

**SİNİR AĞI MODELLEME YÖNTEMLERİ KULLANARAK TEİ
VERİLERİ İLE DURAĞAN VE DİNAMİK BÖLGESEL İYONOSFER
HARİTALARININ OLUŞTURULMASI**

**STATIC AND DYNAMIC REGIONAL IONOSPHERE MAPPING
WITH TEC DATA BY USING NEURAL NETWORK BASED
METHODS**

MELİKE GÜRÜN

Hacettepe Üniversitesi
Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğinin
ELEKTRİK ve ELEKTRONİK MÜHENDİSLİĞİ Anabilim Dalı İçin Öngördüğü
YÜKSEK LİSANS TEZİ
olarak hazırlanmıştır.

2007

Fen Bilimleri Enstitüsü Müdürlüğü'ne,

Bu çalışma jürimiz tarafından ELEKTRİK ve ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI'nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Başkan :
Prof. Dr.Orhan Arıkan

Üye :
Prof.Dr.Feza Arıkan

Üye (Danışman) :
Yrd. Doç. Dr. Atila Yılmaz

Üye :
Yrd. Doç. Dr. Ali Ziya Alkar

Üye :
Dr. Cenk Toker

ONAY

Bu tez/...../2007 tarihinde Enstitü Yönetim Kurulunca belirlenen yukarıdaki jüri üyeleri tarafından kabul edilmiştir.

...../...../2007

Prof.Dr. Erdem Yazgan
FEN BİLİMLERİ ENSTİTÜSÜ MÜDÜRÜ

SİNİR AĞI MODELLEME YÖNTEMLERİ KULLANARAK TEİ VERİLERİ İLE DURAĞAN VE DİNAMİK BÖLGESEL İYONOSFER HARİTALARININ OLUŞTURULMASI

MELİKE GÜRÜN

ÖZ

İyonosfer haritalama, atmosferin bu katmanını daha iyi anlamak ve radyo yayılımı uygulamalarındaki çeşitliliği geliştirmek için kullanılan önemli bir araçtır. İyonosfer yapısının kısa ve uzun dönemli değişimi, yapıdaki düzensizlikler ve bozulmalar, Toplam Elektron İçeriği (TEİ) incelenerek gözlemlenebilir. TEİ verileri, az sayıda ve çoğunlukla seyrek dağılmış olan Yerküresel Konumlama Sistemi istasyonlarından elde edilir. Bu nedenle pek çok uygulamada iyonosfer haritaları oluşturulurken, ölçüm alınamayan noktalar için bir aradeğerleme yöntemiyle TEİ kestirimine ihtiyaç duyulmaktadır. Yapay Sinir Ağları (YSA), belirli bir hata oranında doğrusal olmayan fonksiyona yakınsama yapabildiğinden bölgesel iyonosfer haritalama için güçlü bir alternatiftir. Bu çalışmada TEİ dağılımını modellemek için, Çok Katmanlı Perseptron (ÇKP) ve Yinelenebilir Ağ (YA) olmak üzere iki farklı YSA yöntemi kullanılmaktadır. ÇKP yapısı, geri yayılım algoritmasıyla doğrusal olmayan durağan süreçlerin modellenmesinde kullanılır. YA ise, iç geri beslemeler ile dinamik bir ağ yapısıdır ve Gerçek Zamanlı Yinelemeli Öğrenme (GZYÖ) algoritmasıyla TEİ verilerinin zaman içinde değişimini takip etmek amacı ile kullanılır. ÇKP'nin giriş değerleri istasyonların enlem ve boylam bilgileri, çıkış değeri ise TEİ verisidir. İlk olarak, ÇKP yapısında geri yayılım algoritması kullanılarak iki boyutlu benzetim yüzeyleri üzerinde çalışılmıştır. Benzetim yüzeyleri ile belirlenen YSA parametreleri kullanılarak, gerçek TEİ değerleri ile iyonosfer haritaları oluşturulmuştur. YA'nın giriş değerleri ise belirli bir zaman aralığındaki TEİ verileri, çıkış değeri ise ileri bir andaki TEİ verisidir. YA, durum değişkenleri ile modellenmiş, parametrelerinin performansına etkisi incelenmiş ve TEİ değerleri için öngöründe bulunulmuştur. ÇKP ve YA yapıları kullanılarak D-TEİ yöntemi ile elde edilen ve International Reference Ionosphere (IRI)'dan alınan TEİ verileri için iyonosfer haritaları oluşturulmuştur.

Anahtar Kelimeler: Yapay Sinir Ağları, iyonosfer haritası, Kriging, Geri Besleme Algoritması, Çok Katmanlı Perseptron, TEİ

Danışman: Yrd. Doç. Dr. Atila Yılmaz, Hacettepe Üniversitesi, Elektrik ve Elektronik Mühendisliği Bölümü

STATIC AND DYNAMIC REGIONAL IONOSPHERE MAPPING WITH TEC DATA BY USING NEURAL NETWORK BASED METHODS

MELİKE GÜRÜN

ABSTRACT

Ionospheric mapping is an important tool to understand better the ionosphere and to improve diversity of application in radio-propagation. Ionosphere structure's short term and long term alternation, confusion and corruption can be observed by analysing the Total Electron Content (TEC). Since TEC values can be estimated only for a limited and mostly sparsely distributed number of receiving stations, a suitable interpolation representing the nature of ionosphere is necessary. Neural Network (NN) provides an approximation for any non-linear function in predetermined error margin and becomes a powerful alternative for a certain regional ionosphere model. In this study, two types of NN, namely, multilayer perceptrons (MLP) and Recurrent Network (RN) with Real Time Recurrent Learning (RTRL) are implemented for modeling TEC distribution. MLP networks with backpropagation are extensively used for modeling non-linear processes in static manner. RN is a dynamic network with internal feedback and time variations can be included in network. The input parameters of the MLP are latitude and longitude information of stations, while the output parameter is TEC data. Firstly, the approximation capabilities of different MLP structures using backpropagation algorithm are studied on artificially produced different 2D surfaces. Parameters of MLP affecting the performance have been determined by using previously obtained simulation data. After choosing suitable network structures, real data obtained from GPS stations were used for regional ionosphere mapping by MLP networks. The input parameters of the RN with RTRL are measured TEC values in a definite time interval, the output parameter is the predicted TEC. MLP and RN structures are used for obtaining ionosphere map by using TEC data which are obtained by D-TEI method and supplied by International Reference Ionosphere (IRI).

Keywords: Neural Network, ionosphere mapping, Multilayer Perceptron, TEC

Advisor: Asst. Prof. Dr. Atila Yılmaz, Hacettepe University, Department of Electrical and Electronics Engineering

TEŞEKKÜR

Meleğim anneme,

Bana öğrenmenin güzelliğini keşfettiren, yaşamını bize adayarak yaşamımıza anlam katan babama,

Sabrı, inancı ve içimi ısıtan sevgisiyle bana güç verip, hayatlarımızın kesişmesine her daim şükredeceğim, can yoldaşım, hayat arkadaşım, nişanlım Akif'e,

Yaşama sevincim olan kardeşlerim Ali ve Meltem'e,

Duaları ile hep yanımda olan bana güçlüklerden yılmadan devam etmem gerektiğini, yaptıklarıyla öğreten biricik insan anneanneme,

Yaptıkları ile her daim örnek aldığım, güzel insan İrfan dayıma,

Varlıklarıyla, bilgileriyle, tecrübeleriyle bana bu uzun süreçte destek olan Selime, Işılta, Zeynep, Yasemin, Başak, Rengin ve Erinç'e,

Tez çalışması sırasında karşılaştığım sorunların çözümünde yardımcı olan ve çalışmamın sağlıklı bir şekilde yürütülmesi için yol gösteren tez danışmanım Yrd.Doç.Dr. Atila Yılmaz'a,

Bilgi ve tecrübesini hiç esirgemeyen Prof. Dr. Feza Arıkan'a,

Düşünce ve deneyimlerini paylaşan değerli Tez İzleme Komitesi üyelerine,

içtenlikle teşekkür ederim.

İÇİNDEKİLER DİZİNİ

	<u>Sayfa</u>
ÖZ	i
ABSTRACT	ii
TEŞEKKÜR	iii
İÇİNDEKİLER DİZİNİ	iv
ŞEKİLLER DİZİNİ	vi
ÇİZELGELER DİZİNİ	ix
SİMGELER VE KISALTMALAR DİZİNİ	x
1. GİRİŞ	1
2. İYONOSFERİN YAPISI VE YERKÜRESEL KONUMLAMA İŞARETLERİ İLE TEİ KESTİRİMİ	5
2.1. İyonosferin Yapısı	5
2.2. Yerküresel Konumlama Sistemi (YKS)	9
2.2.1. Yerküresel Konumlama Sistemi ile TEİ Kestirimi	10
2.2.2. Sözde Menzil Modeli	11
2.2.3. Faz Modeli	12
2.3. TEİ Haritalama Çalışmaları	14
2.4. TEİ Haritalama Yöntemleri	16
2.4.1. Küresel Harmonikler	16
2.4.2. İnce Katmanlı Spline Aradeğerleme	17
2.4.3. Multikuadrik Fonksiyon Modeli	18
2.4.4. Kriging Yöntemi	19
3. SİNİR AĞLARI TABANLI DOĞRUSAL OLMAYAN HARİTALAMA	22
3.1. Doğrusal Olmayan Sistem Modeli	22
3.2. Yapay Sinir Ağları	24
3.3. Durağan Yapay Sinir Ağları	27
3.3.1. Tek Katmanlı İleri Beslemeli Yapay Sinir Ağları	27
3.3.2. Çok Katmanlı İleri Beslemeli Ağlar	27

3.3.3. Geri Yayılım Algoritması	28
3.4. Dinamik Yapay Sinir Ağları	30
3.4.1. Yinelemeli Ağ Mimarisi	30
3.4.2. Durum-Uzay Modeli	31
3.4.3. Gerçek Zamanlı Yinelemeli Öğrenme Algoritması	32
4. ÇOK KATMANLI PERSEPTRON İLE DURAĞAN İYONOSFER HARİTALAMA ÇALIŞMALARI	35
4.1. Çok Katmanlı Perseptron Benzetimleri	36
4.1.1. Benzetim Yüzeylerinin Belirlenmesi	38
4.1.2. Benzetim Yüzeyleri ve Veri Setlerinin Oluşturulması	40
4.1.3. Saklı Katman Yapısı ve İşlem Birimi Sayısı	46
4.1.4. Çok Katmanlı Perseptron ve Kriging Yöntemlerinin Karşılaştırılması	58
4.2. Çok Katmanlı Perseptron Yöntemi ile İyonosfer Haritası	61
4.2.1. D-TEİ verileri ile İyonosfer Haritası	62
4.2.2. IRI Verileri ile İyonosfer Haritası	66
5. YİNELEMELİ AĞ İLE DİNAMİK İYONOSFER HARİTASI BENZETİMLERİ ..	69
5.1. YA ile Gerçek Veri Uygulamaları	69
5.1.1. YA Parametrelerinin Belirlenmesi	70
5.1.2. Öngörü Basamağı	72
5.2. Seçilen YA ile Elde Edilen TEİ Öngörüsü ve Haritalama	72
5.3. Seçilen YA ile Elde Edilen Statik Ağın Performans Analizi	75
6. SONUÇ	77
7. EKLER	79
7.1. EK 1: Benzetim Verileri ile YSA Test Sonuçları	79
KAYNAKLAR DİZİNİ	85
ÖZGEÇMİŞ	88

ŞEKİLLER DİZİNİ

	<u>Sayfa</u>
Şekil 2.1. İyonosferin yükseklik ile değişimi, (Skone, 1998)	6
Şekil 2.2. Sözde menzil zaman eşdeğeri	11
Şekil 3.1. Sistem yapısı	23
Şekil 3.2. Doğrusal olmayan sistem tanımlama	24
Şekil 3.3. İşlem birimi modeli	25
Şekil 3.4. Etkinlik fonksiyonları a)Eşik b)Parçalı doğrusal c)Sigmoid d)Hiperbolik tanjant	25
Şekil 3.5. ÇKP ve Geri yayılım algoritması	28
Şekil 3.6. Yinelemeli ağ yapısı ve model değişkenleri	32
Şekil 4.1. İyonosfer haritalama çalışmasında kullanılan ÇKP modeli	36
Şekil 4.2. 07.10.2004 günü saat 04:07:30 için polinom yüzeyi yaklaşımı	39
Şekil 4.3. 07.10.2004 günü saat 04:07:30 için polinom yüzeyi yaklaşım hatası	39
Şekil 4.4. 07.10.2004 günü saat 12:27:30 için polinom yüzeyi yaklaşımı	40
Şekil 4.5. 07.10.2004 günü saat 12:27:30 için polinom yüzeyi yaklaşım hatası	40
Şekil 4.6. Benzetim yüzeylerine eklenen gürültü örneği	42
Şekil 4.7. Benzetim yüzeyleri a) Düzlem, b) Üssel, c) İkinci dereceden polinom, d) Gauss dağılım fonksiyonu, e) Sombrero fonksiyonu, f) Üssel ve sinüsoidal fonksiyon çeşitlemesi	43
Şekil 4.8. Gürültülü benzetim yüzeyleri a) Düzlem, b) Üssel, c) İkinci dereceden polinom, d) Gauss dağılım fonksiyonu, e) Sombrero fonksiyonu, f) Üssel ve sinüsoidal fonksiyon çeşitlemesi	44
Şekil 4.9. Kare ızgara örnekleme a) Rasgele dağılım b) Homojen dağılım	45
Şekil 4.10. Altıgen ızgara örnekleme a) Veri hazırlama b) Veri dağılımı	45
Şekil 4.11. Poisson örnekleme a) Veri hazırlama b) Veri dağılımı	45
Şekil 4.12. Kitleme veri dağılımı örneği	46
Şekil 4.13. 2-5-3-1 ÇKP modeli ile F_6 ve F_5 benzetim yüzeyleri için veri sayısının hata oranına etkisi	50
Şekil 4.14. Homojen dağılımla elde edilmiş 44 veri ile ÇKP modelleri hata oranları değişimi	50

Şekil 4.15. Düzlem yüzey (F_1) a) Benzetim yüzeyi haritası b) 2-5-3-1 ÇKP modeli ile 44 veri için elde edilen harita ($\Delta = 1.04 \times 10^{-12}$)	52
Şekil 4.16. Üssel yüzey (F_2) a) Benzetim yüzeyi haritası b) 2-5-3-1 ÇKP modeli ile 44 veri için elde edilen harita ($\Delta = 6.33 \times 10^{-8}$)	52
Şekil 4.17. Polinom yüzey (F_3) a) Benzetim yüzeyi haritası b) 2-5-3-1 ÇKP modeli ile 44 veri için elde edilen harita ($\Delta = 1.44 \times 10^{-4}$)	53
Şekil 4.18. Gauss yüzey (F_4) a) Benzetim yüzeyi haritası b) 2-5-3-1 ÇKP modeli ile 44 veri için elde edilen harita ($\Delta = 1.1 \times 10^{-3}$)	53
Şekil 4.19. Sombrero yüzey (F_5) a) Benzetim yüzeyi haritası b) 2-5-3-1 ÇKP modeli ile 44 veri için elde edilen harita ($\Delta = 1.8 \times 10^{-2}$)	54
Şekil 4.20. Üssel ve sinüsoidal yüzey (F_6) a) Benzetim yüzeyi haritası b) 2-5-3-1 ÇKP modeli ile 44 veri için elde edilen harita ($\Delta = 4.6 \times 10^{-2}$)	54
Şekil 4.21. Sombrero benzetim yüzeyi için 2-5-3-1 ÇKP modeli ve 85 veri ile elde edilen harita ($\Delta = 1.2 \times 10^{-4}$)	55
Şekil 4.22. Üssel ve sinüsoidal yüzey için 2-20-10-1 ÇKP modeli ve 104 veri ile elde edilen harita ($\Delta = 1.7 \times 10^{-3}$)	55
Şekil 4.23. Polinom benzetim yüzeyi ve kullanılan 44 ketleme örnekleme	56
Şekil 4.24. Polinom benzetim yüzeyi için 44 ketleme örnek ile elde edilmiş 2-5-3-1 ÇKP modeli haritası ($\Delta = 3.2 \times 10^{-4}$)	56
Şekil 4.25. Gauss benzetim yüzeyi ve kullanılan 19 poisson kümeleme örnekleme	57
Şekil 4.26. Gauss benzetim yüzeyi için 19 poisson kümeleme örnek ile elde edilmiş 2-5-3-1 ÇKP modeli haritası ($\Delta = 1.3 \times 10^{-2}$)	57
Şekil 4.27. Üssel benzetim yüzeyi ve kullanılan 15 altıgen örnekleme	58
Şekil 4.28. Üssel benzetim yüzeyi için 15 altıgen örnekleme ile elde edilmiş 2-5-3-1 ÇKP modeli haritası ($\Delta = 1.1 \times 10^{-1}$)	58
Şekil 4.29. 7 Ekim 2004 YKS istasyonları aradeğerleme çalışması	63
Şekil 4.30. 7 Ekim 2004, saat 00:00, 9 veri ile 2-5-3-1 ÇKP modeli kullanılarak elde edilmiş iyonosfer haritası	63
Şekil 4.31. 7 Ekim 2004, saat 06:00, 9 veri ile 2-5-3-1 ÇKP modeli kullanılarak elde edilmiş iyonosfer haritası	64
Şekil 4.32. 7 Ekim 2004, saat 12:00, 9 veri ile 2-5-3-1 ÇKP modeli kullanılarak elde edilmiş iyonosfer haritası	64

Şekil 4.33. 7 Ekim 2004, saat 18:00, 9 veri ile 2-5-3-1 ÇKP modeli kullanılarak elde edilmiş iyonofler haritası	65
Şekil 4.34. 7 Ekim 2004, saat 23:00, 9 veri ile 2-5-3-1 ÇKP modeli kullanılarak elde edilmiş iyonofler haritası	65
Şekil 4.35. 7 Ekim 2004 YKS istasyonları dışdeğerleme çalışması	66
Şekil 4.36. 7 Ekim 2004 saat 00:00 a) IRI haritası b)2-5-3-1 YSA modeli 15 rastgele veri ile elde edilmiş TEİ haritası	68
Şekil 5.1. GZYÖ şematik gösterimi	69
Şekil 5.2. Brus istasyonu için 7-11 Ekim 2004 tarihleri arasında elde edilen veriler ile $ws = 24$, $q = 15$ ve $lr = 1.5$ değişkenleri için a) YA Sonuclari ve Gercek Veriler b) YA Hata Degisimi	71
Şekil 5.3. Öngörü basamağındaki değişim için YA hata kare toplamı (sse)	72
Şekil 5.4. YA ile öngörüde bulunulan YKS istasyonlarının 2-5-3-1 ÇKP modeli ile birlikte kullanımı	74
Şekil 5.5. YKS istasyonlarından elde edilen gerçek veriler kullanılarak 2-5-3-1 ÇKP modeli ile oluşturulmuş iyonofler haritası	74
Şekil 5.6. YKS istasyonları için YA ile öngörülen veriler kullanılarak 2-5-3-1 ÇKP modeli ile oluşturulmuş iyonofler haritası	75
Şekil 5.7. Brus istasyonu için 7-26 Ekim 2004 tarihleri arasında 400 veri ile a) YA sonuçları b)Hata değerleri	75
Şekil 5.8. Brus istasyonu için 7-26 Ekim 2004 tarihleri arasında 300 eğitim verisinin 10 çevrimle eğitilmesi , 100 test verisi sonuçları a) YA sonuçları b) Hata değerleri	76

ÇİZELGELER DİZİNİ

	<u>Sayfa</u>
Çizelge 4.1. ÇKP ile yapılan çalışmalarda kullanılan YKS istasyonları	39
Çizelge 4.2. ÇKP ile 9, 24 ve 44 kare ızgara homojen dağılım ile elde edilmiş veri ile haritalama benzetim sonuçları	48
Çizelge 4.3. ÇKP ile 9, 24 ve 44 kare ızgara rasgele dağılım ile elde edilmiş veri ile haritalama benzetim sonuçları	49
Çizelge 4.4. Kare ızgara homojen dağılımla elde edilen 15, 24 ve 44 veri için M_7 (2-5-3-1) ÇKP modeli hata oranları	51
Çizelge 4.5. Kriging yöntemi kullanarak kare ızgara homojen dağılım haritalama benzetim sonuçları	59
Çizelge 4.6. Kriging yöntemi kullanarak kare ızgara rasgele dağılım haritalama benzetim sonuçları	60
Çizelge 4.7. 2-5-3-1 YSA modeli kullanılarak D-TEİ yöntemi ile elde edilen veriler için iyonosfer haritası hata değerleri	62
Çizelge 4.8. 2-5-3-1 YSA modeli kullanılarak D-TEİ yöntemi ile elde edilen veriler için iyonosfer haritası hata değerleri	66
Çizelge 4.9. IRI verileri ile elde edilen YSA haritaları bağıl hata değerleri (07.10.2004 saat 00:00)	67
Çizelge 5.1. Pencere ve işlem birimi değerlerine göre YA performansının değişimi	71
Çizelge 5.2. YA ile yapılan çalışmalarda kullanılan YKS istasyonları ve herbir istasyon için YA ile elde edilen öngörü hatası	73
Çizelge 5.3. YA ve ÇKP birlikte kullanılarak elde edilen iyonosfer haritasının hata değerleri	74
Çizelge 7.1. Poisson küme örnekleme modeli	79
Çizelge 7.2. Altıgen ızgara örnekleme modeli	80
Çizelge 7.3. Ktleme örnekleme modeli	81
Çizelge 7.4. Gürültülü yüzeylerde homojon kare ızgara örnekleme modeli	82
Çizelge 7.5. Gürültülü yüzeylerde altıgen ızgara örnekleme modeli	83
Çizelge 7.6. Gürültülü yüzeylerde ktleme örnekleme modeli	84
Çizelge 7.7. Gürültülü yüzeylerde Poisson küme örnekleme modeli	84

SİMGELER VE KISALTMALAR DİZİNİ

ÇKP	: Çok Katlı Perseptron
D-TEİ	: Düzgünleştirilmiş Toplam Elektron İçeriği
GZYÖ	: Gerçek Zamanlı Yinelemeli Öğrenme
sse	: Hata Kare Toplamı
TEİ	: Toplam Elektron İçeriği
YKS	: Yerküresel Konumlama Sistemi
YSA	: Yapay Sinir Ağları
YA	: Yinelemeli Ağ
BPTT	: Backpropagation Through Time
CACS	: Canadian Association for Curriculum Studies
CORS	: Continuously Operating Reference Stations
GRNN	: General Regression Neural Network
GPS	: Global Positioning System
GIM	: Global Ionosphere Map
IRI	: International Reference Ionosphere
IGS	: International GPS Service for Geodynamics
IONEX	: Ionosphere Map Exchange Format
MLP	: Multilayer Perceptron
NN	: Neural Network
NARX	: Nonlinear Autoregressive
RBF	: Radial Basis Function
RTRL	: Real Time Recurrent Learning
RN	: Recurrent Network
STEC	: Slant Ray Total Electron Content
TEC	: Total Electron Content
UPC	: Polytechnical University of Catalonia
VTEC	: Vertical Total Electron Content

SÖZLÜK DİZİNİ

aradeğerleme	: interpolation
aşırı öğrenme	: overfitting
az öğrenme	: underfitting
bağıl hata	: relative error
benzetim	: simulation
çevrim	: epoch
Çok Katmanlı Perseptron	: Multilayer Perceptron
çokyolluluk	: multipath
dayanak	: reference
delme noktası	: pierce point
denetimli	: supervised
denetimsiz	: unsupervised
dışdeğerleme	: extrapolation
diferansiyel	: differential
dinamik	: dynamic
doğrusal	: linear
durağan	: static
durum uzay	: state space
eğitim verisi	: training data
en küçük kareler	: least squares
etkinlik fonksiyonu	: activation function
Evrensel Fonksiyon Yakınsayıcı	: Universal Function Approximators
fonksiyon	: function
fonksiyon yaklaşımı	: function approximation
Genel Bağlanımlı Sinir Ağları	: General Regression Neural Network
Gerçek Zamanlı Yinelemeli Öğrenme	: Real Time Recurrent Network
Geri Yayılım Algoritması	: Backpropagation
geribesleme	: feedback
giriş	: input
gürbüz	: robust
gürültü	: noise
hata düzeltme	: error correction

hata kare toplamı	: sum square error
ızgara	: grid
ileri beslemeli	: feedforward
işlem birimi	: neuron
kestirme	: estimation
ketleme	: inhibited
küresel harmonik	: spherical harmonic
morötesi	: Ultra viole
mutlak	: absolute
öğrenme oranı	: learning rate
öngörü	: prediction
Yinelemeli Sinir Ağı	: Recurrent Neural Network
pekiştirmeli	: reinforcement
pozitif gerçek	: positive real
Radyal Taban Fonksiyonu	: Radial Basis Function
rasgele	: random
rekabetçi	: competitive
saçılma	: dispersion
sağlama verisi	: validation data
saklı katman	: hidden layer
sınıflandırıcı	: classifier
sözde menzıl	: pseudorange
stokastik	: stochastic
tepki	: response
Toplam Elektron İçeriği	: Total Electron Content
yaklaşım kuramı	: approximation theory
yanlılık	: bias
Yapay Sinir Ağları	: Neural Network
yapı tanımlayıcı	: pattern recognition engine
Yerküresel Konumlama Sistemi	: Global Positioning System
yineli	: recursive
zamanda geri yayılım	: backpropagation through time

1. GİRİŞ

İyonosfer sözcüğü literatüre 1926 yılında İngiliz radyo araştırmalarında kullanılmak üzere Sir Robert Watson-Watt tarafından kazandırılmıştır. İyonosfer daha önce Kennelly-Heaviside katmanı, üst iletken katman, iyonize olmuş üst atmosfer gibi ifadelerle isimlendirilmiştir (Komjathy, 1997).

İyonosfer yeryüzünden yaklaşık 60 km ile 1100 km arasındaki yükseklikte yer alan bir atmosfer tabakasıdır (Nayir, 2007). İyonosferin, radyo dalgalarının yayılımında, uydu ve yer istasyonu arasındaki radyo link bağlantılarında, haberleşme, güdüm ve gözetleme radarlarında büyük bir önemi vardır. İyonosfer fırtınası gibi hava olayları, kısa dalga haberleşme sistemlerinde ve uydu haberleşmelerinde kesintiye neden olmaktadır. İyonosferin bu gibi etkilerinin tam olarak anlaşılabilmesi ve haberleşme sistemlerinde yol açtığı hata değerlerinin belirlenebilmesi için iyonosferdeki değişimlerin takip edilmesi gerekmektedir. İyonosfer haritalama çalışmaları bu amaçla yapılmaktadır. Haritalama çalışmalarında iyonosfer, en büyük elektron yoğunluğunun olduğu yükseklikte bulunan ve elektronların tümünü içeren ince bir küresel kabuk olarak düşünülür (Liao, 2000).

Literatürde iyonosfer üzerine detaylı çalışmalar yapılmış ve başlıca özellikleri belirlenmeye çalışılmıştır. İyonosfer, nötr moleküllerin, güneş ışınlarından dolayı iyonlaşmasıyla oluşan serbest elektronlar içerir. İyonosferin elektromanyetik dalgalar üzerindeki gecikme etkisi, elektron yoğunluğuna bağlıdır. İyonosferdeki serbest elektronların yoğunluğu, coğrafi ve jeomanyetik konumun, güneş ışınımının, jeomanyetik aktivitenin, mevsimin ve günün saatinin bir fonksiyonudur (Komjathy, 1997). Güneş ışınimleri geceleri azalmakta gündüzleri artmaktadır, bu nedenle iyonosferdeki elektron yoğunluğu yerel saate göre 14:00'da en yüksek seviyeye ulaşmaktadır. Dünyanın güneş etrafında dönmesi ile güneşin ışıma açısı değişmektedir, bu değişim iyonosferde mevsimsel değişime neden olmaktadır. Güneş lekesi adı verilen 11 yıllık güneş çevrimi iyonosferi etkileyen bir diğer parametredir (Liao, 2000).

Roket teknolojisinin 1950'li yıllarda gelişmesi ile ölçüm roketleri kullanarak ilk iyonosfer gözlemleri yapılmıştır (Kaplan, 1996). Yer tabanlı teknikler arasında İyonosonda, Geri Saçılım Radarı ve evre uyumsuz Geri Saçılım Radarı sayılabilir. Bu tekniklerin ortak özelliği iyonosfere radyo dalgaları göndererek inceleme yapılmasıdır. Uydulardan gönderilen işaretlerden de yararlanılmaktadır. Bu uydu sistemlerinden başlı-

caları Yerküresel Konumlama Sistemi (YKS), GLONASS ve TOPEX/Poseidon sistemleridir (Nayir, 2007). Bu çalışmada YYS verileri kullanılarak iyonosferin yapısı incelenecektir.

YKS düzenli olarak kodlanmış bilgi yollayan ve bu sayede uydularla alıcı arasındaki mesafeyi ölçerek dünya üzerinde alıcının bulunduğu noktayı tespit etmek amacıyla kullanılan bir uydu ağıdır. Alıcı ile uydu arasındaki mesafe, geometrik uzaklıktan farklı olarak, işaretin uydudan gönderilme zamanı ile alıcıya ulaşma zamanı arasında geçen süreye bağlı olarak hesaplanan menzildir. YYS verileri kullanılarak hesaplanan bu mesafe iyonosfer, troposfer, alıcı ve uydu yansımaları gibi gecikmelerden de etkilendiği için sözde menzildir. İyonosfer boyunca seyahat eden bir elektromanyetik sinyal iki biçimde etkilenir. Faz hızı artarken grup hızı yavaşlar. Her iki etki de büyüklük olarak aynı fakat ters işaretlidir. Diğer bir deyişle YYS kod ölçmeleri gecikir; taşıyıcı faz ölçmeleri ise hızlanır. Bu yüzden uydu ile alıcı arasındaki geometrik uzunluğa kıyasla sözde menzildir daha uzun, taşıyıcı faz daha kısa ölçülür. YYS yayılım gecikmesi, iyonosfer karakteristiği bilindiğinde daha doğru ve güvenilir olarak hesaplanabilir.

İyonosfer yapısının kısa ve uzun dönemli değişimi, yapıdaki düzensizlikler ve bozulmalar, Toplam Elektron İçeriği (TEİ) incelenerek gözlemlenmektedir. TEİ 1m^2 kesitli bir silindir boyunca toplam serbest elektron miktarıdır. Birimi TECU ile ifade edilir ($1\text{TECU} = 10^{16}\text{el/m}^2$). Düzgünleştirilmiş TEİ Kestirim Yöntemi (D-TEİ) kullanılarak (Nayir, 2007), IGS analiz merkezlerinden (Ionex, 1998) ve International Reference of Ionosphere (IRI)'dan (IRI, 2001) TEİ verileri elde edilebilmektedir. Bu çalışmada D-TEİ yöntemi ile elde edilen veriler (Nayir, 2007) ve IRI'nın TEİ verileri kullanılmıştır.

YKS kullanılarak elde edilen TEİ verileri ile bölgesel iyonosfer haritaları oluşturulabilir. Literatürde çeşitli aradeğerleme yöntemleriyle gözlem yapılamayan yerler için TEİ kestirimi yapılarak, küresel ve yerel iyonosfer haritaları oluşturulmuştur. TEİ haritalama çalışmalarında kullanılan yöntemlerden biri de Yapay Sinir Ağları (YSA)'dır (McKinnel, 2004). YSA yöntemi, doğrusal olmayan fonksiyonları modelleyebilme özelliğinden dolayı, doğrusal olmayan ve her doğa olayı gibi rasgele özellikler taşıyan iyonosferin modellenmesi için uygundur. Haritalama yaparken YSA kullanmanın bir diğer avantajı ise doğrusal olmayan yapı hakkında herhangi bir bağıntının bilinmesine gerek olmadan giriş çıkış veri setini oluşturmanın yeterli ol-

masıdır. YSA modeli, veri seti ile doğrusal olmayan modeli öğrenme işlemini gerçekleştirmektedir. YSA'nın kullanılabilir sonuçlar vermesi için, amaca uygun olarak tasarlanması, hücreler arasındaki bağlantıların doğru yapılması ve bağlantıların uygun ağırlıklara sahip olması gerekmektedir. Bilgiyi işlemede kullanılan deneyim YSA içerisinde öğrenme işlemiyle kazanılır. YSA, istenen davranışı gösterecek şekilde eğitim örneklerini kullanarak modeli öğrenmelidir. Öğrenme algoritmaları sayesinde, bu yapı genelleme yapabilmekte, sisteme ait olası yeni verilere anlamlı sonuçlar yükleyebilmektedir.

TEİ haritaları belirli bir an için oluşturulabileceği gibi, geçmiş ölçümler kullanılarak da oluşturulabilir. Durağan ağlar doğrusal olmayan yapısı ve durağan hafıza özelliği ile anlık haritalama çalışmalarında, dinamik ağlar ise geçmiş verilerin zaman değişkeninin, geçici hafıza kullanılarak işlenebildiği modellerle oluşturulacağı haritalama çalışmalarında kullanılmaktadır. Durağan ağlarda işlem birimleri arasındaki bağlantılar bir döngü oluşturmazlar. Bu ağlar girdiye hızlı bir şekilde karşılık üretirler. Dinamik yapıdaki ağlar, işlem birimlerinin çıkışını hesaplamaya girmesi için önceki işlem birimlerinin girişine geri besleyen bağlantılar içeren ağlardır.

Durağan bir YSA modeli olan Çok Katmanlı Perseptron (ÇKP) yapıları kullanılarak belirli bir andaki TEİ haritaları oluşturulabilir (Leandro, 2004). Bu çalışmada kullanılan ÇKP modelinin giriş değerlerini enlem ve boylam verileri, çıkış değerlerini ise TEİ verisi oluşturmaktadır. Ölçüm noktalarından elde edilen veriler kullanılarak YSA modeli eğitilmektedir. YSA modeli, enlem ve boylam verileri için iki işlem birimli giriş katmanından, bir veya iki saklı katmandan ve TEİ değeri için bir işlem birimli çıkış katmanından oluşmaktadır. YSA modelini oluştururken giriş değerleri dağılımı (eğitim, sağlama ve test verisi oranlaması), saklı katman işlem birimi sayısı, kullanılan etkinlik fonksiyonu, öğrenme sabiti, momentum sabiti gibi sistem parametrelerinin belirlenmesi gerekmektedir. YKS istasyonlarının sayısı belirli bir bölge için kısıtlı olduğundan, oluşturulan iyonosfer haritalarının başarımının kontrolü zorlaşmaktadır. Bu nedenle ilk aşamada, YSA modelinin parametrelerini belirleyen etmenleri ve sonuç başarımına etkisini gözlemlemek için gerçek veriler yerine benzetim verileri kullanılmıştır. YKS istasyonlarından elde edilen TEİ verileri karakteristiği incelenerek hazırlanan benzetim yüzeyleri, YSA parametrelerinin değişiminin haritalama başarımına etkisi hakkında bilgi vermektedir. YKS istasyonlarından elde edilen gerçek TEİ verileri, benzetim yüzeyleri kullanılarak belirlenmiş en uygun YSA

parametreleri ile iyonosfer haritasının oluşturulmasında kullanılacaktır.

İyonosfer değişimini zaman boyutunda inceleyebilmek için dinamik YSA yapılarına ihtiyaç duyulmaktadır. Dinamik YSA yapısı olan yinelemeli ağlar, ÇKP gibi yapılara değişik formlarda geri besleme yapıları eklenmesi ile elde edilir. Gerçek zamanlı yinelemeli öğrenme (GZYÖ) algoritması kullanılarak YKS istasyonlarından belirli bir periyotta alınan TEİ ölçümleri ile YSA eğitilecek ve böylelikle oluşturulacak TEİ haritalarına geçmiş TEİ bilgisi eklenecektir.

ÇKP ve yinelemeli ağlar kullanılarak yapılan bu çalışma iyonosferin karakteristiğini ifade eden TEİ verilerinin, bölgesel ve zamansal değişimi hakkında bilgi vermektedir. İyonosfer haritalama çalışmalarında YSA yönteminin başarımı hakkında bilgi sahibi olunmuş ve literatürde ÇKP ile yapılan iyonosfer haritalama ve öngörü çalışmalarına YA'da eklenerek yeni bir bakış açısı kazanılmıştır.

Bölüm 2'de iyonosfer modeli anlatılmış, YKS gözlem parametreleri ile TEİ hesaplaması yapılmıştır. Literatürdeki TEİ haritalama çalışmaları açıklanmış ve kullanılan yöntemler ana hatları ile anlatılmıştır. Bölüm 3'de TEİ haritalamada kullanılan YSA uygulamalarından ÇKP ve YA incelenmiştir. Bölüm 4'de oluşturulan benzetim yüzeyleri kullanılarak ÇKP parametrelerinin sonuç başarımına etkisi değişen veri dağılımları ve YSA modelleri için incelenmiştir. İşlem birimi sayısı, öğrenme oranı, kayan pencere büyüklüğünün GZYÖ algoritması performansına etkisi zamanla değişen TEİ verileri kullanılarak incelenmiştir. Bölüm 5'de belirlenen parametreler kullanılarak ÇKP ile bölgesel iyonosfer haritaları oluşturulmuş ve YA ile TEİ verileri için bir saatlik öngöründe bulunulmuştur. Bölüm 6'da tez çalışması kapsamında elde edilen sonuçlar özetlenmiştir.


2. İYONOSFERİN YAPISI VE YERKÜRESEL KONUMLAMA İŞARETLERİ İLE TEİ KESTİRİMİ

İyonosfer elektromanyetik dalgaların yayılımında önemli bir rol oynar. Bu nedenle haberleşme sistemleri üzerinde etkilidir (Cheng, 1995). İyonosfer tabakası radyo sinyalleri için yansıtıcı; uzun mesafe telsiz, askeri ve uydu haberleşme sistemlerinde ise ayırgan ortam özelliği göstermektedir. Bu nedenle iyonosferin yapısını anlamaya ve iyonosferdeki değişimleri takip etmeye yönelik çalışmalar son yıllarda önem kazanmıştır. YKS verileri kullanılarak iyonosferin Toplam Elektron İçeriğinin (TEİ) kestirimi yapılabilmektedir. TEİ, iyonosferin yapısı hakkında bilgi veren önemli bir parametredir (Hartman, 1984). Bu çalışmada YKS verileri kullanılarak iyonosferin yapısı incelenecektir.

2.1 İyonosferin Yapısı

İyonosfer, atmosferin üst kısmında güneş ışınları ile iyonize olmuş gazlardan oluşan tabakadır. Bu tabakanın yüksekliği 60 km ile 1100 km arasındadır (Arıkan et al, 2003). İyonosferin herhangi bir noktasındaki elektron yoğunluğunu, güneş ışınları ve dünyanın manyetik alanı etkilemektedir. İyonizasyona sebep olan ve güneşten kaynaklanan morötesi ışınlarının yayılımının sabit olmaması ve dünyanın kendi çevresindeki dönüş hareketi nedeniyle elektron yoğunluğu değişmektedir. Bunun sonucunda ekvator bölgesinde en büyük elektron yoğunluğuna sahip olan ve kutuplara doğru gittikçe azalan, güneşi iki - üç saat gecikmeli olarak takip eden günlük elektron yoğunluğu dağılımı oluşur. Kabaca bu şekilde oluşan elektron yoğunluğu dağılımını kestirmek oldukça zordur (Liao, 2000). İyonosferdeki elektron yoğunluğunu etkileyen diğer bir faktör yüksekliktir. Şekil 2.1'de elektron yoğunluğunun yüksekliğe göre değişimi verilmektedir (Skone, 1998). İyonosferin içerdiği atom ve moleküllerin çeşitleri yükseklikle değiştiği ve bunların ışınları soğurma oranları farklı olduğu için iyonosfer D, E, F1 ve F2 gibi katmanlara ayrılmıştır.

Elektron yoğunluğu Şekil 2.1'de verildiği gibi F2 katmanında en büyüktür. Diğer katmanlara inildikçe veya F2 katmanından daha yükseklerde çıkıldıkça elektron yoğunluğu azalır. İyonosferdeki elektron yoğunluğu güneşteki hareketlilikten ve jeomanyetik alandaki değişimlerden etkilenir. Yüksek enlemler, orta enlemler ve ekvatora yakın enlemlerde farklı özellikler gösterir. Orta enlemlerdeki iyonosfer özellikleri diğer bölgelere göre daha sakin ve daha az değişkendir. İyonosferin büyük bir kıs-



Şekil 2.1. İyonosferin yükseklik ile değişimi, (Skone, 1998)

minı oluşturan nötr gazlar güneşten gelen ışınlar ile iyonlaşarak iyonosferik plazmayı oluşturur. Eşit elektron ve iyon yoğunluklarında iyonize olmuş gazlara plazma denir (Cheng, 1995).

$$\omega_{N_e} = 2\pi \sqrt{\frac{N_e e^2}{m \epsilon_0}} \quad (2.1)$$

Eş. 2.1'de ω_{N_e} elektron plazma açısal hızını (rad/s), N_e elektron yoğunluğunu (el/m^3), e elektron yükünü ($-1.602 \times 10^{-19} \text{ C}$), ϵ_0 serbest uzaydaki dielektrik sabitini (8.854×10^{-12}), m elektron kütlesini ($9.107 \times 10^{-31} \text{ kg}$) göstermektedir. f_{N_e} plazma frekansı ise Eş. 2.2'de verilmiştir.

$$f_{N_e} = \frac{\omega_{N_e}}{2\pi} = \sqrt{\frac{N_e e^2}{m \epsilon_0}} \quad (2.2)$$

İyonosferin eşdeğer dielektrik değeri (F/m), Eş. 2.3'te verilmiştir (Cheng, 1995).

$$\epsilon_{N_e} = \epsilon_0 \left(1 - \frac{f_{N_e}^2}{f^2}\right) \quad (2.3)$$

Burada f radyo dalgasının frekansını vermektedir. Eş. 2.3 kullanılarak elde edilen yayılma sabiti ve gerçek empedans değeri sırasıyla Eş. 2.4 ve 2.5'de verilmiştir.

$$\gamma_{N_e} = j\omega \sqrt{\mu \epsilon_{N_e} \epsilon_0} \sqrt{\left(1 - \frac{f_{N_e}^2}{f^2}\right)} \quad (2.4)$$

$$\eta_{N_e} = \frac{\eta_0}{\sqrt{1 - \frac{f_{N_e}^2}{f^2}}} \quad (2.5)$$

γ_{N_e} yayılma sabiti, η_{N_e} gerçık empedans, $\eta_0 = \sqrt{\frac{\mu_0}{\epsilon_0}} = 120\pi(\Omega)$ boşluğun empedansını, μ ortam geçirgenliğini temsil etmektedir.

Radyo dalgalarının frekansı, plazma frekansına yaklaştıkça ortamın dielektriği sıfıra eşitlenmektedir. Radyo dalgasının frekansı, plazma frekansından küçük olduğunda, yayılma sabiti tamamen gerçık olacaktır. Bu durum sinyalde zayıflama olacağını ve yayılmanın azalacağını gösterir. Aynı zamanda gerçık empedansın tamamen sanal olması reaktif yüklerin gücü geçirmediğini göstermektedir. Radyo dalgasının frekansı, plazma frekansından büyük olduğunda, yayılma sabiti tamamen sanal olacaktır ve elektromanyetik dalgalar zayıflatılmadan plazma ortamında dağılabilecektir (Cheng, 1995). Radyo dalgaları için kesim frekansı olan f_{N_e} değerine bu nedenle kritik frekans denilmektedir.

İyonosferin plazma özelliğinden dolayı 30 MHz ve 50 MHz aralığında frekanslardaki dalgaları geçirmektedir. 30 MHz frekansının altındaki dalgaları yansıtırken 50 MHz'in çok üstündekilerde zayıflama ve gecikme etkisine yol açmaktadır. Plazma frekansı f_{N_e} 30 MHz'i geçmemektedir (Nayir, 2007).

Kırılma indisini kullanarak radyo sinyallerinin bir ortam içinde davranışı incelenebilmektedir. Ortamın kırılma indisi, sinyalin ortamdaki hızı ile boşluktaki hızının oranıdır (Moon, 2004). Kırılma indisi iyonosferi karakterize eden en önemli parametrelerden biridir.

$$n = \frac{c}{v} \quad (2.6)$$

Eş. 2.6' da, c radyo dalgasının boşluktaki hızı, v dalganın ortamdaki hızı, n ise ortamın kırılma indisidir. İyonosferin kırılma indisi Appleton-Hartree formülüne göre Eş. 2.7' deki gibi yazılabilir (Nayir, 2007).

$$n_p^2 = 1 - \frac{X}{1 - iZ - \frac{Y_T^2}{2(1-X-iZ)} \pm [\frac{Y_T^4}{4(1-X-iZ)^2} + Y_L^2]^{\frac{1}{2}}} \quad (2.7)$$

Eş. 2.7'de

$$X = N_e e^2 / \varepsilon_0 m \omega^2 = f_{N_e}^2 / f^2$$

$$Y_L = e B \sin \theta / m \omega = f_H \cos \theta / f$$

$$Y_T = e B \sin \theta / m \omega = f_H \sin \theta / f$$

$$Z = f_v / f$$

$$\omega = 2\pi f$$

B dünyanın manyetik alanının akı yoğunluğu (Tesla), θ gelen dalganın ilerleme yönü ile manyetik alan arasındaki açıyı, f_v elektronun büyük parçacıklarla çarpışma hızını, f_H elektron dönme frekansını temsil etmektedir. Elektron dönme frekansı tipik olarak 1.5 MHz'dir. Çarpışma frekansı f_v ise yaklaşık 10^4 Hz civarındadır (Nayir, 2007). Grup ve faz kırılma indislerinin integrali alındığında YKS işaretlerinin takip ettiği ışın yolu boyunca uydu ve alıcı arasındaki menzil hesaplanabilir. Bu değer gerçek geometrik menzilden iyonosferik hata oranınca farklılık gösterir. İyonosferdeki elektron yoğunluğunun değişimi YKS işaretlerinde farklı gecikmelere sebep olur. YKS faz verileri için ölçülen menzil değeri geometrik menzilden daha kısa, sözde menzil değeri için bu ölçülen değer geometrik menzilden daha uzundur. Bu bilgiler kullanılarak elde edilen faz kırılma indisi:

$$n_p = 1 - (X/2) \quad (2.8)$$

Grup kırılma indisi:

$$n_g = 1 + (X/2) \quad (2.9)$$

$$\frac{X}{2} = \frac{A}{f^2} N_e \quad (2.10)$$

olarak tanımlanabilir (Liao, 2000).

Eş. 2.10, Eş. 2.8 ve Eş. 2.9'da kullanılan X değeri verilmiştir. A değeri sabit olup $40.28 \text{ m}^3/\text{s}^2$ değerine eşittir.

İyonosferin plazma yapısından anlaşılacağı gibi, iyonosfer radyo dalgaları için ayırıcı bir ortamdır. Elektromanyetik dalgaların iyonosfer tabakasını geçebileceği en az frekansa kritik frekans veya plazma frekansı (f_oF2) denir. Plazma frekansı iyonosferdeki elektron yoğunluğuna (N_e) bağlıdır ($N_e = 1.24 \times 10^4 f_oF2$). İyonosferin kırılma indisi elektron yoğunluğunun ve frekansın bir fonksiyonudur. İyonosferden geçen elektromanyetik dalgalar frekanslarına ve iyonosferdeki elektron yoğunluğuna bağlı olarak değişik derecelerde kırılacaklardır. Bu da elektromanyetik dalgaların zamanda gecikmelerine neden olur.

İyonosferin plazma yapısının kırılma indisi radyo dalgalarının frekansının, elektron yoğunluğunun ve dünyanın manyetik alanının bir fonksiyonudur. Birinci dereceden iyi bir yaklaşımda iyonosferik hata elektron yoğunluğunun ışın yolu boyunca integralinin alınması ile elde edilen TEI değeri ile orantılıdır. Aynı zamanda taşıyıcı faz frekansının karesi ile ters orantılıdır (Komjathy, 1997). YKS gözlem parametreleri TEI kestiriminde kullanılmaktadır. YKS işaretlerinin özellikleri ve TEI kestirimi sonraki bölümde incelenmiştir.

2.2 Yerküresel Konumlama Sistemi (YKS)

YKS düzenli olarak kodlanmış bilgi yollayan bir uydu ağıdır ve uydularla alıcı arasındaki mesafeyi ölçerek alıcının dünya üzerindeki yerini tespit etmek amacıyla kullanılır (Misra, 2001). YKS sinyalleri ile dünya çevresindeki yörüngede bulunan 24 aktif uydudan yararlanılarak, dünya üzerindeki alıcı konumu belirlenmektedir. YKS uzay, kontrol ve kullanıcı bölümlerinden oluşmaktadır. Uzay bölümü uyduları, kontrol bölümü uydu operasyonlarının yönetimini, kullanıcı bölümü ise askeri ve sivil alanlarda YKS kullanımını içermektedir (Misra, 2001). YKS de farklı taşıyıcı frekanslarında L bandında bulunan *Link1* ($L1$) ve *Link2* ($L2$) frekansları ile işaretler gönderilir. L bandı 1 GHz ile 2 GHz frekans aralığını içermektedir ve UHF bandının altındadır. YKS işaretinin temel frekansı 10.23 MHz'dir. $f_{L1} = 1575.42 \text{ MHz}$ ve $f_{L2} = 1227.60 \text{ MHz}$ taşıyıcı frekansları değerlerine sahiptir.

YKS işaretleri iyonosfer tabakasından geçerken iyonosferin yapısından etkilenmektedir. Bu durum YKS alıcılarının konumlama hassasiyetini düşürmekte ve aynı za-

manda iyonosferin içeriğini inceleme fırsatı sunmaktadır. İyonosferden kaynaklanan gecikme işaretin frekansına bağlıdır. Bu nedenle, iki farklı frekansta işaret gönderilerek iyonosferden kaynaklanan gecikme kalibre edilir. İki farklı frekanstan elde edilen YKS verileri kullanılarak TEİ kestirimi bir sonraki bölümde anlatılacaktır.

2.2.1 Yerküresel Konumlama Sistemi ile TEİ Kestirimi

Son yıllarda YKS verileri kullanılarak yerel ve küresel TEİ kestirimi yapılmaktadır. YKS alıcıları uydulardan gelen işaretlere ait gözlem parametrelerini belirli zaman aralıkları ile kaydeder. Bu gözlem parametreleri sözde menzil ve fazdır. Sözde menzil değeri ve faz değeri kullanılarak TEİ hesaplamaları yapılmaktadır. İyonosfer yapısının kısa ve uzun dönemli değişimi, yapıdaki düzensizlikler ve bozulmalar Toplam Elektron İçeriği (TEİ) incelenerek gözlemlenebilir. TEİ 1m^2 kesitli bir silindir boyunca toplam serbest elektron miktarıdır. Birimi TECU ile ifade edilir ($1\text{TECU} = 10^{16}\text{el/m}^2$).

Alıcı ile uydu arasındaki mesafe, işaretin uydudan gönderilme zamanı ile alıcıya ulaşma zamanı arasında geçen süreye bağlı olarak hesaplanan menzil değeridir. YKS verileri kullanılarak hesaplanan bu mesafe iyonosfer, troposfer, alıcı ve uydu yansımaları gibi gecikmelerden de etkilendiği için sözde menzil olarak ifade edilmektedir. Sözde menzil Eş. 2.11 kullanılarak hesaplanabilir.


$$P = (T - T_s)c \quad (2.11)$$

Eş. 2.11'de P sözde menzil değeri, T_s işaretin uydudan gönderilme zamanı, T işaretin alıcıya ulaşma zamanı, c boşluktaki elektromanyetik dalga hızı olan 3×10^8 m/s dir. Sözde menzil değerini etkileyen gecikmeler Eş. 2.12'de verilmiştir (Kaplan, 1996).

$$d_{t_D} = d_{t_{atm}} + d_{t_{noise}} + d_{t_{mp}} + d_{t_{hw}} + d_{t_{SA}} \quad (2.12)$$

d_{t_D} toplam zaman gecikmesi, $d_{t_{atm}}$ atmosferden kaynaklanan gecikme, $d_{t_{noise}}$ alıcı gürültüsü ve çözünürlük yansılığı, $d_{t_{mp}}$ çokyolluluk etkisi, $d_{t_{hw}}$ alıcı donanım yansılığı, $d_{t_{SA}}$ seçici erişilebilirlik bozulmasıdır.

Şekil 2.2'de gösterilen sözde menzil zaman eşdeğerinde; δ_t geometrik aralık zaman



Şekil 2.2. Sözde menzil zaman eşdeğeri

eşdeğeri, T_s sinyalin uydudan ayrılma zamanı, T_u sinyalin gecikme olmadan alıcıya ulaştığı zaman, T_u' sinyalin gecikmeli olarak alıcıya ulaştığı zaman, Δt_m uydu saati ile sistem saati yanlılığı, Δt_u alıcı saati ile sistem saati yanlılığı, $T_s + \Delta t_m$ sinyalin uyduyu terk ettiği an uydu saatinde okunan değer, $T_u' + \Delta t_u$ kullanılan alıcıya sinyalin ulaştığında alıcı saatinden okunan değer olarak kullanılmıştır.

YKS alıcıları konumlama hassasiyetlerini artırmak için toplam zaman gecikmesini düzeltmek durumundadır. Zamana bağlı değişkenlerden dolayı başarılı bir şekilde TEİ kestirimi yapmak oldukça zordur. İyonosferin kırılma etkisini ortadan kaldırmak için değişik frekanslarda iki YKS sinyali kullanılır (Hofmann-Wellenhof, 2001). İki farklı frekans bandında çalışabilen YKS alıcılarına gelen sinyallerin sözde menzili, fazı veya her ikisinden faydalanarak TEİ kestirimi yapılabilir (Arıkan et al, 2003).

2.2.2 Sözde Menzil Modeli

Sözde menzil modeli f_1 ve f_2 frekansları için Eş. 2.13'deki gibi yazılabilir.

$$P_{1,u}^m = p_u^m + c(\Delta t_u - \Delta t^m) + d_{ion1,u}^m + d_{trop,u}^m + c(\varepsilon_1^m + \varepsilon_{1,u}) + \alpha \quad (2.13)$$

$$P_{2,u}^m = p_u^m + c(\Delta t_u - \Delta t^m) + d_{ion2,u}^m + d_{trop,u}^m + c(\varepsilon_2^m + \varepsilon_{2,u}) + \alpha \quad (2.14)$$

Eş. 2.13 ve Eş. 2.14'de m uydu numarası; u alıcı numarası; $P_{1,u}^m$ ve $P_{2,u}^m$, f_1 ve f_2 frekanslarına göre sözde menzil; p_u^m uydu ve alıcı arasındaki mesafe; $d_{ion1,u}^m$ ve $d_{ion2,u}^m$, f_1 ve f_2 frekanslarına göre iyonosferden kaynaklanan grup gecikmesi; $d_{trop,u}^m$ troposferden kaynaklanan grup gecikmesi; $\varepsilon_{1,u}$ ve $\varepsilon_{2,u}$, sırasıyla f_1 ve f_2 frekanslarına göre alıcı yanlılığı; ε_1^m ve ε_2^m , sırasıyla f_1 ve f_2 frekanslarına göre uydu yanlılığıdır.

Eş. 2.13 ve Eş. 2.14 birbirlerinden çıkarılarak iki farklı frekansta gönderilen işaretin sözde menzıl değerleri arasındaki fark Eş. 2.15'deki gibi bulunabilir.

$$P_{4,u}^m = P_{2,u}^m - P_{1,u}^m \quad (2.15)$$

2.2.3 Faz Modeli

YKS'den elde edilen faz değeri işaretin kaç dalga boyu yol aldığını göstermektedir. Faz sayısının (ϕ), dalga boyu (λ) ile çarpımı alınan yolu vermektedir. Bu gerçekten yola çıkarak f_1 ve f_2 frekansları için faz modeli

$$\lambda_1 \Phi_{1,u}^m = p_u^m + c(\Delta t_u - \Delta t^m) + \lambda_1 \Phi_{ion1,u}^m + \lambda_1 \Phi_{trop,u}^m - c(\varepsilon_1^m + \varepsilon_{1,u}) + \lambda_1 N_1 + \alpha \quad (2.16)$$

$$\lambda_2 \Phi_{2,u}^m = p_u^m + c(\Delta t_u - \Delta t^m) + \lambda_2 \Phi_{ion2,u}^m + \lambda_2 \Phi_{trop,u}^m - c(\varepsilon_2^m + \varepsilon_{2,u}) + \lambda_2 N_2 + \alpha \quad (2.17)$$

olarak oluşturulur (Nayir, 2007).

Eş. 2.16 ve Eş. 2.17'de; m uydu numarası; u alıcı numarası; $\Phi_{ion1,u}^m$ ve $\Phi_{ion2,u}^m$, sırasıyla f_1 ve f_2 frekanslarına göre iyonosferden kaynaklanan faz gecikmesi; $\Phi_{1,u}$ ve $\Phi_{2,u}$, sırasıyla f_1 ve f_2 frekanslarına göre alıcının kaydettiği faz sayısı; N_1 ve N_2 , sırasıyla f_1 ve f_2 frekanslarına göre ilk faz belirsizliği; $\Phi_{trop,u}^m$ troposferden kaynaklanan faz gecikmesidir.

Eş. 2.16 ve Eş. 2.17 birbirlerinde çıkarılarak iki farklı frekansta gönderilen faz değerleri arasındaki fark Eş. 2.18'deki gibi bulunabilir.

$$L_{4,u}^m = \lambda_1 \Phi_{1,u}^m - \lambda_2 \Phi_{2,u}^m \quad (2.18)$$

Troposferin sözde menzıl ve faz gecikmelerine etkisi frekanstan bağımsızdır. Bu nedenle iki farklı frekans için elde edilen gecikmelerin farkı alınarak iyonosferin etkisine ulaşma yoluna gidilmektedir.

İyonosferden kaynaklanan grup gecikmesi Eş. 2.19'da verilmiştir (Nayir, 2007).

$$\Delta r = \frac{A}{f^2} \int_S N_e dl \quad (2.19)$$

Faz ilerlemesi ise Eş. 2.20'de verilmiştir.

$$\Delta\phi = -\frac{A}{cf} \int_S N_e dl \quad (2.20)$$

Eş. 2.19 ve Eş. 2.20'de S ışın yolunu göstermektedir. A değeri sabit olup değeri $40.28 \text{ m}^3/\text{s}^2$ 'dir.

$$TEI = \int_S N_e dl \text{ olarak verilmiştir (Nayir, 2007).}$$

f_1 ve f_2 frekanslarındaki işaretlerin gecikmeleri arasındaki fark değeri kullanılarak, grup ve faz gecikmelerinden TEI değerini elde etmek mümkündür (Kaplan, 1996). Eş. 2.21'de bu ilişki verilmiştir ve $d_{ion,u}^m$ iyonosferden kaynaklanan grup gecikmesi, $-\phi_{ion,u}^m$ iyonosferden kaynaklanan faz gecikmesidir.

$$d_{ion,u}^m = -\phi_{ion,u}^m \frac{c}{f} = A \frac{STEC_u^m}{f^2} \quad (2.21)$$

TEI , $STEC$ ve $VTEC$ olmak üzere iki şekilde ifade edilir. Seçilen bir istasyon için m . uydudan n . ölçüm zamanında sözde menzil kullanılarak hesaplanan $STEC$ değeri Eş. 2.22'de verilmiştir (Nayir, 2007).

$$STEC_u^m(n) = \frac{1}{A} \left(\frac{f_1^2 f_2^2}{f_1^2 - f_2^2} \right) [P_{4,u}^m(n) + c(DCB_m + DCB_u)] \quad (2.22)$$

DCB_m ve DCB_u differansiyel yanlık değerleridir.

$VTEC$ değeri bir izdüşüm fonksiyonu ile Eş. 2.23'deki gibi hesaplanır:

$$VTEC_m(n) = STEC_m(n) / M(\epsilon_m(n)) \quad (2.23)$$

ve

$$M(\epsilon_m(n)) = \left[1 - \left(\frac{R \cos \epsilon_m(n)}{R + h} \right)^2 \right]^{-1/2} \quad (2.24)$$

Eş. 2.23 ve Eş. 2.24'de kullanılan m uydu numarasını, h iyonosfer yüksekliğini, ϵ ufuk açısını, n ölçüm anını, R dünyanın yarıçapını ifade etmektedir. R dünyanın ekvatorial yarı çapı olup $6.378,137$ metredir.

STEC değerinden VTEC elde ederken iyonosferin sonsuz incelikte bir tabakadan oluştuğu varsayımı yapılmaktadır (Nayir, 2007). Bu varsayım üç boyutlu uzayda yapılması gereken iyonosfer çalışmalarını iki boyutlu uzaya indirgemıştır (Liao, 2000). İstasyon ve uydu arasındaki YKS sinyalinin sonsuz incelikteki bu katmanı kestiği noktaya iyonosferi delme noktaları denilmektedir. İyonosferi delme noktasındaki STEC değerinin dik izdüşümü VTEC değerini vermektedir. Düzgünleştirilmiş TEİ (D-TEİ) yöntemi ile faz ve sözde menzil ölçümleri kullanılarak TEİ kestirimi yapılabilmektedir (Nayir, 2007). VTEC değeri ise D-TEİ yöntemine girdi olarak kullanılmaktadır. D-TEİ yönteminde yükseklik 428.8 km alınmıştır (Nayir, 2007).

TEİ haritalama, iyonosfer kesişim noktalarında ölçülen değerler kullanılarak, aradeğerleme ve dışdeğerlendirme yöntemleriyle, konumda ve zamanda ölçüm yapılmayan yerlerdeki TEİ değerlerinin bulunması ve bir araya getirilmesidir. İyonosfer haritalama çalışmalarında, iyonosferi delme noktasındaki TEİ değerleri ve D-TEİ yöntemi ile elde edilmiş TEİ verileri ayrı ayrı kullanılabilir.

2.3 TEİ Haritalama Çalışmaları

Son on yılda YKS verileri ile TEİ kestirimi konusunda yapılan araştırmalar yaygınlaşmıştır. TEİ haritalama çalışmaları, elde edilen TEİ verileri ile iyonosfer hakkında daha geniş bilgi sahibi olmak için yapılmaktadır. Literatürde sistematik bir iyonosfer haritalama yöntemi olmamakla birlikte, yöntemler geliştirilmeye çalışılmaktadır. Haritalama çalışmalarında iyonosfer, en büyük elektron yoğunluğunun olduğu yükseklikte bulunan ve elektronların tümünü içeren ince bir küresel kabuk olarak düşünülür. İyonosfer modelleri geliştirilirken ızgara tabanlı ve fonksiyon tabanlı yöntemler olmak üzere iki çeşit yöntem kullanılmaktadır. Izgara tabanlı yöntemlerde ızgara noktalarındaki TEİ değerleri hesaplanmaya çalışılırken, fonksiyon tabanlı yöntemde fonksiyonun katsayıları hesaplanmaya çalışılmaktadır.

Uluslararası GPS Servisi (IGS) analiz merkezleri, IONEX formatındaki TEİ haritalarını internet üzerinden yayınlamaktadırlar (Ionex, 1998). Değişik merkezler tarafından hazırlanan haritalar IONEX formatı sayesinde birbirleriyle karşılaştırılabilmekte ve beraberce kullanılabilir. Literatür özetinde TEİ haritalaması konusunda yapılan çalışmalar, kullanılan yöntemler ve alınan sonuçlar bir araya getirilmeye çalışılmıştır. Küresel Harmonikler, İnce Katmanlı Spline Aradeğerleme, Multikvadrik Fonksiyon Modeli, Dalgacık Analiz Yöntemi, Kriging ve Yapay Sinir Ağları yöntemleri

TEİ haritalama çalışmalarında rastlanan yöntemlerdir.

TEİ haritalama için açık literatürde yer alan kaynaklar ve yöntemler incelendiğinde, yöntemlerin birbirinden farklı zaman, konum, istasyon ağı ve veriler üzerinde denenmiş olması genel bir karşılaştırmanın yapılmasını zorlaştırmaktadır. Açık literatürde Küresel Harmonikler ve İnce Katmanlı Spline Aradeğerleme yöntemleri Kanada üzerinde iki farklı YKS alıcı ağında (CACS, WCDA) denenmiş, iyonosferik bozulmanın yüksek olduğu 29 Mayıs 2003 günü daha geniş bir alanı kaplayan ve göreceli olarak daha seyrek örnekleme yapılan CACS ağı üzerinde İnce Katmanlı Spline yönteminin Küresel Harmoniklere göre üstünlük sağladığı gözlenmiştir. İyonosferin daha sakin olduğu 31 Mayıs 2003'te, daha küçük bir alanı kaplayan WCDA ağı üzerinde yine İnce Katmanlı Spline yöntemi Küresel Harmoniklere göre üstünlük sağlamıştır (Moon, 2004). Küresel Harmonik yöntemini kullanarak 1996 yılında Kleusberg ve Bruni tarafından haritalama çalışması yapılmıştır (Komjathy, 1997).

29 Nisan 2003 tarihinde beş Ohio CORS istasyonundan alınan verilerle Kriging ve Multiquadrics yöntemleri kullanılarak TEİ haritaları çıkarılmıştır. IGS merkezleri Global İyonosfer haritalarıyla karşılaştırıldığında Multiquadrics ve Kriging yöntemlerinin birbirlerine yakın sonuçlar verdiği gözlenmiştir. IGS haritaları global tabanlı oldukları için 5 TECU daha fazla TEİ değeri elde edilmiştir. Her iki yöntemin de çok değişkenli durumlar için uygun ve örneklemenin seyrek olduğu durumlarda bile başarılı olduğu gözlenmiştir. Multiquadrics yönteminin formülasyonu daha basit olduğu için Kriging'e göre nümerik olarak daha hızlı ve gerçek zamanlı uygulamalar için daha uygun olduğu sonucuna varılmıştır (Wielgosz, 2003).

IGS analiz merkezlerinden biri olan UPC'de haritalama spline fonksiyonların enterpolasyonundan elde edilen haritaların Gaussian radyal taban fonksiyonlarıyla düzgünleştirilmeleri yöntemi ile yapılmaktadır. Bu yöntem Kriging yöntemi ile geliştirilmiş ve sonuçlar TOPEX/Poseidon verileri ile karşılaştırıldığında hatanın standart sapmasında düşüşler gözlenmiştir (Orús, 2005).

Multikuadrik, VTEC modeli ve uzaklıkla ağırlıklandırma yöntemleri gerçekleştirilmiş, ve üçü de birbirlerine yakın sonuçlar vermiştir. Aradeğerleme için 0.3 metre, dışdeğerleme için ise 30 dakikalık zaman süresinde 0.4 metrelik hassasiyete ulaşılmıştır (Jin, 2005).

YSA yöntemi, iyonosferin haritalamasında girişi enlem ve boylam çıkışı TEİ değerleri olan bir sinir ağı modeli oluşturulmuştur. Geri Yayılım öğrenme algoritması kullanılarak oluşturulan bu modelde %97.5 oranında TEİ kestirimi yapılabilmektedir. Brezilya'yı kapsayan RBMC YKS ağındaki 11 farklı istasyon kullanılarak, toplanan verilerle model denendiğinde ortalama 3.7 TECU hata gözlenmiştir (Leandro, 2004). Radyal Taban Fonksiyonu kullanılarak yapılan iyonosfer haritalama çalışmasında, ağırlıklar haritalama yapılacak noktaların uzaklığının gauss fonksiyonu olarak alınmıştır. Yerel haritalama çalışmalarında 5 TECU seviyesinde hata iyileşmesi gözlenirken, global haritalarda hata 10 TECU'ya çıkmıştır (Hernandez-Pajares, 1999). Genelde YSA yöntemi ile iyonosferin kritik frekans (foF2) değişimi hesaplaması yapılmıştır. foF2'nin saatlik değişimi için, doğrusal olmayan kara-kutu yaklaşımı ile çok katmanlı ileri beslemeli sinir ağlarına dayalı modelleme yapılmıştır. Geçmiş foF2 ve K_p dizini ölçümlerini kullanarak bir saat sonraki foF2 değeri kestirilmektedir. Sinir Ağı oluşumu %6.3 yada 0.4 MHz genel yanılığa sahiptir (Altınay, 1996). Bu çalışma geliştirilerek bir saklı katman ve beş sinir hücresi ile %6.19 ya da 0.47 MHz değerine ulaşılmıştır (Kumluca, 1997).

Bu çalışmada Yapay Sinir Ağları kullanarak TEİ haritaları oluşturulmaya çalışılmıştır. Literatür taramasında karşılaşılan diğer yöntemler bir sonraki bölümde ana hatları ile özetlenmiştir.

2.4 TEİ Haritalama Yöntemleri

TEİ haritalama yöntemleri olan Küresel Harmonikler, İnce Katmanlı Spline Aradeğerleme, Multikvadrik Fonksiyon modeli ve Kriging bu bölümde ana hatları ile anlatılacaktır. Yapay Sinir Ağları yöntemi ise bir sonraki bölümde detaylı bir şekilde incelenecektir. Yöntemlerde $\mathbf{x} = [\theta \ \phi]^T$, θ enlem, ϕ boylam olmak üzere konum vektörünü, $VTEC(\mathbf{x})$, $\mathbf{x}$ noktasındaki TEİ değerini, $\widehat{VTEC}(\mathbf{x}_0)$, $\mathbf{x}_0$ kestirim noktasındaki kestirim değerini göstermektedir. $VTEC(\mathbf{x}_i)$, $\mathbf{x}_i$ ölçüm noktasındaki TEİ değeridir.

2.4.1 Küresel Harmonikler

Küresel Harmonikler, genellikle jeofizikte kullanılan bir yöntem olup, iyonosfer modellerinde de kullanılmaktadır (Zolesi, 1991). Fonksiyon tabanlı bir yöntemdir (Moon, 2004). Zamandan bağımsız ve küresel olarak dağılmış verilerin modellenmesi için uygun bir yöntemdir (Schaer, 1999). Bu modelin temeli boylamda Fourier serisi

açılımına, enlemde ise Legendre fonksiyonlarının ortogonal fonksiyonlarla açılımına dayanır (Lazo, 2004).

$$VTEC(\theta, \phi) = \sum_{n=0}^N \sum_{m=0}^M P_n^m(\sin(\theta)) [C_n^m \cos(m\phi) + S_n^m \sin(m\phi)] \quad (2.25)$$

Eş. 2.25'de n ve m , sırasıyla Legendre fonksiyonunun tamsayı derecesi ve katını, C_n^m , S_n^m , bilinmeyen Küresel Harmonik katsayılarını, P_n^m , normalize edilmiş Legendre fonksiyonunu göstermektedir. Legendre fonksiyonunun derecesi modelin çözünürlüğünü belirlemektedir. Eş. 2.25 global TEİ haritaları için uygundur ancak yerel bölgelerde Legendre fonksiyonları birbirlerine dik olmadıkları için bu denklem yerel haritalamalar için uygun değildir. Katı tamsayı olan ama derecesi tamsayı olmayan Küresel Uyum Analizi modelinde ise Legendre fonksiyonları dik oldukları için yerel bölgelerde haritalama bu fonksiyon kullanılarak yapılabilir (Moon, 2004). Eş. 2.26'da Küresel Uyum Analizi modeli verilmiştir;

$$VTEC(\theta, \phi) = \sum_{l=0}^K \sum_{m=0}^l P_{n_l}^m(m)(\sin\theta) [C_n^m \cos(m\phi) + S_n^m \sin(m\phi)] \quad (2.26)$$

Yukarıdaki eşitlikte n_l , tamsayı olmayan dereceyi göstermektedir.

Tamsayı olmayan Legendre fonksiyonları hesaplandıktan sonra geriye kalan bilinmeyen katsayılar Kalman süzgeci yaklaşımı ile çözülmektedir (Moon, 2004). TEİ haritalama uygulamalarında, Küresel Harmonik fonksiyonları iyonosfer kesişim noktalarına yerleştirilerek Kalman süzgeci veya En Küçük Kareler yöntemi ile fonksiyon katsayıları bulunur. Daha sonra herhangi bir noktadaki TEİ değeri bu fonksiyonlardan hesaplanabilir (Schaer, 1999).

Yerel foF2 haritalamada da bu yöntem kullanılmıştır. Haritalama yapılacak bölgenin dışındaki ölçümler sonsuzdaki sınır koşulları olarak alınmıştır. Bu sayede veri sayısının azlığından kaynaklanan sınırlamanın önüne geçilmiştir (Lazo, 2004).

2.4.2 İnce Katmanlı Spline Aradeğerleme

Tek boyutlu Kübik Spline, parçalı tanımlanan kübik polinomların yerleştirilmesine dayanır. İki parçalı fonksiyonun kesişim noktalarında birinci ve ikinci dereceden

türevlerinin sürekliliği sağlanmalıdır. Bu da eğrinin bütün parçaları boyunca daha düzgün ve sürekli olan, ani değişimler içermeyen fonksiyonlar oluşturur.

İnce Katmanlı Spline, tek boyutlu Kübik Spline'nın iki boyutlu olanıdır. Bu aradeğerleme yöntemi bütün ölçüm noktalarından geçen en az kavisli ve en az değişen yüzeyi bulmaya çalışır. $J(VTEC(\mathbf{x}))$, $VTEC(\mathbf{x})$ bir yüzey olarak düşünülürse, bu yüzeyin eğrilik derecesi ifade edilebilir;

$$J(VTEC(\mathbf{x})) = \int_{R^2} [(\frac{\partial^2 VTEC}{\partial \mathbf{x}_1^2})^2 + 2(\frac{\partial VTEC}{\partial \mathbf{x}_1} \frac{\partial VTEC}{\partial \mathbf{x}_2})^2 + (\frac{\partial^2 VTEC}{\partial \mathbf{x}_2^2})^2] d\mathbf{x} \quad (2.27)$$

Eğrilik derecesinin en aza indirilmesi,

$$\widehat{VTEC}(\mathbf{x}_j) = a_1 + a_2\theta + a_3\phi + \sum_{l=1}^n E(\|\mathbf{x}_j - \mathbf{x}_l\|)b_l \quad (2.28)$$

fonksiyonu ile sağlanır. Bu denklemden, $\| \cdot \|$ mutlak değer işareti, a_1, a_2, a_3, b_l bilinmeyen katsayıları, ϕ polinom fonksiyonu, n ölçüm noktalarının sayısı, E ise radyal taban fonksiyonudur (Moon, 2004). Ölçüm değerleri Eş. 2.28'de yerine konarak elde edilen doğrusal denklem sistemi çözülerek katsayılar bulunur. TEİ değerleri Eş.2.28'den bulunabilir (Moon, 2004).

2.4.3 Multikvadrik Fonksiyon Modeli

Multikvadrik Fonksiyon yönteminde dik TEİ aşağıdaki gibi bir seri şeklinde yazılabilir,

$$VTEC(\theta, \phi) = \sum_{i=1}^n a_i Q(\theta, \phi, \theta', \phi') \quad (2.29)$$

Eş. 2.29'da $VTEC(\theta, \phi)$, iyonosfer kesişim noktasında dik toplam elektron içeriğini, (θ, ϕ) , iyonosfer kesişim noktasının koordinatlarını, (θ', ϕ') , ızgara noktasının koordinatlarını, a_i hesaplanmaya çalışan katsayı değerini, n ölçülen veri sayısını göstermektedir ve

$$Q(\theta, \phi, \theta', \phi') = [(\phi - \phi')^2 + (\theta - \theta')^2 \cos^2 \phi'^2 + \varepsilon^2]^\beta \quad (2.30)$$

olarak verilebilir.

Eş. 2.30 pozitif polinom fonksiyonudur, ε^2 ve β düzgünleştirme faktörleridir (Jin, 2005) .

$$\underbrace{\begin{pmatrix} \text{VTEC}(\phi_1, \theta_1) \\ \text{VTEC}(\phi_2, \theta_2) \\ \vdots \\ \text{VTEC}(\phi_m, \theta_m) \end{pmatrix}}_{\mathbf{v}} = \underbrace{\begin{pmatrix} Q(\phi_1, \theta_1, \phi'_1, \theta'_1) & \dots & Q(\phi_1, \theta_1, \phi'_n, \theta'_n) \\ \vdots & \ddots & \vdots \\ Q(\phi_m, \theta_m, \phi'_1, \theta'_1) & \dots & Q(\phi_m, \theta_m, \phi'_n, \theta'_n) \end{pmatrix}}_{\mathbf{Q}} \underbrace{\begin{pmatrix} a_1 \\ a_2 \\ \vdots \\ a_n \end{pmatrix}}_{\mathbf{a}} \quad (2.31)$$

Eş. 2.31'de soldaki vektör $\mathbf{v}$, polinom matrisi $\mathbf{Q}$, bilinmeyen katsayılar vektörü $\mathbf{a}$ ile gösterilirse $\mathbf{v} = \mathbf{Q}\mathbf{a}$ olur. Bilinmeyen katsayılar vektörü olan $\mathbf{a}$ En Küçük Kareler yöntemine benzer bir yöntemle bulunabilir (Jin, 2004) . Bu durumda hata denklemi Eş. 2.32 ile ifade edilir.

$$\Delta \mathbf{v} = \mathbf{Q}\mathbf{a} - \mathbf{v} \quad (2.32)$$

$$\mathbf{a} = (\mathbf{Q}^T \mathbf{P}_v \mathbf{Q})^{-1} \mathbf{Q}^T \mathbf{P}_v \mathbf{v} \quad (2.33)$$

Eş. 2.33'den ızgara noktasındaki (ϕ', θ') dik toplam elektron içeriği $\widehat{\text{VTEC}}$ bulunabilir.

$$\widehat{\text{VTEC}} = \mathbf{Q}^t \mathbf{a} \quad (2.34)$$

Eş. 2.34'den $\mathbf{Q}^t = (\mathbf{Q}_1, \mathbf{Q}_2, \dots, \mathbf{Q}_i)$ ızgara noktaları için hesaplanan pozitif kuadratik fonksiyonlar olarak verilmiştir (Jin, 2005).

Literatür özetinde bahsedilen yöntemlerden YSA'nın başarımını karşılaştırmak için Kriging yöntemi seçilmiştir. Takip eden bölümde bu yöntem daha ayrıntılı incelenmiştir.

2.4.4 Kriging Yöntemi

Kriging, jeostatistikte yaygın olarak kullanılan bir kestirim tekniğidir. Bir noktanın veya bir bloğun ortalama değerinin en iyi doğrusal yansız kestiricisini belirtmeyi amaçlar. D.G. Krige tarafından ilk defa 1950 yılların başında Güney Afrika'daki altın yataklarında kullanılmıştır. George Matheron bu tekniği Fransa'da bulunan Centre

de Morphologie Mathematique'de geliřtirmiřtir. D.G. Krige'nin onuruna G. Matheron tarafından bu teknięe Kriging adı verilmiřtir (David, 1982). Bu yntemin ilk ıkıř amacı, maden yataklarının deęerlendirilmesinde rneklenmiř noktalarda belirli bir blgeye zg deęiřimleri kullanarak, dięer noktalardaki deęerleri kestirmektir.

Kriging yntemi ile TEİ haritaları, deęiřik YKS istasyonlarının enlem ve boylam deęerleri arasındaki ilintiye bakılarak oluřturulabilir. lm alınamayan noktalar iin TEİ kestirimi Eř. 2.35'deki gibi ifade edilir.

$$\widehat{VTEC} = \sum_{i=1}^N w_i VTEC(\mathbf{x}_i) \quad (2.35)$$

Eř. 2.35'de $\widehat{VTEC}$, bilinmeyen TEİ deęerleri, $\mathbf{x}_i$, lm noktalarının enlem ve boylam deęerleri, $VTEC(\mathbf{x}_i)$, lm yapılan $\mathbf{x}_i$ noktalarındaki TEİ deęerleri, w_i ise Kriging denklemleri ile bulunacak aęırlık deęerleridir ve ara deęerlendirmenin yansız olması iin $\sum_{i=1}^N w_i = 1$ kořulu saęlanmalıdır. Aęırlık deęerlerinin hesaplanmasında, lmler arasındaki konumsal baęımlılıęın bir lt olan yarıdeęiřinti fonksiyonu kullanılır. Yarıdeęiřinti sabit mesafe blmlerine ayrılmıř btn olası noktalar arasındaki farkların varyansının yarısıdır. Deneysel yarıdeęiřinti ařaęıdaki eřitlikte verilmiřtir:

$$\gamma(h_1) = \frac{1}{2m(h_1)} \sum_{i \neq j}^{m(h_1)} (VTEC(\mathbf{x}_i) - VTEC(\mathbf{x}_j))^2 \quad (2.36)$$

h_1 , lm noktaları olan $\mathbf{x}_i$ ve $\mathbf{x}_j$ arasındaki uzaklıęı, $VTEC(\mathbf{x}_i)$, $VTEC(\mathbf{x}_j)$, $\mathbf{x}_i$ ve $\mathbf{x}_j$ noktalarındaki lm deęerlerini, $m(h_1)$, birbirine h_1 uzaklıkta bulunan lm iftleri sayısını gstermektedir. rneklenmemiř noktalardaki deęerlerin kestirimi iin de yarıdeęiřinti deęeri bilinmelidir. Deneysel yarıdeęiřinti deęerlerine bir fonksiyon uyarlanarak teorik yarıdeęiřinti bulunur. Buradan gereken yarıdeęiřinti deęerleri elde edilir. En yaygın kullanılan yarıdeęiřinti modelleri Gauss, ssel ve kresel fonksiyonlardır. Yarıdeęiřinti fonksiyonları kullanılarak aęırlıklar hesaplanmakta ve TEİ kestirimi yapılabilir.

Kriging ynteminin dięer kestirim yntemlerine gre en nemli stnlę, Kriging'in ilinti aracılıęı ile kestirim hatasını vermesidir. Kriging ilintisi, verilerin gerek deęerlerine baęlı deęildir, veri sayısının ve veriler arası uzaklıęın bir fonksiyonudur

(Tercan, 1996). Kriging ağırlıklarının kestirimlerde çok önemli bir yeri vardır ve uzak noktalarda zayıf ağırlıklar alması nedeniyle kestirilecek noktanın çevresinde kullanılan noktaların sayısının büyük tutulmasının Kriging sisteminin çözümünü kolaylaştırdığı belirtilmiştir (Rivoirard, 1984). Kriging yöntemi TEİ haritalama çalışmalarında kullanılan yöntemlerin en önemlilerindendir. Bu çalışmada YSA yöntemi ile elde edilen sonuçlar Kriging yöntemi sonuçları ile karşılaştırılacaktır.

3. SİNİR AĞLARI TABANLI DOĞRUSAL OLMAYAN HARİTALAMA

Yerküresel Konumlama Sistemlerini (YKS) kullanarak dünya üzerinde konumlanmış belirli sayıdaki alıcılardan belirli zaman aralıklarıyla TEİ değerleri elde edilmektedir. Bu veriler kullanılarak çeşitli aradeğerleme yöntemleri ile iyonosferin anlık durumunu gösteren TEİ haritaları oluşturmak mümkündür. Yapay Sinir Ağları (YSA) TEİ haritalama çalışmalarında kullanılan aradeğerleme yöntemlerinden biridir. YSA doğrusal olmayan işlem birimlerinin biraraya gelmesi ile oluşur. YSA'nın doğrusal olmayan yapısının önemi işlenen sinyal (konuşma sinyalinde olduğu gibi) doğası gereği doğrusal değilse önem kazanmaktadır (Kılınç, 2002). İyonosferin karakteristiğini etkileyen birçok etmen olduğundan, doğrusal olmadığı kabul edilebilir. Haritalama yaparken YSA kullanmanın bir diğer avantajı ise doğrusal olmayan yapı hakkında ilgili bağıntının bilinmesine gerek olmadan giriş çıkış veri setini oluşturma'nın yeterli olmasıdır. YSA modeli veri seti ile doğrusal olmayan modeli öğrenme işlemini gerçekleştirmektedir (McKinnel, 2004). YSA genelleme yapabildiği için iyi bir yapı tanımlayıcısı ve gürbüz bir sınıflandırıcıdır. Fonksiyonel yaklaşım ve sistem modelleme gibi fiziksel işlemin anlaşılmadığı veya aşırı karmaşık olduğu problemler yanında konuşma, karakter ve sinyal tanımlama gibi çeşitli sınıflandırma problemleri için çözüm yolları sağlamaktadır (Yurtoğlu, 2005). Özellikle, Evrensel Fonksiyon Yakınsayıcı olarak tanınmasından dolayı tahmin ve öngörü gibi verinin içerdiği yapının tanımlanmasını gerektiren alanlarda sıkça kullanılmaktadır (Hornik, 1989). Yinelemeli Sinir Ağları (YA), Radyal Taban Fonksiyonu (RBF), Geri Yayılım Algoritması ile çok katmanlı perseptron yapısı fonksiyon yakınsamalarında kullanılan YSA çeşitleridir.


Öncelikle sistem tanıma yapısı ve fonksiyon yaklaşımı çalışmaları anlatılacak, takip eden bölümlerde geri yayılım algoritması ile çok katmanlı perseptron yapısı ve gerçek zamanlı yinelemeli öğrenme algoritması ile yinelemeli ağ mimarisi incelenecektir.

3.1 Doğrusal Olmayan Sistem Modeli

Sistemlerin giriş çıkış davranışları tek girişli, tek çıkışlı, doğrusal, nedensel, sabit gibi bir takım özelliklerine bakılarak incelenir. Sistemin modellenebilmesi açısından doğrusal olup olmaması önem taşımaktadır. Doğrusal olmayan sistemlerde giriş ve çıkış değerleri arasında belirli bir değişim oranı bulunmamaktadır. Doğrusal ol-

mayan bir sistem modeli oluřtururken ilk nce sistemin doęrusal olduęu varsayılır ve doęrusal sistem modeli doęru sonu vermedięinde modelin doęrusal olmadıęı sonucuna varılır. Doęrusal olmayan bir model mimarisi kullanıldıęında bu model doęrusal modeli de iermektedir (Nelles, 2001).


Sistem analizlerinde modelleme yapmak sistemin daha iyi anlařılması aısından faydalı bir yntemdir. Modeller sistem davranıřları hakkında benzetimler zerinde tahminlerde bulunulmasını saęlar. Doęrusal olmayan sistemleri tanımlamak ve modellemek olduka zordur nk formlize edilemeyen zellikler ierir. řekil 3.1’de kabaca sistem yapısı gsterilmektedir. Bu yapı hem duraęan hem dinamik sistemlerde uygulanabilir.



řekil 3.1. Sistem yapısı

Doęrusal olmayan bir sistemi tanımlayan řekil 3.2’de ilk drt basamakta eęitim seti verileri kullanılmaktadır. Doęrusal olmayan sistem modelleme, iřlem sonucunda elde edilen grltl veri ile modelleme sonucunda elde edilen veri arasındaki hatayı en aza indirmeyi amalar. Modelin parametreleri eęitim seti verileri ile deęiřtirilerek, hatanın en az olduęu parametrelere ulařılmaya alıřılır. Deęiřik en iyileme teknikleri kullanılarak en iyi model parametre deęerleri elde edilir.

Yapay Sinir Aęları (YSA) doęrusal olmayan sistem modelleme tekniklerinden biridir. İyonosfer benzetiminde kullanılan yaygın ve geliřmekte olan bir yntemdir.



Şekil 3.2. Doğrusal olmayan sistem tanımlama


3.2 Yapay Sinir Ağları

Biyolojik sinir sistemi, bilgiyi alan, yorumlayan ve uygun bir karar üreten, beynin bulunduğu üç katmanlı bir yapı olarak algılanır. Bilgi karmaşık, doğrusal olmayan ve paralel bir şekilde işlenir. Beynin bilgiyi işleme şeklinden esinlenilerek matematiksel model oluşturulmaya çalışılmış ve bunun sonucunda Yapay Sinir Ağları (YSA) kavramı ortaya çıkmıştır. YSA ile, en genel anlamda basit işlem birimleri bir araya getirilerek, karmaşık problemlerin çözümleri araştırılmaktadır.


YSA, işlem birimi adı verilen birbirine bağlı işlem elemanlarından oluşmuş, paralel işleyen yapılardır. Şekil 3.3'de bir işlem biriminin modeli gösterilmiştir. Girişler, çevreden alınan bilgilerdir. Ağırlıklar, girişin etkisini belirleyen katsayılardır. İşlem birimleri arasındaki bağlantıların ağırlıkları, öğrenme sürecinde değişir ve giriş çıkış ilintisi bu bağlantıların ağırlıkları ile tanımlanır. Girişler ağırlıklarla çarpılarak toplanır, eşik değeri eklenerek etkinlik fonksiyonuna girer. Doğrusal olmayan etkinlik fonksiyonu işlem birimlerinin çıkışını sınırlamak için kullanılır. Etkinlik fonksiyonu olarak genellikle eşik, sigmoid, hiperbolik tanjant fonksiyonları kullanılır. En çok kullanılan etkinlik fonksiyonları Şekil 3.4'de verilmiştir. Her işlem biriminin tek çıkışı vardır. Bir işlem biriminin çıkışı, kendinden sonra gelen diğer işlem birimlerine giriş olabilir.

Şekil 3.3'de gösterilen işlem birim modelinin matematiksel ifadesi;

$$v_k = \sum_{j=1}^m w_{kj} x_j + b_k \quad (3.1)$$



Şekil 3.3. İşlem birimi modeli



Şekil 3.4. Etkinlik fonksiyonları a)Eşik b)Parçalı doğrusal c)Sigmoid d)Hiperbolik tanjant

$$y_k = \varphi(v_k) \quad (3.2)$$

Eş. 3.1 ve Eş. 3.2'de φ etkinlik fonksiyonunu, x giriş değerlerini, w ağırlıkları, b_k eşik değerini, y işlem biriminin çıkış değerini ifade etmektedir.

İşlem birimleri bir araya gelerek YSA'yı oluştururlar. YSA'ların en önemli özelliklerinden birisi doğrusal olmayan yapıları da dikkate alabilmesidir. YSA'nın doğrusallığı işlem birimlerinin etkinlik fonksiyonu ile belirlenir. Bu nedenle YSA, özellikle doğrusal olmayan karmaşık problemlerin çözümünde kullanılmaktadır. YSA'nın kullanılabilir sonuçlar vermesi için, amaca uygun olarak tasarlanması, hücreler arasındaki bağlantıların doğru yapılması ve bağlantıların uygun ağırlıklara sahip olması

gerekmektedir. Bilgiyi işlemede kullanılan deneyim YSA içerisinde öğrenme işlemiyle kazanılır. YSA, istenen davranışı gösterecek şekilde eğitim örneklerini kullanarak modeli öğrenmelidir. Öğrenme algoritmaları sayesinde, bu yapı genelleme yapabilmekte, sisteme ait olası yeni verilere anlamlı sonuçlar yükleyebilmektedir. Başlangıç ağırlıkları genellikle rasgele yada sabit bir değerde seçilir. Seçilen öğrenme algoritmasına göre ağırlıkların yenilenerek belirlenen hata kriteri için artık değişmediği durumda öğrenme gerçekleşmiş denilir. Belirli bir problemi çözmek için eğitilen YSA, problemdeki değişimlere göre yeniden eğitilebilmektedir yani uyarlanabilme özelliğine de sahiptir.

Bu özellikleri nedeniyle günümüzde birçok alanda YSA kullanılmaktadır. Özellikle örüntü tanıma, sınıflandırma, doğrusal olmayan denetim, tahmin, yaklaşım, haritalama alanlarında YSA'lar başarı ile kullanılmaktadır.

Birçok farklı yapıda YSA modeli bulunmaktadır ancak bunlar genel olarak öğrenme stratejilerine, öğrenme yöntemlerine, uygulama tiplerine, ağ mimarisine göre kategorilere ayrılabilir.

Öğrenme stratejilerine göre denetimli, denetimsiz ve pekiştirmeli olarak sınıflandırılabilen YSA, öğrenme yöntemine göre dört farklı tipe ayrılabilir. Bunlar, perseptron öğrenme; Delta kuralı ve Geri Yayılım algoritmalarını da içeren hata düzeltme; rekabetçi; Hebbian ve stokastik öğrenme yöntemleridir (Patterson, 1996).

Bir diğer sınıflandırma ise durağan ve dinamik ağlar gözönüne alınarak yapılabilir. Durağan ağlar uzun süreli, kalıcı hafızaya sahiptir ve işlem birimleri arasındaki bağlantılar bir döngü oluşturmazlar, bu ağlar girdiye hızlı bir şekilde karşılık üretirler. Dinamik ağlar geçici hafıza yapısını kullanarak çalışır ve işlem birimlerinin çıkışının tekrar hesaplama girmesi için önceki işlem birimlerinin girişine geri besleyen bağlantılar içeren yapıdaki ağlardır. Dinamik ağlarda işlem birimi denklemleri diferansiyel ve fark denklemlerinden oluşmaktadır (Haykin, 1999). Bu çalışmada durağan ağlar, Tek Katmanlı İleri Beslemeli Ağlar ve Çok Katmanlı İleri Beslemeli Ağlar olarak iki aşamada incelenmiştir. Dinamik ağ olarak ise Durum-Uzay yapısında, Gerçek Zamanlı Yinelemeli Öğrenme algoritması incelenmiştir.

3.3 Durağan Yapay Sinir Ağları

Durağan yapıdaki yapay sinir ağları tek katmanlı ve çok katmanlı ileri beslemeli ağ yapılarında geri besleme öğrenme algoritması kullanılarak incelenecektir.


3.3.1 Tek Katmanlı İleri Beslemeli Yapay Sinir Ağları

Durağan yapıdaki Yapay Sinir Ağlarının temelini tek katmanlı perseptronlar oluşturur. Tek katmanlı perseptron, bir katmanda bir veya birden fazla işlem elemanı ve doğrusal olmayan etkinlik fonksiyonlarından oluşan bir sistemdir. Bu sistemde bilgi ileri yönde işlenir. Tek katmanlı perseptron yapısında kullanılan işlem birimi (nöron) Şekil 3.3'de gösterilmiştir. Fakat tek katmanlı perseptron yapıları, beklenenleri tamamiyle karşılayamadığı ve sadece doğrusal olarak ayrılabilir sınıflandırma problemlerinde kullanılabildiği için çok katmanlı perseptron gibi daha güçlü YSA yapıları geliştirilmiştir (Haykin, 1999). YSA'nın temel işlem elemanı olan işlem birimlerinin yapısı ve modeli, bütün YSA yapılarında aynıdır. Bu nedenle, farklı uygulama alanlarında kullanılan farklı mimarilerde YSA'lar benzer öğrenme algoritmalarını ve teorilerini paylaşabilirler.

3.3.2 Çok Katmanlı İleri Beslemeli Ağlar

İşlem birimleri bir araya gelerek daha karmaşık yapıdaki sinir ağlarını oluştururlar. Çok katmanlı ileri beslemeli ağ en sık kullanılan YSA mimarisidir. Bu tip ağlara çok katmanlı perseptron da denilir. Yapı olarak tek katmanlı perseptronun birden fazla katmana sahip halidir. Bu tip mimarilerde giriş katmanı, bir veya daha fazla sayıda saklı katman ve çıkış katmanı bulunmaktadır. Giriş ve çıkış katmanları arasındaki katmanlara saklı katman denir çünkü bunlar dış ortamdan tamamen izoledir. Katmanlar arasındaki işlem birimleri birbirlerine tamamiyle yada kısmen bağlı olabilir. Giriş katmanında giriş sayısı kadar giriş noktası bulunur. Saklı katmanlarda problemin karmaşıklığına göre işlem birimi ve katman sayısı değişir.

Şekil 3.5'de çok katmanlı ileri beslemeli ağın genel yapısı gösterilmiştir. Çok katmanlı perseptronun girişlerine uygulanan n boyutlu giriş vektörü $\mathbf{x}$, w_{ij} ağırlıkları ile ilk gizli katmanın işlem birimine aktarılır. Burada j saklı katman işlem birimini, i giriş için kullanılan indisleri olup, bu ikisi birbirine w_{ij} ağırlığı ile bağlıdır. j 'inci işlem biriminin çıkış değeri bir sonraki katmanın tüm işlem birimlerine aktarılır. Bu işlem



Şekil 3.5. ÇKP ve Geri yayılım algoritması

çıkış katmanındaki işlem birimine ulaşınca kadar tekrarlanır. Görüleceği üzere bilgi akışı tek yönde ve ileri doğrudur. Ağırlıklar başlangıçta rasgele olarak veya sabit bir değerde seçilir. Kullanılan öğrenme yöntemine göre ağırlıklar her yeni giriş değeri için yenilenir. Çok katmanlı ileri beslemeli ağlar uzun zamandır çalışılmasına rağmen uygun eğitim yöntemleri var olmadığından ancak geri yayılım öğrenme algoritması ile örüntü tanıma için uygulanabilir hale gelmiştir (Haykin, 1999).

3.3.3 Geri Yayılım Algoritması

Geri Yayılım öğrenme algoritması, hatayı azaltmak için en dik iniş tabanlı yöntemleri kullanarak ağırlık değerlerini değiştiren bir yaklaşım algoritmasıdır. Bu yöntem, denetimli eğitimin ve türevlenebilir etkinlik fonksiyonlarının kullanıldığı herhangi bir ÇKP yapısına uygulanabilir. Bu yöntemde, giriş ve bu girişe karşılık gelen çıkış değerinden oluşan örnek çiftlerden bir eğitim veri seti YSA'ya uygulanır ve örnek çiftleri gerçekleyen fonksiyon elde edilmeye çalışılır. Bunun için YSA'ya uygulanan giriş değerinden elde edilen çıkış değeri, istenen çıkış değeri ile karşılaştırılarak hata belirlenir. Hata değerleri geri besleme bağlantılarına giriş olarak kullanılarak ağırlıkların değerleri değiştirilir. Şekil 3.5'de geri yayılım öğrenme algoritması için modifiye edilmiş çok katmanlı ileri beslemeli ağ gösterilmektedir. Geri yayılım algoritması her katmanın ağırlıkları bir sonraki katman için hesaplanan hata değerine göre yenilenir. Çıkış katmanında hesaplanan hata, saklı katman ile çıkış katmanı arasındaki ağırlıkları değiştirir. Saklı katmanın çıkış değerleri için hesaplanan hata, giriş katmanı ile

saklı katman arasındaki ağırlıkları değiştirir. Bu şekilde, hatanın çıkış katmanından giriş katmanına doğru yani geri yönde bir yayılımı söz konusudur.

Geri yayılım öğrenme algoritması aşağıdaki gibi özetlenebilir:

1. Bilinen veri setine uygun bir YSA ağ yapısı ve eşik değerleri seçilir. Tüm ağırlıklar rasgele belirlenir.
2. Seçilen veri çiftleri (giriş, çıkış) YSA modeline uygulanır. Her katmanda, herbir işlem birimi için çıkış değerleri $y_j^0 = x_j$ durumunda Eş. 3.3'deki gibi hesaplanır.

$$y_j^q = \varphi\left(\sum_i y_i^{q-1} w_{ji}^q\right) \quad (3.3)$$

Eş. 3.3'de q saklı katman sırasını, i ve j bağlantılı işlem birimi çiftleri numarasını, y YSA'dan elde edilen çıkış değerini, w_{ji} ağırlık değerini, φ etkinlik fonksiyonunu, x_j girişi göstermektedir.

3. Çıkış katmanında elde edilen değer ile istenen çıkış değerinin farkı Eş. 3.4'deki gibi bulunur.

$$\delta_j^Q = (y_j^Q - t_j^P) \varphi'(x_j^Q) \quad (3.4)$$

Eş. 3.4'de y_j^Q çıkış katmanında hesaplanan YSA çıkışı, t_j^P istenen çıkış değeri, i ve j bağlantılı işlem birimi çiftleri numarasını, x_j^Q son katmana girişi göstermektedir.

4. Eş. 3.5'deki formül ile her katman için hata geri yayılarak fark hesaplanır.

$$\delta_j^{q-1} = \varphi'(x_j^{q-1}) \sum_i \delta_i^q w_{ji}^q \quad (3.5)$$

Eş. 3.5'de δ_j^{q-1} her katmandaki herbir işlem birimi için hata değerini, i ve j bağlantılı işlem birimi çiftleri numarasını, $q = Q, Q - 1, \dots, 2$ olmak üzere katman sayısını göstermektedir.

5. Ağırlıklar Eş. 3.6 ve Eş. 3.7 kullanılarak yenilenir.

$$w_{ji}^{new} = w_{ji}^{old} + \Delta w_{ji}^q \quad (3.6)$$

$$\Delta w_{ji}^q = \eta \delta_i^q y_j^{q-1} + \alpha \Delta w_{ji}^q \quad (3.7)$$

Eş. 3.7'de kullanılan η öğrenme oranı, α momentum katsayısıdır. Bu değişkenler ağırlıkların değişimindeki adım aralığını belirler.

6. Belirlenen hata toleransına ulaşıncaya kadar işlemler tekrarlanır.

Öğrenme işleminde ağırlıklar iki farklı şekilde yenilenebilir. Örüntü tipinde, eğitim veri setindeki her bir örnek çiftin uygulanmasından sonra ağırlıklar yenilenir. Diğer yöntem küme öğrenme tipidir. Bu yöntemde tüm eğitim setinin uygulanmasından sonra hesaplanan toplam hataya göre ağırlıklar değiştirilir. YSA modelinde tüm eğitim setinin bir kez ileri doğru uygulanmasına çevrim denir.

3.4 Dinamik Yapay Sinir Ağları

Dinamik ağlar, durağan ağlardan farklı olarak geçici hafızası olan ve zaman değişimine bağlı sistemleri modelleyebilen bir yapıya sahiptir. Durağan ağlar, giriş değerlerini ileri beslemelerle direk çıkışa iletirken, dinamik ağlar geçmişteki girişlere, çıkışlara ve durum değişkenlerine bağlı olarak çıkış elde ederler. Kısaca dinamik ağlar, geri besleme bağlantılarını kullanarak zamansal değişimi YSA yapısına katmaktadır (De Jesus, 2007).

Dinamik özellik gösteren ağlar, çok katmanlı perseptron gibi yapılara değişik formlarda geri besleme eklenmesi ile elde edilir. Geri beslemeler bölgesel ve genel olabilir (Haykin, 1999). Bu çalışmada genel geri besleme yapısına sahip yinelemeli ağ mimarisi incelenmiştir.

3.4.1 Yinelemeli Ağ Mimarisi

Yinelemeli ağ mimari yapısı durağan çok katmanlı perseptronları içine almaktadır. Çok katmanlı perseptron modelinin doğrusal olmayan haritalama yeteneğini kullanmaktadır. Giriş-çıkış yinelemeli ağ, durum-uzay modeli, yinelemeli çok katmanlı perseptron ve ikinci derecede ağlar olarak dört farklı ağ mimarisinde incelenir (Haykin, 1999). Bu çalışmada durum-uzay modelinde, Gerçek Zamanlı Yinelemeli Öğrenme (GZYÖ) algoritması kullanılmaktadır.

Giriş-çıkış yinelemeli ağ mimarisi, doğrusal sistemlerde olduğu gibi giriş ve çıkış

değerleri arasındaki ilişkinin transfer fonksiyonu kullanarak ifade edilmesidir. Giriş-çıkış ağ mimarisi kullanılarak oluşturulan NARX modeli, belirli bir zamandaki ve daha önceki değerleri içine alan bir giriş kümesi ve bu gecikmeli girişlerin çıkışlarından oluşmaktadır. Yinelemeli çok katmanlı ağ mimarisi genel yinelemeli sinir ağı ve durum-uzay modelini kapsamaktadır. Yinelemeli ağ yapısı bir veya daha fazla saklı katmandan oluşan çok katmanlı perseptron modellerine herbir katmanındaki çıkışlarına geri besleme eklenmesi ile elde edilir. İkinci dereceden ağlar herbir saklı katmanın çıkışına gecikme uygulanması ile, sistem iki kere geciktirilerek elde edilir.

Yinelemeli ağ mimarisinde, en çok kullanılan öğrenme yordamları üçe ayrılır;

- Zamanda geri yayılım
- Gerçek zamanlı yinelemeli öğrenme
- Genişletilmiş Kalman süzgeci

Bu çalışmada gerçek zamanlı yinelemeli öğrenme (GZYÖ) algoritması kullanılacaktır. GZYÖ algoritması durum-uzay modeli kullanılarak tanımlanmaktadır. Bu nedenle bundan sonraki bölümde durum-uzay modeli ve GZYÖ algoritması anlatılacaktır.

3.4.2 Durum-Uzay Modeli

Doğrusal olmayan sistemlerde dinamik yapıyı tanımlamak için matematiksel bir modele ihtiyaç vardır. Durum-uzay modeli bu amaç için kullanılmaktadır. Doğrusal olmayan bir sistemin gelecekteki durumunu öngören, sistemin geçmişteki davranışları ile ilgili yeterli bilgiyi içeren değişkenlere durum değişkenleri denir. Dinamik sistemlerin durum değişkenleri zamanla değişmektedir (Haykin, 1999).

Durum-uzay modeli, fiziksel bir sistemin giriş vektörü, çıkış vektörü ve birinci derece diferansiyel denklemler kullanılarak durum değişkenleri ile ifadesidir. Durum-uzay modelinin YSA'da kullanımı Eş. 3.8 ve Eş. 3.9'da verilmiştir (Haykin, 1999).

$$\mathbf{x}(n+1) = \varphi(\mathbf{W}_a \mathbf{x}(n) + \mathbf{W}_b \mathbf{u}(n)) \quad (3.8)$$


$$\mathbf{y}(n) = \mathbf{C} \mathbf{x}(n) \quad (3.9)$$

$\mathbf{u}(n)$ $m \times 1$ boyutlarında giriş vektörünü, $\mathbf{x}(n)$ $q \times 1$ boyutlarındaki durum vektörünü, φ ($\varphi : R^q \rightarrow R^q$) uzayında etkinlik fonksiyonunu, $\mathbf{y}(n)$ $p \times 1$ boyutlarında n anındaki sistemin çıkışını, $\mathbf{W}_a$ matrisi durum değişkenleri için ağırlıkları, $\mathbf{W}_b$ matrisi giriş değerleri için ağırlıkları, $\mathbf{C}$ çıkışta bulunan ağırlıkları göstermektedir.

Durum-uzay mimarisi en sık kullanılan yinelemeli ağ mimarisidir. Kontrol sistemlerinde olduğu gibi YSA uygulamalarında da kontrol edilebilirlik ve gözlenebilirlik açısından incelenir.

3.4.3 Gerçek Zamanlı Yinelemeli Öğrenme Algoritması

Gerçek zamanlı yinelemeli öğrenme algoritması isminden de anlaşılacağı gibi ağırlık vektörlerinin ayarlanmasını gerçek zamanlı olarak yapmaktadır. Şekil 3.6'da q işlem birimi, m girişi, p çıkışı olan, ileri besleme ve geri besleme yapılarıyla gerçek zamanlı öğrenme algoritması ile çalışan yinelemeli ağ yapısı verilmiştir (Haykin, 1999). z^{-1} , bir zaman birimlik gecikmeyi ifade etmektedir.



Şekil 3.6. Yinelemeli ağ yapısı ve model değişkenleri

Ağ yapısı, Eş. 3.8 ve Eş. 3.9'da verilen durum-uzay yöntemi ile ifade edilir.

$$\xi(n) = \underbrace{\begin{pmatrix} \mathbf{x}(n) \\ \mathbf{u}(n) \end{pmatrix}}_{q+m+1} \quad (3.10)$$

Eş. 3.10'da $\xi(n)$, $(q+m+1) \times 1$ boyutunda giriş ve durum değişkenlerinden oluşan vektördür. Durum değişkenleri Eş. 3.12'de, giriş ve durum değişkenlerinin $(q+m+1)$ boyutundaki ağırlık vektörü ise Eş. 3.11'de verilmiştir ($j=1,2,\dots,q$).

$$\mathbf{w}_j = \underbrace{\begin{pmatrix} \mathbf{w}_{a,j} \\ \mathbf{w}_{b,j} \end{pmatrix}}_{q+m+1} \quad (3.11)$$

$$\mathbf{x}(n+1) = \begin{pmatrix} \varphi(\mathbf{w}_1^T \xi(n)) \\ \vdots \\ \varphi(\mathbf{w}_j^T \xi(n)) \\ \vdots \\ \varphi(\mathbf{w}_q^T \xi(n)) \end{pmatrix} \quad (3.12)$$

Gerçek zamanlı yinelemeli öğreneme algoritmasının gösteriminde kolaylık olması için bazı ara değişkenler tanımlanmalıdır. $\Lambda_j(n)$, $\mathbf{U}_j(n)$, $\Gamma(n)$ olarak isimlendirilen bu ara değişkenler Eş. 3.13, Eş. 3.14 ve Eş. 3.15'de verilmiştir.

- $\Lambda_j(n)$, durum vektörü $\mathbf{x}(n)$ 'in kısmi türevini ifade eder ve $q \times (q+m+1)$ büyüklüğünde bir matristir.

$$\Lambda_j(n) = \frac{\partial \mathbf{x}(n)}{\partial \mathbf{w}_j} \quad (3.13)$$

- $\mathbf{U}_j(n)$, $q \times (q+m+1)$ büyüklüğünde j . satırı $\xi^T(n)$ 'e eşit olan ve diğer satırları sıfıra eşit olan matristir.

$$\mathbf{U}_j(n) = \begin{pmatrix} 0 \\ \xi^T(n) \\ 0 \end{pmatrix} \quad (3.14)$$

- $\Gamma(n)$, $q \times q$ büyüklüğünde köşegenleri etkinlik fonksiyonunun kısmi türevinden oluşan matristir.

$$\Gamma(n) = \text{diag}(\phi(\mathbf{w}_1^T \xi(n)), \dots, \Gamma'(\mathbf{w}_j^T \xi(n)), \dots, \Gamma'(\mathbf{w}_q^T \xi(n))) \quad (3.15)$$

Gerçek zamanlı yinelemeli öğrenme algoritması ara değişkenler kullanılarak aşağıdaki gibi özetlenebilir.

1. Kullanılan parametreler: m , giriş uzayı boyutu; q , durum değişkeni boyutu; p , çıkış uzayı boyutu; $\mathbf{w}_j$ j 'inci işlem biriminin ağırlık değerini ($j = 1, 2, \dots, q$) ifade etmektedir.

2. Değişkenlere başlangıç değeri atamak:

- Ağ yapısının ağırlıkları düzgün dağıtılmış küçük değerlere eşitlenir.
- Durum değişkenleri sıfıra eşitlenir $\mathbf{x}(0)=0$.
- $\Lambda_j(0) = 0$, $j=1, 2, \dots, q$ değerleri için eşitlenir.

3. Hesaplamalar: $n = 0, 1, 2, \dots$ değerleri için

$$\Lambda_j(n+1) = \Gamma(n)[\mathbf{W}_a(n)\Lambda_j(n) + \mathbf{U}_j(n)] \quad (3.16)$$

$$\mathbf{e}(n) = \mathbf{d}(n) - \mathbf{C}\mathbf{x}(n) \quad (3.17)$$

$$\Delta \mathbf{w}_j(n) = \eta \mathbf{C} \Lambda_j(n) \mathbf{e}(n) \quad (3.18)$$

Yukarıda verilen hesaplamalarda ağırlık vektörlerinin değişimi hesaplanır ve en az hataya ulaştıracak YSA yapısı tesbit edilerek doğrusal olmayan sistem yapısı modellenir. Öğrenme işlemi sonucunda gelecek bir an için öngörü yapılabilir.

Bu bölümde YSA'nın temel kuramları, dinamik ve durağan ağlar ana hatları ile anlatılmıştır. Dinamik ve durağan ağlar kullanılarak yapılan haritalama çalışmaları sonraki bölümlerde ayrıntılı bir şekilde incelenecektir.

4. ÇOK KATMANLI PERSEPTRON İLE DURAĞAN İYONOSFER HARİTALAMA ÇALIŞMALARI

TEİ haritalama, YKS istasyonlarından alınan ölçümler kullanılarak ölçüm alınamayan noktalar için TEİ kestirimi yapmaktır. YSA, bu amaçla kullanılabilecek yöntemlerden biridir ve doğrusal olmayan sistemlerin modellenmesinde iyi bilinen istatistiksel yöntemler kadar başarılı olduğu ispatlanmıştır. YSA, giriş çıkış değerleri arasındaki ilişkinin bilinmediği doğrusal olmayan sistemlerin haritasının oluşturulmasında yaygın olarak kullanılır (Marquez, 1992).


Haritalama çalışması ölçüm değerleri için iki boyutlu fonksiyon yaklaşımı olarak da düşünülebilir. Fonksiyon yaklaşımı, çok değişkenli, sürekli bir $f(x)$ fonksiyonu için $\mathbf{X} = (x_1, x_2, \dots, x_n)$ ve $\mathbf{W} = (w_1, w_2, \dots, w_n)$ parametrelerinden oluşan $F(\mathbf{W}, \mathbf{X})$ 'in belirlenmesidir. $F(\mathbf{W}, \mathbf{X})$ fonksiyonu elde edilirken örnek veriler ile en iyi $\mathbf{W}$ parametresinin belirlenmesi gerekmektedir. Bu aşamada öğrenme gerçekleşir (Poggio, 1990). YSA yöntemi ile model fonksiyonuna yaklaşımın doğruluğu istenen oranda saklı katmanların sayısını değiştirerek sağlanır (Hetch, 1989).

Bu çalışmada çok katmanlı ileri besleme sinir ağı yapısı ve öğrenme metodu olarak geri yayılım algoritması kullanılmıştır. YSA algoritmaları hazırlanırken izlenilen süreç aşağıdaki gibidir:

- Giriş ve çıkış veri seti oluşturma
- Veri setinin eğitim, sağlama ve test verilerine ayrılması
- Veri setine ön işleme yapılması
- YSA yapısının belirlenmesi (saklı katman işlem birimi sayısı)
- Öğrenme yönteminin belirlenmesi
- YSA yapısının eğitilmesi
- YSA yapısının sağlamlasının yapılması
- Eğitim verileri ile YSA performansı istenildiği gibi olduğunda test verileri kullanılarak test yapılmalıdır. Eğer test sonuçları istenildiği kadar iyi değil ise ilk basamağa dönülmesi gerekmektedir.

4.1 Çok Katmanlı Perseptron Benzetimleri

Bu çalışmada kullanılan YSA modelinin giriş değerlerini enlem ve boylam verileri, çıkış değerlerini ise TEİ verisi oluşturmaktadır. Ölçüm noktalarından elde edilen veriler kullanılarak YSA modeli eğitilmektedir. YSA modeli, enlem ve boylam verileri için iki işlem birimli giriş katmanından, bir veya iki saklı katmandan ve TEİ değeri için bir işlem birimli çıkış katmanından oluşmaktadır. Şekil 4.1'de üzerinde çalışılacak YSA modeli verilmiştir.



Şekil 4.1. İyonosfer haritalama çalışmasında kullanılan ÇKP modeli

YSA modelini oluştururken giriş değerleri dağılımı (eğitim, sağlama ve test verisi oranlaması), saklı katman işlem birimi sayısı, kullanılan etkinlik fonksiyonu, öğrenme sabiti, momentum sabiti gibi sistem parametrelerinin belirlenmesi gerekmektedir. Bu nedenle ilk aşamada, YSA modelinin parametrelerini belirleyen etmenleri ve sonuç başarımına etkisini gözlemlemek için gerçek veriler yerine benzetim verileri kullanılmıştır. Gerçek veriler kullanıldığında geri yayılım algoritmasının en uygun çözüme yakınsaması amaçlanmaktadır. Bu nedenle benzetimler aşağıda belirtilen özelliklere göre yapılmıştır, (Stengel, 2005).

- Yaklaşım yapılacak fonksiyonun karmaşıklığı arttıkça hata oranı artar. Bu nedenle farklı yüzeyler kullanarak YSA performansı incelenmiştir.
- YSA'nın ideal işlem birimi yapısı en uygun çözümün elde edilebildiği büyüklüktür. YSA olması gerekenden fazla işlem birimi yapısına sahip ise sinyal yanında gürültüyü de modellediği için genelleme yapılamaz ve test verileri için hatalı sonuçlar elde edilmesine neden olur. Bu durum aşırı öğrenme olarak ad-

landırılmaktadır. İşlem birimi sayısı gerekenden az olduğunda ise az öğrenme olmaktadır.

- Veri setinde gürültü arttıkça hata oranı artmaktadır. Bu nedenle gürültünün etkisi incelenmiştir.

YSA'nın fonksiyon yaklaşımı uygulamalarında görüldüğü gibi, iki katmanlı bir perseptron yapısının, herhangi doğrusal olmayan bir dönüşümü yapabilme kabiliyeti vardır. İki katmanlı perseptron yapısının çok fazla işlem birimi gerektirdiği durumlarda üç katmanlı perseptron kullanılabilir. Saklı katman işlem birimi sayısı benzetim yüzeyleri ve örnekleme çeşitleri değiştikçe farklılık göstermektedir. Bu nedenle saklı katman işlem birimi sayısı en uygun çözüme yakınsayacak şekilde testlerle belirlenmeye çalışılmıştır. Eğitim verilerinin sayısı ve dağılımı değiştirilerek öğrenme performansına etkileri incelenmiştir. Eğitim seti ile elde edilen sistem parametrelerinin test verileri kullanıldığında doğru sonuç vermesi beklenmektedir. Benzetim yüzeyleri kullanıldığı için YSA modelinden elde edilmesi gereken yüzeyin haritası bilinmektedir. Böylelikle seçilen bölge için modelin performansı hesaplanabilir.

Etkinlik fonksiyonu YSA modelini oluştururken karar verilmesi gereken parametrelerden biridir. YSA yapısının doğrusal olmamasını kullanan etkinlik fonksiyonu sağlamaktadır. Etkinlik fonksiyonları sınırlı ve türevlenebilir olmalıdır. YSA fonksiyon yaklaşımı uygulamalarında en çok kullanılan etkinlik fonksiyonu sigmoid ve hiperbolik tanjant fonksiyonudur (Marquez, 1992). Bu fonksiyonların yapıları Şekil 3.4'de verilmiştir. Bu çalışmada saklı katmanlar için hiperbolik tanjant, çıkış katmanı için parçalı doğrusal etkinlik fonksiyonu kullanılmıştır.

YSA algoritmasının performansını ölçmek için iki farklı hata ölçütü hesaplanmıştır. Hata oranı Δ , bir yüzey için bütün kestirim hatalarının karelerinin toplamının gerçek değerlerin karelerinin toplamına oranıdır.

$$\Delta = \frac{\sum_{n=1}^N |f(x_n) - F(\mathbf{w}, x_n)|^2}{\sum_{n=1}^N |f(x_n)|^2} \quad (4.1)$$

Eş. 4.1'de Δ bağıl hata, N kestirimin yapıldığı toplam nokta sayısı, $f(x_n)$, n 'inci noktadaki gerçek değeri, $F(\mathbf{w}, x_n)$, n 'inci noktadaki kestirim değerini göstermektedir. Eş. 4.2'de verilen en büyük bağıl hata Δ_{max} ise yüzeydeki her kestirim için hesapla-

nan bağıl hataların en büyüğüdür.

$$\Delta_{max} = \max_{(n=1,...,N)} \left(\frac{f(x_n) - F(w, x_n)}{f(x_n)} \right) \quad (4.2)$$

Bağıl hata ve en büyük bağıl hata değerleri uygun YSA modelini belirlenmesinde ve diğer yöntemlerle karşılaştırırken kullanılmaktadır.

Test ve eğitim verilerini kullanarak YSA'nın performansını incelerken Eş. 4.3'de verilen hata kare toplamı ve Eş. 4.4'de verilen ölçüm değerleri ile model çıkışının farkının mutlak değerine bakan ρ kullanılmıştır.

$$sse = \sum_{n=1}^N (f(x_n) - F(w, x_n))^2 \quad (4.3)$$

$$\rho = |f(x_n) - F(w, x_n)| \quad (4.4)$$

4.1.1 Benzetim Yüzeylerinin Belirlenmesi

Benzetim yüzeyleri belirlenirken gerçek TEİ ölçümlerinden elde edilen değerlere uygun olması için farklı gün ve saatlerde elde edilen veriler üzerinde detaylı inceleme yapılmıştır.

Çizelge 4.1'de verilen YKS istasyonlarından D-TEİ yöntemi ile 7 Ekim 2004 tarihinde elde edilen veriler en az kareler uyarlama yöntemi ile ikinci dereceden polinoma uyarlanmıştır. Eş. 4.5'de verilen değerler elde edilmiştir.


$$y = 16.3966 - 0.005x_1^2 + 0.0037x_2^2 \quad (4.5)$$

Şekil 4.2 ve Şekil 4.4'de günün iki farklı saati için en az kareler yöntemi ile elde edilmiş iyonosfer haritasına polinom yüzeyi yaklaşımları verilmiştir. Şekil 4.3 ve Şekil 4.5'de ölçüm noktalarına karşılık gelen uyarlama hataları verilmiştir.


Benzetim yüzeylerinin oluşturulmasında en az kareler yöntemi yararlı bir yöntem olmasına karşın sadece en az kareler yöntemi kullanılarak iyonosfer haritalarının oluşturulması zaman alıcı ve uyarlanacak polinomun katsayılarının ve derecesinin kullanıcı tarafından belirlenmesi sebebiyle kullanıcıya bağımlı bir uygulamadır. Eğer

YKS İstasyonu	Kısa İsim	Enlem	Boylam
Ankara, Türkiye	Ankr	39,69°N	32,76°E
Brüksel,Belçika	Brus	50,60°N	4,36°E
Herstmaneeux,İngiltere	Hers	50,68°N	0,34°E
Torino,İtalya	Ieng	44,82°N	7,64°E
Kootwijk,Hollanda	Kosg	51,99°N	5,81°E
Paris,Fransa	Opmt	48,64°N	2,3°E
Braunsschweig,Almanya	Ptbb	52,11°N	10,46°E
Westerbang,Hollanda	Tro1	69,54°N	18,94°E
Wettzell,Almanya	Wtzt	48,9°N	12,88°E
Zelenchukskaya, Rusya	Zeck	43,6°N	41,56°E
Metsahovia, Finlandiya	Mets	60,05°N	24,39°E
Oberpfoffenhofen,Almanya	Obet	47,89°N	11,3°E
Sofya,Bulgaristan	Sofi	42,36°N	23,39°E
Westerbang,Hollanda	Wsrt	52,73°N	6,6°E

Çizelge 4.1. ÇKP ile yapılan çalışmalarda kullanılan YKS istasyonları




Şekil 4.2. 07.10.2004 günü saat 04:07:30 için polinom yüzeyi yaklaşımı



Şekil 4.3. 07.10.2004 günü saat 04:07:30 için polinom yüzeyi yaklaşım hatası

polinomun derecesi verilere göre olması gerekenden küçük veya büyük olursa, yaklaşım sonucu iyi çıkmamaktadır. Veriler değiştikçe uyarlanmaya çalışılan fonksiyon katsayıları ve hata oranları değişmektedir. Kullanılması gereken polinom modelini sabitlemek farklı verilerde hataların değişmesine neden olmaktadır. Bu nedenle bu yöntem sadece benzetim yüzeyleri hakkında fikir sahibi olmak için kullanılmıştır. Bu



Şekil 4.4. 07.10.2004 günü saat 12:27:30 için polinom yüzeyi yaklaşımı

Şekil 4.5. 07.10.2004 günü saat 12:27:30 için polinom yüzeyi yaklaşım hatası

çalışma iyonosferin değişimini gözönüne alarak oluşturulan benzetim yüzeyleriyle YSA algoritmasının performansını test etmek amacı ile yapılmıştır. Böylelikle TEİ haritalama için kullanılacak YSA algoritmasının parametreleri ve veri dağılımının haritalama sonuçlarına etkileri incelenmiştir. Benzetim yüzeyleri belirlenirken IRI (IRI, 2001) ve GIM (Ionex, 1998) tarafından hazırlanan haritalardaki değişimlerden de yararlanılmıştır. Bu haritalarda güneşin hareketi, negatif ve pozitif bozulmaların olduğu zamanlar ve sakin zamanlarda iyonosfer fiziksel olarak farklılıklar göstermektedir. Bu bilgiler doğrultusunda benzetim yüzeyleri oluşturulmaya çalışılmıştır.

4.1.2 Benzetim Yüzeyleri ve Veri Setlerinin Oluşturulması

Yapılan testlerde benzetim yüzeylerinin, örnekleme örüntüsünün ve gürültü etkisinin YSA performansına olan etkisi incelenmiştir. Altı farklı yapay yüzeyde; kare, altıgen, rasgele, kümelenmiş örneklemeler için gürültülü ve gürültüsüz veriler kullanılarak, YSA modelinin aşırı öğrenme ve az öğrenme olmayacak şekilde saklı katman sayısı ve işlem birimi sayıları tespit edilmeye çalışılmıştır. Kullanılan benzetim yüzeylerinin matematiksel ifadeleri aşağıda verilmiştir.

$$f_1(x, y) = ax + by + c \quad (4.6)$$

$$f_2(x, y) = a \exp\left(\frac{x - b}{c}\right) \quad (4.7)$$

$$f_3(x, y) = a + bx + cy + dxy + ex^2 + fy^2 \quad (4.8)$$

$$f_4(x, y) = a \exp\left[-\left(\left(\frac{x-b}{c}\right)^2 + \left(\frac{y-d}{e}\right)^2 + \frac{(x-f)(y-g)}{h}\right)\right] \quad (4.9)$$

$$f_5(x, y) = \frac{\sin((a(x-b))^2 + (c(y-d))^2)}{a(x-b)^2 + (c(y-d))^2} \quad (4.10)$$


$$f_6(x, y) = \sqrt{a \sin^2 y + b \sin^2 x} - \exp[c(\cos x + \cos y)] + d \quad (4.11)$$

Yukarıdaki eşitliklerde düzlem için (Eş. 4.6), $a = 0.1$, $b = 0.26$, $c = 0$, üssel fonksiyon için (Eş. 4.7), $a = 1$, $b = 26$, $c = 5$, polinom için (Eş. 4.8) $a = 2817$, $b = -72$, $c = 78$, $d = 0$, $e = f = 1$, Gauss fonksiyonu için (Eş. 4.9) $a = 8.91$, $b = 34$, $c = 5$, $d = 39$, $e = 2$, $h = -7.1$, Sombrero fonksiyonu için (Eş. 4.10) $a = 0.3$, $b = 36$, $c = 0.7$, $d = 39$, üssel ve sinüsoidal fonksiyon çeşitlemesi için (Eş. 4.11) $a = 4$, $b = 1$, $c = 0.5$, $d = 0$ değerleri kullanılmıştır. Benzetim yüzeylerinin değerleri 5 TECU ile 15 TECU arasında değişmektedir. Kullanılan benzetim yüzeyleri Şekil 4.7’de gösterilmiştir.

Benzetim yüzeylerine gürültü eklenerek YSA performansı test edilmiştir. Eklenen gürültü yerel değişkenlerle ilintili olarak oluşturulmuştur. Bu şekilde elde edilen yüzey, gerçek verileri pürüzsüz yüzeylere oranla daha iyi modellemektedir (Stengel, 2005). İlintili hata Eş. 4.12’nin benzetim yüzeylerine eklenmesi ile elde edilmektedir.

$$C(r; \sigma^2, a) = \sigma^2 e^{-ar} \quad (4.12)$$

r haritalamada kullanılan noktalar arasındaki öklit uzaklığı, $\sigma^2 > 0$ hata değişintisi, a ilinti kuvveti parametresini temsil etmektedir. TEİ değerleri 5 ile 15 arasında sınırlandırılmıştır. Bu nedenle eklenen ilintinin büyüklüğünün $[-1, +1]$ arasında olması için $\sigma^2 = 0.15$ ve $a = 0.4$ seçilmiştir. Benzetim yüzeylerine eklenen gürültünün bir örneği Şekil 4.6’da verilmiştir. Kullanılan gürültülü benzetim yüzeyleri ise Şekil 4.8’de gösterilmektedir.



Şekil 4.6. Benzetim yüzeylerine eklenen gürültü örneği

Benzetim yüzeyi haritaları 1° aralıklarla $26^\circ - 46^\circ$ E, $36^\circ - 42^\circ$ N bölgesinde, enlemde 7 nokta , boylamda 21 nokta olmak üzere toplam 147 nokta için oluşturulmuştur. Veri setleri oluşturulan harita üzerine homojen kare ızgara, rasgele kare ızgara, homojen altıgen, ketleme dağılım ve Poisson kümelenme olarak yerleştirilmiştir. Bu yapılar özellikle modelin test aşamasında veri dağılımının performansa etkisinin incelenmesinde kullanılacaktır.

Homojen ve rasgele kare ızgara örneklemelerinde, oluşturulan yüzey haritasının ızgara noktalarından örnekler alınmıştır.


Homojen altıgen örneklemede ise oluşturulan altıgen ızgaranın köşelerinden örnekler alınmıştır. Altıgenin kenar uzunlukları değiştirilerek 15, 21 ve 98 noktada örnekleme yapılmıştır.

Ketleme örneklemede yüzey haritasında rasgele bir noktaya göre en az 1, 2 ve 3 birim aralıklarla sırasıyla 44, 25 ve 15 örnekleme yapılmıştır.

Poisson kümelenmesi kaynak ve alt kümelerden oluşmaktadır. Eş. 4.13'de verilen Poisson dağılımına göre kaynak ve alt kümeler istenilen ortalamalarda dağılmaktadır.

$$P(n) = \exp(\psi) \frac{\psi^n}{n!} \quad (4.13)$$


ψ kaynak ve alt kümeler için dağılım ortalamasını göstermektedir ve 10 alınmıştır. n herbir basamakta hesaplanacak dağılıma eklenebilecek nokta sayısını göstermek-



Şekil 4.7. Benzetim yüzeyleri a) Düzlem, b) Üssel, c) İkinci dereceden polinom, d) Gauss dağılım fonksiyonu, e) Sombrero fonksiyonu, f) Üssel ve sinüsoidal fonksiyon çeşitlemesi


tedir. Seçilen kaynak noktanın etrafında belirlenen ortalama kadar noktalar dağılmaktadır. Bu noktalar alt kümeleri oluşturmaktadır. Alt kümeler belirlenen ortalama kadar dağılım göstermektedir (Bordenave, 2006).

Aşağıda herbir dağılım için 15 veri içeren birer örnek verilmiştir. Şekil 4.9'da kare ızgara homojen ve rasgele örnekleme, Şekil 4.10'da altıgen örnekleme, Şekil 4.11'de Poisson örnekleme, Şekil 4.12'de ketleme örnekleme gösterilmektedir.




Şekil 4.8. Gürültülü benzetim yüzeyleri a) Düzlem, b) Üssel, c) İkinci dereceden polinom, d) Gauss dağılım fonksiyonu, e) Sombrero fonksiyonu, f) Üssel ve sinüsoidal fonksiyon çeşitlemesi


Herbir yüzey için en uygun YSA modeli ve yeterli veri sayısına yapılan testlerle karar verilecektir. Kare ızgara ve ketleme örneklemelerde 15, 24, 44; altıgen örneklemede 15, 21, 98 verinin olduğu varsayılmıştır. YSA algoritması için veriler eğitim, test ve sağlama verisi olmak üzere üç gruba ayrılmaktadır. Eğitim verileri hatayı en aza indirecek şekilde ağırlıkların belirlenmesini sağlamaktadır. Test verileri YSA'nın performansını ölçmek, sağlama verileri az öğrenme ve aşırı öğrenme durumlarını kontrol etmek amacı ile kullanılmaktadır. Veri seti içerisinde eğitim, test ve sağlama



Şekil 4.9. Kare ızgara örnekleme a) Rasgele dağılım b) Homojen dağılım




Şekil 4.10. Altıgen ızgara örnekleme a) Veri hazırlama b) Veri dağılımı



Şekil 4.11. Poisson örnekleme a) Veri hazırlama b) Veri dağılımı

verilerinin nerelerde ve hangi oranlarda seçildiği öğrenme performansı açısından oldukça etkili olduğu yapılan çalışmada gözlenmiştir. İlk aşamada veri sayısını sabitleyip her bir yüzey için en uygun saklı katman işlem birimi sayısı belirlenecektir. Benzetim yüzeyleri gösterim kolaylığı olması açısından düzlem için F_1 , üssel için F_2 , polinom için F_3 , gauss için F_4 , sombrero için F_5 ve üssel sinusoidal için F_6 kısaltmaları kullanılmıştır. Veri sayısı gerekli görüldüğünde artırılarak sonuçları iyileştirme yoluna gidilecektir.



Şekil 4.12. Ketleme veri dağılımı örneği

4.1.3 Saklı Katman Yapısı ve İşlem Birimi Sayısı

Çok Katmanlı Perseptron yapıları geri yayılım algoritmaları ile doğrusal olmayan giriş çıkış verileri arasında fonksiyon benzetimi yapabilmektedir. Evrensel yaklaşım teorisine (Universal Approximation Theorem) göre, yaklaşımı yapılmak istenilen fonksiyonun Fourier dönüşümüne bakılarak tek saklı katmanlı bir yapının en uygun işlem birimi sayısı belirlenebilmektedir (Hornik, 1989). Evrensel yaklaşım teorisinin sürekli sinyaller üzerinde çalışması, bunun yanında pratikte tek saklı katmanda kullanılabilen işlem birimi sayısının sınırlı olması birçok pratik uygulamada bu teoremin kullanımını kısıtlamaktadır. Saklı katman işlem birimi sayısını belirlerken gözönüne alınması gerekenler aşağıda belirtilmiştir (Haykin, 1999):

- Yerel özellikler ilk saklı katmanda seçilmektedir. Özellikle giriş değerleri kendi içinde bölgelere ayrılmakta ve bu bölgesel özellikler öğrenilmektedir.
- Bütünsel özellikler ikinci saklı katmanda seçilmektedir. Özellikle birinci saklı katmandan elde edilen bölgesel çıktıları bütünselleştirmekte ve böylelikle genelleme yaparak bütünsel özellikleri öğrenmektedir.

YSA modeli kullanılarak, iki saklı katman yapısı kullanılarak herhangi bir doğrusal olmayan fonksiyona yaklaşım yapılabilen veya karışık bir sınıflandırma problemi için karar bölgesi bulunabilmektedir (Nielsen, 1989). Hornik ve Stinchcombe daha genel bir teorik sonuç ortaya koymuşlardır. Bu teoriye göre, tek saklı katmanlı ileri beslemeli bir YSA modeli ile herhangi bir sigmoid etkinlik fonksiyonuna sahip bir işlem birimi kullanarak, sınırlı boyuttaki bir uzaydan başka bir uzaya haritalama yapılabilir (Bebis, 1994). Bu yaklaşımlardan yola çıkarak, çok katmanlı perseptron yapısında en uygun sonucu verecek saklı katman yapısı, benzetim ver-

ileri kullanılarak incelenmiştir. YSA yapıları bir ve iki saklı katmandan oluşacak şekilde, saklı katmanlarındaki işlem birimi sayısını artırarak belirlenmeye çalışılmıştır. Giriş verisi enlem ve boylamdan oluştuğu için giriş katmanında iki işlem birimi kullanılmıştır. YSA çıkışında TEİ değeri elde edildiği için çıkışta bir işlem birimi kullanılmıştır. Değişen saklı katman işlem birimi sayılarıdır. Kullanılan modeller; 2-3-1 (M_1), 2-5-1 (M_2), 2-8-1 (M_3), 2-10-1 (M_4), 2-20-1 (M_5), 2-3-3-1 (M_6), 2-5-3-1 (M_7), 2-8-3-1 (M_8), 2-10-3-1 (M_9), 2-20-3-1 (M_{10}) çok katmanlı perseptron yapılarıdır. ($M_1, M_2, \dots, M_{10}$) gösterim kolaylığı olması için YSA modelleri yerine kullanılmaktadır.

Gözlemlenen sonuçlar öğrenme katsayısının 0.3, momentumun 0.6 olduğu durumda elde edilmiştir. Levenberg-Marquardt geri besleme öğrenme algoritması, "tansig" saklı katman etkinlik fonksiyonu, "purelin" çıkış katmanı etkinlik fonksiyonu kullanılmıştır. YSA algoritması başlangıç ağırlıklarını rasgele belirlediğinden dolayı, 6 farklı benzetim yüzeyi 13 farklı örnekleme çeşidi için, gürültülü ve gürültüsüz ortamda, 10 farklı YSA modeli kullanılarak üç kere çalıştırılmıştır. Elde edilen sonuçlarda, değişen saklı katman modellerinde bağıl hata ve en büyük bağıl hatanın en az değerini gösteren model en iyi model olarak belirlenmiştir. Birbirine çok yakın bağıl hata değerleri veren modellerden en az bağıl hata gözlenen seçilmiştir. Herbir model için algoritmanın eğişim, test ve sağlama verileri ile çalışma süresi saniye olarak tesbit edilmiştir. Çizelge 4.2 ve Çizelge 4.3'de homojen ve rasgele kare ızgara örneklemleri için elde edilen sonuçlar verilmiştir. Kullanılan toplam verinin eğitim, test ve sağlama verisi olarak kullanım adetleri sırasıyla verilmiştir. Diğer örneklemlerden elde edilen sonuçlar EK 1'de verilmiştir.

Veri sayısı değişimi YSA yöntemi için öğrenme verisinin artışından dolayı etkili bir parametredir. YSA modelinde F_5 ve F_6 benzetim yüzeylerinin hata oranları, veri sayısı artırıldığında iyileşmektedir. Şekil 4.13' den anlaşılabacağı gibi veri sayısı 44'e ulaştığında F_5 ve F_6 yüzeyleri için YSA'nın performansında iyileşme görülmektedir. Veri sayısı 84'e ulaştığında hata büyük bir ölçüde azalmaktadır.


Çizelge 4.2 ve Çizelge 4.3 elde edilen sonuçlar tek bir YSA saklı katman modelinde birleştirilmeye çalışılmıştır. Bu amaçla, hatanın belli bir ölçüde azaldığı 44 veri için $F_1, F_2, F_3, F_4, F_5, F_6$ benzetim yüzeyleri için Şekil 4.14'deki sonuçlar elde edilmiştir. 44 veri homojen kare ızgara örnekleme yapıları ile elde edilmiştir.

Fn.	Eğitim/Test/Sağlama	En iyi model	Δ	Δ_{max}	SÜRE (sn)
F_1	9/3/3	M_2	3.3×10^{-3}	1.6×10^{-1}	27.2
	14/5/5	M_1	1.1×10^{-14}	5.5×10^{-7}	30.4
	26/9/9	M_6	3.4×10^{-16}	9.9×10^{-8}	37.3
F_2	9/3/3	M_2	1.3×10^{-2}	2.6×10^{-2}	31.8
	14/5/5	M_1	3.2×10^{-8}	4.5×10^{-5}	30.8
	26/9/9	M_1	9×10^{-14}	1.8×10^{-7}	36.7
F_3	9/3/3	M_2	8.9×10^{-3}	6.8×10^{-2}	26.9
	14/5/5	M_1	2.8×10^{-3}	1×10^{-1}	27.1
	26/9/9	M_6	8.6×10^{-12}	5.7×10^{-6}	60.3
F_4	9/3/3	M_7	4.1×10^{-2}	3.1×10^{-1}	31.9
	14/5/5	M_3	2.2×10^{-2}	2.6×10^{-1}	31.4
	26/9/9	M_7	6.1×10^{-4}	7.8×10^{-2}	31.2
F_5	9/3/3	M_6	6.6×10^{-2}	4.4×10^{-1}	28.3
	14/5/5	M_3	4.5×10^{-2}	3.4×10^{-1}	31.2
	26/9/9	M_7	1.8×10^{-2}	3.8×10^{-1}	23.2
F_6	9/3/3	M_3	4.3×10^{-2}	3.2×10^{-1}	32.8
	14/5/5	M_1	4.1×10^{-2}	2.7×10^{-1}	33.2
	26/9/9	M_1	4.3×10^{-2}	2.8×10^{-1}	32.7


Çizelge 4.2. ÇKP ile 9, 24 ve 44 kare ızgara homojen dağılım ile elde edilmiş veri ile haritalama benzetim sonuçları

Fn.	Eğitim/Test/Sağlama	En iyi model	Δ	Δ_{max}	SÜRE (sn)
F_1	9/3/3	M_2	5.6×10^{-3}	1.1×10^{-1}	27.4
	14/5/5	M_6	1.1×10^{-14}	5.5×10^{-7}	32.9
	26/9/9	M_6	4.2×10^{-13}	2.2×10^{-7}	47.8
F_2	9/3/3	M_1	1.8×10^{-3}	1.1×10^{-1}	31.6
	14/5/5	M_1	1.1×10^{-9}	1.1×10^{-6}	46.4
	26/9/9	M_1	1.2×10^{-9}	1.2×10^{-4}	37.8
F_3	9/3/3	M_1	2.2×10^{-2}	2.9×10^{-1}	26.9
	14/5/5	M_6	1.5×10^{-3}	6.8×10^{-1}	27.2
	26/9/9	M_2	6.2×10^{-13}	1.6×10^{-6}	51.5
F_4	9/3/3	M_7	5.9×10^{-2}	3.1×10^{-1}	31.9
	14/5/5	M_6	1.5×10^{-3}	1.5×10^{-1}	31.3
	26/9/9	M_6	4.8×10^{-4}	6.1×10^{-2}	31.9
F_5	9/3/3	M_2	7.8×10^{-2}	7.1×10^{-1}	28.2
	14/5/5	M_9	4.6×10^{-2}	2.2×10^{-1}	31.6
	26/9/9	M_2	5.1×10^{-2}	3.1×10^{-1}	32.3
F_6	9/3/3	M_7	4.5×10^{-2}	2.7×10^{-1}	34.5
	14/5/5	M_6	2.8×10^{-2}	2.8×10^{-1}	33.1
	26/9/9	M_6	2.7×10^{-2}	3.2×10^{-1}	34.2

Çizelge 4.3. ÇKP ile 9, 24 ve 44 kare ızgara rasgele dağılım ile elde edilmiş veri ile haritalama benzetim sonuçları



Şekil 4.13. 2-5-3-1 ÇKP modeli ile F_6 ve F_5 benzetim yüzeyleri için veri sayısının hata oranına etkisi



Şekil 4.14. Homojen dağılımla elde edilmiş 44 veri ile ÇKP modelleri hata oranları değişimi


Şekil 4.14 incelendiğinde 2-5-3-1 (M_7) modelinin altı benzetim yüzeyi içinde iyi sonuç verdiği gözlenmiştir. Çizelge 4.4'de 2-5-3-1 ÇKP modeli için gözlemlenen bağıl hata oranları değişen veri sayıları için verilmiştir.

Fn.	Eğitim/Test/Sağlama	Kullanılan Model	Δ	Δ_{max}
F_1	9/3/3	M_7	3.4×10^{-3}	2.9×10^{-1}
	14/5/5		6.7×10^{-3}	1.2×10^{-1}
	26/9/9		1.04×10^{-12}	2.9×10^{-6}
F_2	9/3/3	M_7	9.6×10^{-2}	6.3×10^{-1}
	14/5/5		1.9×10^{-3}	7.8×10^{-2}
	26/9/9		6.33×10^{-8}	4.5×10^{-4}
F_3	9/3/3	M_7	6.2×10^{-1}	1.5×10^{-1}
	14/5/5		1.3×10^{-2}	3.7×10^{-1}
	26/9/9		1.44×10^{-4}	3.8×10^{-2}
F_4	9/3/3	M_7	4.1×10^{-2}	3.03×10^{-1}
	14/5/5		2.2×10^{-2}	5.0×10^{-1}
	26/9/9		1.1×10^{-3}	7.8×10^{-2}
F_5	9/3/3	M_7	9.03×10^{-2}	3.93×10^{-1}
	14/5/5		9.6×10^{-2}	4.4×10^{-1}
	26/9/9		1.8×10^{-2}	3.8×10^{-1}
F_6	9/3/3	M_7	7.8×10^{-2}	4.4×10^{-1}
	14/5/5		4.7×10^{-2}	3.2×10^{-1}
	26/9/9		4.6×10^{-2}	3.1×10^{-1}


Çizelge 4.4. Kare ızgara homojen dağılımla elde edilen 15, 24 ve 44 veri için M_7 (2-5-3-1) ÇKP modeli hata oranları

Çizelge 4.4'deki sonuçlardan anlaşılacağı gibi 2-5-3-1 modeli 44 veri kullanıldığında benzetim yüzeylerini 15 ve 24 veriye göre daha iyi modellemektedir. Bunun nedeni YSA modellerinde kullanılan veri sayısının ve bu verilerin dağılımının bağlı hata oranını etkileyen parametre olmasıdır.


Kare ızgara örnekleme yapılarak elde edilen 44 homojen veri için 2-5-3-1 YSA modeli ile elde edilen haritalar ve gerçek yüzey haritaları F_1 için Şekil 4.15'de, F_2 için Şekil 4.16'da, F_3 için Şekil 4.17'de, F_4 için Şekil 4.18'de, F_5 için Şekil 4.19'da, F_6 için Şekil 4.20'de verilmiştir.




Şekil 4.15. Düzlem yüzey (F_1) a) Benzetim yüzeyi haritası b) 2-5-3-1 ÇKP modeli ile 44 veri için elde edilen harita ($\Delta = 1.04 \times 10^{-12}$)




Şekil 4.16. Üssel yüzey (F_2) a) Benzetim yüzeyi haritası b) 2-5-3-1 ÇKP modeli ile 44 veri için elde edilen harita ($\Delta = 6.33 \times 10^{-8}$)




Şekil 4.17. Polinom yüzey (F_3) a) Benzetim yüzeyi haritası b) 2-5-3-1 ÇKP modeli ile 44 veri için elde edilen harita ($\Delta = 1.44 \times 10^{-4}$)



Şekil 4.18. Gauss yüzey (F_4) a) Benzetim yüzeyi haritası b) 2-5-3-1 ÇKP modeli ile 44 veri için elde edilen harita ($\Delta = 1.1 \times 10^{-3}$)




Şekil 4.19. Sombroso yüzey (F_5) a) Benzetim yüzeyi haritası b) 2-5-3-1 ÇKP modeli ile 44 veri için elde edilen harita ($\Delta = 1.8 \times 10^{-2}$)




Şekil 4.20. Üssel ve sinüsoidal yüzey (F_6) a) Benzetim yüzeyi haritası b) 2-5-3-1 ÇKP modeli ile 44 veri için elde edilen harita ($\Delta = 4.6 \times 10^{-2}$)

Çizelge 4.4, Şekil 4.15, Şekil 4.16, Şekil 4.17, Şekil 4.18, Şekil 4.19 ve Şekil 4.20 incelendiğinde F_1 , F_2 , F_3 , F_4 gürültüsüz yüzeyleri benzetim yüzeylerine iyi bir şekilde yakınsamaktadır. Bunun yanında F_5 ve F_6 için veri sayısı ve kullanılan YSA modeli

artırılarak yapılan testlerde veri sayısı artışının hata oranında azalmaya saklı katman işlem birimindeki artıştan daha etkili olduğu gözlenmiştir. F_5 ve F_6 yüzeyleri için veri sayısı ve YSA saklı katman sayısı artırılarak bağıl hata oranı azaltıldığında elde edilen haritalar Şekil 4.21 ve Şekil 4.22'de verilmiştir.




Şekil 4.21. Sombrero benzetim yüzeyi için 2-5-3-1 ÇKP modeli ve 85 veri ile elde edilen harita ($\Lambda = 1.2 \times 10^{-4}$)




Şekil 4.22. Üssel ve sinüsoidal yüzey için 2-20-10-1 ÇKP modeli ve 104 veri ile elde edilen harita ($\Delta = 1.7 \times 10^{-3}$)


Benzer durum gürültülü yüzeyler içinde geçerlidir. Veri sayısı arttıkça hata oranı azalmaktadır. Bunun yanında, YSA saklı katman işlem birimi sayısını gerekenden fazla artırdığımızda kullanılan veri sayısı az ise yaklaşım sonucu hatalı olacaktır. 2-5-3-1 modeli ile Poisson, ketleme ve altıgen dağılımlarda Üssel, Polinom ve Gauss yüzeylerinden elde edilen haritalar Şekil 4.23, Şekil 4.24, Şekil 4.25, Şekil 4.26, Şekil 4.27 ve Şekil 4.28’de verilmiştir.




Şekil 4.23. Polinom benzetim yüzeyi ve kullanılan 44 ketleme örnekleme




Şekil 4.24. Polinom benzetim yüzeyi için 44 ketleme örnek ile elde edilmiş 2-5-3-1 ÇKP modeli haritası ($\Delta = 3.2 \times 10^{-4}$)




Şekil 4.25. Gauss benzetim yüzeyi ve kullanılan 19 poisson kümeleme örnekleme



Şekil 4.26. Gauss benzetim yüzeyi için 19 poisson kümeleme örnek ile elde edilmiş 2-5-3-1 ÇKP modeli haritası ($\Delta = 1.3 \times 10^{-2}$)



Şekil 4.27. Üssel benzetim yüzeyi ve kullanılan 15 altıgen örnekleme



Şekil 4.28. Üssel benzetim yüzeyi için 15 altıgen örnekleme ile elde edilmiş 2-5-3-1 ÇKP modeli haritası ($\Delta = 1.1 \times 10^{-1}$)

4.1.4 Çok Katmanlı Perseptron ve Kriging Yöntemlerinin Karşılaştırılması

YSA algoritmasının performansını karşılaştırmak amacı ile, Kriging yönteminin performansı değişen yüzeyler ve örnekleme çeşitleri için incelenmiştir. Bu amaçla, Şekil 4.7'de verilen benzetim yüzeyleri ve Şekil 4.9'da verilen örnekleme yöntemleri kullanılmıştır. Kriging yöntemi ile elde edilen sonuçlar, YSA yöntemi ile elde edilen sonuçlarla karşılaştırılmaktadır. Değişen yüzeyler ve veri dağılımları için ilk önce deneysel yarıdeğişinti elde edilmiştir. Deneysel yarıdeğişinti değerlerine bir fonksiyon uyarlanarak teorik yarıdeğişinti bulunmuştur.

$$\gamma(h) = c_0 + c(1 - \exp(\frac{-h^2}{a^2})) \quad (4.14)$$

Gaussian teorik yarıdeğişinti değeri Eş. 4.14'de verilmiştir. c_0 külçe etkisi, h yaklaşım yapılmak istenen nokta ile ölçüm noktaları arası uzaklık, c yarıdeğişinti yapısal

Fn.	Veri Say.	[c ₀ c a]			Δ	Δ_{max}
F_1	15	0	12	8	1.5×10^{-4}	3.0×10^{-2}
	24	0	12	8	7.8×10^{-5}	2.2×10^{-2}
	44	0	16	12	1.1×10^{-5}	1.9×10^{-2}
F_2	15	0	20	10	1.9×10^{-3}	2.0×10^{-2}
	24	0	20	10	8.4×10^{-4}	1.6×10^{-2}
	44	0	20	10	7.6×10^{-5}	1.3×10^{-2}
F_3	15	0	14	4	4.1×10^{-3}	1.3×10^{-2}
	24	0	13	5	1.2×10^{-3}	0.6×10^{-2}
	44	0	13	5	1.2×10^{-4}	1.1×10^{-2}
F_4	15	0	7	3	3.1×10^{-2}	3.1×10^{-1}
	24	0	7	2	1.8×10^{-2}	2.6×10^{-1}
	44	0	8	3	3.8×10^{-3}	1.3×10^{-1}
F_5	15	0	8	2	6.5×10^{-2}	3.6×10^{-1}
	24	0	12	2	2.5×10^{-2}	2.7×10^{-1}
	44	0	12	2	1.2×10^{-2}	1.6×10^{-1}
F_6	15	0	3.5	5	8.1×10^{-2}	4.9×10^{-1}
	24	0	4.5	3	4.9×10^{-2}	3.3×10^{-1}
	44	0	5.5	2	2.8×10^{-2}	2.9×10^{-1}

Çizelge 4.5. Kriging yöntemi kullanarak kare ızgara homojen dağılım haritalama benzetim sonuçları

bileşenleri için düşey ölçek değeri, a erim değeri olarak adlandırılır. Deneysel yarıdeğişintiye göre, parametreleri belirlenen teorik yarıdeğişinti kullanılarak ağırlık vektörleri hesaplanır. Değişen veri dağılımlarına göre yaklaşımı yapılmak istenen noktalar ağırlık değerleri kullanılarak bulunur. Kriging yöntemi ile Eş. 4.1 ve Eş. 4.2'ye göre benzetim verileri kullanılarak hata oranı ve en büyük bağıl hata değerleri hesaplanmıştır.

Çizelge 4.2, Çizelge 4.3, Çizelge 4.5 ve Çizelge 4.6 incelendiğinde homojen dağılımlı 15 veri kullanıldığında YSA'nın Kriging yöntemine göre yaklaşık 0.05 oranında daha kötü sonuç verdiği gözlenmektedir. Rasgele dağılımda ve veri sayısı artırıldığında değişen benzetim yüzeyleri için YSA'nın sonuçları Kriging yöntemine göre aynı oranda iyileşmektedir.

Fn.	Veri Say.	[c ₀ c a]			Δ	Δ_{max}
F_1	15	0	4	5	6.5×10^{-3}	2.5×10^{-1}
	24	0	7	7	1.1×10^{-3}	1.2×10^{-1}
	44	0	11	10	0.1×10^{-3}	2.7×10^{-2}
F_2	15	0	5	6	2.4×10^{-2}	3.6×10^{-1}
	24	0	9	6	3.8×10^{-3}	2.2×10^{-1}
	44	0	14	7	0.6×10^{-3}	1.1×10^{-1}
F_3	15	0	9	5	2.2×10^{-2}	3.5×10^{-1}
	24	0	13	5	4.6×10^{-3}	2.2×10^{-1}
	44	0	13	5	1.0×10^{-3}	1.1×10^{-1}
F_4	15	0	16	4	2.8×10^{-2}	1.8×10^{-1}
	24	0	7	3	2.4×10^{-2}	2.9×10^{-1}
	44	0	8	3	1.3×10^{-2}	2.6×10^{-1}
F_5	15	0	8	3	6.1×10^{-2}	3.9×10^{-1}
	24	0	11	2	3.8×10^{-2}	2.8×10^{-1}
	44	0	8	2	2.1×10^{-2}	2.3×10^{-1}
F_6	15	0	8	2	4.0×10^{-2}	4.1×10^{-1}
	24	0	6	1	3.5×10^{-2}	3.1×10^{-1}
	44	0	5.5	2	2.6×10^{-2}	2.9×10^{-1}

Çizelge 4.6. Kriging yöntemi kullanarak kare ızgara rasgele dağılım haritalama benzetim sonuçları

4.2 Çok Katmanlı Perseptron Yöntemi ile İyonosfer Haritası

İyonosfer haritalama çalışmasında benzetim verileri ile YSA modellemesi yapılmıştır. YSA algoritmasının çalışma performansı test edilmiş ve YSA parametrelerinin nasıl belirleneceği hakkında bilgi sahibi olunmuştur. Çok katmanlı perseptron yapılarında kaç adet saklı katman bulunacağına dair kesin bir kanıt yoktur. İki katmanlı bir perseptron yapısının, herhangi doğrusal olmayan bir dönüşümü yapabilme kabiliyeti vardır. Bununla birlikte bu durum, daha fazla saklı katmana sahip perseptron yapısının daha uygun olmayacağını göstermez. İki katmanlı perseptronun çok sayıda işlem birimi gerektirdiği problemlerde üç katmanlı perseptron kullanılabilir. Çizelge 4.2 ve Çizelge 4.3 verilen sonuçlar incelendiğinde, homojen veri dağılımlarında iki katmanlı yapılarla iyi sonuçlar elde edilirken, rasgele dağılımlarda ve az sayıda verinin olduğu durumlarda üç katmanlı yapıların daha iyi sonuçlar verdiği görülmüştür.

YSA ile TEİ modelleme yaparken veri setlerinin dağılımının ve sayısının performansı nasıl etkilediği incelenmiştir. YSA modelinin çıktıları o andaki girdi değerlerine bağlıdır, bu durum örnekleme örüntülerini değiştirerek yapılan testlerde gözlenmiştir. Homojen dağılımların sonuçları rasgele dağılımlara göre daha iyi sonuç vermiştir.

Benzetim yüzeyleri incelendiğinde YSA'lar genellikle geçiş kısımlarını çok iyi öğrenmemişlerdir. Bu nedenle diğer yüzeylere göre geçişlerin keskin olduğu sombrero ve üssel sinüsoidel yüzeylerinde hata daha fazladır. Bunun nedeni global minimum değer yerine yerel minimumun bulunmasıdır. Momentum değerlerini değiştirerek YSA modelini test edip sistemi yerel minimumdan kurtarabilecek momentum değerine ulaşılmıştır, bu çalışma için momentum 0.6'dır. 2-5-3-1 saklı katman işlem birimi yapısı kullanıldığında değişen benzetim yüzeyleri ve örnekleme çeşitleri için ortalamada en az hataya ulaşılmıştır. Veri dağılımı ve sayısı YSA performansını etkileyen etmenlerin en önemlisidir.

Sonraki bölümde 2-5-3-1 saklı katman yapısı kullanılarak D-TEİ yöntemi ile elde edilen veriler ve IRI verileri için iyonosfer haritaları oluşturulacaktır.


4.2.1 D-TEİ verileri ile İyonosfer Haritası

D-TEİ yöntemi ile Şekil 4.29'da verilen YKS istasyonları için kesin bir gün olan 7 Ekim 2004 tarihinde elde edilmiş TEİ verileri kullanılmıştır (Center, 1990). Bu çalışmada ÇKP yapısı 2-5-3-1, öğrenme oranı 0.6, momentum 0.3 alınmıştır. 00:00, 06:00, 12:00, 18:00, 23:00 saatleri için haritalama yapılmıştır. Şekil 4.30, Şekil 4.31, Şekil 4.32, Şekil 4.33 ve Şekil 4.34'de verilen TEİ haritalarının güneşin gün içindeki hareketine göre beklendiği şekilde değiştiği gözlenmiştir.


Şekil 4.29'da verilen 9 YKS istasyonundan 7'sinden elde edilen TEİ değerleri eğitim verisi olarak, 2'si ise test istasyonu olarak kullanılmıştır. Bu şekilde yapılan aradeğerleme çalışmasında test istasyonları için ölçüm değerleriyle ÇKP çıkışı arasındaki fark değerleri (ρ) ve haritalama yapılan saatler için eğitim ve test istasyonlarından elde edilen hata kare toplamı (sse) değerleri Çizelge 4.7'de verilmiştir.

saat	Test Verisi1 için ρ	Test Verisi2 için ρ	Test verisi için sse	Eğitim verisi için sse
00:00	0.33 TECU	1.5 TECU	3.1×10^{-1}	2.9×10^{-21}
06:00	0.20 TECU	1.11 TECU	8.6×10^{-1}	2.6×10^{-19}
12:00	0.3 TECU	1.33 TECU	3.2×10^{-1}	1.7×10^{-18}
18:00	0.18 TECU	1.89 TECU	4.1×10^{-1}	1.144×10^{-15}
23:00	0.29 TECU	1.21 TECU	0.9×10^{-1}	1.6×10^{-17}


Çizelge 4.7. 2-5-3-1 YSA modeli kullanılarak D-TEİ yöntemi ile elde edilen veriler için ionosfer haritası hata değerleri




Şekil 4.29. 7 Ekim 2004 YKS istasyonları aradeğerleme çalışması




Şekil 4.30. 7 Ekim 2004, saat 00:00, 9 veri ile 2-5-3-1 ÇKP modeli kullanılarak elde edilmiş iyonosfer haritası




Şekil 4.31. 7 Ekim 2004, saat 06:00, 9 veri ile 2-5-3-1 ÇKP modeli kullanılarak elde edilmiş iyonosfer haritası



Şekil 4.32. 7 Ekim 2004, saat 12:00, 9 veri ile 2-5-3-1 ÇKP modeli kullanılarak elde edilmiş iyonosfer haritası




Şekil 4.33. 7 Ekim 2004, saat 18:00, 9 veri ile 2-5-3-1 ÇKP modeli kullanılarak elde edilmiş iyonosfer haritası



Şekil 4.34. 7 Ekim 2004, saat 23:00, 9 veri ile 2-5-3-1 ÇKP modeli kullanılarak elde edilmiş iyonosfer haritası

9 YKS istasyonu için test verisi dağılımı Şekil 4.35'deki gibi olduğunda ÇKP yapısı test noktası için dışdeğerleme yapmaktadır ve test istasyonları için ölçüm değerleriyle ÇKP çıkışı arasındaki fark değeri (ρ), Çizelge 4.8'de verilmiştir.

Yapılan bölgesel haritalama çalışmasında veri sayısı az olmasına rağmen ölçüm verileri ile ÇKP modelinden elde edilen TEİ değerleri arasındaki fark (ρ) değeri 0.18



Şekil 4.35. 7 Ekim 2004 YKS istasyonları dışdeğerleme çalışması

saat	Test Verisi1 için ρ
00:00	0.86 TECU
06:00	0.18 TECU
12:00	2.1 TECU
18:00	0.72 TECU
23:00	0.31 TECU

Çizelge 4.8. 2-5-3-1 YSA modeli kullanılarak D-TEİ yöntemi ile elde edilen veriler için ionosfer haritası hata değerleri

TECU ile 2.1 TECU arasında değişmektedir. Veri sayısı artırıldığında maksimum hatanın azalması beklenmektedir.

4.2.2 IRI Verileri ile İyonosfer Haritası



IRI haritalarından 7 Ekim 2004 tarihinde $44^{\circ} - 55^{\circ}$ E, $0^{\circ} - 15^{\circ}$ N bölgesi için örnek-leme yapılarak elde edilen TEİ verileri kullanılarak ÇKP ile bölgesel ionosfer haritaları oluşturulmuştur (IRI, 2001). IRI internet sitesinden elde edilen veriler GPSTool(ver 4.1) programı kullanılarak hazırlanmıştır. Bu çalışmada ÇKP yapısı 2-5-3-1, öğrenme oranı 0.6, momentum 0.3 alınmıştır. ÇKP, rasgele seçilmiş 15, 24 ve 44 veri ile eğitilmiş ve sırasıyla 3, 6, 12 veri ile test edilmiştir. Elde edilen iy-

ionosfer haritaları IRI haritaları ile karşılaştırılmıştır. Test noktalarındaki hata kare toplamı ve ölçüm değeri ile ÇKP farkını ifade eden ρ değerleri Çizelge 4.9'da verilmiştir. Çizelge 4.9'da ayrıca ÇKP ile elde edilen haritaların 1° aralıklarla enlemde 11 nokta , boylamda 16 nokta olmak üzere toplam 176 nokta için bağıl hata değerleri verilmiştir. 7 Ekim 2004 saat 00:00 için 15 veri kullanılarak, 2-5-3-1 ÇKP modeli için elde edilen ionosfer haritası ve IRI haritası Şekil 4.36'de verilmiştir.

Kullanılan Eğitim Verisi	Bağıl Hata	sse	ρ
15	3.7×10^{-3}	9.3×10^{-2}	0.3 TECU
24	1.9×10^{-3}	4.6×10^{-4}	0.02 TECU
44	1.09×10^{-4}	3.4×10^{-4}	0.01 TECU

Çizelge 4.9. IRI verileri ile elde edilen YSA haritaları bağıl hata değerleri (07.10.2004 saat 00:00)

Sinir Ağları yapısı, bu tür çalışmalarda kabul görmüş IRI verileri üzerinden oluşturduğu harita Çizelge 4.9 ve Şekil 4.36 ele alındığında başarılı bir model olduğu görülmektedir.



Şekil 4.36. 7 Ekim 2004 saat 00:00 a) IRI haritası b)2-5-3-1 YSA modeli 15 rastgele veri ile elde edilmiş TEİ haritası


5. YİNELEMELİ AĞ İLE DİNAMİK İYONOSFER HARİTASI BENZETİMLERİ

Önceki bölümde, çok katmanlı perseptron yapısı kullanılarak TEİ haritaları oluşturulmuştur. Çok katmanlı perseptron geri besleme içermeyen durağan bir model olduğundan, oluşturulan haritalar anlıktır ve iyonoser haritalarının zamanla değişimi incelenememektedir. Bu bölümde, Yinelemeli Ağ yapısı ile Gerçek Zamanlı Yinelemeli Öğrenme (GZYÖ) algoritması kullanılarak TEİ değerlerinin zamansal değişimi incelenecektir.

5.1 YA ile Gerçek Veri Uygulamaları

TEİ değerlerinin zaman içindeki değişimini inceleyebilmek için dinamik ağlara ihtiyaç duyulmaktadır. Bu amaçla geri besleme içeren YA yapısı ve GZYÖ algoritması kullanılacaktır.

Şekil 5.1'de GZYÖ algoritmasının şematik gösterimi verilmiştir (De Vries B., 1992). $u(s,t)$, $s_0 < s < s_f$ örnek uzayının, $t_0 < t < t_f$ zaman aralığındaki değişimini göstermektedir.



Şekil 5.1. GZYÖ şematik gösterimi

Herhangi bir anda $u(s,t)$ 'nin belirlenen bir zaman aralığındaki değerleri GZYÖ algoritmasına giriş olarak uygulanmaktadır. Bu aralık pencere (ws) olarak adlandırılır. ws aralığı üç farklı şekilde seçilebilir.

- ws , t_0 'dan t_f 'e kadar olan zaman aralığının tümünü kapsar. Bütün veriler GZYÖ

algoritmasına bir defada uygulandığı için algoritma durağan yapıya dönüşmektedir.

- ws , t_0 ve t_f aralığının bir bölümü olarak seçilebilir. Bu durumda, $u(s,t)$ 'nin ws aralığı kadar olan bölgesi giriş olarak YA'ya uygulanır ve bu bölge zaman boyutunda kaydırılarak tüm giriş uzayı taranır. Bu uygulama, kayan pencere tekniği olarak isimlendirilir.
- $ws \rightarrow 0$ olarak seçilirse kayan pencere tekniğinin uç bir durumu oluşur. Bu durumda YA'ya, her defasında $u(s,t)$ 'nin o anki değeri uygulanır.

Bu çalışmada kayan pencere tekniği uygulanmıştır. Oluşturulan YA modelinin girişi belirli zaman aralıkları ile örneklenmiş TEİ değerleri, çıkışı ise öngöründe bulunulması istenilen zamana ait TEİ değeridir. YA ile yapılan çalışmalarda Hers istasyonuna ait 7 Ekim 2004 ve 11 Ekim 2004 tarihleri arasında elde edilen D-TEİ yöntemiyle düzgünleştirilmiş veriler kullanılmıştır. Zaman boyutunda beş günlük verilerden 15 dakikalık örneklemeler yapılarak eğitim için veri setleri oluşturulmuştur. Elde edilen sonuçlarla hata kare toplamaları hesaplanarak, algoritma performansı incelenecektir.

D-TEİ yöntemi ile elde edilen TEİ verileri kullanılarak, zaman boyutunda girişlerin sayısını belirleyecek olan pencere büyüklüğü, çıkışı belirleyecek olan öngörü basamağı, hata oranını değiştiren durum-uzay değişkeni sayısı ve öğrenme oranı gibi YA parametrelerinin kestirim sonuçlarına etkisi incelenmiştir.

5.1.1 YA Parametrelerinin Belirlenmesi


YA performansını etkileyen önemli parametreler işlem birimi sayısı (q), öğrenme oranı (lr) ve pencere büyüklüğüdür (ws). Bu çalışmada, YA yapısı TEİ verileri ile eğitilmektedir ve TEİ verileri 24 saatlik periyotlarda değişim göstermektedir. Bu nedenle pencere büyüklükleri 6, 12, ve 24 alınmıştır. İşlem birimi 5, 15 ve 30 için öğrenme oranı değiştirilerek en az hata ile bir basamaklı öngörü için YA performansı incelenmiştir. YA modelleri hata kare toplamaları Çizelge 5.1'de verilmiştir. En az hatanın gözlemlendiği noktalar koyu renkle belirtilmiştir.

Çizelge 5.1'den anlaşılacağı gibi pencere büyüklüğü ve işlem birimi sayısı azaldığında, en az hataya ulaşmak için öğrenme oranı artırılmalıdır. Pencere küçük seçildiğinde TEİ değerlerindeki küçük değişimler daha iyi takip edilebilmektedir, büyük seçildiğinde

		Öğrenme Oranı (lr)															
ws	q	0.5	1	1.5	2	2.5	3	3.5	4	4.5	5	5.5	6	6.5	7	7.5	8
6	2	6.46	3.74	2.55	1.9	1.4	1.21	1.01	0.83	0.75	0.66	0.58	0.52	0.46	0.44	0.34	0.43
6	5	5.23	2.82	1.77	1.3	1.01	0.84	0.65	0.58	0.48	0.45	0.4	0.35	0.33	0.29	0.35	0.71
6	15	2.65	1.18	0.75	0.53	0.44	0.38	0.32	0.34	0.94	1.13						
6	30	1.15	0.55	0.44	1.11	1.41	1.71										
12	2	5.28	2.77	1.76	1.29	0.99	0.78	0.67	0.53	0.48	0.52						
12	5	4.29	2.19	1.33	1.01	0.76	0.60	0.50	0.40	0.56							
12	15	2.44	1.04	0.70	0.49	0.45	0.76	1.80									
12	30	1.11	0.63	0.57	2.36	3.4											
24	2	2.79	1.27	0.77	0.51	0.63											
24	5	2.23	1.02	0.60	0.40	1.13	1.93										
24	15	1.21	0.50	0.30	2.37	5.66											
24	30	0.57	2.97	4.20	8.10	8.30	9.01										

Çizelge 5.1. Pencere ve işlem birimi değerlerine göre YA performansının değişimi


ise daha pürüzsüz bir çıkış eğrisi elde edilmektedir. İşlem birimi sayısı çok azaltıldığında (2'ye indirildiğinde) veriyi öğrenmede işlem birimi yetersiz kalmaktadır. TEİ verileri ile yapılan incelemelerde, pencere büyüklüğü 24 alındığında işlem birimi 15, öğrenme oranı 1.5; pencere büyüklüğü 6 alındığında işlem birimi sayısı 5, öğrenme oranı 7 alınmalıdır. Şekil 5.2'de elde edilen YA sonuçları ve hata değişimleri verilmiştir. Pencere büyüklüğü 6 ve işlem birimi 5 alındığında öğrenme başlangıcında hata değeri daha büyük olmaktadır. Bunun nedeni kullanılan hafızanın küçük olmasıdır.



Şekil 5.2. Brus istasyonu için 7-11 Ekim 2004 tarihleri arasında elde edilen veriler ile $ws = 24$, $q = 15$ ve $lr = 1.5$ değişkenleri için a) YA Sonuçları ve Gerçek Veriler b) YA Hata Değişimi

5.1.2 Öngörü Basamağı

Öngörü basamağındaki değişime göre hata kare toplamı Şekil 5.3'de verilmiştir. Hers istasyonuna ait 7 ve 26 Ekim 2004 tarihleri arasında elde edilen D-TEİ yöntemiyle düzgünleştirilmiş veriler kullanılmıştır. Zaman boyutunda 20 günlük verilerden bir saatlik örneklemeler yapılarak eğitim için veri setleri oluşturulmuştur. Pencere büyüklüğü 24, öğrenme oranı 1.5 ve işlem birimi sayısı 15 alınmıştır bu değerler Çizelge 5.1'de verilen en uygun parametrelerdir. GZYÖ algoritması kullanılarak, öngöründe bulunmak istenilen TEİ verisinin öngörü basamağı artırıldıkça Eş. 4.3'e göre hata kare toplamı (sse) arttığı gözlenmiştir.



Şekil 5.3. Öngörü basamağındaki değişim için YA hata kare toplamı (sse)

5.2 Seçilen YA ile Elde Edilen TEİ Öngörüsü ve Haritalama

Çizelge 5.2'de verilen YKS istasyonları için 7 - 11 Ekim 2004 tarihleri arasında bir saatlik örneklemeler ile oluşturulan veri seti kullanılarak GZYÖ algoritması ile bir basamaklı öngörü yapılmıştır. Pencere büyüklüğü 24, öğrenme oranı 1.5 ve işlem birimi sayısı 15 alınmıştır. D-TEİ yöntemi ile elde edilmiş gerçek veri ve GZYÖ algoritması öngörü değeri Çizelge 5.2'de verilmiştir. d , öngöründe bulunulan anın gerçek değeri, y ise GZYÖ algoritması ile elde edilen değeri olup birimleri TECU'dur. ws ise GZYÖ sonuçlarının her bir istasyon için bağıl hata değerini vermektedir.

Dokuz istasyon için 2-5-3-1 ÇKP yapısına gerçek veriler uygulanarak Şekil 5.5'da verilen TEİ haritası elde edilmiştir. Şekil 5.4 blok şemasında gösterildiği gibi GZYÖ algoritması ile dokuz istasyonun bir saat sonraki TEİ değeri için öngöründe bulunul-


Kısa İsim	Enlem	Boylam	d (TECU)	y (TECU)	ρ (TECU)	Δ
Brus	50,47°	4,21°	10.12	10.499	0.379	0.0014
Hers	50,68°	0,34°	9.61	10.01	0.4	0.0018
Ieng	44,84°	7.63°	11.69	12.00	0.31	0.0007
Kosg	51,99°	5,81°	9.02	9.79	0.77	0.0073
Obet	47,89°	11,3°	10.2	10.92	0.72	0.0052
Opmt	48,5°	2,2°	11.56	11.65	0.09	0.0001
Ptbb	52,11°	10,46°	8.87	9.41	0.54	0.0037
Wsrt	52,73°	6,6°	9.80	10.65	0.85	0.0077
Wtzt	48,9°	12,88°	9.96	10.28	0.32	0.0011

Çizelge 5.2. YA ile yapılan çalışmalarda kullanılan YKS istasyonları ve herbir istasyon için YA ile elde edilen öngörü hatası


muştur. Bu değerlerle, 2-5-3-1 ÇKP modeli kullanılarak, Çizelge 5.3'de verilen hata ile bir saat sonrası için iyonosfer haritası elde edilmiştir. GZYÖ algoritması ile öngöründe bulunularak elde edilen iyonosfer haritası Şekil 5.6'de verilmiştir. Elde edilen iki harita arasında 0.0086 değerinde bağıl hata vardır.

Harita	Eğitim verisi sse	Test verisi sse
YA öngörü haritası	4.59×10^{-20}	1.1×10^{-1}
Gerçek veri ile harita	5.9×10^{-21}	5.2×10^{-1}


Çizelge 5.3. YA ve ÇKP birlikte kullanılarak elde edilen ionosfer haritasının hata değerleri



Şekil 5.4. YA ile öngöründe bulunan YKS istasyonlarının 2-5-3-1 ÇKP modeli ile birlikte kullanımı




Şekil 5.5. YKS istasyonlarından elde edilen gerçek veriler kullanılarak 2-5-3-1 ÇKP modeli ile oluşturulmuş iyonosfer haritası



Şekil 5.6. YKS istasyonları için YA ile öngörülen veriler kullanılarak 2-5-3-1 ÇKP modeli ile oluşturulmuş iyonosfer haritası

5.3 Seçilen YA ile Elde Edilen Statik Ağın Performans Analizi


GZYÖ algoritması ile ağırlık değerleri zaman içinde dinamik olarak değiştirilmektedir. Brus istasyonu için 7 - 26 Ekim 2004 tarihleri arasında bir saatlik örnekleme ile oluşturulmuş TEİ verileri 15 işlem birimi, 24 pencere büyüklüğü, 1.5 öğrenme oranı kullanılarak dinamik olarak eğitildiğinde Şekil 5.7'de verildiği gibi bir saatlik öngöründe bulunulur.



Şekil 5.7. Brus istasyonu için 7-26 Ekim 2004 tarihleri arasında 400 veri ile a) YA sonuçları b) Hata değerleri

Aynı veri setinin belirli bir kısmında YA eğitilir ve ağırlıklar dinamik olarak değişim gösterip, veri setinin kalan kısmına sabitlenen ağırlık değerleri uygulanabilir. Bu durumda hata öğrenme için kullanılan veri setinin büyüklüğüne bağlı olarak değişmektedir. 200 öğrenme verisi, 250 test verisi ve 300 öğrenme verisi, 150 test verisi

kullanılarak hata değışimi incelenmiş, 300 veri ile YA eğitildiğinde hata miktarındaki değışimin daha az olduđu gözlenmiştir. GZYÖ algoritması 200 veriyle eğitildiğinde elde edilen ağırlık vektörü sonraki iki basamağı, 10^{-1} 'in altında hata ile öngörebilmektedir. Eğitim veri sayısı 300'e çıkarıldığında ise sonraki dört basamak 10^{-1} 'in altında hata ile öngörölür. Brus istasyonu için 300 saatlik verinin, 10 çevrim boyunca eğitilmesi ile elde edilen ağırlık değeri, 150 saatlik veriyle test edildiğinde test verisi için elde edilen hata kare toplamı 0.15'dir. Şekil 5.8'da elde edilen sonuçlar verilmiştir.



Şekil 5.8. Brus istasyonu için 7-26 Ekim 2004 tarihleri arasında 300 eğitim verisinin 10 çevrimle eğitilmesi , 100 test verisi sonuçları a) YA sonuçları b) Hata değeri

6. SONUÇ

TEİ haritalama, YKS istasyonlarından ölçülen TEİ değerleri kullanılarak, aradeğerleme ve dışdeğerleme yöntemleriyle, konumda ve zamanda ölçüm yapılamayan yerlerdeki TEİ değerlerinin bulunması ve bir araya getirilmesidir. İyonosfer, en büyük elektron yoğunluğunun olduğu yükseklikte bulunan ve elektronların tümünü içeren ince bir küresel kabuk olarak düşünülür. Bu da ionosferi iki boyutlu modelleme imkanı sunar. Bu çalışmada YSA yöntemlerinden ÇKP ile anlık ionosfer haritası oluşturulmuş, YA ve öğrenme algoritması GZYÖ ile TEİ değerlerinin zamansal değişimi incelenmiştir.

Kullanılan ÇKP modelinin giriş değerlerini enlem ve boylam verileri, çıkış değerlerini ise TEİ verisi oluşturmaktadır. ÇKP parametrelerinin haritalama başarımına etkisini inceleyebilmek için farklı benzetim yüzeyleri ve veri dağılımları kullanılmıştır. Oluşturulan benzetim yüzeyleri 1°'lik aralıklarla enlemde 7, boylamda 21 olmak üzere toplam 147 ızgara noktasından oluşmaktadır. Homojen ve rasgele dağılmış 15, 24, ve 44 veri için ÇKP ile elde edilen haritaların bağıl hata değerleri incelenmiştir. 44 veri ile keskin geçişlerin olmadığı benzetim yüzeylerinde bağıl hata ortalama 10^{-5} 'dir. Yüzeyindeki geçişlerin keskin olduğu benzetim yüzeylerinde ise bağıl hata 10^{-2} 'dir. Hatanın azaltılabilmesi için veri sayısının artırılması gerekmektedir. Altıgen, poisson ve ketleme dağılımlarında ise bağıl hatanın ortalama 10^{-2} olduğu gözlenmiştir. Kullanılan benzetim yüzeylerinin haritasını oluşturmak için 2-5-3-1 ÇKP modelinin yeterli olduğu görülmüştür. 15 Mayıs 2003 tarihinde IRI haritasından yapılan örnekleme verileri 2-5-3-1 ÇKP modeline uygulanmış ve rasgele dağılmış 15 veri için 10^{-4} bağıl hata elde edilmiştir. Başarılı bir benzetim gerçekleştirilmiştir.

ÇKP ile yapılan haritalama çalışmaları, birbaşka YSA yöntemi olan Radyal Tabanlı Ağlar (RTA) ile kıyaslandığında, ÇKP yönteminin YKS istasyonunun az olduğu durumlarda RTA'ya göre daha iyi sonuç verdiği gözlenmiştir (Gürün, 2007). IRI haritalarının örneklenmesi ile elde edilen veriler ile iki yöntemde eğitilmiş ve veri sayısının artırılması RTA'nın performansını ÇKP'ye göre artırdığı gözlenmiştir (Gürün et al, 2007).

ÇKP ve Kriging yöntemleri kullanılarak yapılan haritalama çalışmalarında, homojen dağılımlı veri kullanıldığında YSA'nın Kriging yöntemine göre daha kötü sonuç verdiği gözlenmektedir. Rasgele dağılımda ve veri sayısı artırıldığında değişen ben-

zetim yüzeyleri için YSA'nın sonuçları Kriging yinönemine göre aynı oranda iyileşmektedir.

YA yapısı, GZYÖ algoritması ile kullanılarak TEİ değerlerinin zamansal değişiminin etkileri incelenmiş ve tek istasyon için zamansal öngörüler elde edilmiştir. Oluşturulan YA modelinin girişi belirli zaman aralıkları ile örneklenmiş TEİ değerleri, çıkışı ise öngöründe bulunulması istenilen zamana ait TEİ değeridir. YA'nın hafıza içeren yapısı sayesinde tek bir istasyon için ortalama 0.003 hata oranında bir saatlik öngöründe bulunulabilmektedir. Bu çalışmada Çizelge 5.2'de verilen 9 YKS istasyonu için 7-11 Ekim 2004 tarihlerindeki TEİ değerleri kullanılarak YA ile elde edilen bir saat sonraki TEİ verileri 2-5-3-1 ÇKP modeline uygulanarak iyonosfer haritaları oluşturulmuştur. Daha önce YSA yöntemleri iyonosfer haritalama çalışmalarında kullanılmakta iken bu çalışma kapsamında YA ve ÇKP yapıları bir arada kullanılmıştır.

D-TEİ yöntemi ile elde edilen ve belirli bir zaman aralığındaki TEİ verileri GZYÖ algoritmasına uygulanmıştır. GZYÖ algoritması 200 veriyle eğitildiğinde elde edilen ağırlık vektörü sonraki iki basamağı, 10^{-1} 'in altında hata ile öngörebilmektedir.

Bu çalışmada iyonosfer haritalarının oluşturulmasında YSA yöntemi birçok yönü ile incelenmiş; YSA'nın, iyonosferin bölgesel haritalarının oluşturulmasında gözönüne alınması gereken alternatif bir yöntem olduğu ortaya konulmuştur.

7. EKLER

7.1 EK 1: Benzetim Verileri ile YSA Test Sonuçları

YSA saklı katman modellerinin değişen benzetim yüzeyleri, örneklemeler ve gürültü faktörlerine karşı performansının incelendiği test sonuçları tablolar halinde verilmiştir.

F _n .	Eğitim/Test/Sağlama	En iyi model	Δ	Δ_{max}	SÜRE (sn)
F_1	9/5/5	M_3	2×10^{-3}	1.9×10^{-1}	47.7
F_2	18/9/9	M_6	5.6×10^{-3}	8.2×10^{-2}	51.7
F_3	18/9/9	M_1	7.9×10^{-3}	2.9×10^{-1}	21.9
F_4	9/5/5	M_6	1.6×10^{-1}	1	24.1
F_5	10/5/5	M_{10}	1.1×10^{-1}	5.8×10^{-1}	23.3
F_6	18/10/10	M_7	4.4×10^{-2}	2.1×10^{-1}	22.9

Çizelge 7.1. Poisson küme örnekleme modeli

Fn.	Eğitim/Test/Sağlama	En iyi model	Δ	Δ_{max}	SÜRE (sn)
F_1	7/4/4	M_1	1.6×10^{-3}	1.6×10^{-1}	25.4
	11/5/5	M_1	4.3×10^{-3}	3.3×10^{-1}	30.1
	48/25/25	M_1	3.9×10^{-4}	8.9×10^{-2}	44.4
F_2	7/4/4	M_1	9×10^{-3}	2.2×10^{-1}	25.7
	11/5/5	M_1	2.3×10^{-3}	4.5×10^{-3}	26.2
	48/25/25	M_1	1.3×10^{-10}	3.4×10^{-5}	33.7
F_3	7/4/4	M_6	6×10^{-2}	4.6×10^{-1}	25.6
	11/5/5	M_2	4.2×10^{-2}	4.9×10^{-1}	25.9
	48/25/25	M_2	7.9×10^{-4}	1.9×10^{-2}	36.3
F_4	7/4/4	M_{10}	10×10^{-2}	5.2×10^{-1}	30.3
	11/5/5	M_9	3.3×10^{-2}	3.7×10^{-1}	31
	48/25/25	M_6	1.8×10^{-4}	4.8×10^{-2}	30.2
F_5	7/4/4	M_{10}	1.2×10^{-1}	3.7×10^{-1}	25.4
	11/5/5	M_{10}	4.7×10^{-2}	4.9×10^{-1}	25.3
	48/25/25	M_7	1.3×10^{-2}	7×10^{-1}	25.8
F_6	7/4/4	M_{10}	4.5×10^{-2}	3.8×10^{-1}	25.2
	11/5/5	M_6	5.1×10^{-2}	2.6×10^{-1}	37
	48/25/25	M_4	2.7×10^{-2}	3.4×10^{-1}	25.5

Çizelge 7.2. Altıgen ızgara örnekleme modeli

Fn.	Eğitim/Test/Sağlama	En iyi model	Δ	Δ_{max}	SÜRE (sn)
F_1	7/4/4	M_2	1.8×10^{-2}	4.1×10^{-1}	25.1
	13/7/6	M_2	2.1×10^{-3}	1.6×10^{-2}	25.7
	22/11/11	M_2	1.4×10^{-3}	1.2×10^{-1}	35.9
F_2	7/4/4	M_1	2×10^{-2}	3.4×10^{-1}	29.6
	13/7/6	M_7	2.9×10^{-2}	1.6×10^{-1}	25.3
	22/11/11	M_1	7.8×10^{-4}	2.9×10^{-4}	26.4
F_3	7/4/4	M_1	7×10^{-2}	4.8×10^{-1}	30.4
	13/7/6	M_1	2.8×10^{-3}	1.2×10^{-1}	31.9
	22/11/11	M_1	3.9×10^{-4}	1.9×10^{-2}	29.9
F_4	7/4/4	M_1	5.8×10^{-2}	8.4×10^{-1}	29.9
	13/7/6	M_7	2.4×10^{-2}	1.9×10^{-1}	27.2
	22/11/11	M_8	8×10^{-3}	1.9×10^{-1}	23.7
F_5	7/4/4	M_6	7.1×10^{-2}	2.9×10^{-1}	30.1
	12/6/6	M_{10}	6.2×10^{-2}	5.5×10^{-1}	23.7
	22/11/11	M_7	4.1×10^{-2}	3.3×10^{-1}	27.3
F_6	7/4/4	M_7	8.3×10^{-2}	2.9×10^{-1}	22.7
	13/7/6	M_3	4.9×10^{-2}	3.9×10^{-1}	28.2
	22/11/11	M_3	3.9×10^{-2}	3.3×10^{-1}	28.2

Çizelge 7.3. Ketleme örnekleme modeli

F _n	Eğitim/Test/Sağlama	En iyi model	Δ	Δ_{max}	SÜRE (sn)
F_1	9/3/3	M_3	2.9×10^{-3}	1.6×10^{-1}	22.1
	14/5/5	M_2	1.7×10^{-3}	1×10^{-1}	22.1
	26/9/9	M_6	2.4×10^{-2}	7.8×10^{-2}	22.5
F_2	9/3/3	M_1	1.2×10^{-2}	1.2×10^{-1}	22.3
	14/5/5	M_1	3.3×10^{-3}	1.5×10^{-1}	22.4
	26/9/9	M_6	3.2×10^{-3}	1.7×10^{-1}	26.3
F_3	9/3/3	M_1	4.4×10^{-2}	3.2×10^{-1}	22.1
	14/5/5	M_1	3.1×10^{-3}	1.2×10^{-1}	22.1
	26/9/9	M_6	3.3×10^{-3}	1.8×10^{-1}	26.1
F_4	9/3/3	M_8	3.8×10^{-2}	3.3×10^{-1}	22.3
	14/5/5	M_2	1.3×10^{-2}	2.3×10^{-1}	22.1
	26/9/9	M_9	1.4×10^{-2}	2.2×10^{-1}	26.1
F_5	9/3/3	M_3	9.3×10^{-2}	3.2×10^{-1}	22.2
	14/5/5	M_3	7.1×10^{-2}	5.2×10^{-1}	22.2
	26/9/9	M_3	3.2×10^{-2}	4.3×10^{-1}	25.8
F_6	9/3/3	M_2	5.9×10^{-2}	4×10^{-1}	22.3
	14/5/5	M_1	4.3×10^{-2}	2.9×10^{-1}	22.1
	26/9/9	M_6	3.7×10^{-2}	2.8×10^{-1}	25.8

Çizelge 7.4. Gürültülü yüzeylerde homojon kare ızgara örnekleme modeli

Fn.	Eğitim/Test/Sağlama	En iyi model	Δ	Δ_{max}	SÜRE (sn)
F_1	7/4/4	M_7	3.2×10^{-2}	3×10^{-1}	20.9
	11/5/5	M_{10}	1.3×10^{-2}	3.5×10^{-1}	20.8
	48/25/25	M_6	5.2×10^{-3}	1.6×10^{-1}	20.5
F_2	7/4/4	M_8	3.2×10^{-2}	3.7×10^{-1}	21
	11/5/5	M_1	4.8×10^{-3}	1.6×10^{-1}	20.9
	48/25/25	M_1	2.6×10^{-3}	1.3×10^{-1}	21.4
F_3	7/4/4	M_8	6.6×10^{-2}	5.9×10^{-1}	21.1
	11/5/5	M_1	5.9×10^{-3}	1.6×10^{-1}	20.8
	48/25/25	M_2	2.5×10^{-3}	1.1×10^{-1}	21
F_4	7/4/4	M_8	4.5×10^{-2}	7.7×10^{-1}	22
	11/5/5	M_9	5.1×10^{-2}	3.2×10^{-1}	21.4
	48/25/25	M_7	1.3×10^{-2}	7.1×10^{-2}	20.7
F_5	7/4/4	M_6	1.1×10^{-1}	3.1×10^{-1}	22.1
	11/5/5	M_3	1.4×10^{-1}	3×10^{-1}	21.5
	48/25/25	M_{10}	6.2×10^{-2}	3.9×10^{-1}	20.8
F_6	7/4/4	M_6	5.2×10^{-2}	3.1×10^{-1}	21.7
	11/5/5	M_6	5.1×10^{-2}	3.3×10^{-1}	22.5
	48/25/25	M_4	3.7×10^{-2}	3.7×10^{-1}	21.1

Çizelge 7.5. Gürültülü yüzeylerde altıgen ızgara örnekleme modeli

Fn.	Eğitim/Test/Sağlama	En iyi model	Δ	Δ_{max}	SÜRE (sn)
F_1	7/4/4	M_{10}	4.4×10^{-2}	6.7×10^{-2}	22.2
	13/7/6	M_{10}	1.9×10^{-2}	2.7×10^{-1}	22.1
	22/11/11	M_1	1.4×10^{-2}	3.2×10^{-1}	22.3
F_2	7/4/4	M_1	1.2×10^{-2}	4.3×10^{-1}	23.4
	13/7/6	M_{10}	2.2×10^{-2}	4.1×10^{-1}	23.3
	22/11/11	M_1	3.7×10^{-3}	1.2×10^{-1}	24.9
F_3	7/4/4	M_2	2.5×10^{-3}	1.1×10^{-1}	20.6
	13/7/6	M_1	5.9×10^{-3}	1.6×10^{-1}	20.8
	22/11/11	M_8	6.6×10^{-2}	5.9×10^{-1}	21
F_4	7/4/4	M_3	1.2×10^{-2}	1.2×10^{-1}	20.5
	13/7/6	M_9	5.1×10^{-2}	3.2×10^{-1}	21.4
	22/11/11	M_7	4.5×10^{-2}	7.7×10^{-1}	21.9
F_5	7/4/4	M_1	6.7×10^{-2}	3.1×10^{-1}	20.9
	13/7/6	M_3	1.4×10^{-1}	3×10^{-1}	21.5
	22/11/11	M_6	1.1×10^{-1}	3.1×10^{-1}	22.1
F_6	7/4/4	M_6	3.7×10^{-2}	3.7×10^{-1}	21.1
	13/7/6	M_1	5.1×10^{-2}	3.3×10^{-1}	22.5
	22/11/11	M_6	5.2×10^{-2}	3.1×10^{-1}	21.7

Çizelge 7.6. Gürültülü yüzeylerde ketleme örnekleme modeli

Fn.	Eğitim/Test/Sağlama	En iyi model	Δ	Δ_{max}	SÜRE (sn)
F_1	17/8/8	M_8	7.6×10^{-2}	1.8×10^{-1}	32.9
F_2	10/5/5	M_2	1.5×10^{-2}	2.3×10^{-1}	22.1
F_3	12/7/7	M_1	1.3×10^{-2}	2.2×10^{-1}	22
F_4	13/7/7	M_3	8.1×10^{-2}	4.1×10^{-1}	21.8
F_5	16/8/8	M_1	6×10^{-2}	6.8×10^{-1}	22
F_6	13/6/6	M_8	4.8×10^{-2}	3.6×10^{-1}	22

Çizelge 7.7. Gürültülü yüzeylerde Poisson küme örnekleme modeli

KAYNAKLAR DİZİNİ

- Altınay, O., 1996, Nonlinear black-box modeling of ionospheric critical frequency process using neural networks, Master's thesis, Department of Electrical and Electronics Engineering, The Middle East Technical University, Ankara.
- Arıkan et al, F., Erol C.B. Arıkan O., 2003, Regularized estimation of vertical total electron content from global positioning system data, *Journal of Geophysical Research*. 118, 1469–1480.
- Bebis, G., Georgiopolus M., 1994, Optimal feed-forward neural network architectures, *Department of Electrical Computer Engineering University of Central Florida, Orlando*.
- Bordenave, C., Torrisi G.L., 2006, Large deviations of poisson cluster processes. Center, Ionospheric Dispatch, 1990, <http://www.cbk.waw.pl/rwc/q d days.cfl>.
- Cheng, D.K., 1995, *Field and Wave Electromagnetics*, Addison-Wesley Publishing Company-Canada.
- David, M., 1982, *Geostatistical Ore Reserve Estimation*, Elsevier Scientific Publishing Company.
- De Jesus, O., Hagan M.T., 2007, Backpropagation algorithms for a broad class of dynamic networks, *IEEE Transactions on Neural Networks*.
- De Vries B., Principe J. C., 1992, The gamma model - a new neural model for temporal processing, *Neural Networks* 5(22), 565–576.
- Gürün et al, M., Akdoğan K.E. Yılmaz A., 2007, Yapay sinir ağları kullanılarak bölgesel iyonosfer haritalaması, *Sinyal İşleme ve İletişim Uygulamaları Kurultayı SİU 2007*.
- Gürün, M., Akdoğan K.E. Yılmaz A., 2007, Regional ionosphere mapping by using neural network, *Recent Advances in Space Technologies, RAST 2007*.
- Hartman, G.K., R. Leitingner, 1984, Range errors due to ionospheric and tropospheric effects for signals above 100 mhz, *Bulletin Geodesique* 58, 109–136.
- Haykin, S., 1999, *Neural Networks A Comprehensive Foundation*, Prentice Hall International.
- Hernandez-Pajares, M., Juan J.M. Sanz J., 1999, New approaches in global ionospheric determination using ground gps data, *Journal of Atmospheric and Solar-Terrestrial Physics* (61), 1237–1247.
- Hetch, N.R., 1989, Theory of the backpropagation neural network, *IJCNN International Joint Conference* 1, 593–605.
- Hofmann-Wellenhof, B., 2001, *GPS Theory and Practice*, Springer WienNewYork.
- Hornik, K., Stinchcombe M. White H., 1989, Multilayer feedforward networks are universal approximators, *Neural Networks* 2, 359–366.

- Ionex 1998, <ftp://igs.ensg.ign.fr/pub/igs/iono>.
- IRI 2001, <http://nssdc.gsfc.nasa.gov/space/model/models/iri.htm>.
- Jin, S., Wang J. Hossain Z., 2005, Monitoring ionospheric behaviours over australia using gps-derived tec, Technical report.
- Jin, S., Wang J. Zhang H. Zhu W., 2004, Real-time monitoring and prediction of ionospheric electron content by means of gps, *Chinese Astronomy and Astrophysics* 28(3), 6331–337.
- Kaplan, E.D., 1996, *Understanding GPS Principles and Applications*, Artech House Publishers - Boston,London.
- Kılınç, İ., 2002, Haberleşme Şebekelerinde Hata Yönetimi Analizi, PhD thesis, Hacettepe Üniversitesi, Ankara, Türkiye.
- Komjathy, A., 1997, Global Ionospheric Total Electron Content Mapping Using the Global Positioning System, PhD thesis, Department of Geodesy and Geomatics Engineering Technical Report No. 188 University of New Brunswick Fredericton, New Brunswick, Kanada, 248s.
- Kumluca, A., 1997, Neural Network Modelling of an Ionospheric Process: Temporal and Spatial forecasting of the critical frequency, PhD thesis, Ortadoğu Teknik Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
- Lazo, B., Calzadilla A. Alazo K. Rodríguez M. González J.S., 2004, Regional mapping of f2 peak plasma frequency by spherical harmonic expansion, *Advances in Space Research* 33(6), 880–883.
- Leandro, R.F., Santos M.C., 2004, Regional computation of tec using neural network model, *Department of Geodesy and Geomatics Engineering University of New Brunswick,Fredericton,Canada*.
- Liao, X., 2000, Carrier phase based ionosphere recovery over a regional area gps network, Master's thesis, Department of Geomatics Engineering,The University of Calgary,Calgary,Kanada.
- Marquez, L., Hill T., 1992, Function approximation using backpropagation and general regression neural networks,system sciences, *Proceeding of the Twenth - Sixth Hawaii International Conference* 4, 607–615.
- McKinnel, L.A., Poole A. W. V., 2004, Neural network based ionospheric modelling over the south african region, *South African Journal of Science*.
- Misra, P., Enge P., 2001, *Global Positioning System Signals, Measurements and Performance*, Ganga-Jamuna Press,Massachusetts.
- Moon, Y., 2004, Evalution of 2-dimensional ionosphere models for national and regional gps networks in canada, Master's thesis, The University of Calgary, Calgary, Alberta, Canada.

- Nayir, H., 2007, Yerküresel konumlama sistemi işaretleri kullanarak iyonosfer toplam elektron içeriği kestirimi, Master's thesis, Fen Bilimleri Enstitüsü, Elektrik ve Elektronik Mühendisliği Anabilim Dalı, Hacettepe Üniversitesi, Ankara.
- Nelles, O., 2001, *Nonlinear System Identification*, Springer-Verlag Berlin Heidelberg.
- Nielsen, R., 1989, Theory of the backpropagation neural networks, *Proc. Inter. Joint Conf. Neural Networks* 1, 593–611.
- Orús 2005, Improvement of global ionospheric vtec maps by using kriging interpolation technique, *Journal of Atmospheric and Solar-Terrestrial Physics* (67), 1598–1609.
- Patterson, D.W., 1996, *Artificial Neural Networks Theory and Applications*, Prentice Hall.
- Poggio, T., Girosi F., 1990, Networks for approximation and learning, *IEEE*.
- Rivoirard, J., 1984, *Le Comportement Des Poids de Krigeage*, These de Docteur Ingenieur en Sciences et Techniques Minieres, E.N.S.M.P.
- Schaer, S., 1999, Mapping and Predicting the Earth's Ionosphere Using the Global Positioning System, PhD thesis, Astronomical Institute, University of Bern, Bern, Switzerland.
- Skone, S., 1998, Wide Area Ionosphere Grid Modelling in the Auroral Region UCGE Reports Number 20123, PhD thesis, The University of Calgary, Calgary, Alberta, Canada.
- Stengel, R.F., Ferrari S., 2005, Smooth function approximation using neural network, *IEEE Transactions* 16, 125–143.
- Tercan, A.E., 1996, Maden yatakları sınır belirsizliğinin indikatör kriging ile değerlendirilmesi ve sivas-kangal-kalburçayırı kömür yatagında bir uygulama, *Madencilik Dergisi*.
- Wielgosz, P., Brzezinska D. Kashani I., 2003, Regional ionosphere mapping with kriging and multiquadric method, *Journal of Global Pos. Sys.* 2(1), 48–55.
- Yurtoğlu, H., 2005, *Yapay Sınır Ağları Metodolojisi ile Öngörü Modellemesi*, Devlet Planlama Teşkilatı.
- Zolesi, B., Cander L.R., 1991, Review of progress in ionospheric mapping, *Il Nuovo Cimento* 14(2), 153–169.

ÖZGEÇMİŞ

Adı Soyadı : MELİKE GÜRÜN
Doğum Yeri : Ankara
Doğum Yılı : 21.11.1979
Medeni Hali : Bekar

Eğitim ve Akademik Durumu

Lise 1990-1997 : Ç.E.K Anadolu Lisesi, KAHRAMANMARAŞ
Lisans 1997-2002 : Hacettepe Üniversitesi
Elektrik ve Elektronik Mühendisliği Bölümü,
ANKARA

Yabancı Dil : İngilizce

İş Tecrübesi

2002-2005 : ROKETSAN
ANKARA
Mühendis
2005-..... : TÜBİTAK-UZAY
ANKARA
Mühendis

YAPAY SİNİR AĞLARI KULLANILARAK BÖLGESEL İYONOSFER HARİTALAMASI

REGIONAL IONOSPHERE MAPPING BY USING NEURAL NETWORKS

Melike Gürün

Tübitak Uzay, ODTÜ, Ankara
melike.gurun@uzay.tubitak.
gov.tr

Kurtuluş Erinç Akdoğan

Elektrik ve Elektronik
Mühendisliği Bölümü,
Hacettepe Üniversitesi, Ankara
kurtulus@ee.hacettepe.edu.tr

Atila Yılmaz

Elektrik ve Elektronik
Mühendisliği Bölümü,
Hacettepe Üniversitesi, Ankara
ayilmaz@hacettepe.edu.tr

Özetçe

Doğrusal olmayan bir yapıya sahip olan iyonosferin bölgesel haritalaması, iyonosferin rastgele yapısını incelemek için yararlıdır. Bu çalışmada, çok katmanlı perseptron ve radyal tabanlı ağlar kullanılarak iyonosfer haritalaması yapılmaktadır. Yapay yüzeylerin üzerinde performansları karşılaştırılan bu iki model, gerçek TEİ verilerine uygulanarak, bölgesel iyonosfer haritalaması yapılmaktadır.

Abstract

Regional ionosphere mapping is necessary to analyze the unknown distribution structure of ionosphere. In this paper, mapping ionosphere over a chosen region is realized by using multilayer perceptron and radial basis networks. Performances of two networks on artificial surfaces are compared and these neural networks are applied on real TEC values to obtain regional ionosphere mapping.

1. Giriş

İyonosfer yeryüzünden yaklaşık 60 km ile 1100 km arasındaki yükseklikte yer alan bir atmosfer tabakasıdır[1]. İyonosferin, radyo dalgalarının yayılımında, uydu ve yer istasyonu arasındaki radyo link bağlantılarında, haberleşme, güdüm ve gözetleme radarlarında büyük bir önemi vardır [2]. İyonosferin etkilerini tam olarak anlayabilmek ve haberleşme sistemlerinde yol açtığı hata değerlerini belirleyebilmek için iyonosferde ki değişimleri takip etmek gerekmektedir. İyonosfer haritalama çalışmaları bu amaçla yapılmaktadır.

İyonosfer yapısının kısa ve uzun dönemli değişimi, yapıdaki düzensizlikler ve bozulmalar, Toplam Elektron İçeriği (TEİ) incelenerek gözlemlenmektedir. TEİ 1m² kesitli bir silindirik boyunca toplam serbest elektron miktarıdır. Birimi TECU ile ifade edilir (1 TECU = 10¹⁶ el/m²). Yerküresel Konumlama Sistemi (YKS) kullanılarak elde edilen TEİ verileri ile iyonosferin bölgesel haritaları oluşturulmaktadır. Literatürde Kriging, Multiquadratic[3,4], küresel harmonikler[5], ince katmanlı spline[6] gibi çeşitli aradeğerlendirme yöntemleri kullanılmış ve haritalama performansları karşılaştırılmıştır. Gözlem yapılamayan yerler için TEİ kestirimi yapılarak küresel ve yerel iyonosfer haritaları oluşturulmuştur. TEİ haritalama çalışmalarında kullanılan yöntemlerden biri de Yapay Sinir Ağları (YSA)'dır. YSA yöntemi, doğrusal olmayan fonksiyonları modelleyebilme özelliğinden dolayı iyonosferin modellenmesi için uygundur. Haritalama yaparken YSA kullanmanın bir

diğer avantajı ise doğrusal olmayan yapı hakkında modele ait içsel bağlantıların bilinmemesine rağmen giriş çıkış veri setini kullanılarak modellemenin mümkün olmasıdır [7]. YSA'nın kullanılabilir sonuçlar vermesi için, amaca uygun olarak tasarlanması, hücreler arasındaki bağlantıların doğru yapılması ve bağlantıların uygun ağırlıklara sahip olması gerekmektedir. Evrensel Fonksiyon Yakınsayıcı olarak tanınmasından dolayı tahmin ve öngörü gibi verinin içerdiği yapının tanımlanmasını gerektiren alanlarda sıkça kullanılmaktadır [8]. Bu çalışmada Geri Yayılım Algoritması ile çok katmanlı perseptron yapısı (ÇKP) ve Radyal Tabanlı Ağlar (RTA) kullanılarak TEİ haritaları oluşturulması hedeflenmiştir.

İlk bölümde kullanılan YSA yöntemleri olan ÇKP ve RTA'nın yapısı hakkında bilgi verilmektedir. İkinci bölümde RTA ve ÇKP yapılarının farklı örnek sayıları ve farklı yapay yüzeyleri için yapılan benzetimlerden elde edilen hata oranları hesaplanmaktadır. Elde edilen hata oranları kullanılarak belirlenecek olan ÇKP ve RTA sinir ağı yapıları kullanılarak, belirli bir benzetim yüzeyi için veri sayısı değişiminin hata oranlarına etkisi incelenmektedir. Son bölümde, ÇKP ve RTA yöntemleri kullanılarak elde edilen yüzeylerdeki hata oranları göz önüne alınarak, gerçek TEİ verilerinden bölgesel iyonosfer haritaları oluşturulmaktadır.

2. Sinir Ağları

İyonosfer hakkındaki bilgilerimiz, dünya üzerinde konumlanmış, belirli sayıdaki alıcılardan, belirli zaman aralıklarıyla elde edilen TEİ değerleri ile sınırlıdır. Bu yüzden, iyonosferin anlık durumunu gösteren bir harita elde etmek için aradeğerlendirme yapacak yöntemlere ihtiyaç vardır. Bu yöntemlerden birisi de parametrik bağlanım yapan ve güdümlü öğrenen sinir ağları yapısıdır. İyonosferin haritalaması için sinir ağlarının doğrusal olmayan fonksiyonları, modelleyebilme özelliği kullanılacaktır.

2.1. Çok Katmanlı Perseptron

Çok Katmanlı Perseptron, sinir hücresi adı verilen birbirine bağlı işlem elemanlarından oluşmuş, paralel işleyen yapılardır[9]. Girişler, YKS istasyonlarından alınan enlem ve boylam bilgileridir. Ağırlıklar, girişin etkisini belirleyen katsayılardır. İşlem birimleri arasındaki bağlantıların ağırlıkları, öğrenme sürecinde değişir ve giriş çıkış ilintisi bu bağlantıların ağırlıkları ile tanımlanır. İşlem birimlerinde kullanılan ağırlık değerlerini elde etmek için geri yayılım algoritması kullanılmaktadır. Girişler ağırlıklarla çarpılarak

toplanır, eşik değeri eklenerek etkinlik fonksiyonuna girer. Doğrusal olmayan etkinlik fonksiyonu sinir hücrelerinin çıkışını sınırlamak için kullanılır. Etkinlik fonksiyonu olarak hiperbolik tanjant fonksiyonu kullanılmıştır. Bu yapı, doğrusal olmayan bir fonksiyonu modelleyebilecek güçtedir. Ancak, saklı katmanlardaki sinir hücresi sayısının iyi belirlenmesi gerekmektedir. Bu çalışmada, benzetim yüzeyleri kullanılarak, iyonosfer haritalama çalışmasında kullanılabilecek en uygun ÇKP parametreleri belirlenmiştir.


2.2. Radyal Tabanlı Ağlar

RTA, ÇKP gibi sinir hücrelerinden oluşmasına karşın, yöntem ve yapı olarak ÇKP'den farklılıklar göstermektedir. Her iki yöntem de aynı sorunları farklı yaklaşımlarla çözmektedir. ÇKP genel bir yaklaştırma yaparken, RTA, eğitim için kullanılan verilere, yerel olarak yaklaştırma yapar[9]. Yapısal olarak, en temel farklılık katman sayılarında ve bu katmanların işlevinde ortaya çıkmaktadır.

ÇKP ile çözülebilen tüm problemler, RTA ile de çözülebilmektedir. Ancak her iki yöntemin, yaklaşım farklılığından kaynaklanan birbirlerine göre olumlu ve olumsuz yanları vardır. RTA'nın tasarımı, ÇKP'nin tasarımına göre kolay olmasına karşın, eğitime yani katsayıların ayarlanma süresi daha uzun sürmektedir. RTA'nın yerel yaklaştırma yapması, daha çok test verisine ihtiyaç duymasına yol açmaktadır. Bu özelliklere sahip olan RTA, doğrusal olmayan fonksiyonların modellenmesinde oldukça başarılıdır.

3. Benzetimler

Bu çalışmada benzetimler MATLAB NNET Toolbox paket programı kullanılarak gerçekleştirilmiştir. Bölgesel iyonosfer haritalaması için Türkiye'nin bulunduğu 26°-46° boylamları, 36°-42° enlemleri arasında kalan bölge seçilmiştir. Benzetim yüzey haritaları 1° aralıklarla, enlemde 7 nokta, boylamda 21 nokta olmak üzere toplam 147 nokta için oluşturulmaktadır. Veri setleri oluşturulan harita üzerinde homojen kare ızgara ve rastgele kare ızgara olarak Şekil 1'de gösterildiği gibi yerleştirilmektedir.




Şekil 1: Örneklem çeşitleri ve seçilen iyonosfer bölgesi

Bu örnekleme yöntemleri, modellerin test aşamasında veri dağılımının performans etkisinin incelenmesinde kullanılmaktadır. Seçilen bu bölge için dört farklı yapay yüzey üretilmektedir. Kullanılan benzetim yüzeylerinin matematiksel ifadeleri denklem 1,2,3 ve 4 'de gösterilmektedir. Şekil 2 'de bu fonksiyonların seçilen bölgede aldığı değerler yer almaktadır.

RTA ve ÇKP yöntemleriyle, homojen ve rastgele örnekleme, 15 veri kullanılarak ara değerlendirme yapılmaktadır. Yapılan benzetimlerde, YSA modellerine giriş olarak verilen enlem ve boylam değerlerinin [-1, +1] arasına normalize edilmesi ile aradeğerlendirme hatasının azaldığı

gözlenmiştir. Bu nedenle ÇKP ve RTA girdileri normalize edilerek kullanılmaktadır.



Şekil 2: Yapay iyonosfer yüzeyleri

$$f_1(x, y) = 0.1x + 0.26y \quad (1)$$

$$f_2(x, y) = \exp\left(\frac{x-26}{5}\right) \quad (2)$$

$$f_3(x, y) = 2817 - 72x + 78y + x^2 + y^2 \quad (3)$$

$$f_4(x, y) = 8.91e^{\left(-\left(\frac{(x-34)}{5}\right)^2 + \left(\frac{(y-39)}{2}\right)^2 + \frac{(x-1)(y-1)}{-7.1}\right)} \quad (4)$$

$$\Delta = \frac{\sum_{n=1}^N |f(X_n) - F(W, X_n)|^2}{\sum_{n=1}^N |f(X_n)|^2} \quad (5)$$

Bağıl hata, bir yüzey için bütün kestirim hatalarının karelerinin toplamının gerçek değerlerin karelerinin toplamına oranıdır. Denklem 5'te Δ bağıl hata, N kestirimin yapıldığı toplam nokta sayısı, $f(X_n)$, n 'inci noktadaki gerçek değeri, $F(W, X_n)$, n 'inci noktadaki kestirim değerini göstermektedir.

Kullanılan benzetim yüzeyleri, homojen ve rastgele olmak üzere farklı şekillerde ve farklı örnek sayıları ile örneklenebilir. Örneklenen verilerle eğitilen sinir ağları, benzetim yüzeylerini yeniden oluşturmak için kullanılmaktadır. Üretilen yüzeyler, kaynak yüzeylerle karşılaştırılarak, RTA ve ÇKP yapılarının farklı örnek sayıları ve farklı benzetim yüzeyleri için yapılan benzetimlerden elde edilen bağıl hata değerleri hesaplanmaktadır. Elde edilen hata oranlarından belirlenecek olan ÇKP ve RTA sinir ağı yapıları kullanılarak, her bir benzetim yüzeyi için rastgele örneklenen verinin sayısının değişiminin hata oranlarına etkisi incelenmektedir. Yapay yüzeylerin, tekrar oluşturulmasında ortaya çıkan bağıl hata değerleri göz önünde bulundurularak ve en uygun ÇKP ve RTA yapıları kullanılarak benzetimler gerçekleştirilmektedir.

3.1. ÇKP Benzetimleri

ÇKP yöntemi ile benzetimler 2-3-1 (M_1), 2-5-1 (M_2), 2-8-1 (M_3), 2-10-1 (M_4), 2-20-1 (M_5), 2-3-3-1 (M_6), 2-5-3-1 (M_7), 2-8-3-1 (M_8), 2-10-3-1 (M_9), 2-20-3-1 (M_{10}) yapıları kullanılarak gerçekleştirilmektedir. Tablo 1'de homojen durum için elde edilen en az bağıl hata miktarları gösterilmektedir. Farklı yüzeyler için farklı ÇKP yöntemlerinin en az hatayı verdiği gözlenmektedir. Tablo 1'de homojen durum için elde edilen en az bağıl hata miktarları gösterilmektedir. Rastgele dağılım, üssel yapay yüzey hariç diğer yüzeylerde bağıl hatanın artmasına yol açmıştır. Rastgele durum için de farklı yüzeyler için farklı ÇKP yöntemlerinin en az hatayı verdiği gözlenmektedir.

Tablo 1: 15 Homojen veri dağılımı için bağıl hata değerleri


Fonksiyon	Düzlem	Üssel	Polinom	Gauss
Bağıl Hata	3.3×10^{-3}	1.3×10^{-2}	8.9×10^{-3}	4.1×10^{-2}
En iyi model	M ₂	M ₂	M ₂	M ₇

Tablo 2: 15 rastgele veri dağılımı için bağıl hata değerleri

Fonksiyon	Düzlem	Üssel	Polinom	Gauss
Bağıl Hata	5.6×10^{-3}	1.8×10^{-3}	2.2×10^{-2}	5.9×10^{-2}
En iyi model	M ₂	M ₁	M ₁	M ₇

YKS istasyonlarının rasgele dağıldığı varsayılarak, tüm yüzeyler için gerçek verilerle kullanılacak bir ÇKP yapısı belirlenebilir. Şekil 3'de her bir yüzey için 15 rastgele veri ile YSA modellerinden elde edilen bağıl hata oranları verilmiştir. Şekil 3'ten anlaşılacağı gibi M₇ modeli her bir yüzeyi, bağıl hata değerleri açısından en uygun şekilde modellemektedir.


M₇ modeli kullanarak veri sayısını artışının benzetim yüzeylerine etkisi Şekil 4'te verilmiştir. Sonuçlardan da anlaşıldığı gibi 2-5-3-1 (M₇) ÇKP modeli kullanıldığında veri sayısı artırılarak herhangi iki boyutlu bir fonksiyona yaklaşım yapılabilir. Veri sayısı az olduğunda belirli bir oranda hata olduğu göz önüne alınmalıdır.



Şekil 3: Rastgele durumda ÇKP modelleri için bağıl hata değerleri

3.2. RTA Benzetimleri

Paket programın fonksiyonunun parametresi olan yayılma (spread) katsayısının (YK) seçimi yaklaştırmanın hatasının belirlenmesinde önemlidir. Eğer YK olması gerekenden küçük seçilirse, yaklaştırmanın sonucu pürüzlü bir yüzey olmakta, olması gerekenden büyük seçilirse yaklaştırmanın sonucu düz bir yüzey olmaktadır. Çeşitli yüzey ve örnekleme yöntemleri için yapılan benzetimlerde, YK, bağıl hata miktarını en aza indirecek şekilde seçilmektedir.



Şekil 4: ÇKP için veri sayısına göre BHO değişimi

RTA benzetimlerinde, herbir yüzey için seçilen örnekleme çeşidi ve örnek sayısına göre, çıkışta en az bağıl hatayı verecek YK, 0-1 aralığından seçilmesi gerekmektedir. Tablo 3'te bağıl hata değerleri ve en az hatayı veren YK gösterilmektedir. Homojen örnekleme durumunda, en az bozulan yüzeyin, en az değişime sahip olan doğrusal düzlem yüzeyi olduğu görülmektedir. Tablo 3'teki bağıl hata sonuçlarına göre ise, RTA'nın en çok hata yaptığı yüzey Gauss yüzeyi olarak belirlenmektedir.


Tablo 3: 15 Homojen veri dağılımı için bağıl hata değerleri

Fonksiyon	Düzlem	Üssel	Polinom	Gauss
Bağıl Hata	4×10^{-4}	4.9×10^{-3}	3.6×10^{-3}	32.8×10^{-3}
YK	1	0.45	0.71	0.61

Tablo 4: 15 rastgele veri dağılımı için bağıl hata değerleri

Fonksiyon	Düzlem	Üssel	Polinom	Gauss
Bağıl Hata	3.5×10^{-3}	18.5×10^{-3}	7×10^{-3}	4.9×10^{-3}
YK	1	1	1	0.48

Rastgele örnekleme durumu için RTA yöntemi ile elde edilen bağıl hata değerleri, Tablo 4'te gösterilmektedir. Gauss yüzeyi hariç, diğer tüm yüzeyler için bağıl hata oranları, homojen durumdakilerden büyüktür. Bu durum için de en az hata düzlem yüzeyinde elde edilmiştir. Veri sayısının, bağıl hataya etkisi, dört yüzey için Şekil 5'te gösterilmektedir. Verilerin gerçek durumda olduğu gibi rastgele dağıldığı varsayılmıştır. Gauss yüzeyi hariç diğer tüm yüzeyler için 44 veri sayısına kadar hatanın belirgin bir şekilde düştüğü gözlenmektedir. Veri sayısı artırıldığında ise hata miktarının değişimi azalmaktadır. Bu benzetimde en çok sinir hücresi sayısı 12 olarak seçilmiştir.




Şekil 5: RTA için veri sayısına göre BHO değişimi

4. İyonosfer Haritalama


Avrupa üzerindeki YKS istasyonlarından elde edilen veriler kullanılarak ÇKP ve RTA yöntemleri ile iyonosfer haritaları oluşturulmaktadır. Şekil 6'da dokuz gerçek TEİ verisinin bulunduğu konum gösterilmektedir. Bu verilerden yedi tanesi YSA'yı eğitmek için iki tanesi ise test etmek için kullanılmaktadır. Bu benzetim için, ÇKP yapısı olarak seçilen M₇ kullanılmaktadır. RTA yapısı için KK, en az hatayı veren en olarak belirlenmiştir. En çok sinir sayısı parametresi ise, test verisi sayısına eşit seçilmiştir.

Bölgesel iyonosfer haritalaması için, Şekil 6'da gösterilen Avrupa üzerinde bulunan 0°-15° boylamları, 44°-54° enlemleri arasında kalan bölge seçilmiştir. Benzetim yüzey haritaları 1° aralıklarla, enlemde 11 nokta, boylamda 16 nokta olmak üzere toplam 176 nokta için oluşturulmaktadır. Şekil 7'de, dört farklı saat için ÇKP ve RTA'dan elde edilen sonuçlar gösterilmektedir. Tüm şekillerde, güneşin iyonosfer

tabakasına olan etkisi ve enlemin etkisi gözlenmektedir. TEİ değeri, yüksek enlemlerde ve soğuk bölgelerde düşmektedir. Saat 18:00'daki haritalama sonuçları hariç, genel olarak ÇKP ve RTA'nın sonuçları birbirleriyle örtüşmektedir.



Şekil 6: Test noktaları ve seçilen iyonosfer bölgesi



Şekil 7: 07 Ekim 2004 tarihli gerçek veriler için, 00:00, 06:00, 12:00 ve 18:00 saatleri için RTA ve ÇKP sonuçları

Tablo 5'te, ÇKP ve RTA'nın test noktalarında oluşan, ortalama hatalar kare değerleri gösterilmektedir. Bu değerler incelendiğinde saat 00:00 ve 06:00 için ÇKP'nin daha az hata yaptığı, diğer saatlerde ise RTA'nın daha az hata yaptığı ortaya

çıkılmaktadır. Veri sayısının dokuz ile sınırlı olmasında dolayı, RTA'nın yapacağı hatanın ÇKP'ye göre yüksek olması beklenmektedir. Bu kısıtlamaya rağmen, RTA'nın ve ÇKP sonuçları birbirlerini desteklemektedir. Yapay yüzeyler de yapılan benzetimler göz önünde bulundurularak, veri sayısı arttırıldıkça hata miktarının azalacağı ve RTA'nın, ÇKP'den daha iyi sonuçlar vereceği beklenmektedir.

Tablo 5: Test verilerinden elde edilen ortalama kare hatalar

	saat 00:00	saat 06:00	saat 12:00	saat 18:00
Model	0.156	0.435	0.164	0.518
ÇKP				
RTA	0.176	1.351	0.044	0.220

5. Sonuç

Bu çalışmada farklı koşulların sonuçlara etkisi ve bu koşullarda RTA ve ÇKP'nin haritalama sonuçları incelenmiş ve karşılaştırılmıştır. Homojen ve rastgele örnekleme performansına olan etkisi incelendiğinde, RTA'nın homojen durumda daha az hata üretirken, ÇKP'nin farklı yapılarının ürettiği hata miktarının, homojen ve rastgele durum için farklılıklar gösterdiği gözlenmiştir. Genel olarak farklı koşullar için yapay yüzeylerde RTA, ÇKP'ye göre daha az hatalı sonuçlar vermiştir. Ancak veri sayısı arttırıldığında, RTA'nın, ÇKP'ye göre çıkış vermesi yavaşlamaktadır. Az sayıda gerçek veri kullanıldığında ise iki yöntemin performansları yakın çıkmıştır. Bu makalede yapılan çalışmalar, belirli koşullar için gerçekleştirilmiştir. Farklı örnekleme çeşitleri için, üzerine gürültü bindirilerek gerçek TEİ değerlerine daha çok yaklaşan yapay veriler kullanılarak, YSA'nın performansının araştırılması sonraki çalışmaların konusu olacaktır.

6. Teşekkür

Bu çalışma TÜBİTAK EEAG 105E171 tarafından desteklenmektedir.

7. Kaynakça

- [1] Arıkan, F., Erol C.B. Arıkan O., 2003, Regularized estimation of vertical total electron content from global positioning system data, Journal of Geophysical Research.118, 1469–1480.
- [2] Cheng, D.K., 1995, Field and Wave Electromagnetics, Addison-Wesley Publishing Company-Canada.
- [3] Wielgosz, P., Brzezinska, D., Kashani, I., Regional Ionosphere mapping with Kriging and Multiquadric method, 2003, Journal of Global Pos. Sys., vol. 2, no.1, 48-55.
- [5] Schaer, S. (1999). Mapping and Predicting the Earth's Ionosphere Using the Global Positioning System, PhD dissertation, Astronomical Institute, University of Bern, Switzerland.
- [6] Moon, Y., 2004, Evaluation of 2-dimensional ionosphere models for national and regional networks in Canada, Master's thesis, The University of Calgary, Calgary, Alberta, Canada.
- [7] McKinnel, L.A., Poole A. W. V., 2004, Neural network based ionospheric modelling over the south african region, South African Journal of Science.
- [8] Hornik, K., Stinchcombe M. White H., 1989, Multilayer feedforward networks are universal approximators, Neural Networks 2, 359–366.
- [9] Haykin, S., 1999, Neural Networks A Comprehensive Foundation, Prentice Hall International.

Regional Ionosphere Mapping By Using Neural Networks

Melike Gürün¹, Kurtuluş Erinc Akdoğan², Atila Yılmaz³

¹Tübitak Uzay, melike.gurun@uzay.tubitak.gov.tr
ODTÜ, Ankara, Türkiye

²Elektrik ve Elektronik Mühendisliği Bölümü,
Hacettepe Üniversitesi, kurtulus@ee.hacettepe.edu.tr
Ankara, Türkiye

³Elektrik ve Elektronik Mühendisliği Bölümü,
Hacettepe Üniversitesi, ayilmaz@hacettepe.edu.tr
Ankara, Türkiye

Abstract-Regional ionosphere mapping is necessary to understand the underlying characteristics of ionosphere. In this paper, multilayer perceptrons and radial basis networks, as chosen neural network methods, are used to obtain a map of ionosphere based on a number of given (Total Electron Content) TEC values. For varying number of given data and locations, their performances are analyzed and compared. Their performances are also tested for artificially formed data points and they are applied to real data from GPS stations and IRI.

I. INTRODUCTION

Ionosphere mapping and modeling has been the subject of geophysicists and radio users to understand characteristics of ionosphere better and used to improve applications in radio-propagation. Ionosphere has important affects on the propagation of radio waves, links between satellite and ground stations, telecommunication, guidance and surveillance radars [1]. Depending on the short term and long term variations in ionosphere due to position of the sun and solar impacts, ionosphere causes errors on communication systems [2]. In order to determine errors caused by ionosphere and to analyze ionosphere's effect on these systems, it is needed to track the changes in the ionosphere. Regional ionosphere mapping gives opportunity to analyze random characteristics and to observe changes occurred in ionosphere in time [3].

Ionosphere is an atmosphere layer situated between 60 km and 1100 km distance from earth [4]. Long term and short term variations, irregularities in ionosphere are observed by using total electron content (TEC) values. TEC is defined as the number of free electrons along the ray path above one square meter on the ionosphere and its unit is represented as TECU ($1 \text{ TECU} = 10^{16} \text{ el/m}^2$) [4]. Ionosphere is a dispersive medium and this situation causes delays during the transmission of GPS (Global Positioning Systems) signals [3]. By using that fact, the influence of ionosphere on GPS signal can be computed by using dual frequency receivers to obtain TEC values [1]. Obtained TEC values are for a certain number of receiving stations and in order to obtain a regional map of ionosphere, these TEC values must be interpolated by a suitable method. Kriging, Multiquadratic [5, 6], Spherical Harmonics, Thin Plate Spline Interpolation [7] are some of frequently used methods to estimate TEC values for locations where

ionosphere can't be observed. These methods are used to form global and regional maps and their performances can be compared. In addition to these methods, neural networks (NN) methods are used to model ionosphere and gives a different approach for the solution [8]. NN method is appropriate to map ionosphere due to its capability to model nonlinear functions [9]. NN ensures that although the relation between chosen location and the corresponding TEC value it is not known, based on the measured data set, it is possible to guess a map of the ionosphere in a certain error margin. In order to make NN produce results with less error, the structure of NN must be designed according to specific application and the optimal weights of the internal connections between neurons must be adjusted reasonably. Due to fact that NN is well known as universal function approximator, it is frequently used in estimation and prediction for the cases where the structure of the given data is required to be defined [10]. In this study two NN methods, Multilayer Perceptron (MLP) and Radial Basis Networks (RBN), are analyzed and applied to obtain a map for ionosphere over a certain region.

In the first section, NN methods, MLP and RBN, are introduced and a summary about their structure and application areas is given. In the second section, instead of measured TEC values, artificial ionosphere surfaces are produced by using four functions chosen as examples of ionosphere distributions. Sampled points from these functions are used as inputs for the training of the NN as if they are measured TEC values and by using MLP and RBN, rests of the sampled surfaces are reconstructed. These simulations are repeated several times for different sampling methods and different number of samples to analyze the effects of them on mapping. In the following section for determined NNs, mapping is realized by using data obtained from International Reference Ionosphere (IRI) [11], and results are compared with maps provided by IRI. In the last simulation, mapping is done by using real TEC values obtained from stations located in Europe. Finally results are discussed and compared with each other.

II. NEURAL NETWORK

The regional behavior of ionosphere is modeled in a way that it is possible to estimate the TEC values inside or near the

region by using the measurement of TEC data on the limited number of GPS stations. NN is useful tool to predict values for a station either within or outside the network, due to the adaptation capability of NN training process. NN is information processing system formed by simple processing elements, called artificial neurons, or simply neurons [12]. For regional ionosphere mapping, function approximation property of NN is used. MLP and RBF networks are used to model TEC distribution in ionosphere. The input parameters of the neural network model are latitude and longitude, while the output parameter is regularized VTEC data. The structure of MLP for this application is given in Fig. 1.




Fig. 1. Structure of a MLP network

A. Multilayer Perceptrons

MLP consists of an input layer, one or more hidden layers, and an output layer [12]. Input and output layers are related to the input and output parameters of the training data. Hidden neurons enable the network to learn complex task by extracting progressively more meaningful features from the input patterns [12]. The model of each neuron in the network includes a nonlinear activation function. A neuron computes its output as a linear combination of its input signal by using the synaptic weights which are adjusted at the training process. This network is applied successfully to solve some difficult and diverse problems by training them in supervised manner with the error back-propagation algorithm. This algorithm is based on the error-correction learning rule. Backpropagation training algorithm is composed of two steps [12]. The first one is the feed-forward, when the signal is propagated through the network, from the input layer to the output layer. After that the output value is compared with the known output and residuals are computed. The second step is the feed-backward stage. In this step the errors are propagated through the network from the output layer to the input layer. During the feed-backward step the synaptic weights are adjusted. This is performed several times on each parameter up to the residuals converge to a desired threshold value. The processing of neuron k can be represented as in (1). y_k is the neuron output, ϕ is an activation function, m is the number of input parameter, x_i is the input parameter, w_{ki} is the i th synaptic weight and b_k is the bias.

$$y_k = \phi\left(\sum_{i=1}^m x_i w_{ki}\right) + b_k \quad (1)$$

During the training process, MLP weight values are determined then the performance of the network is tested by using test data.

B. Radial Basis Networks

Although RBN is composed of neurons like MLP, it applies different method and has a different structure. For this reason two methods solves the problem with different approaches. As MLP approximates the function globally, RBN approximates the function locally towards data used for training [12]. In point of their structure, the main difference appears in number of hidden layers and their purposes. There is only one hidden layer with some neurons that respond to the input data as sensory units of receptive fields. The nonlinearity of neurons in hidden layer is often chosen as Gaussian function constructing local approximations to input-output mappings.

Generally, a problem which can be solved by MLP also can be solved by RBN. But due to having different solution techniques, the advantages and disadvantages of these methods differ in many issues [12]. While designing RBN is simpler than MLP, RBN needs more time to adjust its coefficients. Due to fact that RBN approximates locally, it requires more test data than MLP. However, as requirements of RBN are satisfied, RBN is also successful in modeling nonlinear functions.

III. SIMULATIONS

In this paper, simulations are realized by using MATLAB NNET Toolbox. For the region between longitudes 26° - 46° and latitudes 36° - 42° where Turkey is situated, regional ionosphere maps are obtained artificially. Maps consist of 147 points due to diving latitude into 7 segments and longitude into 21 segments. As a result of segmentation, the region is divided into square grids which have sides 1° long. Samples that are used to form map are collected from the grid in two ways, homogenously and randomly as shown in Fig. 2.

In the simulations, these two sampling methods are used to analyze the effect of different distributions of GPS receiver stations on the performance of the formed maps. For a predetermined region of four artificial surfaces and one IRI surface, artificial surfaces are obtained by using the equations (2), (3), (4) and (5) and 5th surface is the estimated map for Turkey on 15.05.2003 by IRI. In Fig. 3, five surfaces are shown in this predetermined region.

In the following simulations, by using MLP and RBN, for this determined region, homogenously and randomly sampled 15 data are interpolated to form ionosphere maps. Inputs, longitude and latitude values, for MLP and RBN are normalized to $[-1, +1]$ in order to accelerate the learning process.

In order to analyze the results of methods, the relative error (RE) given in the equation (6) is used. In the equation (6), Δ represents RE, N is the number of data points, $f(x_n)$ is the real value to be estimated at n th point and $F(W, X_n)$ is the value of the estimation.




Fig. 2. Data distribution for 15 samples




Fig. 3. Simulation surfaces

$$f_1(x, y) = 0.1x + 0.26y \quad (2)$$

$$f_2(x, y) = \exp\left(\frac{x-26}{5}\right) \quad (3)$$

$$f_3(x, y) = 2817 - 72x + 78y + x^2 + y^2 \quad (4)$$

$$f_4(x, y) = 8.91e^{\left(-\left(\frac{(x-34)}{5}\right)^2 + \left(\frac{(y-39)}{2}\right)^2 + \frac{(x-1)(y-1)}{-7.1}\right)} \quad (5)$$

$$\Delta = \frac{\sum_{n=1}^N |f(X_n) - F(W, X_n)|^2}{\sum_{n=1}^N |f(X_n)|^2} \quad (6)$$

Surfaces are sampled homogeneously and randomly for different number of samples. NN methods use these samples to form maps by interpolating. By comparing reconstructed surfaces with the original surfaces, the relative errors caused by MLP and RBN are calculated. In the first simulations, RE obtained from MLP and RBN for a fixed number of data sampled homogeneously and randomly from five surfaces are observed. Secondly for random case, RE obtained from MLP and RBN for different number of data and five surfaces are analyzed. The structures of MLP and RBN used for each simulation are determined to minimize RE.

A. MLP Simulations

Simulations by using MLP are realized by using ten structures, such as 2-3-1 (M_1), 2-5-1 (M_2), 2-20-1 (M_5), 2-5-3-1 (M_7), 2-10-3-1 (M_9) showing the number of neurons in each layer. In Table I, the least RE values obtained for homogeneously sampled 15 data from five surfaces are shown. It is observed that the least RE caused by MLP structures are varying for different surfaces. In Table II, the least RE values obtained for randomly sampled 15 data from five surfaces are shown. Like homogeneous case, least RE caused by MLP structures are varying for different surfaces. Except the RE calculated for the exponential and IRI surfaces, RE increases in the random case.

TABLE I
RE FOR HOMOGENOUS CASE

Function	Plane	Exponential	Polynom	Gauss	IRI
RE	3.3×10^{-3}	1.3×10^{-2}	8.9×10^{-3}	4.1×10^{-2}	6.6×10^{-4}
SP	M_2	M_2	M_2	M_7	M_7

TABLE II
RE FOR RANDOM CASE

Function	Plane	Exponential	Polynom	Gauss	IRI
RE	5.6×10^{-3}	1.8×10^{-3}	2.2×10^{-2}	5.9×10^{-2}	6.3×10^{-2}
SP	M_2	M_1	M_1	M_7	M_7




Fig. 4. Relative Error of MLP

Assuming that GPS stations are distributed randomly, a MLP structure to use for all surfaces can be determined. In Fig. 4, for randomly sampled 15 data, REs of each structure for each surface are shown. According to the REs of each structure, M_7 may be chosen to be general MLP structure due to reasonable error levels for all distributions than the others. By using M_7 , Fig. 5 where number of data versus RE for each surface is obtained. As a conclusion drawn from the results, when 2-5-3-1 (M_7) MLP structure is used and the number of data increases, these types of two dimensional surfaces can be modeled effectively as expected. But under a certain limit in the number of data, value of RE naturally increases. According to the results, 44 data is a reasonable choice for sampling surfaces.




Fig. 5. Relative Error for Varying Number of Data

B. RBN Simulations

Choice of the spread coefficient (SC), which is a parameter of the learning, is important in the error minimization performance. If SC is chosen too small, the result of the approximation possibly becomes a rough surface and over fitting occurs. On the other hand, if SC is chosen too big, the result of the approximation becomes a flat surface where the local information is lost. In each simulation realized for surfaces and various numbers of data, SC is determined beforehand to minimize the error.

For each simulation, SC has to be determined in the range 0-1. In Table III, for homogeneously sample 15 data, RE values for each surface and corresponding SC are shown. Under these

conditions, the least RE is obtained for IRI surface and the highest RE is obtained for the Gaussian function.

TABLE III
RE FOR HOMOGENOUS CASE

Function	Plane	Exponential	Polynomial	Gauss	IRI
RE	4×10^{-4}	4.9×10^{-3}	3.6×10^{-3}	32.8×10^{-3}	3×10^{-5}
SC	1	0.45	0.71	0.61	0.55

TABLE IV
RE FOR RANDOM CASE

Function	Plane	Exponential	Polynomial	Gauss	IRI
RE	3.5×10^{-3}	18.5×10^{-3}	7×10^{-3}	4.9×10^{-3}	6.8×10^{-4}
SC	1	1	1	0.48	0.49

For randomly sampled 15 data, RE values for each surface is shown in Table IV. In this simulation, the number of neurons used in RBN is 12. Except the gauss surface, RE values for the other surfaces are higher than the one in homogenous case. Under these conditions the least RE is obtained for the plane surface. The effect of number of data on RE for five surfaces is shown in Fig. 6. It is assumed that like the real case, the data are sampled randomly. Like MLP results, the critic number of data chosen for the training set of the learning stage is around 44.




Fig. 6. Relative Error for Varying Number of Data

IV. REGIONAL IONOSPHERE MAPPING

Using data obtained from GPS stations situated in Europe, regional ionosphere maps are formed by using chosen MLP and RBN structures. In Fig. 7, nine GPS receiver locations are shown. Seven of these are used to train NN methods and two of them are used to test the performance of the training stage. In this simulation for MLP structure M_7 is also used and for RBN, SC which gives the least RE is chosen. The number of neurons used in RBN is also chosen to be equal to the number of training data as in the simulation part.

For regional ionosphere mapping, the region on Europe located between latitudes 0° - 15° and longitudes 44° - 54° is chosen as shown in Fig. 7. Simulated surface maps are formed for 176 points, 11 points on latitude and 16 points on longitude with 1° gap between each other. In Fig. 8, for four different hours, maps obtained by MLP and RBN are shown. In all figures, the effect of latitude and the sun on ionosphere can be observed. TEC values decreases at high latitudes and in cold

regions except the maps of MLP and RBN for hour 18:00 that coincide reasonably.

In Table V, sum square errors (SSE) which are calculated at test points for MLP, RBN are shown. While four hours 00:00 and 06:00, MLP produce less error than RBN, for the rest of the hours RBN is better. Due to number of data being limited to nine, RBN is expected to result in an higher error than MLP. MLPs construct global approximations to nonlinear input-output mapping. On the other hand, RBN networks using exponentially decaying localized nonlinearities construct local approximations to non-linear input-output mappings [12]. Despite this limitation, the results obtained by RBN and MLP support each other. Considering the effect of increasing number of data on performance, as number of data increases, RBN is expected to give a better result than that of MLP.




Fig. 7. GPS Stations located on Europe





Fig. 8. Regional Ionosphere Map by using MLP, RBF (07.10.2004 , 00:00, 06:00, 12:00 and 18:00)

TABLE V
SSE OF MAPS

	Hour 00:00	Hour 06:00	Hour 12:00	Hour 18:00
Method				
MLP	0.156	0.435	0.164	0.518
RBN	0.176	1.351	0.044	0.220

Turkey on 15.05.2003 by IRI

The regional ionosphere map of Turkey on 15.05.2003 can be formed by using those chosen MLP and RBN structures. The training data, for this case, are obtained from IRI map. In Table VI, relative error (RE), which are calculated by using IRI Map for 15, 24, 44 data, are shown [11]. According to test result, the amount of training data is an important parameter for obtaining a trade off for minimum error and the number of training data. These figures are 24 random sampled data as optimum training data for RBN and 44 sampling data for MLP. Regional ionosphere maps by training 44 data are given in Figure 9. MLP regional ionosphere map is obtained by 2-5-3-1 (M_7) MLP structure, 0.6 learning rate, and 0.3 momentum.

TABLE VI
RE OF IRI MAPs BY USING MLP AND RBN

Method	15 data	24 data	44 data
MLP	0,00080566	0,00068	3.9557e-005
RBN	0,00068365	7,9338e-006	4,0477e-006




Fig. 9. IRI, MLP, RBF Regional Ionosphere Map, which is obtained by sampled IRI MAP (05.05.2003, 00:00)

In figure 9, the regional ionosphere maps generated by MLP and RBN structures are depicted. For both cases, the data is provided by IRI. These figures showed that the non-linear modeling capabilities of neural networks are promising reliable alternatives for ionosphere modeling.

V. CONCLUSION

In this study, the effect of different conditions on the providing of mapping obtained by MLP and RBN are tested and compared. In the investigation of finding a better selection scheme for the locations of GPS receiver stations, it is observed that RBN produces less error in the testing stage if the training set is arranged in homogeneous manner rather than random approach. However, the amount of error produced by MLP differs for both homogeneous and random cases with respect to the distributions defined by functions. As the number of data is increased, generally on both artificial surfaces and the IRI surface, the RBN shows better results than that of MLP. However, the RBN becomes slower than MLP in the training process of mapping. As observed in the last simulation in figure 9, for a few number of real data, performances of both methods are close to each other.

In the future work, this study will be extended to the analysis performances of neural network models under different mapping approaches such as well known GIM and IRI with different TEC calculations. Comparison of GIM and IRI results

with neural network based mapping requires a special attention. The second aim is also to use the dynamic networks to handle the time variations on stations over different time intervals. Prediction of TEC values of GPS receivers beforehand and providing time related mappings are also in our scope for further studies.

ACKNOWLEDGEMENT

This study is supported by TÜBİTAK EEAG 105E171 project.

REFERENCES

- [1] Kaplan, E.D., 1996, Understanding GPS Principles and Applications, Artech House Publishers-Boston, London
- [2] Liao, X., 2000, Carrier Phase Based Ionosphere Recovery Over A Regional Area GPS Network, Master's Thesis, Department of Geomatic Engineering, The University of Calgary, Canada.
- [3] Komjathy, A., 1997, Global Ionospheric Total Electron Content Mapping Using Global Positioning System, Ph.D.thesis of Geodesy and Geomatics Engineering of the University of New Brunswick
- [4] Arkan, F., Erol C.B. Arkan O., 2003, Regularized Estimation of Vertical Total Electron Content from Global Positioning System Data, Journal of Geophysical Research.118, 1469–1480.
- [5] Orús, R., 2005, Improvement of Global Ionospheric VTEC Maps by Using Kriging Interpolation Technique, Journal of Atmospheric and Solar-Terrestrial Physics (67), 1598–1609.
- [6] Wielgosz, P., Brzezinska, D., Kashani, I., 2003, Regional Ionosphere Mapping with Kriging and Multiquadratic method, Journal of Global Pos. Sys., vol. 2,no. 1, 48-55.
- [7] Moon, Y., 2004, Evaluation of 2-dimensional Ionosphere Models for National and Regional GPS Networks in Canada, Master's thesis, The University of Calgary, Calgary, Alberta, Canada.
- [8] McKinnel, L.A., Poole A. W. V., 2004, Neural Network Based Ionospheric Modeling over the South African Region, *South African Journal of Science*.
- [9] Nelles, O., 2001, Nonlinear System Identification, Springer-Verlag Berlin Heidelberg.
- [10] Hornik, K., Stinchcombe M. White H., 1989, Multilayer Feedforward Networks are Universal Approximators, Neural Networks 2, 359–366.
- [11] IRI TEC Maps, <http://nssdc.gsfc.nasa.gov/space/model/models/iri.html>
- [12] Haykin, S., 1999, Neural Networks A Comprehensive Foundation, Prentice Hall International.
- [13] Schaer, S., 1999, Mapping and Predicting the Earth's Ionosphere Using the Global Positioning System, Ph. D Dissertation, Astronomical Institute, University of Bern, Switzerland.