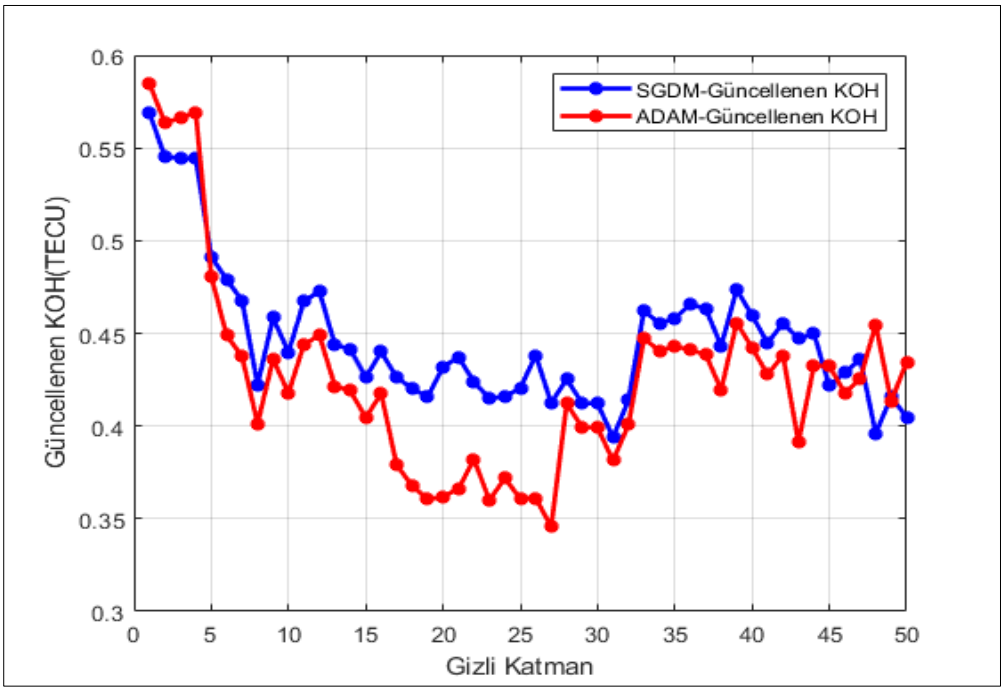
İlk tahminlerin ardından gradyan ile tahminlerde güncellenme yapılmış (Şekil 4.14) ve KOH değeri ±2.76 TECU olarak elde edilmiştir. Ardından tasarlanan ağ tekrardan optimizasyon çözümleriyle ele alınmış ve gerçeğe yakın değerler elde edilmiştir. Şekil 4.15'te güncellenen tahmine uygulanan ADAM optimizasyonu işleminde gizli katman sayısı 1 seçildiğinde en yüksek KOH değeri ±0.58 TECU, gizli katman sayısı 27 seçildiğinde ise KOH değeri en düşük ±0.34 TECU olarak saptanmıştır. Şekil 4.16'da ise güncellenen tahmine SGDM optimizasyonu uygulanmış ve gizli katman sayısının 1 seçildiği durumda en yüksek KOH değeri ±0.57 TECU, gizli katman sayısının 31 seçildiği parametrede ise en düşük KOH değeri ±0.39 TECU olarak belirlenmiştir. Şekil 4.17'de ise bu 2 farklı optimizasyon çözümleri karşılaştırılmıştır.



Şekil 4. 15. ADAM optimizasyonuyla güncellenen yeni KOH değerleri



Şekil 4. 16. SGDM optimizasyonuyla güncellenen yeni KOH değerleri



Şekil 4. 17. ADAM ve SGDM optimizasyonlarının duyarlılıkları

Bu çözümlemelerin ardından ANTL istasyon verilerinde bazı gizli katman sayılarında SGDM çözümü daha iyi iken, 5-40 gizli katman sayılarındaki çözümlerde ise ADAM optimizasyonunun daha başarılı olduğu ortaya konmuştur.

Çizelge 4. 5. ANTL istasyonunda ilk tahmindeki optimizasyonlarının duyarlılıkları

Gizli Katman Sayısı	ADAM (±TECU)	SGDM (±TECU)	Gizli Katman Sayısı	ADAM (±TECU)	SGDM (±TECU)
1	1.7196	1.8572	26	1.5606	1.4772
2	1.5655	1.6907	27	1.3709	1.3840
3	1.4933	1.6128	28	1.4737	1.4859
4	1.4863	1.6052	29	1.3887	1.3986
5	1.5728	1.6514	30	1.3914	1.3997
6	1.3398	1.4068	31	1.3191	1.3254
7	1.5466	1.6239	32	1.3987	1.4038
8	1.3678	1.4117	33	1.4221	1.4256
9	1.4198	1.4622	34	1.3936	1.3954
10	1.4515	1.4947	35	1.4222	1.4224
11	1.5824	1.6271	36	1.4560	1.4851
12	1.6643	1.7093	37	1.3794	1.4054
13	1.5057	1.5446	38	1.3575	1.3815
14	1.4489	1.4847	39	1.3784	1.4062
15	1.6024	1.6401	40	1.3748	1.3959
16	1.4544	1.4869	41	**1.3181**	1.3368
17	1.4577	1.4886	42	1.3804	1.4023
18	1.3956	1.4235	43	1.3579	1.3739
19	1.3643	1.3900	44	1.4231	1.4404
20	1.4030	1.4278	45	1.3375	1.3502
21	1.4398	1.4635	46	1.3579	1.3692
22	1.4913	1.5142	47	1.4082	1.4189
23	1.4154	1.4354	48	1.4509	**1.3166**
24	1.3806	1.3985	49	1.4309	1.4378
25	1.3959	1.4124	50	1.3544	1.3594

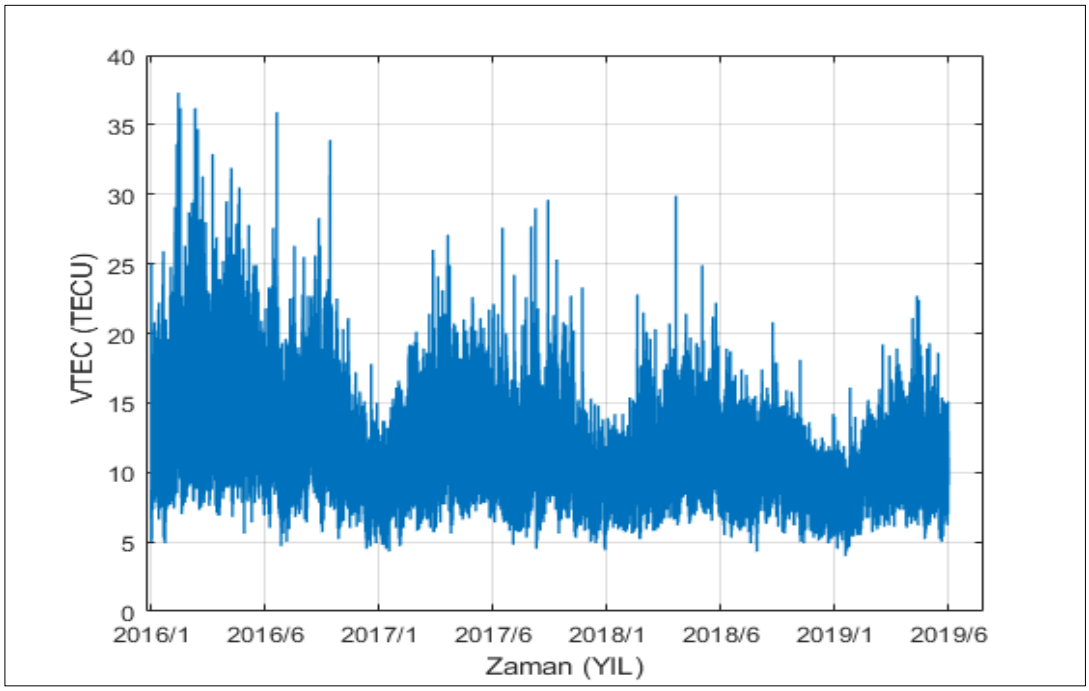
Çizelge 4. 6. ANTL istasyonunda güncellenen tahmindeki optimizasyonlarının duyarlılıkları

Gizli Katman Sayısı	ADAM (±TECU)	SGDM (±TECU)	Gizli Katman Sayısı	ADAM (±TECU)	SGDM (±TECU)
1	0.5848	0.5690	26	0.3611	0.4382
2	0.5637	0.5452	27	**0.3456**	0.4124
3	0.5661	0.5443	28	0.4120	0.4253
4	0.5692	0.5441	29	0.3994	0.4123
5	0.4809	0.4913	30	0.3991	0.4121
6	0.4488	0.4791	31	0.3813	**0.3939**
7	0.4375	0.4676	32	0.4006	0.4139
8	0.4013	0.4222	33	0.4473	0.4622
9	0.4360	0.4583	34	0.4405	0.4553
10	0.4178	0.4398	35	0.4430	0.4580
11	0.4440	0.4673	36	0.4411	0.4658
12	0.4489	0.4726	37	0.4385	0.4632
13	0.4215	0.4439	38	0.4196	0.4432
14	0.4190	0.4414	39	0.4557	0.4735
15	0.4046	0.4263	40	0.4423	0.4597
16	0.4175	0.4400	41	0.4277	0.4447
17	0.3790	0.4262	42	0.4381	0.4556
18	0.3678	0.4204	43	0.3913	0.4470
19	0.3605	0.4156	44	0.4324	0.4499
20	0.3618	0.4318	45	0.4324	0.4216
21	0.3662	0.4372	46	0.4178	0.4287
22	0.3821	0.4238	47	0.4256	0.4362
23	0.3602	0.4149	48	0.4548	0.3960
24	0.3718	0.4159	49	0.4133	0.4158
25	0.3609	0.4205	50	0.4345	0.4047

Çizelge 4.5 ve 4.6'daki ANTL istasyonun optimizasyon çözümleri dikkate alındığında ilk tahmin üzerinden yapılan optimizasyonda SGDM yönteminin ADAM yönteminden daha üstün performans gösterdiği görülmüştür. Güncellenen tahmin üzerinden yapılan optimizasyonda ise ADAM yöntemi daha başarılı olmuştur.

4.3. GEME İstasyonu GPS-TEC Tahmini

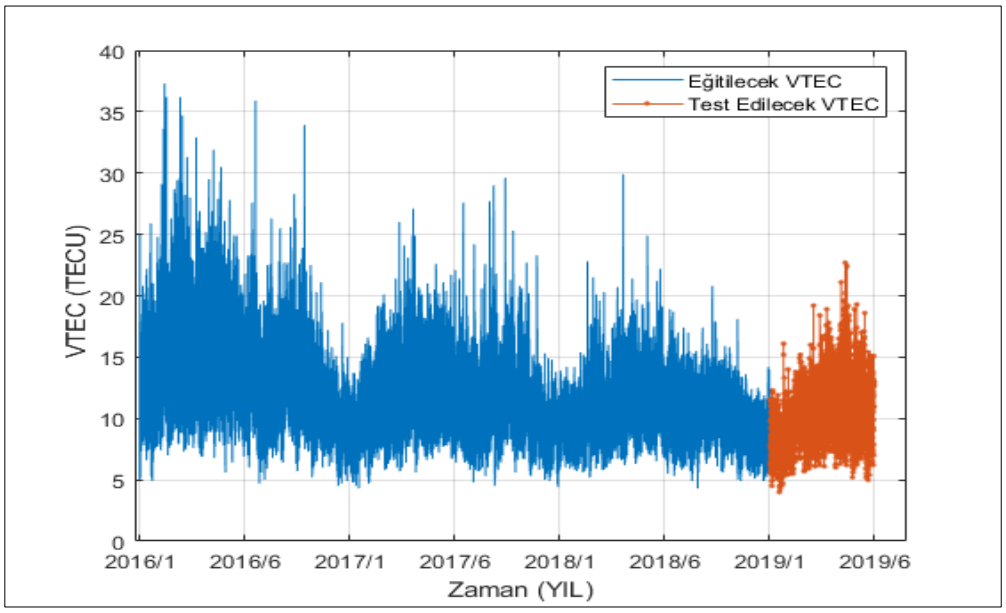
Sivas İli'nde bulunan ve TUSAGA-Aktif sistemine kayıtlı olan GEME istasyonuna (Enlem:39.18513◦ Kuzey, Boylam:36.08084◦ Doğu) ait 2 saat çözünürlüklü VTEC değişimlerini (Şekil 4.18) içeren 3.5 yıllık veri seti eğitilmiş ve 6 aylık bir VTEC tahmini yapılmıştır. Daha sonra bu tahmini VTEC'in doğruluğunun tespiti KOH yöntemi kullanılarak saptanmıştır.



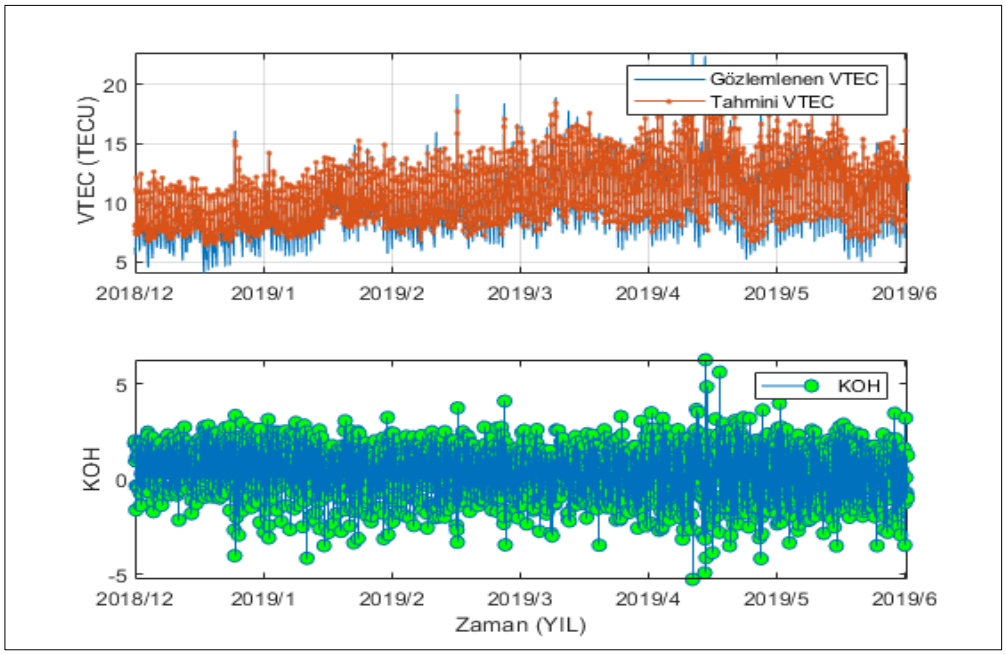
Şekil 4. 18. GEME istasyonunun 2 saatlik çözünürlüklü VTEC değişimleri

Literatürdeki çalışmalar (Pala ve Atıcı, 2019; Srivani ve ark., 2019) dikkate alınarak seçilen 50 gizli katman sayısına sahip ve 100 iterasyonlu LSTM ağına GEME istasyonuna ait GPS-TEC gözlemlerinin ilk 3 yıllık veri seti önerilen ağa

girdi olarak eklenmiştir. Daha sonra son 6 aya ait veriler ise test verisi olarak seçilmiştir (Şekil 4.19).

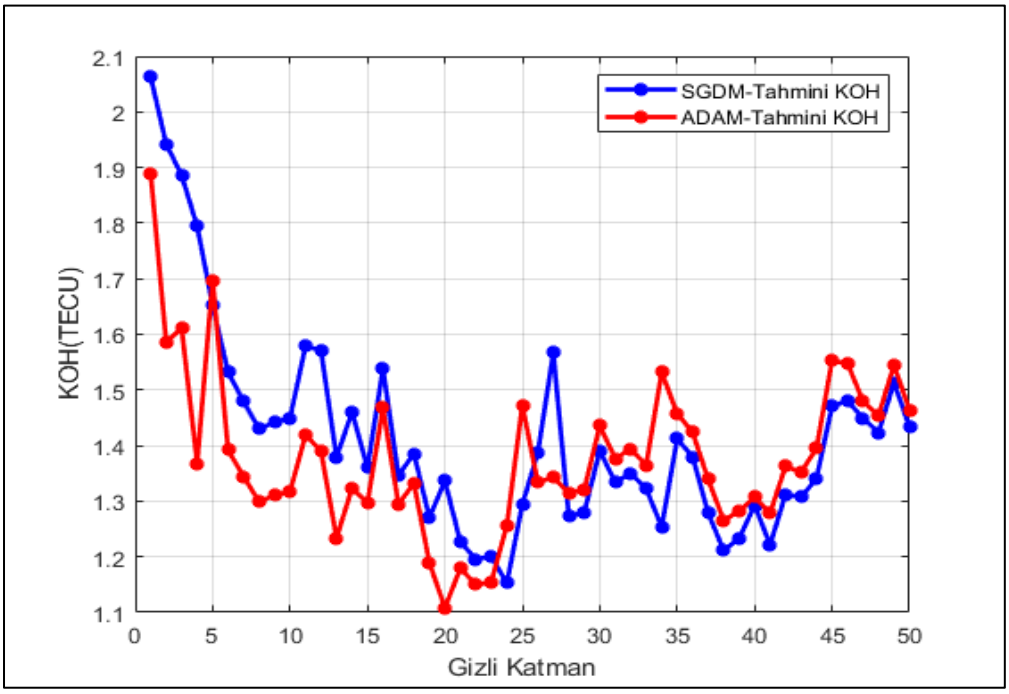


Şekil 4. 19. GEME istasyonunda eğitilecek ve test edilecek VTEC değerleri



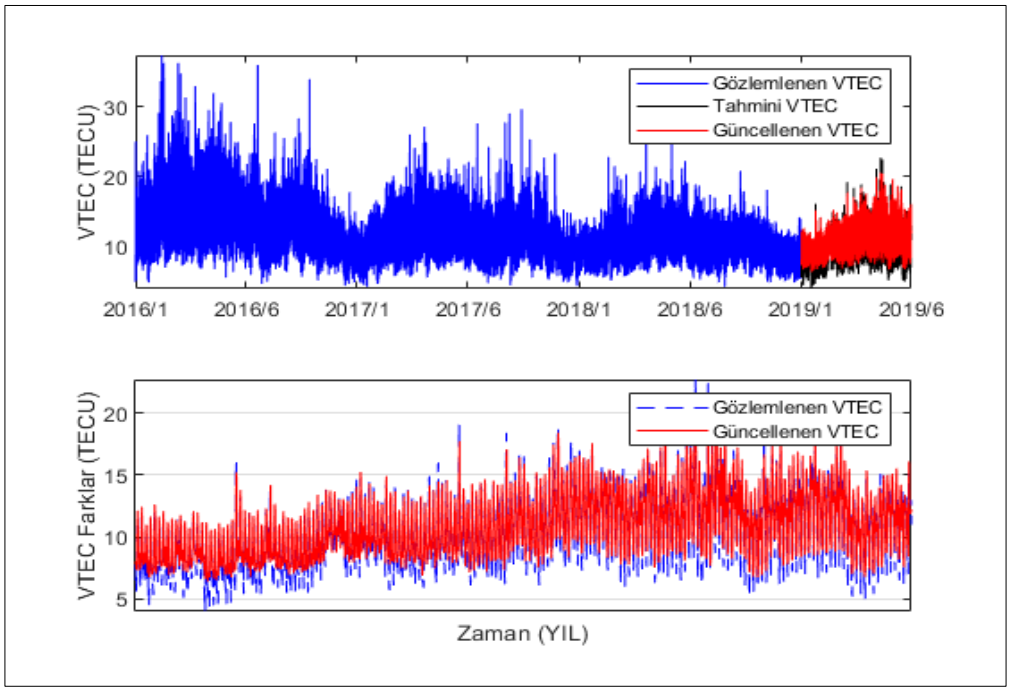
Şekil 4. 20. GEME istasyonunda tahmini ve gözlemlenen VTEC değerleri (üst), KOH (alt)

Daha sonra tasarlanan LSTM ağında ilk tahmin yapılmış ve bu ilk tahmine ait KOH değer ±3.21 TECU olarak elde edilmiştir (Şekil 4.20). İlk tahmin yapıldıktan sonra da SGDM ve ADAM optimizasyonlarıyla da her gizli katmanda elde edilen KOH değerleri ayrı ayrı bulunmuştur (Şekil 4.21).



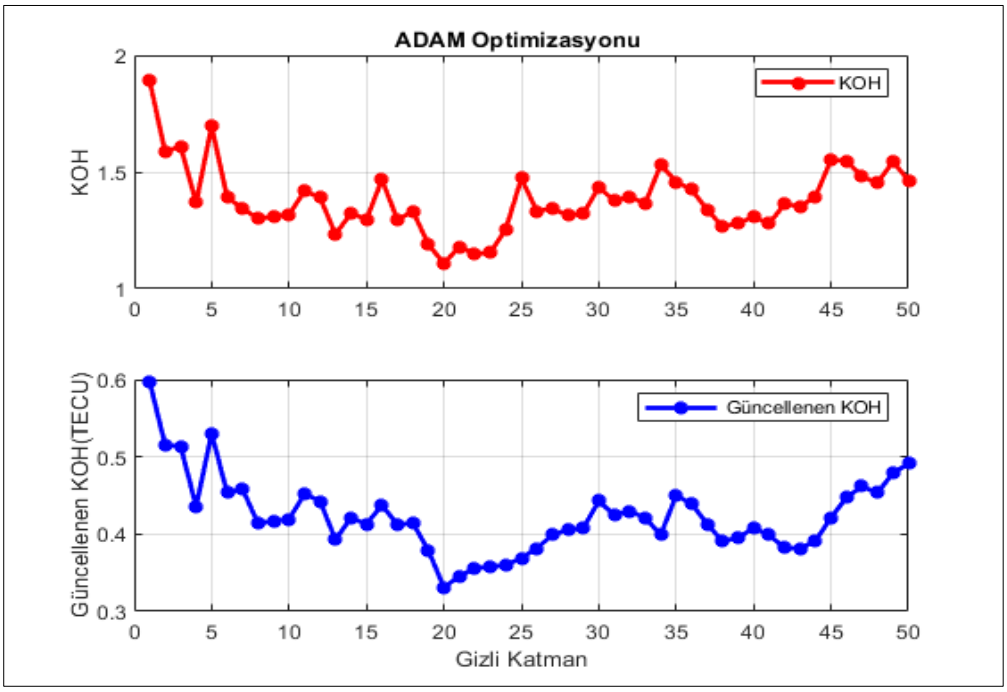
Şekil 4. 21. İlk tahmin verileriyle SGDM ve ADAM optimizasyon çözümleri

Yapılan ilk tahmin neticesinde, SGDM optimizasyonuyla gizli katman sayısı 1 seçildiğinde KOH değeri en yüksek ±2.06 TECU, gizli katman sayısı 24 seçildiğinde ise ±1.15 TECU olarak saptanmıştır. ADAM optimizasyonunda ise gizli katman sayısının 1 seçildiği durumda KOH değeri en yüksek ±1.88 TECU, gizli katman sayısının 20 seçildiği durumda ise ±1.11 TECU olarak elde edilmiştir.

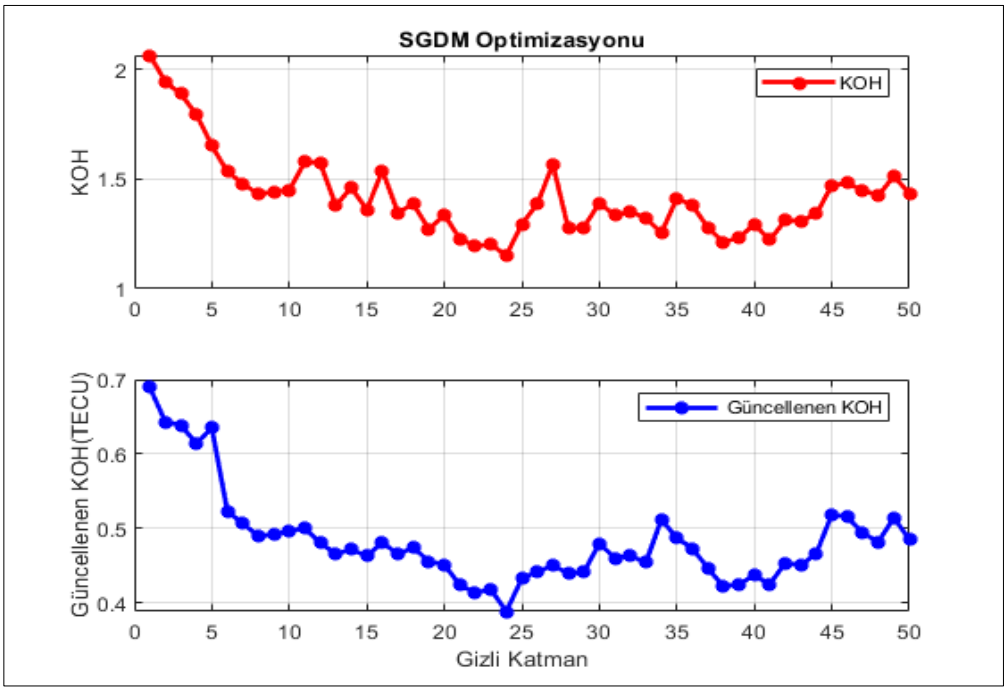


Şekil 4. 22. GEME istasyonunda tahmine yapılan güncelleme

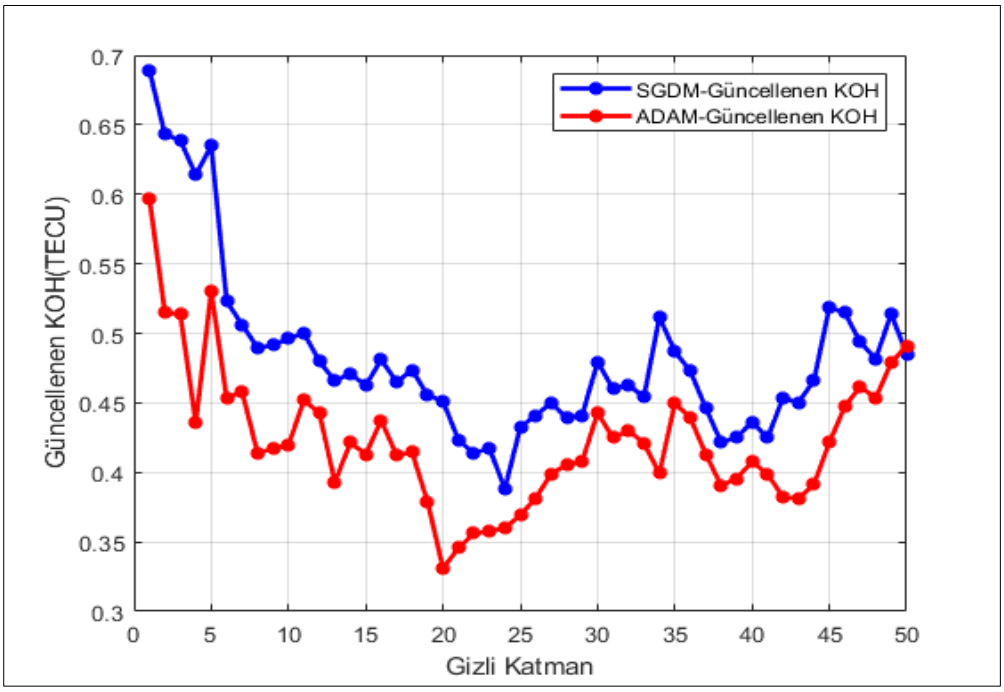
İlk tahminlerin ardından gradyan ile tahminlerde güncellenme yapılmış (Şekil 4.22) ve KOH değeri ±2.76 TECU olarak elde edilmiştir. Ardından tasarlanan ağ tekrardan optimizasyon çözümleriyle ele alınmış ve gerçeğe yakın değerler elde edilmiştir. Şekil 4.23'te güncellenen tahmine uygulanan ADAM optimizasyonu işleminde gizli katman sayısı 1 seçildiğinde en yüksek KOH değeri ±0.60 TECU, gizli katman sayısı 20 seçildiğinde ise KOH değeri en düşük ±0.33 TECU olarak saptanmıştır. Şekil 4.24'da ise güncellenen tahmine SGDM optimizasyonu uygulanmış ve gizli katman sayısının 1 seçildiği durumda en yüksek KOH değeri ±0.69 TECU, gizli katman sayısının 31 seçildiği parametrede ise en düşük KOH değeri ±0.38 TECU olarak belirlenmiştir. Şekil 4.25'de ise bu 2 farklı optimizasyon çözümleri karşılaştırılmıştır.



Şekil 4. 23. ADAM optimizasyonuyla güncellenen yeni KOH değerleri



Şekil 4. 24. SGDM optimizasyonuyla güncellenen yeni KOH değerleri



Şekil 4. 25. ADAM ve SGDM optimizasyonlarının duyarlılıkları

Bu çözümlemelerin ardından GEME istasyon verilerinde 20-25 gizli katman aralıklarında her iki yöntemde de başarılı sonuçlar alınmıştır. Güncellenen optimizasyonlar paralel bir yakınsama izlese de bazı noktalarda yapılan sıçramalarla farklı KOH değerleri elde edilmiştir.

Çizelge 4. 7. GEME istasyonunda ilk tahmindeki optimizasyonlarının duyarlılıkları

Gizli Katman Sayısı	ADAM (±TECU)	SGDM (±TECU)	Gizli Katman Sayısı	ADAM (±TECU)	SGDM (±TECU)
1	1.8891	2.0628	26	1.3333	1.3905
2	1.5859	1.9422	27	1.3431	1.3339
3	1.6114	1.8857	28	1.3145	1.3502
4	1.3682	1.7943	29	1.3213	1.3222
5	1.6971	1.6518	30	1.4353	1.2536
6	1.3916	1.5315	31	1.3769	1.4121
7	1.3441	1.4791	32	1.3937	1.3794
8	1.2991	1.4297	33	1.3649	1.2787
9	1.3101	1.4417	34	1.5316	1.2114
10	1.3173	1.4497	35	1.4576	1.2331
11	1.4194	1.5788	36	1.4238	1.2923
12	1.3899	1.5711	37	1.3391	1.2218
13	1.2338	1.3788	38	1.2658	1.3119
14	1.3229	1.4602	39	1.2818	1.3071
15	1.2972	1.3597	40	1.3074	1.3408
16	1.4674	1.5387	41	1.2785	1.4707
17	1.2946	1.3464	42	1.3627	1.4802
18	1.3323	1.3856	43	1.3521	1.4493
19	1.189	1.2708	44	1.3951	1.4235
20	**1.1084**	1.3362	45	1.5524	1.5127
21	1.1795	1.2267	46	1.5477	1.4341
22	1.1497	1.1957	47	1.4799	1.4493
23	1.1544	1.2006	48	1.4536	1.4235
24	1.2565	**1.1527**	49	1.5446	1.5127
25	1.4727	1.294	50	1.4643	1.4340

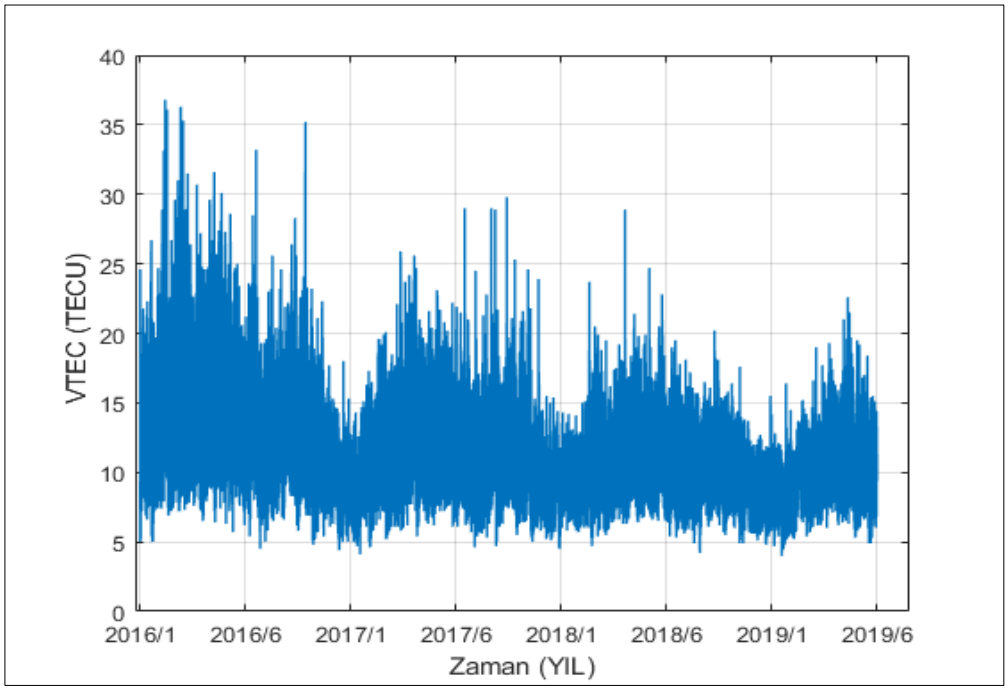
Çizelge 4. 8. GEME istasyonunda güncellenen tahmindeki optimizasyonlarının duyarlılıkları

Gizli Katman Sayısı	ADAM (±TECU)	SGDM (±TECU)	Gizli Katman Sayısı	ADAM (±TECU)	SGDM (±TECU)
1	0.5969	0.6892	26	0.3816	0.4411
2	0.5151	0.6431	27	0.3989	0.4499
3	0.5135	0.6388	28	0.4056	0.4392
4	0.4357	0.6139	29	0.4077	0.4407
5	0.5304	0.6349	30	0.4428	0.4795
6	0.4532	0.5233	31	0.4248	0.4613
7	0.458	0.5062	32	0.4312	0.4631
8	0.4137	0.4896	33	0.4211	0.454
9	0.4172	0.4913	34	0.3992	0.5117
10	0.4195	0.4964	35	0.4497	0.487
11	0.452	0.5111	36	0.4393	0.4729
12	0.4426	0.4808	37	0.4131	0.4464
13	0.3929	0.4657	38	0.3905	0.4215
14	0.4213	0.4719	39	0.3955	0.4254
15	0.4131	0.4625	40	0.4078	0.4363
16	0.4373	0.4811	41	0.3988	0.4248
17	0.4123	0.4649	42	0.3822	0.4535
18	0.4143	0.4737	43	0.3811	0.4502
19	0.3787	0.4555	44	0.3914	0.4661
20	**0.3311**	0.4511	45	0.4214	0.5187
21	0.3456	0.4233	46	0.4474	0.5148
22	0.3561	0.4137	47	0.4616	0.4936
23	0.3577	0.4175	48	0.4534	0.4817
24	0.3601	**0.3881**	49	0.4788	0.5141
25	0.3692	0.4324	50	0.4911	0.4848

Çizelge 4.7 ve 4.8'deki GEME istasyonunda yapılan tahmin sonuçlarına etki eden optimizasyon çözümleri dikkate alındığında ADAM yönteminin her 2 tahminde de SGDM yönteminden daha iyi bir sonuç verdiği gözlemlenmiştir.

4.4. HEND İstasyonu GPS-TEC Tahmini

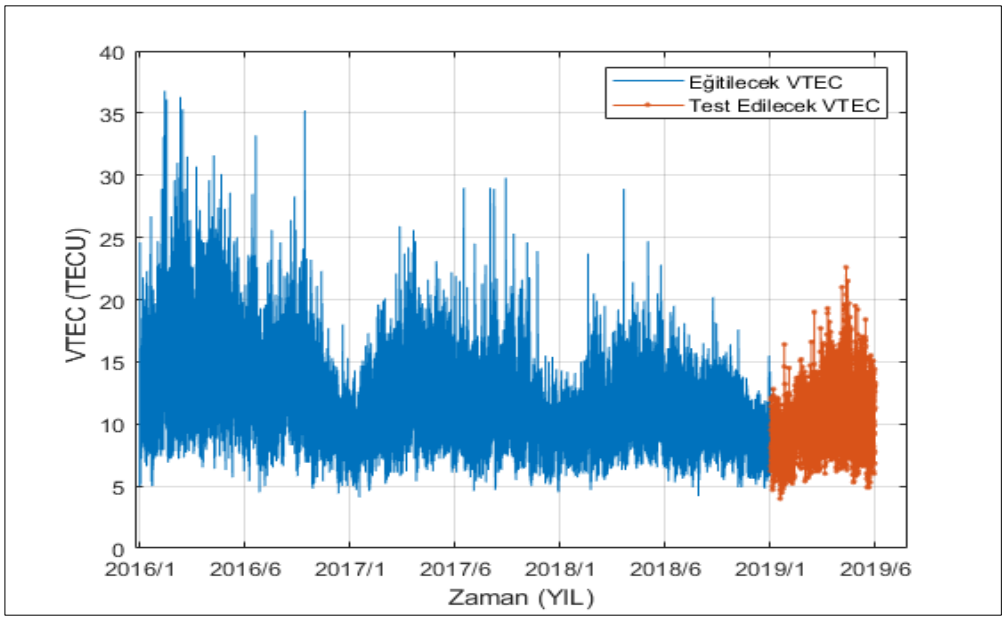
Sakarya İli'nde bulunan ve TUSAGA-Aktif istasyonuna kayıtlı olan HEND istasyonuna (Enlem:40.79499◦ Kuzey, Boylam:30.74075◦ Doğu) ait 2 saat çözünürlüklü VTEC değişimlerini (Şekil 4.26) içeren 3.5 yıllık veri seti eğitilmiş ve 6 aylık bir VTEC tahmini yapılmıştır. Daha sonra bu tahmini VTEC'in doğruluğunun tespiti KOH yöntemi kullanılarak saptanmıştır.



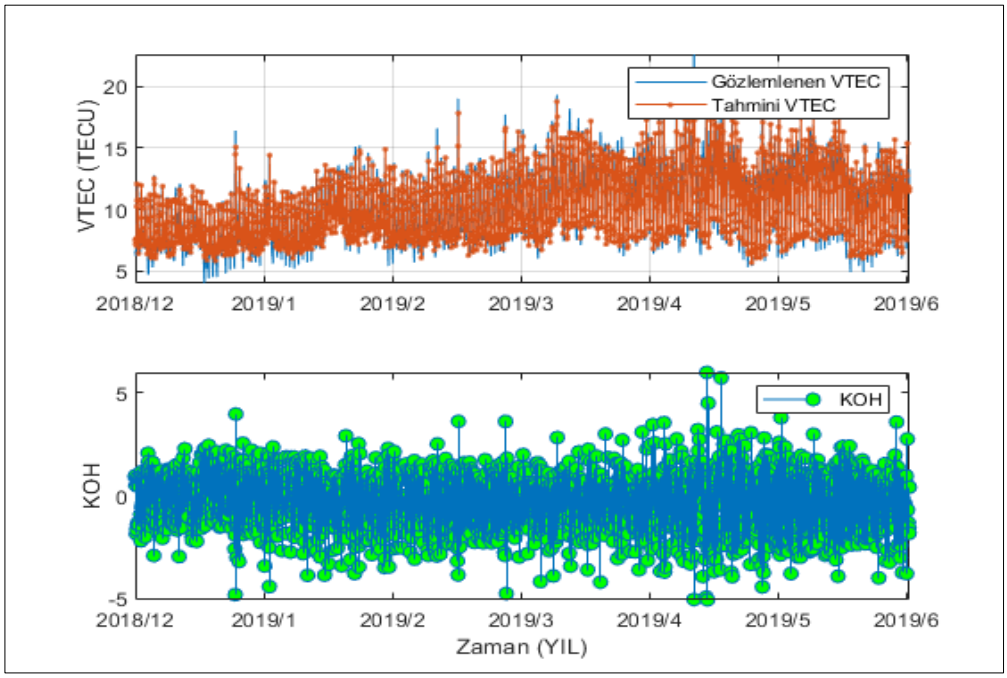
Şekil 4. 26. HEND istasyonunun 2 saatlik çözünürlüklü VTEC değişimleri

Literatürdeki çalışmalar (Pala ve Atıcı, 2019; Srivani ve ark., 2019) dikkate alınarak gizli katman sayısı 50, iterasyon sayısı 100 seçilen LSTM ağına HEND istasyonuna ait GPS-TEC gözlemlerinin ilk 3 yıllık veri seti önerilen ağa girdi olarak

eklenmiştir. Daha sonra son 6 aya ait veriler ise test verisi olarak seçilmiştir (Şekil 4.27).

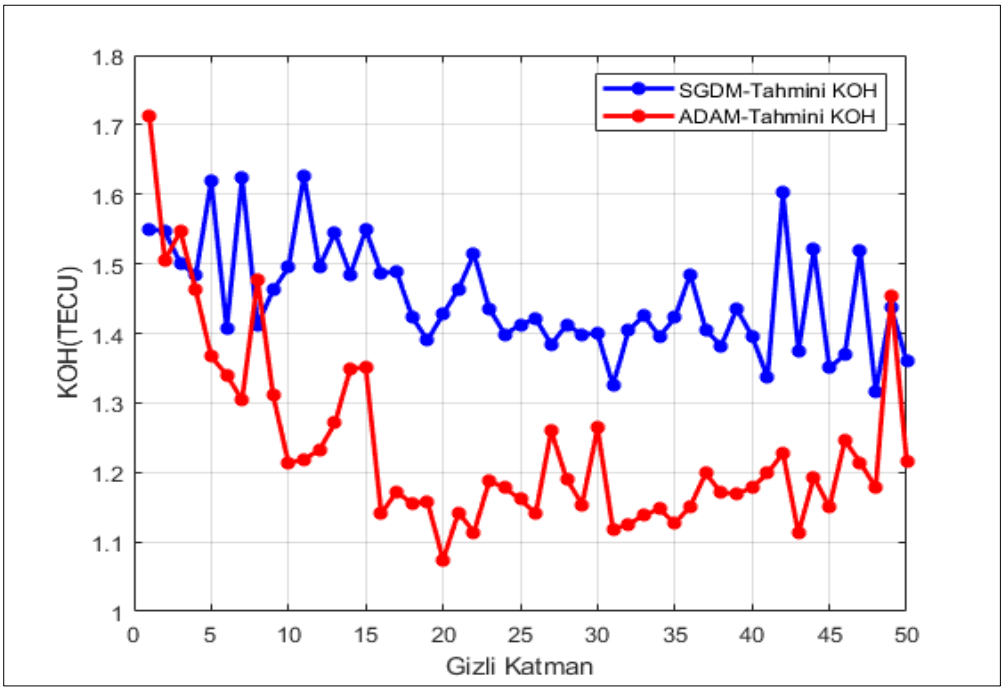


Şekil 4. 27. HEND istasyonunda eğitilecek ve test edilecek VTEC değerleri



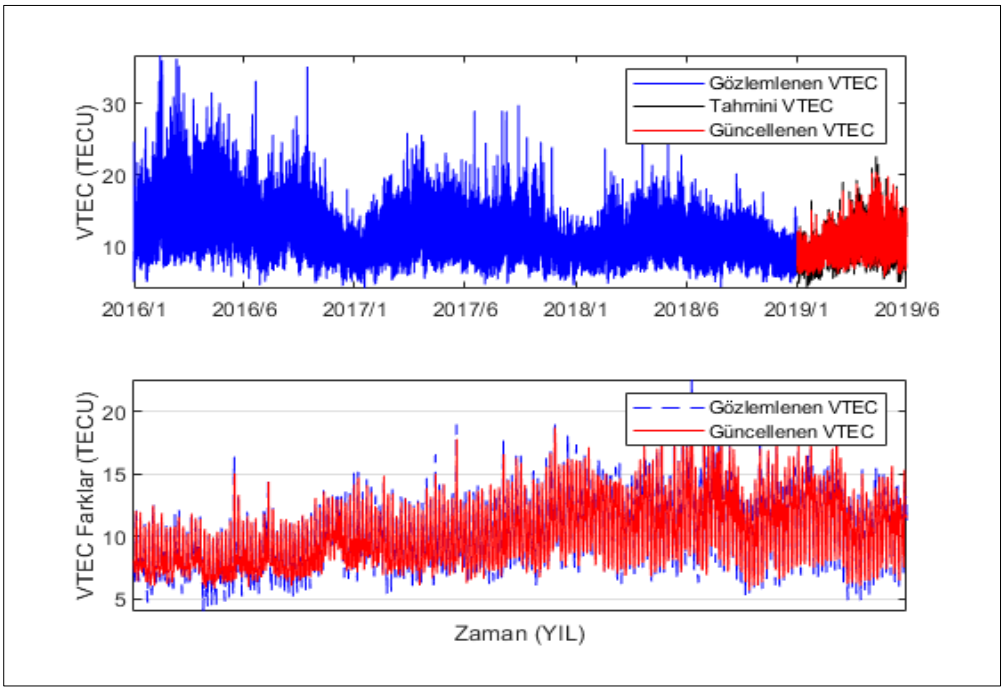
Şekil 4. 28. HEND istasyonunda tahmini ve gözlemlenen VTEC değerleri (üst), KOH (alt)

Daha sonra tasarlanan LSTM ağında ilk tahmin yapılmış ve bu ilk tahmine ait KOH değeri ±3.47 TECU olarak elde edilmiştir (Şekil 4.28). İlk tahmin yapıldıktan sonra, SGDM ve ADAM optimizasyonlarıyla her gizli katmanda elde edilen KOH değerleri ayrı ayrı bulunmuştur (Şekil 4.29).



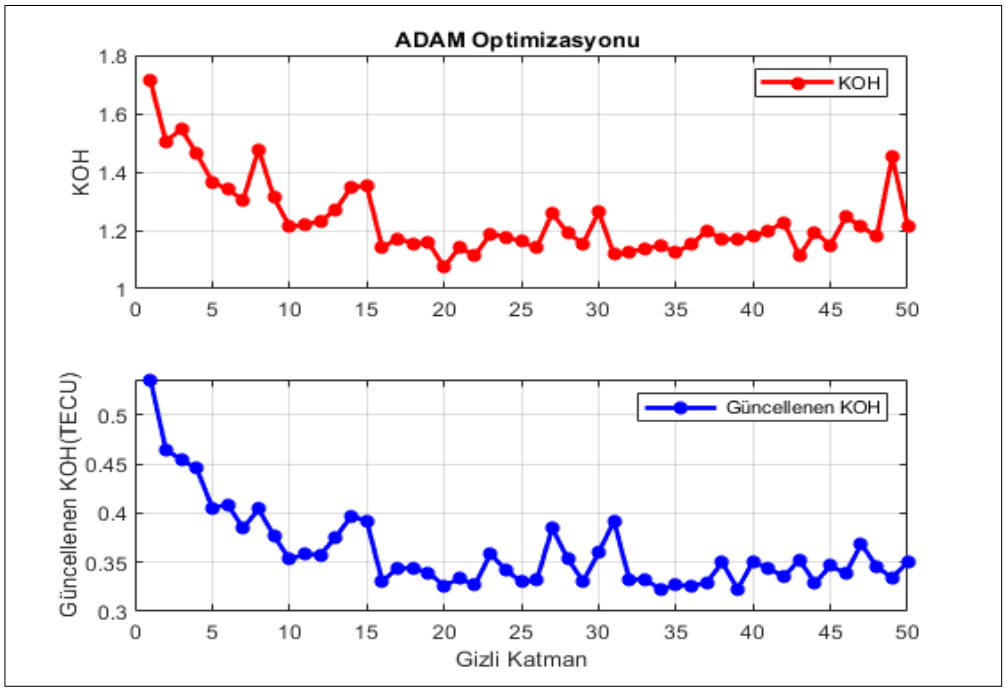
Şekil 4. 29. İlk tahmin verileriyle SGDM ve ADAM optimizasyon çözümleri

Yapılan ilk tahmin neticesinde, SGDM optimizasyonuyla gizli katman sayısı 11 seçildiğinde KOH değeri en yüksek 1.63 ±TECU, gizli katman sayısı 48 seçildiğinde ise ±1.32 TECU olarak saptanmıştır. ADAM optimizasyonunda ise gizli katman sayısının 1 seçildiği durumda KOH değeri en yüksek ±1.71 TECU, gizli katman sayısının 20 seçildiği durumda ise ±1.07 TECU olarak elde edilmiştir.

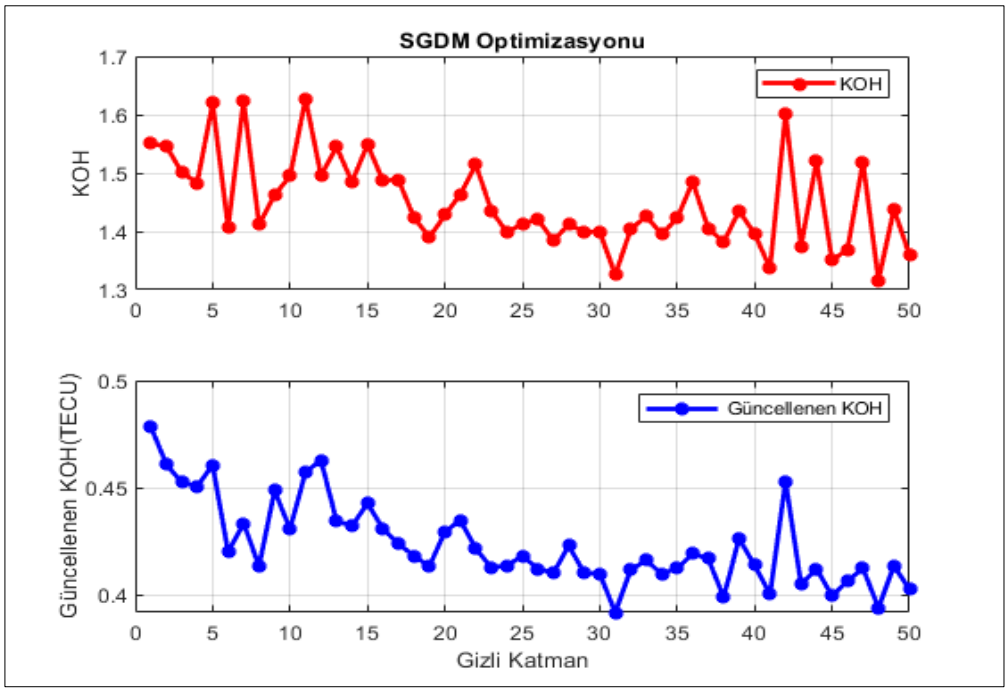


Şekil 4. 30. HEND istasyonunda tahmine yapılan güncelleme

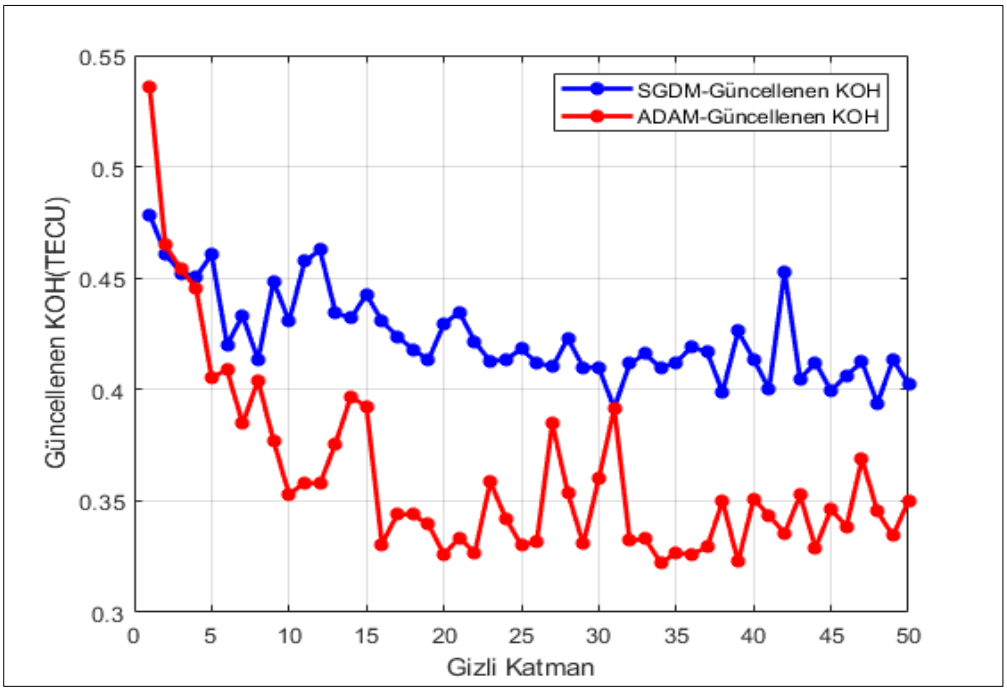
İlk tahminlerin ardından gradyan ile tahminlerde güncellenme yapılmış (Şekil 4.30) ve KOH değeri ±2.95 TECU olarak elde edilmiştir. Ardından tasarlanan ağ tekrardan optimizasyon çözümleriyle ele alınmış ve gerçeğe yakın değerler elde edilmiştir Şekil 4.31'de güncellenen tahmine uygulanan ADAM optimizasyonu işleminde gizli katman sayısı 1 seçildiğinde en yüksek KOH değeri 0.54 ±TECU, gizli katman sayısı 32 seçildiğinde ise KOH değeri en düşük 0.32 ±TECU olarak saptanmıştır. Şekil 4.32'de ise güncellenen tahmine SGDM optimizasyonu uygulanmış ve gizli katman sayısının 1 seçildiği durumda en yüksek KOH değeri 0.48 ±TECU, gizli katman sayısının 31 seçildiği parametrede ise en düşük KOH değeri 0.39 ±TECU olarak belirlenmiştir. Şekil 4.33'de ise bu 2 farklı optimizasyon çözümleri karşılaştırılmıştır.



Şekil 4. 31. ADAM optimizasyonuyla güncellenen yeni KOH değerleri



Şekil 4. 32. SGDM optimizasyonuyla güncellenen yeni KOH değerleri



Şekil 4. 33. ADAM ve SGDM optimizasyonlarının duyarlılıkları

Bu çözümlemelerin ardından HEND istasyon verilerinde başlangıçtaki çözümlerde SGDM çözümü daha iyi iken, diğer gizli katman sayılarındaki çözümlerde ise ADAM optimizasyonunun daha başarılı olduğu ortaya konmuştur. Ayrıca 33 gizli katman sayılı ağ mimarisinde ise KOH değerleri birbirlerine benzerlik göstermiştir.

Çizelge 4. 9. HEND istasyonunda ilk tahmindeki optimizasyonlarının duyarlılıkları

Gizli Katman Sayısı	ADAM (±TECU)	SGDM (±TECU)	Gizli Katman Sayısı	ADAM (±TECU)	SGDM (±TECU)
1	1.7123	1.5501	26	1.1408	1.4211
2	1.5049	1.5463	27	1.2595	1.3840
3	1.5470	1.5013	28	1.1906	1.4122
4	1.4624	1.4831	29	1.1538	1.3986
5	1.3666	1.6195	30	1.2637	1.3997
6	1.3402	1.4068	31	1.1178	1.3254
7	1.3041	1.6239	32	1.1256	1.4038
8	1.4777	1.4117	33	1.1383	1.4256
9	1.3115	1.4622	34	1.1475	1.3954
10	1.2134	1.4947	35	1.1264	1.4224
11	1.2187	1.6271	36	1.1512	1.4851
12	1.2322	1.4956	37	1.1987	1.4054
13	1.2707	1.5446	38	1.1705	1.3815
14	1.3490	1.4847	39	1.1692	1.4352
15	1.3511	1.5487	40	1.1780	1.3959
16	1.1409	1.4869	41	1.1987	1.3368
17	1.1721	1.4886	42	1.2278	1.6023
18	1.1550	1.4235	43	1.1123	1.3739
19	1.1582	1.3900	44	1.1933	1.5211
20	**1.0740**	1.4278	45	1.1498	1.3502
21	1.1422	1.4635	46	1.2458	1.3692
22	1.1139	1.5142	47	1.2143	1.5189
23	1.1881	1.4354	48	1.1778	**1.3166**
24	1.1775	1.3985	49	1.4528	1.4378
25	1.1613	1.4124	50	1.2165	1.3594

Çizelge 4. 10. HEND istasyonunda güncellenen tahmindeki optimizasyonlarının duyarlılıkları

Gizli Katman Sayısı	ADAM (±TECU)	SGDM (±TECU)	Gizli Katman Sayısı	ADAM (±TECU)	SGDM (±TECU)
1	0.5359	0.4786	26	0.3317	0.4121
2	0.4647	0.4611	27	0.3849	0.4101
3	0.4543	0.4523	28	0.3537	0.4229
4	0.4453	0.4505	29	0.3306	0.4100
5	0.4055	0.4606	30	0.3599	0.4098
6	0.4088	0.4200	31	0.3918	**0.3917**
7	0.3846	0.4333	32	0.3321	0.4116
8	0.4041	0.4133	33	0.3330	0.4160
9	0.3769	0.4486	34	**0.3222**	0.4097
10	0.3529	0.4305	35	0.3265	0.4122
11	0.3582	0.4574	36	0.3261	0.4191
12	0.3577	0.4626	37	0.3292	0.4168
13	0.3758	0.4345	38	0.3500	0.3989
14	0.3969	0.4320	39	0.3226	0.4261
15	0.3922	0.4427	40	0.3508	0.4137
16	0.3306	0.4307	41	0.3435	0.4002
17	0.3442	0.4238	42	0.3355	0.4530
18	0.3438	0.4181	43	0.3525	0.4048
19	0.3394	0.4133	44	0.3289	0.4121
20	0.3261	0.4294	45	0.3462	0.3994
21	0.3333	0.4348	46	0.3385	0.4064
22	0.3268	0.4214	47	0.3689	0.4123
23	0.3586	0.4126	48	0.3452	0.3938
24	0.3421	0.4135	49	0.3343	0.4135
25	0.3301	0.4181	50	0.3501	0.4025

Çizelge 4.9 ve 4.10'daki HEND istasyonu için yapılan tahmin sonuçlarına etki eden optimizasyon çözümleri dikkate alındığında ADAM yönteminin her 2 tahminde de SGDM yönteminden büyük bir farkla üstün olduğu ortaya konmuştur.

Gizli katman sayılarına bağlı olarak 100 iterasyonlu çözümlere ait KOH değerleri SURF (Çizelge 4.3 ve Çizelge 4.4), ANTL (Çizelge 4.5 ve Çizelge 4.6), GEME (Çizelge 4.7 ve Çizelge 4.8), HEND (Çizelge 4.9 ve Çizelge 4.10) istasyonlarının sonuç çizelgelerinde görülmektedir. Her bir gizli katmanda 100 iterasyon yapılmış olup her iterasyon süresi yukarıda belirtilen bilgisayar sisteminde yaklaşık 5 dakika sürmüştür. Bu tez çalışmasında, her bir istasyonda yapılan ilk tahmin ve güncellenmiş tahmin için yaklaşık 830 (34 gün) saat geçmiştir. 4 istasyon için geçen süre yaklaşık 136 gündür. Daha gelişmiş bilgisayar sistemlerinde, gizli katman sayısı ve iterasyon sayısı azaltılarak çözüm süresi azaltılabilir fakat ağ parametrelerinin tahmin doğruluğunu etkileyebildiği göz önünde bulundurulmalıdır.

Çizelge 4. 11. Her istasyonda yapılan tahminlere optimizasyonların etkisi

İstasyonlar	Tahmin		Optimizasyon (İlk Tahmin)		Optimizasyon (Güncellenmiş Tahmin)	
	İlk (±TECU)	Güncellenmiş (±TECU)	SGDM (±TECU)	ADAM (±TECU)	SGDM (±TECU)	ADAM (±TECU)
SURF	3.43	2,92	1.2714	1.2225	0.3811	0.348
ANTL	3.29	2.76	1.3166	1.3181	0.3939	0.3456
GEME	3.21	2.67	1.1527	1.1084	0.3881	0.3311
HEND	3.47	2.95	1.3166	1.074	0.3917	0.3222

Tüm istasyon üstü VTEC değişimlerinin girdi olarak tasarlandığı LSTM ağında ilk tahmin ve güncellenmiş tahminler yapılmıştır. Ardından bu tahminlere optimizasyonlar uygulanmıştır. Tasarlanan LSTM ağında elde edilen en iyi KOH değerleri Çizelge 4.11'de gösterilmiştir. Bu sonuçlara göre, güncellenen tahminler, ilk tahminlere göre daha iyi bir performans göstermiştir. Ardından uygulanan optimizasyonlar tahmin doğruluklarını artırmıştır.

5. SONUÇLAR VE ÖNERİLER

Çalışmada, SURF, ANTL, GEME ve HEND sabit GNSS istasyonuna ait TEC değişimlerinin 2019 yılının ilk 6 ayına ait TEC tahminleri MATLAB derin öğrenme aracılığıyla hazırlanan, farklı parametrelerle elde edilen ağın istenilen duyarlıkta oluşturulan LSTM mimarisine göre araştırılmıştır. Bu tez çalışması, SURF, ANTL, GEME ve HEND GNSS istasyonlarının 2016-2019 yılları arasındaki GPS gözlemlerinden elde edilen TEC değerleri kullanılarak 2019 yılının ilk yarısındaki 2,172 TEC değerinin tahmin edilmesi için yapılmıştır. GPS gözlemlerinin alıcıdan bağımsız bir veri biçimi olan RINEX formatındaki veriler kullanılarak istasyon üstü iyonosferik TEC değişimleri, TECU biriminde elde edilmiştir.

Bu çalışmada hatayı geriye yayma tekniği olan momentumlu stokastik gradyan inişi (SGDM) ve uyarlanabilir momentum (ADAM) optimizasyon algoritmaları kullanılmıştır. Modeldeki TEC değişimlerine ait zaman serisi verileri iki saat çözünürlüklü elde edilen 3,5 yıllık TEC değişimlerinden oluşmaktadır. TEC değişimlerine ait 3 yıllık veri seti tasarlanan LSTM ağ mimarisi içerisinde 13,152 eğitim verisi, geriye kalan 4368 adet veri ise test verisi olarak kullanılmıştır. Bu çalışmada, önerilen LSTM modelinde TEC değişimlerinin 2019 yılının ilk altı aylık verilerinin tahminine yönelik değerlendirilmeler yapılmıştır. LSTM modelinin performansı GPS-TEC verileriyle incelenmiş KOH ve gizli katman sayılarına göre elde edilen sonuç parametreleri birbirleriyle mukayese edilmiştir. Hesaplamalar sonucunda, her bir istasyon için güncellenen tahmin verilerine ADAM ve SGDM optimizasyon çözümleri eklenmiştir. Bu optimizasyon çözümlerinden sonra KOH değerlerinde iyileşmeler belirlenmiştir.

İlk ve güncellenmiş tahmin sonuçlarına göre en iyi tahmin sırasıyla ±1.0740 ve ±0.3222 TECU ile HEND istasyonunda yapılmıştır. Genel sonuç itibariyle

ADAM yöntemi SGDM'den daha iyi bir sonuç vermesine karşın, SGDM yöntemi ANTL istasyonunda ilk tahminde ADAM yönteminden daha iyi sonuçlar vermiştir (Çizelge 4.11).

Gizli katman sayısının artırılmasına bağlı olarak hesaplanacak KOH değerleri arasında doğrusal bir değişimin olmadığı 50 gizli katmanlı modelden hesaplanan KOH değerinin farklı gizli katmanlarında farklı değerler verdiği ortaya çıkarılmıştır. KOH değerlerinin sıçrama yapmasının sebebi ise oluşturulan LSTM mimarisinin bazı gizli katmanlarından sonraki gizli katmanlarda bilgi eksikliği yaşayan nörona denk gelen verilerden kaynaklı olabileceği söylenebilir.

Derin öğrenme farklı öğrenme algoritmaları ile yeni bilgiler üreten bilgi işlem teknolojisi olmakla beraber kullanıldığı alanlarda hem avantajları hem de dezavantajları bulunmaktadır. Bilgisayar donanımına bağlı olması, farklı parametrelerle farklı sonuçlar çıkması ve aynı parametrelerin farklı bilgisayarda bile aynı olmaması (davranışının bilinmemesi), yapılacak çözümler için uygun ağ yapısını ve optimizasyon türünü belirleme için işlem sürecinin çok uzun sürmesi, ağın eğitilme sürecinin bilinmemesi ve başlangıçtaki öğrenme oranının ağın gidişatını etkilemesi, yazılım kullanma konusunda bir uzmanlık gerektirmesi gibi faktörler derin öğrenmede karşılaşılan bazı problemlerdir. Bu problemlerin aksine, veri setinin içinde 0 değeri bulunsa bile ağı durdurmaması, matematiksel olarak açıklanabilecek hata toleransına sahip olması, ürettiği bilgileri kendi ağında depolayıp bunu kullanabilmesi, birden fazla işi yapacak sayısal güce sahip olması derin öğrenmenin son zamanlarda popülerliğini artırmaktadır. MATLAB® ortamında hazırlanmış Derin Öğrenme Araç Kutusunu kullanabilmek için bilgisayar donanımı (işlemci, ekran kartı, hafıza kartı vs.) performansının yüksek olması gerekmektedir. Ayrıca seçilen ağın çözüm yöntemi, zaman serisi verilerini daha iyi temsil edecek bir biçimde seçilmelidir.

KAYNAKLAR

ABDULLAH, M., STRANGEWAYS, H. J. and WALSH, D. M. A. 2009. Improving ambiguity resolution rate with an accurate ionospheric differential correction. Journal of Navigation. https://doi.org/10.1017/S0373463308004979

ABHISHEK, K., KUMAR, A., RANJAN, R. and KUMAR, S. 2012. A rainfall prediction model using artificial neural network. Proceedings - 2012 IEEE Control and System Graduate Research Colloquium, ICSGRC 2012. https://doi.org/10.1109/ICSGRC.2012.6287140

AKCA, M.F., 2020. https://medium.com/deep-learning-turkiye/gradient-descent-nedir-3ec6afcb9900. Erişim Tarihi: 27.09.2020.

AKIN M., 2001. Yapay Sinir Ağları. İstanbul Üniversitesi Siyasal Bilgiler Fakültesi Dergisi, 25; 7-19.

AKIR, R. M., CHELLAPPAN, K. and ABDULLAH, M., 2017. Total electron content forecasting using artificial neural network. Pertanika Journal of Science and Technology.

ALPAYDIN, E., 2018. "Yapay Öğrenme". Boğaziçi Üniversitesi Yayınevi, İstanbul

ATASEVEN BURÇIN, 2013. Yapay Sinir Ağları ile Öngörü Modellemesi, Öneri, Cilt 10, 39; 101-115.

AYDEMIR E., KARAATLI M., YILMAZ G. ve AKSOY S., 2014. 112 Acil Çağrı Merkezine Gelen Çağrı Sayılarını Belirleyebilmek için bir Yapay Sinir Ağları Tahminleme Modeli Geliştirilmesi. Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi, Cilt 20, 5; 145-149.

BENLI Y. ve YILDIZ A., 2014. Altın Fiyatlarının Zaman Serisi Yöntemleri ve Yapay Sinir Ağları ile Öngörüsü. Dumlupınar Üniversitesi Sosyal Bilimler Dergisi. 42; 213-224.

BOULCH, A., NOËLIE, C. and THIBAUT, C., 2018. Ionospheric activity prediction using convolutional recurrent neural networks.

CHAKRABORTY, M., KUMAR, S., DE, B. K. and GUHA, A., 2014. Latitudinal characteristics of GPS derived ionospheric TEC: A comparative study with IRI 2012 model. Annals of Geophysics. https://doi.org/10.4401/ag-6438.

COLLOBERT R. and WESTON J., 2008. A unified architecture for natural language processing. In: Proceedings of the 25th International Conference on Machine Learning; 160–167.

DACH, R., HUGENTOBLER, U., FRIDEZ, P. AND MEINDL, M., 2007. Manual of Bernese GPS Software Version 5.0. Astronomical Institute. University of Bern

DEFAZIO, A. and JELASSI, S., 2021. Adaptivity without Compromise: A Momentumized, Adaptive, Dual Averaged Gradient Method for Stochastic Optimization.

DEFAZIO, A., 2020. Optimization Methods 2. https://atcold.github.io/pytorch-Deep-Learning/tr/week05/05-2/. Erişim Tarihi: 05.11.2020.

FUKUSHIMA K., 1980. Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. Biol Cybern 36; 193–202. doi: 10.1007/BF00344251.

GILES, C. L., LAWRENCE, S. and CHUNG, A., 2001. Noisy Time Series Prediction using a Recurrent Neural Network and Grammatical Inference. 44(1), 161–183.

GONCALVES, V., MARIA, K., DA SILVA B.F., 2013. Applications of Artificial Neural Networks in Chemical Problems. In: Suzuki K (ed) Artificial Neural Networks - Architectures and Applications. IntechOpen, Rijeka

GREFENSTETTE, E., BLUNSOM, P., DE FREITAS, N. and HERMANN, K.M., 2015. A Deep Architecture for Semantic Parsing. 22–27. doi: 10.3115/v1/w14-2405

GÜLPINAR V., 2013. Yapay Sinir Ağları ve Sosyal Ağ Analizi Yardımı ile Türk Telekomünkasyon Piyasasında Müşteri Kaybı Analizi. Marmara Üniversitesi İİB Dergisi, Cilt XXXIV, I; 331-350.

HABARULEMA, J. B., MCKINNELL, L. A. and CILLIERS, P. J., 2007. Prediction of global positioning system total electron content using Neural Networks over South Africa. Journal of Atmospheric and Solar-Terrestrial Physics. https://doi.org/10.1016/j.jastp.2007.09.002

HABARULEMA, J. B., MCKINNELL, L. A. and OPPERMAN, B. D. L., 2011. Regional GPS TEC modeling; Attempted spatial and temporal extrapolation of TEC using neural networks. Journal of Geophysical Research: Space Physics. https://doi.org/10.1029/2010JA016269

HINTON G E. and SALAKHUTDINOV R. R., 2006. Reducing the dimensionality of data with neural networks. Science 80; 313; 504–507. doi:10.1126/science.1127647

HOCHREITER, S. and SCHMIDHUBER J., 1997. Long short-term memory. Neural computation. Vol. 9, 8; 1735–1780

HOFMANN-WELLENHOF, B., LICHTENEGGER, H. and COLLINS, J., 1993. Global Positioning System. Theory and practice in Global Positioning System. Theory and practice.

HOMAM, M., 2016. Prediction of total electron content of the ionosphere using neural network. Jurnal Teknologi; 78. https://doi.org/10.11113/jt.v78.8750

HOMAM, M. J., 2014. Initial Prediction of Total Electron Content (TEC) At a Low Latitude Station Using Neural Network. 2; 8–10.

HUANG, Z. and YUAN, H., 2014. Research on regional ionospheric TEC modeling using RBF neural network. Science China Technological Sciences, 57(6); 1198–1205. https://doi.org/10.1007/s11431-014-5550-0

INYURT, S., MEKIK, Ç. ve YILDIRIM, Ö., 2020. Deprem Kaynaklı Olabilecek İyonosferik Değişimlerin Belirlenmesi üzerine yeni bir yaklaşım geliştirilmesi. Geomatik 5; 127–133. doi: 10.29128/geomatik.592477

INYURT, S., and SEKERTEKIN, A., 2019. Modeling and predicting seasonal ionospheric variations in Turkey using artificial neural network (ANN). Astrophysics and Space Science. https://doi.org/10.1007/s10509-019-3545-9

INYURT, S., YILDIRIM, O., MEKIK, C., 2017. Comparison between IRI-2012 and GPS-TEC observations over the western Black Sea. Ann Geophys. doi: 10.5194/angeo-35-817-2017

JELASSI, S. and DEFAZIO, A., 2020. Dual Averaging is Surprisingly Effective for Deep Learning Optimization. ArXiv, abs/2010.10502.

KALCHBRENNER, N., GREFENSTETTE, E. and BLUNSOM, P., 2014. A convolutional neural network for modelling sentences. 52nd Annu Meet Assoc Comput Linguist ACL 2014 - Proc Conf 1;655–665. doi: 10.3115/v1/p14-1062

KARAHAN M., 2015. Turizm Talebini Yapay Sinir Ağları Yöntemiyle Tahmin Edilmesi. Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, C. 20, 2; 195-209.

KARIM, R., 2018. https://towardsdatascience.com/10-gradient-descent-optimisation-algorithms-86989510b5e9 .Erişim Tarihi: 27.09.2020.

KARPATHY, A., FEI-FEI, L., 2017. Deep Visual-Semantic Alignments for Generating Image Descriptions. IEEE Trans Pattern Anal Mach Intell 39; 664–676

KARYMSHAKOV, K. and ABDYKAPAROV, Y., 2012. Forecasting Stock Index Movement with Artificial Neural Networks: The Case of Istanbul Stock Exchange. Trakya Üniversitesi Sosyal Bilimler Dergisi, Cilt 14, 2; 231-242.

KASELIMI, M., DELIKARAOGLOU, D. and DOULAMIS, N., 2019. Ionospheric Modeling in GNSS Positioning Using Deep Learning Models. Earth and Space Science Open Archive. https://doi.org/10.1002/essoar.10500959.1

KIM, M. and KIM, J., 2019. Extending the coverage area of regional ionosphere maps using a support vector machine algorithm. Annales Geophysicae. https://doi.org/10.5194/angeo-37-77-2019

KIM, Y., 2014. Convolutional neural networks for sentence classification. EMNLP 2014 - 2014 Conf Empir Methods Nat Lang Process Proc Conf 1746– 1751. doi: 10.3115/v1/d14-1181

KIZRAK, M.A., ve BOLAT, B., 2019. Uçak Motoru Sağlığı için Uzun-Kısa Süreli Bellek Yöntemi ile Öngörücü Bakım. Bilişim Teknolojileri Dergisi; 103-109. 10.17671/gazibtd.495730.

KRIZHEVSKY, A., HINTON, G.E., 2011. Using very deep autoencoders for content-based image retrieval. In: ESANN 2011 - 19th European Symposium on Artificial Neural Networks; 489–494

KOMJATHY, A., 1997. Global Ionospheric Total Electron Content Mapping Using the Global Positioning System. Ph.D. Thesis, Dept. of Geodesy and Geomatics Engineering Technical Report No. 188. Univ. of New Brunswick, Fredericton, New Brunswick, Canada

KURT, F., 2018. Evrişimli Sinir Ağlarında Hiper Parametrelerin Etkisinin İncelenmesi (Yüksek Lisans Tezi). Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü. Ankara, Türkiye.

LAROCHELLE, H. and BENGIO, Y., 2008. Classification using discriminative restricted boltzmann machines. In: Proceedings of the 25th International Conference on Machine Learning; 536–543

LEANDRO, R. F. and SANTOS, M. C., 2007. A neural network approach for regional vertical total electron content modelling. Studia Geophysica et Geodaetica, 51(2); 279–292. https://doi.org/10.1007/s11200-007-0015-6

LEICK, A., 2004. GPS Satellite Surveying. 3rd ed., John Wiley and Sons Inc., New Jersey

LIAO, X., 2000. Carrier phase based ionosphere recovery over a regional area GPS network. MSc. Thesis, Univ. of Calgary, Canada.

LIOU, C.Y., CHENG, W.C., LIOU, J.W. and LIOU, D.R., 2014. Autoencoder for words. Neurocomputing 139:84–96. doi: 10.1016/j.neucom.2013.09.055

MAKALEA, J. J., KELLEY, M. C., SOJKA, J. J., PI, X., and MANUCCI, A. J., 2001, GPS normalization and preliminary modeling results of total electron content during midlatitude space weather event. Radio Sci. 36; 356–361.

MCRAE, P., PARTHASARATHI, P., ASSRAN M. and CHANDAR, S., 2021. Memory Augmented Optimizers for Deep Learning.

MIKOLOV, T., KARAFIÁT, M. and BURGET, L., 2010. Recurrent neural network based language model. In: Proceedings of the 11th Annual Conference of the International Speech Communication Association, INTERSPEECH 2010; 1045–1048

NI, L., WANG, D., SINGH, V. P., WU, J., WANG, Y., TAO, Y. and ZHANG, J., 2019. Streamflow and rainfall forecasting by two long shortterm memory-based models. Journal of Hydrology, in press, 124296.

NWANKPA, C.E., IJOMAH, W., GACHAGAN, A. and MARSHALL, S., 2018. Activation fucntions: Comparison of trends in practice and research for deep learning. https://arxiv.org/pdf/1811.03378.pdf Erişim tarihi: 21.08.2020.

OKOH, D., 2018. GPS Modeling of the Ionosphere Using Computer Neural Networks. In Multifunctional Operation and Application of GPS. https://doi.org/10.5772/intechopen.75087

OLAH, C., 2019. Understanding LSTM Networks. http://colah.github.io/posts/2015- 08-Understanding-LSTMs [Erişim: 04/08/2020].

ÖZDEMİR, S., 2016. TUSAGA ve TUSAGA-Aktif İstasyonlarının Hassas Koordinat ve Hızlarının Hesaplanması Üzerine (On the Estimation of Precise Coordinates and Velocities of TNPGN and TNPGN- Active Stations). Harita dergisi, 155; 53-81.

ÖZKAN, F., 2012. Döviz Kuru Tahmininde Parasal Model ve Yapay Sinir Ağları Karşılaştırması. Business and Economics Research Journal, Vol. 3, Bo. 1; 27-39.

ÖZTEMEL, E., 2006. Yapay Sinir Ağları, Papatya Yayıncılık, İstanbul.

ÖZTÜRK, K. ve ŞAHIN, M.E., 2018. Yapay Sinir Ağları ve Yapay Zekâ'ya Genel Bir Bakış. Tak Vekayi 6; 25–36

PALA, Z. and ATICI, R., 2019. Forecasting Sunspot Time Series Using Deep Learning Methods. Solar Physics, 294(5); 50. https://doi.org/10.1007/s11207-019-1434-6

RANZATO, M., HUANG, F.J., BOUREAU, Y.L. and LECUN. Y., 2007. Unsupervised learning of invariant feature hierarchies with applications to object recognition. In: Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition; 1–8

SABZEHEE, F., FARZANEH, S., SHARIFI, M. A. and AKHOONDZADEH, M. 2018. TEC Regional Modeling and prediction using ANN method and single frequency receiver over IRAN. Annals of GeophysicsAnnals of Geophysics. https://doi.org/10.4401/ag-7297

SALAKHUTDINOV, R. and HINTON, G., 2009. Replicated softmax: An undirected topic model. In: Advances in Neural Information Processing Systems 22 - Proceedings of the 2009 Conference; 1607–1614

SALAKHUTDINOV, R., MNIH, A. and HINTON, G., 2007. Restricted Boltzmann machines for collaborative filtering. In: ACM International Conference Proceeding Series; 791–798

SCHAER, S., 1999. Mapping and predicting the Earth's ionosphere using the Global Positioning System. Dissertation of Doctoral Degree. Bern: Astronom Inst, Univ Bern,

SCHMIDT, M., BILITZA, D., SHUM, C. K. and ZEILHOFER, C. 2008. Regional 4-D modeling of the ionospheric electron density. Advances in Space Research. https://doi.org/10.1016/j.asr.2007.02.050

SER, G. ve BATI, C. T., 2019. Derin Sinir Ağları ile En İyi Modelin Belirlenmesi: Mantar Verileri Üzerine Keras Uygulaması. Yüzüncü Yıl Üniversitesi Tarım Bilimleri Dergisi; 406-417. 10.29133/yyutbd.505086.

SHEN, Y., HE, X., GAO, J., DENG, L. and MESNIL, G., 2014. Learning semantic representations using convolutional neural networks for web search; 373-374. 10.1145/2567948.2577348.

SOMPOTAN, A.F., PUSPITO, N.T., JOELIANTO, E. and HATTORI, K., 2015. Analysis of ionospheric precursor of earthquake using GIM-TEC, kriging and neural network. Asian Journal of Earth Sciences. https://doi.org/10.3923/ajes.2015.32.44

SONG, R., ZHANG, X., ZHOU, C., LIU, J. and HE, J., 2018. Predicting TEC in China based on the neural networks optimized by genetic algorithm. Advances in Space Research. https://doi.org/10.1016/j.asr.2018.03.043

SRIVANI, I., SIVA. and VENKATA R.D., 2019. A Deep Learning-Based Approach to Forecast Ionospheric Delays for GPS Signals. IEEE Geoscience and Remote Sensing Letters. https://doi.org/10.1109/LGRS.2019.2895112

SUN, W., XU, L., HUANG, X., ZHANG, W., YUAN, T., CHEN, Z. and YAN, Y., 2017. Forecasting of ionospheric vertical total electron content (TEC) using LSTM networks. Proceedings of 2017 International Conference on Machine Learning and Cybernetics, ICMLC 2017. https://doi.org/10.1109/ICMLC.2017.8108945

ŞEKER, A., DIRI, B. ve BALIK H.H., 2017. Derin Öğrenme Yöntemleri Ve Uygulamaları Hakkında Bir İnceleme. Gazi Mühendislik Bilim Dergisi 3; 47–64

ŞENTÜRK, E. ve ÇEPNI M.S., 2018. A statistical analysis of seismo-ionospheric TEC anomalies before 63 M w ≥ 5.0 earthquakes in Turkey during 2003–2016. Acta Geophys 66:1495–1507. doi: 10.1007/s11600-018- 0214-2

TAN, S.S., 2008. Development and thought of compass navigation satellite system. Yuhang Xuebao/Journal of Astronautics, 29; 391–396.

TAN, S., ZHOU, B., GUO, S. and LIU, Z., 2011. Research on COMPASS navigation signals of China. Zhongguo Kongjian Kexue Jishu/Chinese Space Science and Technology, 31; 9-14+29. https://doi.org/10.3780/j.issn.1000-758X.2011.04.002

TOSUNOĞLU, N. G. ve BENLI, Y.K., 2012. Morgan Stanley Capital International Türkiye Endeksinin Yapay Sinir Ağları ile Öngörüsü. Ege Akademik Bakış, Cilt 12, 4; 541-547.

TULUNAY, E., SENALP, E.T., CANDER, L.R., TULUNAY, Y.K., BILGE, A.H., MIZRAHI, E. and JAKOWSKI, N., 2004. Development of algorithms and software for forecasting, nowcasting and variability of TEC. Annals of Geophysics. https://doi.org/10.4401/ag-3294

TULUNAY, E., SENALP, E.T., RADICELLA, S.M. and TULUNAY, Y., 2006. Forecasting total electron content maps by neural network technique. Radio Science. https://doi.org/10.1029/2005RS003285

TÜZÜNTÜRK, S., SERT, E.F. and SEZEN, K., 2016. Yapay Sinir Aği Yöntemi İle Damacana Su Satiş Miktarlarinin Tahmini Estimation Of The Sales Amounts Of The Dispenser Size Water With Artificial Neural Network Method. Akademik Bakış, 56; 129-145.

ULUKAVAK, M., 2017. IGS İstasyon Noktalarının Sabitliğinin Araştırılması: TRAB IGS Noktası Örneği. Doktora Tezi, Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü. Trabzon, Türkiye.

VENKATA, R., VINDHYA, G. and DABBAKUTI, J. R. K. K., 2017. Ionospheric forecasting model using fuzzy logic-based gradient descent method. Geodesy and Geodynamics. https://doi.org/10.1016/j.geog.2017.05.003

WANG, W. and XU, Z., 2004. A heuristic training for support vector regression. Neurocomput. 61; 259–275. DOI:https://doi.org/10.1016/j.neucom.2003.11.012

WARNANT, R., 1997. Reliability of the TEC computed using GPS measurements - The problem of hardware biases. Acta Geod. Geoph. Hung. 32(3– 4); 451– 459

WATTHANASANGMECHAI, K., SUPNITHI, P., LERKVARANYU, S., TSUGAWA, T., NAGATSUMA, T. and MARUYAMA, T., 2012. TEC prediction with neural network for equatorial latitude station in Thailand. Earth, Planets and Space. https://doi.org/10.5047/eps.2011.05.025

XENOS, T. D., KOURIS, S. S. and CASIMIRO, A., 2003. Time-dependent prediction degredation assessment of neural-networks-based TEC forecasting models. Nonlinear Processes in Geophysics. https://doi.org/10.5194/npg-10-585-2003

XU, G., 2007. GPS: Theory, algorithms and applications. In GPS: Theory, Algorithms and Applications. https://doi.org/10.1007/978-3-540-72715-6

YAACOB, N., ABDULLAH, M. and ISMAIL, M., 2010. GPS Total Electron Content (TEC) Prediction at Ionosphere Layer over the Equatorial Region. In Trends in Telecommunications Technologies. https://doi.org/10.5772/8474

YADAV, S. and SUBRAMANIAN S., 2016. Detection of Application Layer DDoS attack by feature learning using Stacked AutoEncoder. In: 2016 International Conference on Computational Techniques in Information and Communication Technologies, ICCTICT 2016 – Proceedings; 361–366

YAZAN, E., ve TALU, M.F., 2017. Comparison of the stochastic gradient descent based optimization techniques. Artificial Intelligence and Data Processing Symposium (IDAP), International. IEEE,

ZHANG, Q., WANG, H., DONG, J., ZHONG, G. and SUN, X., 2017. Prediction of Sea Surface Temperature Using Long Short-Term Memory. IEEE Geoscience and Remote Sensing Letters. https://doi.org/10.1109/LGRS.2017.2733548