

**UYARLAMALI YANKILAŞIM TEORİSİ İLE EPİLEPSİ VERİLERİNİN
ÖBEKLENMESİ VE BİR EPİLEPSİ MODELİ**

YÜKSEK LİSANS TEZİ

Ahmet Hıfzı BACAKSIZ

Elektronik ve Haberleşme Mühendisliği Anabilim Dalı

Biyomedikal Mühendisliği Programı

TEMMUZ 2020

**UYARLAMALI YANKILAŞIM TEORİSİ İLE EPİLEPSİ VERİLERİNİN
ÖBEKLENMESİ VE BİR EPİLEPSİ MODELİ**

YÜKSEK LİSANS TEZİ

**Ahmet Hıfzı BACAKSIZ
(504151401)**

Elektronik ve Haberleşme Mühendisliği Anabilim Dalı

Biyomedikal Mühendisliği Programı

Tez Danışmanı: Prof. Dr. Neslihan Serap Şengör

TEMMUZ 2020

İTÜ, Fen Bilimleri Enstitüsü'nün 504151401 numaralı Doktora Öğrencisi Ahmet Hıfzı BACAKSIZ, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “UYARLAMALI YANKILAŞIM TEORİSİ İLE EPİLEPSİ VERİLERİNİN ÖBEKLENMESİ VE BİR EPİLEPSİ MODELİ” başlıklı tezini aşağıdaki imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Prof. Dr. Neslihan Serap Şengör**
İstanbul Teknik Üniversitesi

Jüri Üyeleri : **Prof. Dr. Fatma İnci Çilesiz**
İstanbul Teknik Üniversitesi

Doç. Dr. Rıfat Koray Çiftçi
Namık Kemal Üniversitesi

.....

Teslim Tarihi : **15 Haziran 2020**

Savunma Tarihi : **13 Temmuz 2020**





Bilim İnsanlarına,



ÖNSÖZ

Öğretmen kavramının bende algısını deęiřtiren, lisans dönemimde kendisinden almıř olduęum dersler sırasında ve SIMMAG Laboratuvar ortamında çalıřırken bilmedięim bir dünya üzerine ıřık tutan kıymetli danıřmanım Prof.Dr. Neslihan Serap řengör'e

SIMMAG oluřumunda katkısı olan ve ierisinde bulunduęum süreçte tanışma sanřı yakaladıęım Hesaplamalı Sinir Bilim meraklılarına,

Lisans eęitimim sırasında birlikte projeler yaptıęım dostum Sabiha Yarlųękal'a

Hayatta tökezledięim her an bana umut ıřıęı tutan Babam Aydın Bacaksız'a

řürkanlarımı sunarım.

TEMMUZ 2020

Ahmet Hıfzı BACAKSIZ



İÇİNDEKİLER

Sayfa

ÖNSÖZ	vii
İÇİNDEKİLER	ix
KISALTMALAR.....	xi
ÇİZELGE LİSTESİ.....	xiii
ŞEKİL LİSTESİ.....	xv
ÖZET	xix
SUMMARY	xxi
1. GİRİŞ	1
2. UYARLAMALI YANKILAŞIM KURAMI.....	5
2.1 ART yapısının genel tanıtımı.....	5
2.2 Dinamik Bir Sistem Olarak ART	7
2.3 Makina Öğrenmesi Uygulamalarında Kullanılan ART Algoritması	18
3. ADAPTİF REZONANS TEORİSİ İLE BAZI UYGULAMALAR.....	21
3.1 ART ile Harf Öbekleme problemi	21
3.2 Epilepsi Veri Seti	26
3.2.1 Kullanılan veri seti içeriği	28
3.2.2 Öznitelik çıkarma yöntemleri	29
3.3 Çok katmanlı Algılayıcı Sonuçları	34
3.4 ART ile Epilepsi Verilerinin Öbeklenmesi	37
3.4.1 Dinamik sistem yaklaşımı ile öbekleme	37
3.4.2 Algoritmik yaklaşım ile öbekleme	43
4. JANSEN KORTİKAL KOLONLAR MODELİ İLE EPİLEPSİ MODELİ .	47
5. SONUÇ	53
KAYNAKLAR.....	55
EKLER	57
EK A.1 :.....	59
1.1 Temel ART Yapısı için Uyanıklık Katsayısının Etkisi: Küçük boyutlu örnek	59
EK A.1 :.....	63
2.1 Temel ART Yapısı için Uyanıklık Katsayısının Etkisi: Harfler	63
EK A.1 :.....	67
3.1 Algoritmik ART Yapısı için Uyanıklık Katsayısının Etkisi: Harfler.....	67
EK A.1 :.....	71
4.1 Epilepsi veri seti Temel ART yapısı ilk durum için farklı p değerlerine ilişkin sonuçlar.....	71
EK A.1 :.....	75
5.1 Epilepsi veri seti Temel ART yapısı durum 2 için farklı p değerlerine ilişkin sonuçlar.....	75

EK A.1 :	79
6.1 Epilepsi veri seti Temel ART yapısı durum 3 için farklı p değerlerine ilişkin sonuçlar.....	79
EK A.1 :	83
7.1 Epilepsi veri seti Algoritmik ART yapısı ilk durum için farklı p değerlerine ilişkin sonuçlar.....	83
EK A.1 :	87
8.1 Epilepsi veri seti Algoritmik ART yapısı durum 2 için farklı p değerlerine ilişkin sonuçlar.....	87
EK A.1 :	93
9.1 Epilepsi veri seti Algoritmik ART yapısı durum 3 için farklı p değerlerine ilişkin sonuçlar.....	93
ÖZGEÇMİŞ	99



KISALTMALAR

ANFIS	: Bulanık Sinir Ağı Sistemi
ART	: Uyarlamalı Yankılaşım Teorisi
ÇKA	: Çok Katmanlı Algılayıcı
DWT	: Ayrık Dalgacık Dönüşümü
EEG	: Elektroensefalografi
ELM	: Aşırı Öğrenme Makinesi
USB	: Uzun Süreli Bellek
WT	: Dalgacık Dönüşümü
YSA	: Yapay Sinir Ağları



ÇİZELGE LİSTESİ

Sayfa

Çizelge 3.1: Çok Katmnlı Algılayıcı ile ele alınan epilepsi verisi için seçilen özniteliklere bağlı sınıflandırma başarı sonuçları.	36
Çizelge 4.1: Jansen Model Genel Parametreler Çizelge.....	50





ŞEKİL LİSTESİ

	<u>Sayfa</u>
Şekil 2.1 : ART Sinir Ağı Modeli	6
Şekil 2.2 : 3 girişli örüntü ile F1 katmanı etkileşimi	8
Şekil 2.3 : F1 katmanı için dinamik denklemin durum portresi.....	9
Şekil 2.4 : 3 girişli örüntü için aşağıdan yukarı süreç.....	10
Şekil 2.5 : Aşağıdan yukarı ağırlık oluşum süreci için dinamik denkleme ilişkin durum portresi	10
Şekil 2.6 : 3 girişli örüntü ile F1 katmanı etkileşimi	11
Şekil 2.7 : F2 katmanı için dinamik denklemin durum portresi.....	12
Şekil 2.8 : Yukarıdan aşağıya ağırlık oluşum süreci için blok diyagramı.....	13
Şekil 2.9 : Yukarıdan aşağıya ağırlık oluşum süreci için durum portresi	14
Şekil 2.10 : Örüntünün F1 katmanı ile ikinci kez etkileşme sürecine ilişkin blok diyagram	14
Şekil 2.11 : Örüntünün F1 katmanı ile ikinci kez etkileşme sürecine ilişkin durum portresi.....	15
Şekil 2.12 : Uyanıklık katsayısı $p=0.2$ için öbekleme başarıları	17
Şekil 2.13 : Uyanıklık katsayısı $p=0.4$ için öbekleme başarıları	17
Şekil 2.14 : Uyanıklık katsayısı $p=0.7$ için öbekleme başarıları	18
Şekil 2.15 : Makina öğrenmesinde kullanılan ART yapısının blok diyagramı.....	19
Şekil 2.16 : Makina öğrenmesine ilişkin ART algoritması ile örüntülerin farklı p değerine bağlı öbekleme başarıları	20
Şekil 3.1 : ART yapısı için kullanılan harf örüntü kümesi	22
Şekil 3.2 : $p=0.1$ değerine bağlı harf öbeklemesi	22
Şekil 3.3 : $p=0.8$ değerine bağlı harf öbeklemesi	23
Şekil 3.4 : $p=0.9$ değerine bağlı harf öbeklemesi	24
Şekil 3.5 : uyanıklık katsayısına bağlı öbekleme başarı yüzdesi	24
Şekil 3.6 : $p=0.1$ değerine bağlı harf öbeklemesi	25
Şekil 3.7 : $p=0.5$ değerine bağlı harf öbeklemesi	25
Şekil 3.8 : $p=0.7$ değerine bağlı harf öbeklemesi	26
Şekil 3.9 : Uluslararası 10-20 sistemi esas alınarak oluşturulmuş elektrot dizilimi esaslı EEG cihazı kullanılmıştır. Burada elektrot adlandırması anatomik konum üzerinden türetilmiştir. A ve B setleri için kayıtlar bu düzen esasında edinilmiştir [1].	29
Şekil 3.10 : Epilepsi hastalarının ameliyat öncesi değerlendirilmesi için implante edilen intrakraniyal elektrot şeması esaslı ölçüm yöntemi [2]......	29
Şekil 3.11 : Yukarıdan aşağıya: A-E'yi sıralanmış beş veri setinin her birinden örnek EEG zaman serileri gösterimi.....	30
Şekil 3.12 : A ve D veri setlerinden örnek veriler	30

Şekil 3.13	: DWT uygulamasının alt bant ayrışması; $h[n]$ yüksek geçiren filtre, $g[n]$ düşük geçiren filtre [3].	31
Şekil 3.14	: A seti içeriğinden elde edilmil db4 dalgacık spektrumu sonucu, D seti içeriğinden elde edilmil db4 dalgacık spektrumu sonucu.	32
Şekil 3.15	: A ve D seti içeriğinden elde edilmiş Shannon Entropisi.	32
Şekil 3.16	: Veri setleri içeriğinden elde edilmiş enerji değerleri.	33
Şekil 3.17	: Veri setleri içeriğinden elde edilmiş standart sapma Değerleri.	33
Şekil 3.18	: İlk durum için farklı p değerine bağlı elde edilen öbekleme başarıları	38
Şekil 3.19	: İlk durumda $p=0.1$ için elde edilen öbekleme sonuçları	38
Şekil 3.20	: İlk durumda $p=0.95$ için elde edilen öbekleme sonuçları	39
Şekil 3.21	: İlk durumda $p=0.5$ için elde edilen öbekleme sonuçları	39
Şekil 3.22	: 2. durum için farklı p değerine bağlı elde edilen öbekleme başarıları.	40
Şekil 3.23	: 2.durumda $p=0.1$ için elde edilen öbekleme sonuçları	40
Şekil 3.24	: 2.durumda $p=0.95$ için elde edilen öbekleme sonuçları	41
Şekil 3.25	: 2.durumda $p=0.5$ için elde edilen öbekleme sonuçları	41
Şekil 3.26	: 3.durum için farklı p değerine bağlı elde edilen öbekleme başarıları..	42
Şekil 3.27	: 3.durumda $p=0.1$ için elde edilen öbekleme sonuçları	42
Şekil 3.28	: 3.durumda $p=0.95$ için elde edilen öbekleme sonuçları	42
Şekil 3.29	: 3.durumda $p=0.5$ için elde edilen öbekleme sonuçları	43
Şekil 3.30	: 1.durum için farklı p değerine bağlı elde edilen öbekleme başarıları..	43
Şekil 3.31	: 1.durumda $p=0.1$ için elde edilen öbekleme sonuçları	44
Şekil 3.32	: 1.durumda $p=0.95$ için elde edilen öbekleme sonuçları	44
Şekil 3.33	: 1.durumda $p=0.5$ için elde edilen öbekleme sonuçları	45
Şekil 3.34	: 2.durum için farklı p değerine bağlı elde edilen öbekleme başarıları..	45
Şekil 3.35	: 3. durum için farklı p değerine bağlı elde edilen öbekleme başarıları.	46
Şekil 4.1	: Jansen kortikal kolonlar modeli blok diyagramı.	48
Şekil 4.2	: Farklı A parametre değerine bağlı olarak modelin ürettiği dört farklı zaman serisi işareti	50
Şekil 4.3	: Jansen Modeli çıkışında elde edilen işaretin frekans analizi sonuçları	50
Şekil 4.4	: A set of four subfigures.	51
Şekil A.1	: Uyanıklık katsayısı $p=0.1$ için öbekleme başarıları	59
Şekil A.2	: Uyanıklık katsayısı $p=0.3$ için öbekleme başarıları	59
Şekil A.3	: Uyanıklık katsayısı $p=0.5$ için öbekleme başarıları	60
Şekil A.4	: Uyanıklık katsayısı $p=0.6$ için öbekleme başarıları	60
Şekil A.5	: Uyanıklık katsayısı $p=0.8$ için öbekleme başarıları	61
Şekil A.6	: Uyanıklık katsayısı $p=0.9$ için öbekleme başarıları	61
Şekil A.7	: Uyanıklık katsayısı $p=0.95$ için öbekleme başarıları	62
Şekil B.1	: Uyanıklık katsayısına $p=0.2$ değerine bağlı harf öbeklemesi	63
Şekil B.2	: Uyanıklık katsayısına $p=0.3$ değerine bağlı harf öbeklemesi	63
Şekil B.3	: Uyanıklık katsayısına $p=0.4$ değerine bağlı harf öbeklemesi	64
Şekil B.4	: Uyanıklık katsayısına $p=0.5$ değerine bağlı harf öbeklemesi	64
Şekil B.5	: $p=0.6$ değerine bağlı harf öbeklemesi	65
Şekil B.6	: Uyanıklık katsayısına $p=0.7$ değerine bağlı harf öbeklemesi	65
Şekil B.7	: Uyanıklık katsayısına $p=0.95$ değerine bağlı harf öbeklemesi	66
Şekil C.1	: Uyanıklık katsayısına $p=0.2$ değerine bağlı harf öbeklemesi	67

Şekil C.2	: Uyanıklık katsayısına $p=0.3$ değerine bağlı harf öbeklemesi.....	67
Şekil C.3	: Uyanıklık katsayısına $p=0.4$ değerine bağlı harf öbeklemesi.....	68
Şekil C.4	: Uyanıklık katsayısına $p=0.6$ değerine bağlı harf öbeklemesi.....	68
Şekil C.5	: Uyanıklık katsayısına $p=0.8$ değerine bağlı harf öbeklemesi.....	69
Şekil C.6	: Uyanıklık katsayısına $p=0.9$ değerine bağlı harf öbeklemesi.....	69
Şekil C.7	: Uyanıklık katsayısına $p=0.95$ değerine bağlı harf öbeklemesi.....	70
Şekil D.1	: ilk durumda $p=0.2$ için elde edilen öbekleme sonuçları.....	71
Şekil D.2	: ilk durumda $p=0.3$ için elde edilen öbekleme sonuçları.....	71
Şekil D.3	: ilk durumda $p=0.4$ için elde edilen öbekleme sonuçları.....	72
Şekil D.4	: ilk durumda $p=0.6$ için elde edilen öbekleme sonuçları.....	72
Şekil D.5	: ilk durumda $p=0.7$ için elde edilen öbekleme sonuçları.....	73
Şekil D.6	: İlk durumda $p=0.8$ için elde edilen öbekleme sonuçları	73
Şekil D.7	: İlk durumda $p=0.9$ için elde edilen öbekleme sonuçları	74
Şekil E.1	: 2.durumda $p=0.2$ için elde edilen öbekleme sonuçları.....	75
Şekil E.2	: 2.durumda $p=0.3$ için elde edilen öbekleme sonuçları.....	75
Şekil E.3	: 2.durumda $p=0.4$ için elde edilen öbekleme sonuçları.....	76
Şekil E.4	: 2.durumda $p=0.6$ için elde edilen öbekleme sonuçları.....	76
Şekil E.5	: 2.durumda $p=0.7$ için elde edilen öbekleme sonuçları.....	77
Şekil E.6	: 2.durumda $p=0.8$ için elde edilen öbekleme sonuçları.....	77
Şekil E.7	: 2.durumda $p=0.9$ için elde edilen öbekleme sonuçları.....	78
Şekil F.1	: 3.durumda $p=0.2$ için elde edilen öbekleme sonuçları.....	79
Şekil F.2	: 3.durumda $p=0.3$ için elde edilen öbekleme sonuçları.....	79
Şekil F.3	: 3.durumda $p=0.4$ için elde edilen öbekleme sonuçları.....	80
Şekil F.4	: 3.durumda $p=0.6$ için elde edilen öbekleme sonuçları.....	80
Şekil F.5	: 3.durumda $p=0.7$ için elde edilen öbekleme sonuçları.....	81
Şekil F.6	: 3.durumda $p=0.8$ için elde edilen öbekleme sonuçları.....	81
Şekil F.7	: 3.durumda $p=0.9$ için elde edilen öbekleme sonuçları.....	82
Şekil G.1	: 1.durumda $p=0.2$ için elde edilen öbekleme sonuçları.....	83
Şekil G.2	: 1.durumda $p=0.3$ için elde edilen öbekleme sonuçları.....	83
Şekil G.3	: 1.durumda $p=0.4$ için elde edilen öbekleme sonuçları.....	84
Şekil G.4	: 1.durumda $p=0.6$ için elde edilen öbekleme sonuçları.....	84
Şekil G.5	: 1.durumda $p=0.7$ için elde edilen öbekleme sonuçları.....	85
Şekil G.6	: 1.durumda $p=0.8$ için elde edilen öbekleme sonuçları.....	85
Şekil G.7	: 1.durumda $p=0.9$ için elde edilen öbekleme sonuçları.....	86
Şekil H.1	: 2.durumda $p=0.1$ için elde edilen öbekleme sonuçları.....	87
Şekil H.2	: 2.durumda $p=0.2$ için elde edilen öbekleme sonuçları.....	87
Şekil H.3	: 2.durumda $p=0.3$ için elde edilen öbekleme sonuçları.....	88
Şekil H.4	: 2.durumda $p=0.4$ için elde edilen öbekleme sonuçları.....	88
Şekil H.5	: 2.durumda $p=0.5$ için elde edilen öbekleme sonuçları.....	89
Şekil H.6	: 2.durumda $p=0.6$ için elde edilen öbekleme sonuçları.....	89
Şekil H.7	: 2.durumda $p=0.7$ için elde edilen öbekleme sonuçları.....	90
Şekil H.8	: 2.durumda $p=0.9$ için elde edilen öbekleme sonuçları.....	90
Şekil H.9	: 2.durumda $p=0.95$ için elde edilen öbekleme sonuçları.....	91
Şekil I.1	: 3.durumda $p=0.1$ için elde edilen öbekleme sonuçları.....	93
Şekil I.2	: 3.durumda $p=0.2$ için elde edilen öbekleme sonuçları.....	93

Şekil I.3	: 3.durumda $p=0.3$ için elde edilen öbekleme sonuçları.....	94
Şekil I.4	: 3.durumda $p=0.4$ için elde edilen öbekleme sonuçları.....	94
Şekil I.5	: 3.durumda $p=0.5$ için elde edilen öbekleme sonuçları.....	95
Şekil I.6	: 3.durumda $p=0.6$ için elde edilen öbekleme sonuçları.....	95
Şekil I.7	: 3.durumda $p=0.7$ için elde edilen öbekleme sonuçları.....	96
Şekil I.8	: 3.durumda $p=0.8$ için elde edilen öbekleme sonuçları.....	96
Şekil I.9	: 3.durumda $p=0.9$ için elde edilen öbekleme sonuçları.....	97
Şekil I.10	: 3.durumda $p=0.95$ için elde edilen öbekleme sonuçları.....	97



UYARLAMALI YANKILAŞIM TEORİSİ İLE EPİLEPSİ VERİLERİNİN ÖBEKLENMESİ VE BİR EPİLEPSİ MODELİ

ÖZET

Bu tez çalışmasının amacı, yapay zeka alanında son yıllarda daha da dikkat çekmeye başlayan yapay sinir ağı yapılarından biri olarak bilinen ve özellikle mühendislik uygulamalarında öbekleme probleminin çözümünde kullanılan adaptif rezonans teorisine (ART) ilişkin temel yapıyı incelemektir. Adaptif rezonans teorisi aslında primat beyninin anlaşılmasına yönelik bir yapı koyup, davranışları açıklayacak bir model oluşturmak amacıyla önerilmiş ve ilk önerildiği 70'li yıllardan bu yana çeşitli şekillerde temel yapı genişletilerek birçok nörolojik ve davranışsal olguya ilişkin modeller sunulmuştur.

Bu tezde ilk olarak temel ART yapısı ele alınacak ve bu yapıya ilişkin diferansiyel denklemlerden yararlanılarak küçük boyutlu bir problemin çözümünde neler olmakta olduğu durum uzayındaki davranışlar elde edilerek açıklanacaktır. Sonra genel olarak kullanılan ART algoritması tanıyılıp, bu algoritma ile asıl yapı arasındaki ilişki açıklanacaktır.

Dünya Sağlık Örgütü verilerine göre yeryüzünde 50 milyonu aşkın kişi epilepsi ile başetmek durumundadır ve epilepsi en yaygın nörolojik hastalıktır. Epilepsinin tanısının konulması ve oluşumunda meydana gelen sürecin açıklanması için farklı şekillerde matematiksel modellerden ve bu matematiksel modellere dayanan benzetimlerden yararlanılmaktadır. Tezin bir bölümünde ilk olarak epilepsi hakkında kısa bir bilgi verildikten sonra, önce bir başka yapay sinir ağı yapısı çok katmanlı algılayıcı ile elde edilen sınıflandırma sonuçlarının nasıl elde edildiği açıklanacak, sonra ART yapısı ile öbekleme yapılarak elde edilen sonuç sınıflandırma problemi olarak ele alındığında elde edilen sonuç ile karşılaştırılacaktır. En son olarak da Epilepsi'ye ilişkin verilen bir model olan Jansen modeli ele alınıp bu model ile elde edilen sonuçlar verilecektir.



CLUSTERING EPILEPSY DATA WITH ADAPTIVE RESONANCE THEORY AND AN EPILEPSY MODEL

SUMMARY

The aim of this thesis is to examine the basic structure of the adaptive resonance theory (ART), which is known as one of the artificial neural network structures used for clustering. It started to draw attention in the field of artificial intelligence, especially in engineering applications, but adaptive resonance theory was originally proposed to establish a model for understanding the primate brain, and to explain behaviors. ART has been used to model many neurological and behavioral phenomena and it is developed by expanding the basic structure in various ways since the 70s.

In this thesis, the basic ART structure will be discussed first and its structure will be given by the differential equations. How these differential equations define the processes each substructure realize will be explained by giving state space results for a simple example. Then, the ART algorithm used in machine learning applications will be introduced and the relationship between this algorithm and the actual structure will be explained.

According to the data of the World Health Organization, more than 50 million people in the world have to cope with epilepsy, and epilepsy is the most common neurological disease. Different forms of mathematical models and simulations based on these mathematical models are used to diagnose epilepsy and explain the process occurring in its formation. In the second part of the thesis, after brief information about the epilepsy data is given, the data classified by multi-layer perceptron. The same data then is considered without labels and clustering results are obtained with dynamic ART structure and algorithmic ART structure. Finally, the Jansen model, which is a model related to Epilepsy, is introduced and the results obtained with Jansen model is discussed using power spectrum analysis and state space representation.



1. GİRİŞ

Öğrenmenin bir tanımı, devam eden olay ve durumların arasındaki ilişkinin açıklanıp, gerekli eylemlere yönelik uygun tepkilerin üretilmesi işlemidir. Bu işlem, tek hücreli canlılardan en gelişmiş memeli türü olarak kabul görmüş insan ırkına kadar birçok farklı türden canlı tarafından yaşamları boyunca farklı şekillerde ve durumlarda gerçekleşmektedir. Birçok canlı türü değişen dünya düzeni karşısında uyum sağlamayı öğrenme yetisi sayesinde gerçeklerken, uyum sağlayamayan türler ise varlıklarını sürdürememiştir [4]. Canlıların öğrenme sürecinden esinlenerek son yıllarda birçok akıllı sistem geliştirilmiş ve karmaşık konu ve problemlerin çözülmesinde kolaylık sağlamıştır [5,6].

Tıp alanında birçok hastalığın teşhis edilebilmesi için de bu yöntemlere başvurulur hale gelinmiştir [7]. Bu hastalıklardan biri de epilepsi hastalığıdır [8–10]. Sinir hücrelerinde geçici olarak meydana gelen anormal elektriksel aktivite sonucu meydana gelen bu hastalık dünya üzerinde yaklaşık 50 milyon kişide görülmektedir. Teşhis edildiği takdirde, yüzde 70 oranında tedaviye yanıt verebilir özellikte olması erken teşhis edilmesini önemli kılmaktadır. Genellikle EEG verileri üzerinden tanısı konulan bu hastalığın diğer beyin işaretleri içerisinde ayrıştırıp belirlenmesi karmaşık bir problem olarak karşımıza çıkmaktadır.

Epilepsi verilerini incelenip, veri üzerinden değerli öznitelikler elde edilerek, akıllı bir sistem tarafında bu özniteliklerin öğrenilmesi teşhis sürecini önemli ölçüde kısaltmakta ve başarılı sonuçlar vermektedir [11]. Kullanılan sınıflayıcı yöntemler genellikle öznitelikler belirlendikten sonra, sınıflandırma ölçütleri dahilinde veriyi değerlendirme yoluyla çalışmaktadır.

Halen nedenleri hakkında çok fazla bilgi sahip olmadığımız bu hastalık için öbekleme yaklaşımı ile çalışan eğiticişiz öğrenme yöntemleri ile yeni bilgi elde etmek ve bu yönde var olan matematiksel modelleri geliştirmek önemli olabilir.

Bu amaçla, tez çalışmasında öbekleme probleminin çözümü için makina öğrenmesinde kullanılan bir eğiticişiz öğrenme yöntemi olan Uyarlamalı Yankılařım Teorisi epilepsi verilerinin öbeklenmesi için ele alınmıřtır. Ancak bu yöntem alıřılagediđi biçimi ile deđil, özgün olarak önerildiđi biçimi olan diferansiyel denklemler ile gereklenmiřtir. Ayrıca, sadece epilepsi tanısı için verilerden yararlanmanın dıřında, hastalıđa iliřkin bilgi edinmenin bir yolu olarak epilepsinin oluřmasında etkin olduđu dıřınülen nöral yapıların modellenmesi de tez çalışmasının bir bölümünde ele alınmıřtır.

Tez çalışmasında ele alınan Adaptif Rezonans Teorisine (ART) iliřkin yapı, genellikle mühendislik uygulamalarında kullanıldıđından daha farklı olarak, önerildiđi diferansiyel denklemler ile 2. Bölümde ele alınmıřtır. İlk olarak bu diferansiyel denklemlerin gerekledikleri süreçler açıklanmıř, daha sonra görsel olarak takip edilebilmesi için küçük boyutlu veriler ile durum portreleri ve zamanla deđiřimleri çizilerek anlatılmıřtır. 2. bölümde son olarak, makina öğrenmesi için yapılan çalışmalarda kullanılan ART yapısına iliřkin algoritma verilmiřtir. 3. Bölümde, ART yapısına iliřkin MATLAB ortamında hazırlanan kod ile harf öbekleme problemi, hem diferansiyel denklem yapısı ile hem de algoritmik yapı ile çözülmüř ve Epilepsi veri setine uygulanmadan önce kodun çalışmakta olduđu sınanmıřtır. 3.2 alt bölümünde [12] çalışmasında kullanılan Epilepsi veri seti kullanılmıřtır, Burada öncelikle Epilepsi veri seti tanıtılmıř ve bu veri setinden öbekleme ve sınıflama problemlerinde kullanılacak özniteliklerin nasıl elde edildiđi anlatılmıřtır. 3.3 alt bölümünde veri setini daha iyi anlamak için veri seti ile yine MATLAB ortamında hazırlanan m-file ile çok katmanlı algılayıcı yapısı oluřturulmuř ve sınıflandırma problemi çözülmüřtür. 3.4 alt bölümünde ise ART yapısı Epilepsi verisini öbeklemek için veriler önce ikili tabanda kodlanmıřtır sonra öbekleme problemi hem dinamik sistem olarak ele alınan ART yapısı ile hem de Bölüm 2.3’de verilen ART yapısına iliřkin makine öğrenmesinde kullanılan algoritmik yapı ile çözülmüřtür. 4. Bölümde, tezde bu aşamaya kadar yapılan çalışmadan farklı olarak, Epilepsi’ye iliřkin bir dinamik sistem modeli Jansen yapısından faydalanarak verilmiřtir. 5. Bölümde tezde yapılanlar kısaca özetlendikten sonra, elde edilen sonuçlar yorumlanmıřtır.

Tez çalışmasında Cem Yücelgen tarafından 2011 yılında hazırlanan "Uyarlamalı Yankılařım Kuramı ve Pekiřtirmeli Öğrenme ile Uygulanması", isimli bitirme ödevi ile Nevroz Aslan tarafından 2002 yılında hazırlanan "Adaptif Rezonans Teorisi" isimli

bitirme ödevinden faydalanılmıştır. Tez çalışmasının 4. bölümündeki sonuçlar, 2017 yılında BİYOMUT kongresinde sunulmuştur.



2. UYARLAMALI YANKILAŞIM KURAMI


Bu bölümde 1970’li yıllardan günümüze geliştirilmekte olan ve Grossberg tarafından psikolojideki klasik şartlanmaya dayalı öğrenmeyi gerçeklemeye yönelik olarak önerilen Uyarlamalı Yankılaşım Kuramı (Adaptive Resonance Theory-ART) ele alınacaktır [13]. ART yapısı, zaman içinde bilişsel süreçlerin açıklanması için de genişletilip bu bilişsel süreçlerin oluşmasında yer alan beyindeki bölgelerin işlevlerini de açıklanmakta kullanılmıştır [14, 15]. Temel olarak esneklik (plasticity) kararlılık (stability) ilkesine dayanan ART yapısı bir dizi birbirini etkileyen differansiyel denklem takımı ile verilmiştir. Ancak, özellikle öbekleme problemini çözmek için mühendislik uygulamalarında bir makina öğrenmesi yapısı olarak kullanılan ART algoritması, bu birbirlerini etkileyen dinamik sistemlerin kararlı denge noktalarına oturduktan sonraki davranışlarına dayalı algoritmik bir yapıdır. Bu bölümde ART yapısı öncelikle bir dinamik sistem olarak ele alınarak, her bir alt yapıya ilişkin denklemler açıklanacak ve basit bir örnek üzerinden durum uzayında gözlemlenen sonuçlar ile ART yapısının gerçeklediği süreçler belirtilecektir. Sonra makina öğrenmesinde kullanılan algoritma verilecektir.

2.1 ART yapısının genel tanıtımı

Burada ele alındığı yapı itibariyle Uyarlamalı Yankılaşım Kuramı(ART), Eğiicisiz (Unsupervised) bir öğrenme yöntemi olarak reel değerlerden oluşan örüntüler ile çalışabilme esnekliğine sahip bir yapay sinir ağı modelidir. Bu modelin öğrenmesi, insanın öğrenme mekanizmasına benzer nitelikte olup model, algılama ve algılanın var olan belleğin içerisinde sorgulandığı, buna göre algılanan bilginin yeni bilgi olup olmadığının kararının verildiği bir yapı olarak kurgulanmıştır.

ART, yeni bilgi olarak tanımladığı her bir örüntü için kendi içerisinde yeni bir nöron oluştururken, var olan nöronları ile temsil edebileceği bilgiler için, var olan nöronların içinden gelen uyarana ilişkin temsilci nöronda güncelleme yaparak öğrenme sürecinde bir pekiştirmeye gitmektedir. Ağın yeni nöron yaratma ve eskiden var olan nöronları

üzerinde değişiklik yapma kararı ağı bir parametresi olan uyanıklık katsayısı ile sağlanmaktadır. Uyanıklık katsayısı ile belirlenen bir eşiğin aşılamadığı uyarılama olarak nitelendirilen durumda, ağı kendini yeni duruma adapte etmesi, rezonans yani yankılaşım ya da etkileşim diye adlandırılır ve bu durumda, ağı algılayacağı bir örüntünün ağı var olan yapısıyla etkileşmesi dolayısıyla ağı örüntüyü yeni bir nöron kullanmadan daha iyi temsil etmesi sağlanır. ART, yeni durumlar söz konusu değilken, eski durumları kararlı bir şekilde uzun süreli belleğinde tutabilir. Kararlılık ile belirlenen, bir daha, eski durumlar ile karşılaşıldığında yeni bir nöron kullanımına gerek duyulmamasıdır. Hem kararlı hem de yeni bilgi öğrenebilme esnekliğine sahip olan bu yapı kararlılık-esneklik ikilemi üzerine kurgulanmış uzun süreli bellek(USB) mekanizması ile çalışır. Bu belleğin oluşumu, çağrışımsal azalma kuralı (Associative Decay Rule), Weber ilkesi kuralı (Weber Law Rule) ve yukarıdan-aşağıya öğrenme şablonu kuralının (Top-down Template Learning Rule) sistemli bir şekilde çalışması ile sağlanır. Sonuç olarak, ART modeli kendini yeni durumlara uyarlayabilen ve sahip olduğu bellek sayesinde geçmişle etkileşimi olan bir sinir ağı modelidir.



Şekil 2.1 : ART Sinir Ağı Modeli

Bu bölümde seksenli yıllarda önerilen [16, 17] ART yapısı kullanılmıştır. Bu model Şekil 2.1 görüldüğü üzere iki katmanlı bir yapıya sahiptir. Bu katmanlardan ilki olan F1 katmanı giriş örüntüsünün tanınması sürecini yönetmektedir. İkinci katman olan F2 katmanı, yeni gelen örüntüyü var olan örüntülere ilişkin gösterimlerle kıyaslama işlemini yürütmektedir. Bu iki katman bir ölçüde ağı kısa süreli belleğini (Short Term Memory, STM) oluşturan yapılardır. Bu yapılar arasında aşağıdan yukarı(bottom-up) ve yukarıdan aşağı(top-down) bilgi akışına izin veren sinaptik boşluk vardır. Bu

yapı öğrenme eylemine bağlı dinamik bir yapıya sahiptir. Bu kısım ağı uzun süreli belleğini oluşturur. Ayrıca, ağı kontrol birimleri olan A, B ve C’de katmanlar arasında haberleşme ve gelen bilginin kontrolü sağlanır. Bu ağ yapısında ateşleyici ve baskılayıcı işaretin oluşması her bir katmana ilişkin sürecin sonunda elde edilen çıktıya göre şekillenmektedir.

2.2 Dinamik Bir Sistem Olarak ART


Bu bölümde ele alınan ART yapısı [16, 17] için katmanlardaki süreçlere karşılık düşen işlemler diferansiyel denklem takımları ile tanımlanacak ve bu diferansiyel denklem takımlarının modellediği dinamik davranışın anlaşılması için basit bir veri kümesi ile ağı öğrenmesi aşamaları durum portreleri verilerek açıklanacaktır.

ART yapısını tanımlayan denklem takımları öğrenmenin süreçsel bir eylem olduğu varsayımı üzerine kurgulandığı için süreci diferansiyel denklem takımları olarak ele almıştır. Bu bağlamda ağı girişine gelen örüntü üç boyutlu bir vektör olarak tanımlanarak süreç boyunca bu örüntünün öğrenme adımları sırasında geçirdiği değişimler her bir katmanın çıkışında o katmana ilişkin durum uzayındaki davranışı verilerek incelenecektir. Veri kümesi olarak $[0 \ 1 \ 0]$ değerlerinden oluşan basit bir örüntü ART’a ilişkin dinamik sürecin görsel olarak takip edilebilmesi için kullanılacaktır.

F1 Katmanı Örüntü Etkileşimi

İlk olarak, Şekil 3.9’de blok diyagramı gösterilen, bir örüntünün ART yapısının tanıma katmanı olarak bilinen F1 katmanında geçirmiş olduğu dinamik süreç izah edilecektir. Örüntü olarak süreç boyunca ele alınacak olan ikili tabanda tanımlanmış üç boyutlu bir giriş örüntüsü kullanılarak durum uzayında bu örüntünün ne şekilde davranış sergilediği incelenecektir.

Giriş örüntüsünün F1 katmanını, ateşleyici davranış ile uyaracağı büyüklük, Denklem 2.1 tarafından belirlenmektedir. Bu değer J_i^+ olarak tanımlanmıştır. Giriş örüntüsünden gelen I_i işareti ile yukarıdan aşağıya şablon örüntüsü V_i ’nin toplamı olarak ifade edilir. bu süreçte ağı girişine gelen örüntünün F1 katmanı ile ilk etkileşime geçtiği için $V_i = 0$ dır. Bu nedenle F1 katmanı sadece giriş örüntüsü I_i tarafından uyarılır.



Şekil 2.2 : 3 girişli örüntü ile F1 katmanı etkileşimi

$$J_i^+ = I_i + V_i \quad (2.1)$$


F1 katmanına gelen örüntü Denklem 2.2 ile belirtilen dinamik bir süreç tarafından ilk kez algılanır. Diferansiyel bir denklem olarak tanımlanmış olan bu denklemde A_1 kazanç kontrol birimi ve I_i giriş örüntüsü değeri, başlangıçta rastgele tanımlanmış olan x_i değerini sürecin sonunda I_i giriş örüntüsü değerine yaklaştırır.

$$\varepsilon \frac{d}{dt} x_i = -x_i + (1 - A_1 x_i) I_i \quad (2.2)$$

F1 katmanında gerçekleşen dinamik süreç sonunda elde edilen x_i , bir aktivasyon fonksiyonu olan Denklem 2.3 uygulanarak katman çıkışında sinaptik boşluğa iletilecek bilgi olan S işaretini oluşturur. Bu bilgi uzun süreli belleğin bir parçası olan aşağıdan yukarı sürece etki eder. İkili tabanda bilgi olarak ifade edilen S işareti F1 katmanında gerçekleşen süreç sonunda işaretin ateşleme eşiğine ulaşp ulaşmadığının bilgisini uzun süreli belleğe taşıma özelliğine sahiptir.

$$S = h(X_i^*) = \begin{cases} 1 & X_i^* > 0 \\ 0 & \text{diğer} \end{cases} \quad (2.3)$$

Giriş Örüntüsü $[0, 1, 0]^T$ tanımlanarak, ART yapısı içerisinde tanıma katmanı olan F1 üzerinde ne gibi davranış sergilediği Şekil 2.3 görülmektedir. Bu grafikte yeşil ile



Şekil 2.3 : F1 katmanı için dinamik denklemin durum portesi

belirtilen noktadan dinamik sisteme ilişkin süreç başlar ve x_i değerleri sürecin sonunda ağın girişine verilen değerler ile belirtilen noktalara erişerek sonlanır. Burada, F1 katmanında oluşan örüntünün I_i giriş örüntüsü değerlerine yakınsadığı görülmektedir.


Aşağıdan Yukarı Süreç

Burada, uzun süreli belleği oluşturan süreçlerden biri olan aşağıdan yukarı süreç ele alınmıştır. Şekil 2.4’de blok diyagramı verilen bu süreç F1 katmanı çıkışından F2 katmanı için giriş değeri oluşumuna kadar geçen süreci kapsamaktadır.

Denklem 2.4 ile aşağıdan yukarı sürecin oluşumundan sorumlu E_{ij} elde edilmektedir. Bu değer F1 katmanın çıkışındaki değer ile model için tanımlı L değişkeni etkisinde oluşmaktadır. Burada L değişkeni nörotransmitterlerin inaktive edilme ve serbest bırakılma oranlarını ifade etmekte olup ART yapısının ele alınan örüntü için uzun süreli bellekten çağırılacağı öbeğe karar verme sürecine etki etmektedir.


$$E_{ij} = h(x_i) + L_1^- \sum_{k \neq i} h(x_k) \quad (2.4)$$

Ele alınan örüntü için aşağıdan yukarı süreçte Denklemi 2.5 deki dinamik süreç sonunda bir temsil oluşturulur. Bu temsil z_{ij} olarak tanımlanmıştır. Bu değer



Şekil 2.4 : 3 girişli örüntü için aşağıdan yukarı süreç

oluşumunda aşağıdan yukarı süreçte seçilen ağırlıkları temsil eden bir skaler olan $f(x_j)$, Denklem 2.4 ile elde edilen E_{ij} ve F1 katmanından sinaptik boşluğa bırakılan işareti temsil eden $h(x_i)$ etkilidir. Dinamik sürecin sonunda z_{ij} değeri Şekil 2.5 eksenleri belirtilen noktalarda konumlanmaktadır.



Şekil 2.5 : Aşağıdan yukarı ağırlık oluşum süreci için dinamik denkleme ilişkin durum portresi

$$\frac{d}{dt} z_{ij} = K_1 f(x_j) [-E_{ij} z_{ij} + h(x_i)] \quad (2.5)$$


Aşağıdan yukarı süreç sonunda F2 katmanına uyaran olarak gelecek işaret Denklem 2.6 ile belirlenir.

$$T_j = D_2 \sum_i h(X_i^*) z_{ij} \quad (2.6)$$

Bu süreç sonunda F2 katmanına ulaşan uyarının değeri Denklem 2.7 ile elde edilir.

$$J_j^+ = I_i + T_j \quad (2.7)$$

F2 Katmanı Örüntü Etkileşimi




Şekil 2.6 : 3 girişli örüntü ile F1 katmanı etkileşimi

Bu süreç, Şekil 2.6 blok diyagram olarak ifade edilen, aşağıdan yukarı süreç sonucunda meydana gelen J_j^+ işareti ile tetiklenir. Yukarıdan aşağı sürecin başlamasını tetikleyen U işareti oluşuncaya kadar ki süreci kapsamaktadır.

$$\varepsilon \frac{d}{dt} x_j = -x_j + (1 - A_2 x_j) J_j^+ \quad (2.8)$$

Denklem 2.9 ile F2 katmanını içerisinde gerçekleşecek olan dinamik süreç başlar. Bu süreçte F2 katmanını uyaran J_j^+ işareti ile kontrol birimi parametresi olan A_2 etkilidir. Üç boyutlu giriş örüntüsü için F2 katmanında gerçekleşen süreç Şekil 2.7'deki yeşil nokta üzerinde başlayarak değerleri verilen nokta üzerinde tamamlanır.

$$U = f(X_j^*) = \begin{cases} 1 & T_j = \max(T_k) \\ 0 & \text{diğer} \end{cases} \quad (2.9)$$



Şekil 2.7 : F2 katmanı için dinamik denklemin durum portesi


F2 katmanı çıkışında oluşan sürecin sonunda x_j işareti elde edilir. F2 katmanı çıkışında sinaptik boşluğa bırakılacak uyarın U ile denklem 2.9'deki gibi oluşturulur. U işareti yukarıdan aşağı süreçte hangi ağırlığın seçileceğinin belirlenmesi açısından önemlidir. U işareti aşağıdan yukarı süreçte örüntüyü F2 katmanına en fazla başarı ile ulaştırmış ağırlığı seçilmesi ile belirlenir. Belirlenen ağırlık ile uzun süreli belleğin diğer bir parçası olan yukarıdan aşağı dinamik süreç tetiklenir.

Yukarıdan Aşağıya Süreç

Şekil 2.8'de blok diyagramı verilen, yukarıdan aşağı süreç F2 katmanından gelen U işareti ile başlatılır. Bu süreç, F1 katmanını uyaracak işaretin oluşumuna kadar geçen süreci kapsar. Dinamik bir değişken olan ve z_{ji} değişkeni ile belirtilen süreç $f(X_j^*)$ işaretinin belirlediği ağırlık kullanılarak Denklem 2.10 ile belirlenir. Bu sürecin sonunda Denklem 2.11 ile F1 katmanını uyaracak V_i işareti oluşturulur.

$$\frac{d}{dt}z_{ji} = K_2 f(x_j)[-E_{ji}z_{ji} + h(x_i)] \quad (2.10)$$

Burada V_i değeri, ağırlık ilk örüntü alması nedeniyle doğrudan ilk tanımlanmış $F(X_j^*)$ değeri üzerinden hesaplanarak F1 katmanına uyarın olarak yansımaktadır.



Şekil 2.8 : Yukarıdan aşağıya ağırlık oluşum süreci için blok diyagramı


$$V_i = D_1 \sum_j f(X_j^*) z_{ji} \quad (2.11)$$

z_{ij} işaretinin uzun süreli bellek mekanizması ile dinamik değişimi Şekil 2.9 görülmektedir. Grafikte yeşil işaretli nokta başlangıç noktasını belirtmektedir ve elde edilen z_{ij} değeri ile ilk örüntü için yukarıdan aşağı süreçte uzun süreli belleğin oluşması sağlanmaktadır. Bu sürecin sonunda grafikte görüldüğü üzere giriş örüntüsüne yakın değerler civarına yakınsama yaptığı görülmektedir.


F1 Katmanı ile İkinci Etkileşim

Şekil 2.10 blok diyagramı verilen, bu süreçte F1 katmanı hem giriş örüntüsü hem de uzun süreli belleğin bir parçası olan yukarıda aşağı sürecin çıktısı olan V_i tarafından uyarılmaktadır. Bu süreç bir bakıma hem giriş örüntünün hem de ağı bu örüntüyü kendi içinde değerlendirmesi sonucu oluşan çıktının F1 katmanı üzerinde yaratmış olduğu etkiyi gözlemlememize olanak sağlamaktadır.

$$\varepsilon \frac{d}{dt} x_i = -x_i + (1 - A_1 x_i)(I_i + V_i) \quad (2.12)$$



Şekil 2.9 : Yukarıdan aşağıya ağırlık oluşum süreci için durum portresi




Şekil 2.10 : Örüntünün F1 katmanı ile ikinci kez etkileşme sürecine ilişkin blok diyagram

Örüntünün F1 katmanı ile ikinci kez etkileşmesine ilişkin dinamik süreç Denklem 2.12 ile sağlanmaktadır. Bu süreci belirten x_i işaretinin durum uzayında ilerleyişi Şekil 2.11 gösterilmektedir. Burada yeşil işaretli nokta üzerinden süreç başlamıştır. Bu nokta sürecin sonunda belirtilen noktalar üzerine oturmaktadır. Bu sürecin sonunda ele alınan örüntü ile ağırlık etkileşimi tamamlanır.

$$\varepsilon \frac{d}{dt} x_i = -x_i + (1 - A_1 x_i) J_i^+ - (B_1 + C_1 x_i) J_i^- \quad (2.13)$$

$$\varepsilon \frac{d}{dt} x_j = -x_j + (1 - A_2 x_j) J_j^+ - (B_2 + C_2 x_j) J_j^- \quad (2.14)$$



Şekil 2.11 : Örüntünün F1 katmanı ile ikinci kez etkileşme sürecine ilişkin durum portresi

Bu kısma kadar ART yapısını oluşturan katmanlar için tanımlı denklem takımlarının bir örüntü ile ilk karşılaşmasında nasıl işlemlerin gerçekleştiği açıklandı. Burada kısa süreli bellek olan F1 ve F2 katmanları için ilk örüntünün dışında başka örüntülerde ağa sunulduğunda, bu örüntülerin değerlendirilmesi için önerilen kazanç kontrol mekanizmasında etkili olan A, B, C parametre değerleri ele alınacaktır. Bu parametrelerin etkisi Denklem 2.13 ve Denklem 2.14 ile oluşturulmaktadır. F1 katmanı için tanımlanmış Denklem 2.13 ile bu parametrelerin aktif duruma gelmesi J_i^+, J_i^- işaretlerinin 1 olması durumu ile sağlanırken pasif duruma geçmesi bu işaretlerin 0 olması ile sağlamaktadır. F2 katmanı için ise Denklem 2.14’de tanımlı J_j^+, J_j^- değerinin 0 ve 1 olma durumuna göre kazanç kontrol mekanizmasından sorumlu parametrelerin pasif ve aktif olması sağlanmaktadır. Bu değerlerin 0 ve 1 olması bir önceki katmanın çıkış sonucuna göre belirlenir. Bu mekanizmalar sayesinde ağı bozuk örüntüler ile eğitim sürecinde kısa süreli belleğinde müdahale ederek uzun süreli belleğinde yanlış bilgi tutulması durumunun önüne geçilir.

Uyanıklık Testi

ART yapısında ağa sunulan veriler öbeklenirken, öbeklerdeki verilerin birbirlerine benzerliğine dair bir ölçüt uyanıklık katsayısı p ile belirlenir. Uyanıklık katsayısı kullanıcı tarafından belirlenir ve 0 ile 1 arasında değer alır. 1 sayısına ne kadar yakın ise öbeğe giren verilerin benzerliği o kadar fazladır. Dolayısıyla, ağa sunulan bir veri için

öbeklerden biri belirlendiğinde bu verinin öbekdeki verilere benzerliği ayrıca uyanıklık katsayısının değeri gözönüne alınarak test edilir. Bu katsayının değerine göre Denklem 2.15 ve Denklem 2.16 koşullarına bağlı olarak ağa sunulan veri için belirlenen öbeğin temsil ettiği verilere göre benzerlik değerlendirmesi yapılır. Bu testin varlığı ART yapısına esneklik özelliği katmaktadır. Bilginin ağ içersindeki belleklerde tutulup tutulmama kararı bu testin sonucuna göre belirlenir.

$$p > \frac{\sum_i X}{\sum_i I} \quad (2.15)$$


Ağ ile etkileşmiş örüntünün giriş örüntüsüne oranı bu p uyanıklık katsayısı değerinden küçük olması durumunda Denklem 2.15 ile verilen koşul sağlanır. Bu durumu sağlayan örüntüler için katmanlarda resetleme işlemi gerçekleştirilir. Bu tanımlı J_i^- veya J_j^- değerlerini 1 yaparak kazanç kontrol birimlerinin katmanlar içerisinde devreye girmesini sağlar. Bu durum ağ ile etkileşmiş bu örüntünün bellekten uzaklaştırılmasını sağlamaktadır.

$$p \leq \frac{\sum_i X}{\sum_i I} \quad (2.16)$$


Denklem 2.15 ağ ile etkileşmiş örüntünün giriş örüntüsüne oranı uyanıklık katsayısından büyük veya eşit olması durumunda ağ J_i^- ve J_j^- işaretlerini 0 yaparak kazanç kontrol birimlerinin katmanlar içerisinde devre dışı bırakarak örüntünün ağ içinde etkileşiminin belleklerde kalmasını sağlar. Bu sayede ART yapısı esnek ve kararlı bir öğrenme davranışı sergiler.

p uyanıklık katsayısı değerinin belirlenmesi ağın öğrenme sürecinde kritik öneme sahiptir. Ele alınan öbekleme probleminin doğasına göre en uygun p değeri değişiklik göstermektedir. Uygunluk değerinin en uygun değerinin altındaki p değeri için ART örüntüleri daha az sayıdaki öbeklerle temsil etmek isteyecektir. Bu durum ayrışması öngürülen örüntülerin aynı öbekler üzerinde tutulmasına neden olacaktır. Ele alınan probleme göre p katsayısını uygunluk değerinin üstünde tanımlandığı durumda ART örüntüleri daha çok öbeklerle temsil etmek isteyecektir. Bu durum aynı öbek içinde olması öngürülen örüntülerin farklı öbeklerle temsil edilmesi sonucunu ortaya çıkaracaktır.


Bu bölüm içerisinde ART yapısında var olan katmanlar dinamik ilişkinin anlaşılması için $[0,1,0]$ üç boyutlu örüntü ele alınmıştır ve bu örüntü için kısa ve uzun süreli belleklerde oluşan değerler durum portreleri ile verilmiştir. Aynı boyutta tanımlanmış $([0 \ 1 \ 0],[1,0,0],[1,0,0],[1,1,0],[1,1,1],[0 \ 1 \ 0],[1,0,0],[1,0,0],[1,1,0],[1,1,1])$ 5 farklı örüntü içeren kümenin ART yapısı içerisinde öbekleme süreci incelenmiştir uyanıklık katsayısının etkisini göstermek için p katsayısını farklı değerlerine bağlı olarak elde edilen öbekleme başarıları incelenmiştir.



Şekil 2.12 : Uyanıklık katsayısı $p=0.2$ için öbekleme başarıları



Şekil 2.13 : Uyanıklık katsayısı $p=0.4$ için öbekleme başarıları



Şekil 2.14 : Uyanıklık katsayısı $p=0.7$ için öbekleme başarısı


Şekil A.1'den Şekil C.7 arasında üç boyutlu örüntü kümesi için değişen p uyanıklık katsayısı için ağıın sergilemiş olduğu öbekleme başarısı görülmektedir. Burada $p=0.7$ olarak tanımlanmış uyanıklık katsayısı değerinden sonra ağıın bütün örüntüleri beklenen öbeklere yerleştirdiğini görülmektedir. Ağıın bu değer altında tanımlı p uyanıklık katsayısı değeri için öbekleme hatasının arttığı görülmektedir. Bu model ile farklı p değerleri için elde edilen sonuçlar EK'ler kısmında paylaşılmıştır.

2.3 Makina Öğrenmesi Uygulamalarında Kullanılan ART Algoritması

Şekil 2.16 blok diyagramı gösterilen makina öğrenmesinde kullanılan ART yapısı iki katmanlı kısa süreli bellek yapısı ile bu iki katman arasında oluşan uzun süreli bellek üzerine kurulmuştur. p uyanıklık katsayısı değeri ile ağıın öğrenme süreci yönetilir. Süreç içerisinde ikili tabanda örüntüler ile çalışılmaktadır.

Ağıın içerisinde bilgi z_{ij} yukarıdan aşağı bağlantılar ve w_{ji} aşağıdan yukarı bağlantılar sayesinde tutulmaktadır. Bu bağlantıların ilk tanımlaması denklem 2.17 belirtildiği şekilde yapılmaktadır. Burada n değeri ağa sunulan örüntünün boyutunu temsil etmektedir. x değişkeni ile belirtilen ve ele alınan her bir örüntü F1 katmanında denklem 2.18 belirtildiği gibi aşağıdan yukarı bağlantı ile etkileşime girer.

$$w_{ji}(0) = \frac{1}{1+n}; z_{ij}(0) = 1 \quad (2.17)$$



Şekil 2.15 : Makina öğrenmesinde kullanılan ART yapısının blok diyagramı

$$y_j = w_j^T x \quad (2.18)$$

Bu etkileşme sonucunda Denklem 2.19 ile kazanan nöron belirlenmesi yapılır. Ağ yapısında F2 katmanında kazanan her nöron aslında oluşturulan bir öbeği temsil etmektedir.

$$y^* = \max(y_j) \quad (2.19)$$

$$p < \frac{z^T x}{\|x\|} \quad (2.20)$$


Bu aşamadan sonra yukarıdan aşağı bağlantısında etkili olduğu Denklem 2.20 ile uyanıklık testi yapılır. Bu denklem şartı sağlanırsa Denklem 2.21 ve Denklem 2.22 ile ağırlık güncellemesi yapılır.

$$z_{ij}(k+1) = z_{ij}^*(k)x_j \quad (2.21)$$

$$w_{ji}(k+1) = \frac{z_{ij}^*(k)x_j}{0.5 + z_{ij}^*(k)x_j} \quad (2.22)$$

Bu şartın sağlanamadığı durumda F2 katmanına yeni örüntü, yeni bir öbeğin oluşması için yeni bir nöron olarak yerleştirilir ve ilgili aşağıdan yukarı ve yukarıdan aşağı bağlantılar düzenlenir. Süreç kendini yeni gelen örüntülere göre şekillendirerek yeni öbek açma ve var olan öbekler ile temsil edilecek verileri belirleme sürecini devam ettirir.

Algoritmik ART yapısı ile ([1 1 0 0 0 0 1],[0 0 1 1 1 1 0],[1 0 1 1 1 1 0],[0 0 0 1 1 1 0],[1 1 0 1 1 1 0]) 7 boyutlu 5 örüntü etkileşime girmiştir. Elde edilen sonuçlar Şekil 2.16 gösterilmektedir.



Şekil 2.16 : Makina öğrenmesine ilişkin ART algoritması ile örüntülerin farklı p değerine bağlı öbekleme başarıları

3. ADAPTİF REZONANS TEORİSİ İLE BAZI UYGULAMALAR

Bölüm 2’de tanıtılan ART yapısı ile MATLAB ortamında m-file olarak hazırlanan kodun öbekleme problemini çözdüğünü göstermek için öncelikle siyah üstüne beyaz yazı ile verilmiş ikili tabanda kodlanmış alfabadeki harfler ve birimleri yer değiştirilerek bozulmuş harflerden oluşan verilerin öbeklenmesi problemi ele alınmış ve farklı uyanıklık katsayıları ile elde edilen sonuçlar verilmiştir. Bu öbekleme problemi çözülürken sadece diferansiyel denklem takımları çözülerek oluşturulan ART yapısı değil aynı zamanda makina öğrenmesinde öbekleme için kullanılan ve bir Bölüm 2.3’de açıklanan algoritma ile gerçekleştirilen ART yapısı ile de sonuçlar elde edilmiştir. ART yapısı ile hastalıklı ve sağlıklı epilepsi veri seti ile verilen epilepsi verilerinin öbeklenmesinden önce, veri setinin analizi yapıp, öznitelikler belirlenmiştir. Sonra bu özniteliklerden yararlanarak epilepsi teşhisi amacıyla sınıflandırma problemi yine MATLAB ortamında m-file olarak oluşturulan çok katmanlı algılayıcı ile çözülmüştür. Bu bölümde son olarak veri kümesi bir sınıf etiketi gözönüne alınmadan öbekleme problemi olarak ele alınarak, dinamik denklemler ile ele alınan ART yapısı ve algoritma ile verilen ART yapısı ile farklı uyanıklık katsayıları için irdelenmiştir.

3.1 ART ile Harf Öbekleme problemi

Bu bölümde daha önceki bölümlerde irdelenen ART yapısına ilişkin tez kapsamında MATLAB ortamında m-file geliştirilen kod ile harf öbekleme problemi ele alınmıştır ve farklı uyanıklık katsayısı ile elde edilen sonuçlar verilmiştir.


Dinamik bir sistem olarak ele alınan ART yapısı ve Algoritmik ART yapısı için ağırlık girişinde ikili tabanda kodlanmış Şekil 3.1’de görülen alfabadeki bazı harfler ve bu harflerin birimleri yer değiştirilerek elde edilmiş bozuk harflerden oluşan örüntü kümesi kullanılmıştır. ART yapılarından beklenti bu veri setinde bulunan aynı harflerin düz ve bozuk hallerini aynı öbeklerde tutarken farklı harfleri ayrı öbeklerde tutması şeklindedir. Bu bağlamda farklı p için elde edilen sonuçlar paylaşılmıştır.



Şekil 3.1 : ART yapısı için kullanılan harf örüntü kümesi


Dinamik ART yapısı ile Harf Öbekleme

Burada 5 farklı harfin düzgün ve bozuk hallerini içeren Şekil 3.1'deki örüntü kümesi kullanılmıştır. Farklı uyanıklık katsayısına bağlı dinamik ART yapısının öbekleme sonuçları paylaşılmıştır. Burada süreç olarak öğrenmeyi modelleyen yapı için her açılan yeni öbekte temsil edilen örüntü ekrana gelecek şekilde uzun süreli belleğin çıkışına yansıyan sonuçlar paylaşılmıştır.



Şekil 3.2 : $p=0.1$ değerine bağlı harf öbeklemesi

$p = 0.1$ seçilerek yapılan öbekleme sonucunda ağın uzun süreli belleğinde Şekil 3.2’de görüldüğü gibi ilk karşılaşılan A harfi için bir öbekleme yapılmıştır. Geriye kalan 28 örüntü bu öbek ile temsil edilmektedir. Kısaca küçük bir uyanıklık katsayısı ile verilerdeki farklılıklar çok kaba bir şekilde ele alındığından tüm harfler tek bir öbeğe atanmıştır.




Şekil 3.3 : $p=0.8$ değerine bağlı harf öbeklemesi


$p = 0.8$ seçilerek yapılan öbekleme sonucunda ağın uzun süreli belleğinde Şekil 3.3’de görüldüğü gibi dinamik ART yapısı farklı tip harfler için farklı örüntüler ile ilk karşılaştığında bu örüntülere ilişkin öbekler açmıştır ve kimi bozukluklar olsa da bütün harfleri düzgün bir şekilde ilgili harf öbeğinin içerisine atmıştır. Bu ölçüde başarılı öbekleme Algoritmik ART ile denenen farklı p değerleri için gözlenmemiştir.

$p = 0.9$ seçilerek yapılan öbekleme sonucunda ağın uzun süreli belleğinde Şekil 3.4 de görüldüğü gibi ağın öbekleme sayısında ART yapısının doğası gereği artan p değerine bağlı olarak uzun süreli belleğinde tutmuş olduğu öbekleme sayısında artış görülmektedir. Kimi bozuk harfleri, yeni örüntüler olarak belirleyip bu harfler için ayrı öbek oluşturmuştur.

Farklı uyanıklık katsayısı değerine bağlı olarak harflerin aynı öbekle temsil edilme durumuna ilişkin sonuçlar Şekil 3.5 de görülmektedir. Ağın bozuk örüntüleri de doğru şekilde sınıfladığı uyanıklık katsayısı değerleri 0.7 ve 0.8’dir. Burada incelenen her bir katsayı değeri haricindeki sonuçlar ekte paylaşılmıştır.




Şekil 3.4 : $p=0.9$ değerine bağlı harf öbeklemesi



Şekil 3.5 : uyanıklık katsayısına bağlı öbekleme başarı yüzdesi

Algoritmik ART yapısı ile Harf Öbekleme

Burada dinamik ART yapısı kullanılarak yapılan incelemenin bir benzeri Algoritmik ART yapısı için yapılmıştır. Yine 5 farklı harfin düzgün ve bozuk halleri Şekil 3.1 görüldüğü sırada bu ART yapısına sunulmuştur. Ağın öbekleme davranışından beklenen, aynı harf temsillerini bir arada tutabilen öbekler oluşmasıdır. İstenilen bu duruma p değerinin etkisini gözlemlemek için farklı p değerleri ile ağın öbekleme sonuçları incelenmiştir.



Şekil 3.6 : $p=0.1$ değerine bağlı harf öbeklemesi

$p = 0.1$ seçilerek yapılan öbekleme sonucunda ağın üç öbek üzerine örüntüleri öbeklediği Şekil 3.6 görülmektedir. Burada farklı harf örüntülerinin birarada bulunduğu öbekler dikkat çekmektedir.



Şekil 3.7 : $p=0.5$ değerine bağlı harf öbeklemesi

$p = 0.5$ seçilerek yapılan öbekleme sonucunda ağın beş öbek üzerine örüntüleri öbeklediği Şekil 3.7 görülmektedir. Burada A ve Ç harflerine ilişkin öbeklerde sadece bu harfler gözükürken, B harfine ilişkin öbekte Ç harfi, D öbeğine ilişkin öbekte ise B

harfi bulunmaktadır. Ayrıca, B harfine ilişkin bozuk örüntülerin bir kısmını B harfine ilişkin öbeğe yerleşmemiş, yeni bir öbek oluşmuştur.



Şekil 3.8 : $p=0.7$ değerine bağlı harf öbeklemesi

$p = 0.7$ seçilerek yapılan öbekleme sonucunda ağın yedi öbek üzerine örüntüleri öbeklediği Şekil 3.8 görülmektedir. Sadece A harfleri başarılı bir şekilde öbeklenmiştir. Burada $p = 0.5$ durumuna benzer sonuçlar gözükmemektedir. Bozuk örüntüler için daha fazla öbek oluşturulmuştur. Ekte bu ART yapısı ile farklı uyanıklık katsayıları denenerek elde edilmiş sonuçlar paylaşılmıştır.

Yukarıda da belirtildiği gibi, dinamik ART yapısı ile elde edilen sonuçlar Algortimik ART yapısına göre daha başarılıdır.

3.2 Epilepsi Veri Seti

Elektroensefalogram (EEG) sinyali, ilk ölçülebildiği yıllarda beyin hasarlarının belirlenmesi ve anatomik kaynaklı bozuklukların teşhis edilmesi amacı ile kullanılmıştır. Ancak sonrasında nörolojik hastalıkların teşhisinde daha anlamlı sonuçlar verdiği gözlemlenmiştir [18]. Bu yöntem, beyinde geçici elektriksel aktivite bozukluğu oluşmasına neden olan ve sık bilinen nörolojik bir hastalık olan epilepsinin teşhisi sürecinde başvurulan ilk yöntemlerdendir. Epilepsi rahatsızlığı, kronik yapıda olabiliyor olması ve nöbet geçirme anında kontrol kaybına bağlı olarak ciddi fiziksel hasarlar ortaya çıkmasına neden olması tedavi sürecinde erken teşhisi önemlidir.

Dünya nüfusunun yaklaşık yüzde 4 – 5'i bu hastalığa sahip olmasına karşın, nöbet geçirmeden bu hastalığın teşhisi mümkün olmadığından bu hastaların belirlenmesi yüzde 1 gibi düşük bir oranda kalmıştır [8].

Epilepsinin diğer beyin işaretleri içerisinde ayrıştırılıp varlığının tahmin edilmesi uzun süreli EEG kayıtları alınıp, detaylı inceleme ile olasıdır. İnsan kontrolünde böylesi bir analizin yapılması nöbet öncesinin tahmin edilmesi çok düşük oranlarda kalmıştır [8]. Bu oranı yükseltmek amaçlı epilepsinin bilgisayarlı tespiti ve EEG sinyallerinin sınıflandırılması için yöntem arayışı son yıllarda birçok bilim insanının araştırma konusu olmuştur [9].

Son dönemde Kaotik EEG verileri üzerine yoğun araştırmalar yapılmıştır. Andrzejak'ın çalışması [1], farklı fizyolojik ve patolojik durumlar da birçok ekstrakraniyal ve intrakraniyal kayıt bölgelerindeki elektriksel beyin aktivitesinin dinamik özelliklerini sabit analiz parametreleri kullanarak karşılaştırmayı amaçlamıştır. EEG zaman serilerindeki deterministik ve düşük boyutlu yapıların göstergelerini sıfır hipotezine karşı test etmiştir.


Doğrusal olmayan teknikler uygulayarak epilepsiyi tespit etmek için de birçok çalışma yapılmıştır. Bunlardan biri, yeni bir yöntem olarak önerilmiş LAMSTAR Sinir Ağı kullanarak epileptik nöbetlerin saptanması ile ilgili çalışmadır [9, 19]. İki farklı EEG veri seti kullanarak çalışma yürütülmüştür. Bu veri setlerinden epileptik nöbetleri karakterize etmek için epileptik vuru genliği ve epileptik vuru oluşum sıklığını ele alan iki özellik kullanılmıştır [8]. Bu veri setlerinden ilki gözleri açık normal kişilerden ölçülen EEG zaman serilerini içerirken diğer set epileptik nöbetlerin ortaya çıkması sırasındaki ölçülen EEG kayıtlarından oluşmaktadır. Burada LAMSTAR ağı yüzde 98.4 doğrulukla epilepsiyi saptayabilmiştir. Bir başka çalışmada Shannon'ın entropisi, Renyi'nin entropisi ve Kolmogorov — Sina entropisi gibi farklı entropi tahmin edicileri bir önceki çalışmaya benzer nitelikteki EEG veri setlerine uygulayarak epilepsi tahmin edicisi oluşturulmuştur [9]. Bu sınıflayıcı yaklaşık yüzde 90 doğrulukta sonuçlar üretmektedir. EEG sinyallerinin sınıflandırılmasına dayanan bir başka çalışma, Abdulhamit Subaşı'nın veri üzerinden dalgacık dönüşümü ile öznelilik çıkartma temelli denetimli modüler sinir ağı kullanarak yürütmüş olduğu çalışma olmuştur. Bu çalışma yüzde 94.5'lik sınıflama başarısına sahiptir [19].

Problem için diğer bir sınıflandırma yöntemi olarak uyarlanabilir Bulanık-Sinir Ağı Sistemi (ANFIS) kullanılmıştır [20]. Burada iki aşamada karar verme süreci içeren yapı; dalgacık dönüşümü (WT) kullanılarak öznitelik çıkarımı yapılmış ve geri yayımlı gradyan iniş yöntemi ile ANFIS eğitilmiştir. Uygulamak amaçlı bu tezde de kullanılan A, B, C, D, E veri kümesi olan beş tip EEG sinyali kullanılmıştır. Veri setlerinde bu 5 veri setinin ANFIS ağı ile sınıflanma başarısı yüzde 98.68 doğrulukla gerçekleşmiştir. Epileptik nöbetlerin saptanması ve sınıflandırılmasına yönelik incelenen çalışmaların sonuncusu Kaya'nın çalışmasıdır [21]. Bu çalışmada, epileptik EEG sinyallerinin sınıflandırılması için aşırı öğrenme makinesi (ELM) kullanılmıştır. ELM, tek bir gizli katmanlı ileri beslemeli yapay sinir ağı (YSA) modelidir. Burada, ayrık dalgacık dönüşümü ile elde edilen istatistiksel özellikler sınıflandırma sürecinde kullanılmıştır. Bu bölümde detaylı incelenen veri seti ile yürütülen çalışma, A-D, A-E veri setlerini yüzde 100 oranında doğru sınıflamıştır.

3.2.1 Kullanılan veri seti içeriği

Kullanılan veri seti 23.6 saniye süren veri kaydı olup 100 parçadan oluşan EEG segmenti halinde beş farklı setten (A-E ile ifade edilecek biçimde) oluşmaktadır. Bu segmentler, kas aktivitesi veya göz hareketleri nedeniyle oluşabilecek gürültülerden temizlenmiştir. Set A ve B, Şekil 3.9 de dizilimi gösterilen standart bir elektrot yerleştirme şeması kullanılarak beş sağlıklı gönüllü denek ile yapılan ölçümler ile elde edilmiştir. Uyanık haldeki katılımcıların rahat bir vaziyette bulunmaları durumunda önce gözetilerek sırasıyla gözleri açık vaziyette A veri seti elde edilmiş, sonra gözleri kapalı olma durumunda B veri seti edinimi sağlanmıştır. D seti beynin epileptojenik bölge içinden ve C setindeki veriler beynin karşı yarıküresinin hipokampal yapıdan kaydedilmiştir. C ve D veri seti içeriğinde nöbet geçirilmediği aralıklardaki ölçülen aktiviteyi içerirken, E setindeki veri içeriği sadece nöbet aktivitesi içermektedir.

Tüm EEG sinyalleri, genel ortalamanın referans alındığı, patolojik aktivite (C, D ve E) veya güçlü göz hareketi aktivitelerini (A ve B) içeren elektrotların ihmal edildiği aynı 128 kanallı amplifikatör sistemi ile kaydedilmiştir. 12 bit analog-dijital dönüşümden sonra, veriler 173.61 Hz örnekleme hızında veri toplama amaçlı bilgisayar sistemine iletilmiş ve burada veri kaydı disklere yazılmıştır. Şekil 3.11'de bu tez çalışması için



Şekil 3.9 : Uluslararası 10-20 sistemi esas alınarak oluşturulmuş elektrot dizilimi esaslı EEG cihazı kullanılmıştır. Burada elektrot adlandırması anatomik konum üzerinden türetilmiştir. A ve B setleri için kayıtlar bu düzen esasında edinilmiştir [1].



Şekil 3.10 : Epilepsi hastalarının ameliyat öncesi değerlendirilmesi için implante edilen intrakraniyal elektrot şeması esaslı ölçüm yöntemi [2].


ele alınan Bant Geçiren Filtre ayarları 0.53-40 Hz özelliğindeki filtre uygulanmış bu veri setlerinden örnekler gösterilmektedir.

Bu çalışmada, esas alınan A ve D veri setleri olmuştur. Bu veri setleri hem sağlıklı gönüllülerin epilepsi tanısı koymak hem de epilepsi hastalarının kriz öncesi epileptik bulgularını sınıflandırmak için anlamlı bilgi içeriği sunmaktadır. Analizlerde hastadan alınan EEG belirteçlerinin sınıflandırılması, gözler açık sağlıklı gönüllüler (set A) ve epilepsi öncesi (set D) veri seti ile eğitilmiş öğrenme algoritmaları sağlanmıştır [8]. Bu iki veri setinin zaman serisi olarak gösterimi Şekil3.12 verildiği gibidir.


3.2.2 Öznitelik çıkarma yöntemleri

Ayrık Dalgacık Dönüşümü Tekniği

Dalgacık dönüşümü, herhangi bir genel fonksiyonun sonsuz bir dalgacık serisi olarak ifade edilebildiği bir gösterimdir. Ele alınan fonksiyon baz vektörleri dalgacık fonksiyonları olmak üzere ifade edilmektedir. Dalgacık analizi, bir sinyali, ana



Şekil 3.11 : Yukarıdan aşağıya: A-E’yi sıralanmış beş veri setinin her birinden örnek EEG zaman serileri gösterimi.




Şekil 3.12 : A ve D veri setlerinden örnek veriler

dalgaçık olarak adlandırılan tek bir fonksiyonun kaydırılması ve genişletilmesiyle elde edilen belirli bir baz fonksiyon grubunun doğrusal bir kombinasyonu olarak ifade edilebileği fikri üzerine kurulmuştur. Bu durumda ele alınan sinyal, dalgaçık katsayıları ile ağırlıklandırılmış, dalgaçık fonksiyonlarının doğrusal bir kombinasyonu olarak yeniden oluşturulmaktadır. Sinyalin düzgün ifade edilebilirliği için yeterli çoklukta katsayı hesaplanmalıdır. Dalgaçıkların en önemli özelliği zaman-frekansı lokalizasyonuna sahip olmasıdır. Bu durum dalgaçık enerjisinin çoğunun sınırlı bir zaman aralığıyla sınırlanabilir olduğu anlamına gelir. EEG sinyaline uygulanan dalgaçık tekniği, özellikle sinyalin Fourier dönüşümü ile zaman geçişlerindeki anlık bilgilerin kaybını önemli ölçüde telafi etmektedir [19] .

Ayrık dalgacık dönüşüm tekniği (DWT) denklem 3.1 ile ifade edilmektedir.


$$w(i, j) = \sum_j \sum_k x[n] 2^{\frac{-j}{2}} \phi(1/2^j n - k) \quad (3.1)$$

Burada $x[n]$ sinyalin kendisi ve Φ ana dalgacıktır. DWT farklı frekans bantlarındaki sinyali farklı çözünürlüklerle analiz etmemizi sağlar. Böylece sinyal hem ayrıntılı hem de kaba bir yaklaşımla ifade edilmiş olur. Ayrıntılı terimlere ilişkin katsayılar için yüksek geçiren, yaklaşık katsayıları için ise alçak geçiren filtreler uygulanır. Bir X sinyalinin n çok çözünürlüklü ayrıştırma prosedürü Şekil 5'te şematik olarak gösterilmektedir. Bu şemanın her aşaması, iki dijital filtre ve iki aşağı örnekleyiciden oluşur. İlk filtre, $h[n]$ ayrık ana dalgacık, ikincisi, $g[n]$ ayna versiyonu olarak ifade edilir [20,21].



Şekil 3.13 : DWT uygulamasının alt bant ayrışması; $h[n]$ yüksek geçiren filtre, $g[n]$ düşük geçiren filtre [3].

DWT kullanarak sinyallerin analizinde uygun dalgacık seçimi ve ayrışma seviyesi sayısı büyük önem taşımaktadır. Ayrışma seviyelerinin sayısı, sinyalin baskın frekans bileşenlerine göre seçilir. EEG sinyallerinin 30 Hz'nin üzerinde herhangi bir yararlı frekans bileşeni olmadığından, ayrışma seviye sayısı 5 olarak hesaplanmıştır. Böylece, EEG sinyalleri D1-D5 bileşeni ile son ayrışımı A5 olmuştur. EEG sinyallerindeki değişiklikleri saptamak için genellikle 4. sıradaki Daubechies dalgacığının (db4) ve 10. sıradaki Symmlet'in (sym10) yumuşatma özelliği kullanılmaktadır. Ele alınan veri seti için Şekil 6'da, db4 dalgacık zaman-frekans lokalizasyonu sonuçları elde edilmiştir. Daha düşük frekanslarda, A veri kümesi D veri kümesinden daha yüksek genlik değerlerine sahiptir. Bu çalışmada, normal ve epileptik denekleri ayırt etmek için belirli bir frekans aralığındaki genlik değerleri toplanarak özellik olarak eklenmiştir.




Şekil 3.14 : A seti içeriğinden elde edilmil db4 dalgacık spektrumu sonucu, D seti içeriğinden elde edilmil db4 dalgacık spektrumu sonucu.

Shannon Entropisi

EEG sinyali karmaşık, doğrusal ve durağan olmayan rastgeleliktedir. Doğrusal olmayan bir analiz yöntemi olan Entropi, EEG verileri için analiz amaçlı başvuru yöntemlerinden olmuştur. Burada, Entropi belirsizliğin bir ölçüsüdür ve veri içeriğindeki kaos seviyesini ölçtünü yansıtmaktadır [22]. Bu çalışmada Shannon'ın entropisi normal ve epileptik EEG sinyallerini incelemek ve araştırmak için kullanıldı. Ayrık tip RV X 'in Shannon Entropisi [23] şu şekilde tanımlanır:

$$H(X) = - \sum_{i=1}^N p_i \log_b p_i \quad (3.2)$$




Şekil 3.15 : A ve D seti içeriğinden elde edilmiş Shannon Entropisi.

Burada N olası durumların sayısını ifade ederken π , $X = x_i$ olayının gerçekleşme olasılığını ifade etmektedir. $\pi > 0$ olduğu varsayılarak olay ele alınır; en sık kullanılan değerler $b = 2$ ve $b = e$ 'dir [9, 23].

Enerji


Genel hastalık senaryolarında enerji kavramı hasta ve sağlıklı birey ayrımında önemli bir metrik olarak kabul görmüştür. Burada, EEG sinyallerinin enerjisi normal ve epileptik veri setlerini belirler. Ayrık zamanlı sinyaldeki $x(n)$ sinyal enerjisi şu şekilde tanımlanmaktadır:

$$E = \sum_n^{\infty} |x(n)|^2 \quad (3.3)$$



Şekil 3.16 : Veri setleri içeriğinden elde edilmiş enerji değerleri.

Standart sapma



Şekil 3.17 : Veri setleri içeriğinden elde edilmiş standart sapma Değerleri.

Sistemik faktörlerden ve rastgelelikten ortaya çıkan durumların sayısal ifadesini sağlayan bu yöntem Denklem 3.4 ile ifade edilir.

$$S = \sqrt{\frac{1}{N-1} \sum_{i=1}^N |A_i - \mu|^2} \quad (3.4)$$

μ , A'nın ortalamasıdır.

Bu bölümde anlatılan büyüklükler, epilepsi verilerinin sınıflandırılması ve öbeklenmesi için gereken öznitelik kümesini oluşturmakta kullanılmıştır.

3.3 Çok katmanlı Algılayıcı Sonuçları

Bir önceki bölümde açıklanan epilepsi veri seti için çok katmanlı algılayıcı (ÇKA) ile sınıflandırma sonuçları bu bölümde paylaşılmıştır. Burada, yapılan çalışmalar [20, 21] baz alınarak işaret üzerinden Tablo 3.1'de belirtilen 12 farklı öznitelik çıkarılarak ağ üzerinde sınıflandırma başarısı test edilmiştir. Sınıflama amaç ölçütü A ve D veri setlerinin birbirinden ayrıştırılması şeklindedir. Bu bağlamda, Tablo 3.1 belirtilen öznitelikler; Shannon Entropi, işaretin her bir bölümü için enerji değeri, genliğin en yüksek olduğu değer, işaretin standart sapma değeri, frekans hesabında maksimum değer, reel kısmı, frekans domeninden ve dalgacık dönüşümünden gelen parametre değerleri öznitelik olarak alınmıştır. Öncelikle ağın bu örüntülerin hepsi dahil edilerek sınıflandırma başarısı incelenmiştir. Sonrasında Tablo 3.1 görüldüğü gibi her bir öznitelik hariç tutularak ağın sınıflandırma başarısı test edilmiştir. Her bir özniteliğin dahil edildiği 1.durum sonucunda elde edilen sınıflandırma başarısının altında kalan öznitelikler için 14.durumda tekrardan sadece bu özniteliklerin ağına verildiği bir eğitim süreci tasarlanmıştır. Elde edilen sınıflandırma başarısı bütün özniteliklerin sürece dahil edildiği durum ile kıyaslanmıştır. Sonuç olarak frekans tanım bölgesine geçiş sırasında elde edilen öznitelikler ve dalgacık dönüşümünden gelen özniteliklerden oluşan toplam 4 öznitelikli durum ile 12 öznitelik kullanılan durum arasında sınıflandırma başarısı olarak benzerlik gözlenmiştir.

Bu ağın sınıflandırma işlemi süresince eğitim ve test aşamalarında aktivasyon fonksiyonu olarak tanjant hiperbolik fonksiyonu kullanılmıştır. İki gizli katmanlı bir yapı üzerinden tanımlanmış olan bu ağ için ağırlıklar başlangıçta Gauss dağılımı (Gauss distribution) ile elde edilen bir rastgelelikle tanımlanmıştır. Eğitim ve test kümesi verileri yine bir Gauss dağılımı üzerinden seçilerek yüzdesel olarak 80'lik kısmı ile eğitim 20'lik kısmı ile test seti oluşturulmuştur. Eğitim sırasında ağın

ıkışında g zlemlenen ortalama karesel hata deęeri  zerinden eęitimin tamamlanması kararı verilmiřtir.Aęın tutarlılıęını ortaya koymak adına her bir sınıflandırma durumu 20 kez tekrarlanan bu s re iin her bir test bařarısı sonucu Tablo 3.1 elde edilmiřtir.



Çizelge 3.1 : Çok Katmanlı Algılayıcı ile ele alınan epilepsi verisi için seçilen özniteliklere bağlı sınıflandırma başarı sonuçları.

<i>Durumlar</i>	Entropy	Enerji	maxValue	stdValue	sumWPS1	mVRF	mVAbsF	sum _a bs1	sum _a bs2	sum _a bs3	maxValuePF	sumWPS2	Sonuçlar
1. <i>Durum</i>	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	95,99
2. <i>Durum</i>		✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	96,49
3. <i>Durum</i>	✓		✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	97,44
4. <i>Durum</i>	✓	✓		✓	✓	✓	✓	✓	✓	✓	✓	✓	96,35
5. <i>Durum</i>	✓	✓	✓		✓	✓	✓	✓	✓	✓	✓	✓	96,29
6. <i>Durum</i>	✓	✓	✓	✓		✓	✓	✓	✓	✓	✓	✓	92,13
7. <i>Durum</i>	✓	✓	✓	✓	✓		✓	✓	✓	✓	✓	✓	95,96
8. <i>Durum</i>	✓	✓	✓	✓	✓	✓		✓	✓	✓	✓	✓	97,25
9. <i>Durum</i>	✓	✓	✓	✓	✓	✓	✓		✓	✓	✓	✓	95,92
10. <i>Durum</i>	✓	✓	✓	✓	✓	✓	✓	✓		✓	✓	✓	96,45
11. <i>Durum</i>	✓	✓	✓	✓	✓	✓	✓	✓	✓		✓	✓	96,26
12. <i>Durum</i>	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓		✓	96,12
13. <i>Durum</i>	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓		80,96
14. <i>Durum</i>	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	95,33

3.4 ART ile Epilepsi Verilerinin Öbeklenmesi


Burada Bölüm 3 içerisinde ele alınan epilepsi veri seti Dinamik ART ve Algoritmik ART yapıları ile öbekleme problemi olarak ele alınmış ve elde edilen sonuçları paylaşılmıştır. Bölüm 3.2.2 ile veri seti üzerinden çıkarılan öznitelikler bu ağ yapılarında giriş örüntüsü olarak düzenlenmiştir. Bu düzenleme için öncelikle ele alınan öznitelik verilerine her bir öznitelik boyutuna Denklem 3.5 uygulanarak veri her öznitelik boyutu için 0 ile 1 arasında tanımlı reel sayılara dönüştürülmüştür. 100 örnekten oluşan 12 boyutlu bu veri seti, her iki ART yapısı içinde analiz edilebilmesi için ikili tabana dönüştürülmüştür. Bu dönüşüm için 0 ile 1 arasında reel sayılardan oluşan her bir öznitelik değerinin ondalıklı kısmının iki basamağını ifade etmesi amaçlı ikilik tabanda 7 boyutlu veri açılmıştır. Öznitelik veri kümesinde 12 farklı öznitelik tanımlı olduğundan ART yapısı için ikili tabanda tanımlı örüntü 84 boyutlu hale dönüşmüştür. Böylece elde edilen 100 örnekle 84 boyutlu örüntü kümesi, Dinamik ART ve Algoritmik ART yapıları ile öbeklenmiştir.

$$x^* = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (3.5)$$

3.4.1 Dinamik sistem yaklaşımı ile öbekleme

İkili tabana dönüştürülmüş epilepsi öznitelik verileri, Bölüm 2.2’de açıklanan dinamik ART yapısı kullanılarak öbekleme işlemine tabi tutulmuştur. Burada, farklı p değerlerine bağlı öbekleme başarıları sınanmıştır. Başarı ölçütü, ağın veri seti içerisindeki hastalıklı ve sağlıklı veri örneklerinin farklı öbeklere ayırabilmesi olarak tanımlanmıştır. Veri seti 50 hastalıklı ve 50 de sağlam kişiye ait 100 örnekten oluşmaktadır. Burada ağın başarısına etkisi olup olmadığını incelemek adına; ilk durum olarak sağlıklı ilk 50 veri sırasıyla örüntü girişi olarak tanımlanmıştır. Sonrasında hastalıklı veri örnekleri örüntü olarak uygulanarak öbekleme başarıları değerlendirilmiştir.

Bu başarı puanı oluşturulurken maksimum öbek sayısınca örüntülerin temsil edildiği öbeklere bakılmıştır. Her öbek içeriğindeki örüntüler hastalıklı ve sağlıklı veri setine ait olma durumu ile incelenmiştir. Öbek içerisinde sayıca yoğun örüntüye göre



Şekil 3.18 : İlk durum için farklı p değerine bağlı elde edilen öbekleme başarıları


hastalıklı veya sağlıklı öbek olarak nitelendirilmiştir. Örneğin bir öbekte 5 tane sağlıklı olarak etiketlenmiş veri 3 tane hasta olarak etiketlenmiş veri var ise bu öbek sağlıklı duruma karşı düşen öbek olarak belirlenmiştir. Bu durumda niteliğin dışında kalan örüntülerin hatalı öbekleme olduğu kanaatine varılır. Öbek içerisinde eşit yoğunlukta örüntü bulunması durumunda her iki örüntünün de kusurlu öbeklendiği kararı verilmiştir.



Şekil 3.19 : İlk durumda $p=0.1$ için elde edilen öbekleme sonuçları


Bu başarı koşulları altında sağlıklı veri setlerinin öncelikle sunulduğu birinci durum için farklı p değerlerine bağlı elde edilen başarı yüzdeleri Şekil 3.18 görülmektedir. Düşük p değerlerinde öbekleme başarısının az olduğu görülmektedir. Buna ağırlık düşük uyanıklık katsayısına bağlı olarak örüntüleri temsil etmek için az sayıda öbek oluşturma eğiliminde olması neden olmaktadır. Bu durum, $p = 0.1$ gibi düşük p için elde edilen Şekil 3.19 öbekleme sonuçlarında net bir şekilde görülmektedir. Burada ART yapısı

örüntüleri tek bir öbek içerisinde tutma yönünde davranış sergilemektedir. Şekil 3.18 p değerinin artmasına bağlı olarak öbekleme başarısının arttığı görülmektedir. Bu duruma kaynaklık eden, ART yapısının yüksek p değerine bağlı olarak ağırlık ele aldığı örüntüler için öbek sayısını arttırma eğiliminde olmasıdır. Şekil 3.20 de $p = 0.95$ değeri için elde edilen sonuçlar bu durum için örnek olarak verilebilir.




Şekil 3.20 : İlk durumda $p=0.95$ için elde edilen öbekleme sonuçları

Burada, örüntü sayısı kadar öbek açılmasına bağlı olarak öbekleme başarısı yüksek olmaktadır. Ancak burada veriler arasında ilişkinin kaybolduğu görülmektedir. Bu noktada öbekleme sürecinde uygun p değerinin belirlenmesi büyük önem taşımaktadır. Şekil 3.21 $p = 0.5$ değeri için hastalıklı ve sağlıklı veri örüntülerinin iki ayrı öbek üzerinde etkin bir şekilde ayrıldığı görülmektedir. Burada alt öbeklerde toplanan örüntülerde de belirgin ayrışmalar görülmektedir.




Şekil 3.21 : İlk durumda $p=0.5$ için elde edilen öbekleme sonuçları

Hastalıklı örüntülerin ilk olarak sunulduğu sonrasında sağlıklı örüntülerin sunulduğu ikinci durumda farklı p değerine bağlı ağın öbekleme başarısı Şekil 3.22 gösterilmektedir.



Şekil 3.22 : 2. durum için farklı p değerine bağlı elde edilen öbekleme başarısı


Burada ilk duruma benzer nitelikte p değeri düşük olduğu durumda ağın başarısının düşük olduğu, p değerinin artmasına bağlı olarak öbekleme başarısının arttığı gözlemlenmektedir.




Şekil 3.23 : 2.durumda $p=0.1$ için elde edilen öbekleme sonuçları

Şekil 3.23 $p = 0.1$ değeri için örüntülerin bir öbek üzerinde toplandığı görülmektedir.

$p = 0.95$ gibi yüksek p değeri için Şekil 3.24'de görüldüğü üzere, ağın örüntü sayısı ölçütünde öbek oluşturmaya bağlı olarak yüksek öbekleme başarısı ortaya çıkmaktadır.



Şekil 3.24 : 2.durumda $p=0.95$ için elde edilen öbekleme sonuçları




Şekil 3.25 : 2.durumda $p=0.5$ için elde edilen öbekleme sonuçları

Şekil 3.25 de $p = 0.5$ değeri için belli öbeklerde hastalıklı ve sağlıklı örüntülerin görece yoğun bulunduğu öbekler görülmektedir.


Hastalıklı ve sağlıklı örüntülerin rastgele ağa sunulduğu 3. durum için p değerine bağlı öbekleme başarı sonuçları Şekil 3.26 görülmektedir.

Burada diğer durumlara benzer nitelikte düşük p değeri için Şekil 3.27 görüldüğü gibi ağ tek bir öbek üzerinde bütün öbekleri toplamak yönünde davranış sergilemektedir.


Şekil 3.28 yüksek p değeri için ağın her örüntü için bir öbek oluşturduğu görülmektedir. $p = 0.5$ için ağın sağlıklı örüntülerin yoğun bulunduğu öbekler oluşturduğu görülmektedir.



Şekil 3.26 : 3.durum için farklı p değerine bağlı elde edilen öbekleme başarıları




Şekil 3.27 : 3.durumda $p=0.1$ için elde edilen öbekleme sonuçları



Şekil 3.28 : 3.durumda $p=0.95$ için elde edilen öbekleme sonuçları


Örüntüler arasındaki ilişkiyi koruyarak yapılan öbeklemeleri belirlemek için farklı uyanıklık katsayıları için ağır öbekleme davranışları gözlemlemek amaçlı deneyler yapılmıştır. Bu yönde elde edilen sonuçlar ekte paylaşılmıştır.



Şekil 3.29 : 3.durumda $p=0.5$ için elde edilen öbekleme sonuçları


3.4.2 Algoritmik yaklaşım ile öbekleme

İkili tabana dönüştürülmüş epilepsi öznitelik verileri Algoritmik ART yapısına da uygulanmıştır. Hastalıklı ve sağlıklı veri setinden oluşan bu örüntülerden ilk olarak sağlıklı veriler ağı sunulduğu durumda p değişimine bağlı öbekleme başarısı Şekil 3.30 görülmektedir.




Şekil 3.30 : 1.durum için farklı p değerine bağlı elde edilen öbekleme başarısı

$p = 0.1$ için örüntülerin öbeklenmesi Şekil 3.31 görülmektedir. Burada örüntüler için 4 öbek oluşturulmuştur. 2. ve 4. öbekleri sağlıklı örüntülerden oluşurken diğer iki öbekte her iki veri kümesinden örüntü içermektedir.



Şekil 3.31 : 1.durumda $p=0.1$ için elde edilen öbekleme sonuçları


$p = 0.95$ yüksek p değeri için örüntülerin öbeklenmesi Şekil 3.32 görülmektedir. Yüksek p değeri için elde edilen sonuçlara benzer nitelikte her örüntü için öbek oluşturulduğu görülmektedir.



Şekil 3.32 : 1.durumda $p=0.95$ için elde edilen öbekleme sonuçları


Dinamik ART yapısı için öbekleme başarısı yüksek olan $p = 0.5$ için sağlıklı verilerin önce uygulandığı durumda elde edilen Algoritmik ART sonucu Şekil 3.33 görülmektedir. Algoritmik ART yapısında bu p değeri için öbekleme başarısı daha düşük olduğu görülmektedir.

Hastalıklı verilerin öncelikli olarak ağırlı uygulandığı 2.durum için farklı p değerlerinde elde edilen öbekleme başarısı Şekil 3.34 görülmektedir. Bu sonuçların sağlıklı örüntülerinin ağırlı ilk verdiği durum ile benzerlik göstermektedir. Bu durum ve aşağıda



Şekil 3.33 : 1.durumda $p=0.5$ için elde edilen öbekleme sonuçları


verilen 3. durum için Algoritmik ART yapısına ilişkin sonuçlar farklı p değerleri için Ekte verilmiştir.



Şekil 3.34 : 2.durum için farklı p değerine bağlı elde edilen öbekleme başarıları

Sağlıklı ve hastalıklı örüntülerin ağa rastgele bir şekilde verildiği 3.durumda elde edilen öbekleme başarı sonuçları Şekil3.35 görülmektedir. Bu sonuçlar örüntülerin öncelik sırası ile ağa sunulması durumlarına göre görece daha başarısız öbekleme sonuçları verdiği görülmektedir.

Epilepsi verilerini öbeklemek için iki farklı ART yapısı kullanılmıştır.ÇKA ile elde edilen sınıflandırma başarılarına yakın öbekleme başarıları elde edilmiştir. Bu öbeklemeler ART yapısının p uyanıklık parametresine bağlı olarak şekillenmektedir. Yüksek p değerleri ağın çok sayıda öbek açması ile örüntüler arasında ilişkiyi kaybetmesine neden olduğundan yüksek öbekleme başarısının bir anlamı bulunmamaktadır.Düşük p değeri, ağın öbek sayısını azaltmakta ve öbeklerin içinde farklı



Şekil 3.35 : 3. durum için farklı p değerine bağlı elde edilen öbekleme başarıları

özellikteki verilerin alınmasına neden olmaktadır. Burada esas amaç veriler arasındaki ilişkiyi koruyarak öbekleme imkanı tanıyacak p değerinin belirlenmesidir. Bu amaç için farklı p değerleri ile ART yapılarının öbekleme davranışı gözlemlenmiştir. Bu yönde elde edilen sonuçlar Ekte paylaşılmıştır.

4. JANSEN KORTİKAL KOLONLAR MODELİ İLE EPİLEPSİ MODELİ

Bölüm 3’de EEG verilerinin yapay sinir ağ yapıları ile sınıflandırılması ve öbeklenmesine dayanarak epilepsi tanısı konulmasına ilişkin tez kapsamında yapılan çalışmalara ilişkin sonuçlar verilmiştir. Bu bölümde ise, hesaplamalı sinir bilim bakış açısı ile EEG kayıtlarına yansıyan epilepsi işaretlerine odaklanılacaktır. Bu işaretlerin nasıl oluştuğuna ilişkin yapılan çalışmalar ve bu yönde elde edilen sonuçlar verilecektir. Burada, EEG kayıtlarına yansıyan epilepsi işaretlerinin oluşumunda yer alan nöral yapıların bir modeli Jansen’ın Kortikal Kolonlar Modeli ile ele alınacaktır. Jansen’ın modeli hesaplamalı sinirbilim alanında ele alınan değişik seviyelerdeki modellerden, bir nöral popülasyonun davranışını modellemeye yönelik Nöral Kütle Modelidir [24]. Tez kapsamında Jansen modeline dayanarak önerilen, model, epilepsi sırasında izlenen davranışları ve beyinde oluşan alfa dalgaları boyundaki işaretlerin oluşmasına ilişkin sonuçlar sunmaktadır.

Şekil4.1’de blok diyagramı olarak görüleceği üzere, nöron grupları seviyesinde [24] çalışmasından esinlenen bir modelleme yapılmaktadır. Bu çalışmanın [24]’de verilen çalışmadan farkı olarak modelin üretmiş olduğu işaretlerin durum uzayında sergilemiş olduğu davranışlara bakılmıştır. Ayrıca işaretin frekans bileşenlerine bakılmış beyinde gerçekleşen süreçlerdeki frekans aralıklarıyla uyumlu olduğu görülmüştür.

Model;ateşleyen, sönümleyen ve piramidal nöron gruplarından oluşmaktadır. Bu yapılardan, ateşleyen ve sönümleyen nöron grupları piramidal nöron grubu üzerine sırasıyla ateşleyici ve sönümleyici yönde giriş uygulamaktadır. Bu giriş, piramidal nöron grubu tarafından ateşleyici yönde, aynı nöron gruplarına geri beslenmektedir. Ayrıca bu grup üzerine diğer kolonları ve talamus gibi korteks altı yapıları temsil edecek şekilde ateşleyici yönde harici bir P gürültüsü uygulanmaktadır.

Bu modeldeki piramidal hücre grubuna ilişkin işaret, EEG işaretlerine karşı düşmektedir. Bu işaret Şekil 4.1’de y değişkeni ile ifade edilmiştir. y , y_1 ateşleyen davranış sergileyen hücre gövdesinin sinaptik boşluğa bıraktığı işaret ile y_2 sönümleyen davranış sergileyen hücre gövdesinden sinaptik boşluğa bırakılan işaretin

işaretlerden etkilendiği görülmektedir. Bu etki hücre gövdesini temsil eden sigmoid bir fonksiyon üzerinden sinaptik boşluğa aktarılmaktadır. Burada sinaptik boşluğa bırakılan y_0 işareti ateşleyen ve sönümleyen davranış sergileyen hücre gruplarına Denklem 4.4 ile tanımlı ağırlıklar oranında etki etmektedir.

$$\begin{aligned}\dot{y}_1(t) &= y_4(t) \\ \dot{y}_4(t) &= Aa[p(t) + C_2 \text{Sigm}[C_1 y_0(t)]] - 2ay_4(t) - a^2 y_1(t)\end{aligned}\tag{4.2}$$

Ateşleyen davranış sergileyen hücre grubunu taklit etmek için Denklem 4.2 kullanılmaktadır. Burada korteks altı yapıların davranışlarını ifade eden tek düze stokastik bir dağılıma ilişkin $P(t)$ işareti ve piramidal hücre grubunun sinaptik boşluğa bıraktığı işaret olan y_0 'in etkili olduğu görülmektedir. Bu denklem de ateşleyici hücre gövdesinin sinaptik boşluğa bıraktığı işaret y_1 ile ifade edilmektedir.

$$\begin{aligned}\dot{y}_2(t) &= y_5(t) \\ \dot{y}_5(t) &= BbC_4 \text{Sigm}[C_3 y_0(t)] - 2by_5(t) - b^2 y_2(t)\end{aligned}\tag{4.3}$$


Nöral yapıların davranışını temsil eden bir diğer popülasyon sönümleyici davranış sergileyen hücre grubudur ve bu hücre grubunun davranışı Denklem 4.3 ile modellenmiştir. Temel olarak piramidal hücre grubunun sinaptik boşluğa bıraktığı işaret olan y_0 'in etkili olduğu görülmektedir. Bu nöral yapıların etkileşimi sonucunda elde edilen işaret y_2 ile ifade edilmektedir. Farklı popülasyonların birbirine etkilerine ilişkin katsayılar Denklem 4.4 ile denklemler içerisinde kullanılan diğer sabitler için belirtilen değerler Çizelge 4.1 ile verilmiştir.

$$\begin{aligned}C_1 &= C \\ C_2 &= 0.8C \\ C_3 &= 0.25C \\ C_4 &= 0.25C\end{aligned}\tag{4.4}$$


Bu değerlere bağlı olarak model üzerinden çıkış, piramidal nöron grubunun gövdesindeki giriş işareti üzerinden gözlemlenmiştir. Bu işarete ilişkin zaman serisi Şekil 4.2 ile verilmiştir. Ayrıca, işaretin frekans analiz yapıldığında Şekil 4.3

Çizelge 4.1 : Jansen Model Genel Parametreler Çizelge.

Parametre	Tanımlar	Tipik Değerler
C	Popülasyonlar arasındaki ortalama sinaps sayısı	135
A	Ortalama ateşleyici sinaptik kazanç	3.25 mV
B	Ortalama sönümleyici sinaptik kazanç	22 mV
α^{-1}	Ateşleyici nöron popülasyonları için sinaptik iletimdeki gecikme sabiti	10 ms
b^{-1}	Sönümleyici nöron popülasyonları için sinaptik iletimdeki gecikme sabiti	20 ms
v_o	maksimum ateşleme oranının yarısına ulaşma değeri	6 mV
v_{omax}	Nöron popülasyonlarının maksimum ateşleme oranı	$5 s^{-1}$
r	v_o da sigmoid fonksiyonun eğimi	$0.56 mV_1^{-1}$




Şekil 4.2 : Farklı A parametre değerine bağlı olarak modelin ürettiği dört farklı zaman serisi işareti



Şekil 4.3 : Jansen Modeli çıkışında elde edilen işaretin frekans analizi sonuçları

sonuçlar elde edilmiştir. Burada işaretin frekans bileşenlerinin beyinden kaydedilen EEG kayıtlarına yansıyan işaretlerin sahip olduğu aralıkta bulunduğu görülmektedir. Epilepsi için yapılan çalışmalarda elde edilen sonuçlarla uyumlu şekilde baskın olarak

alfa bandında frekans bileşeni görülmektedir [10]. Buna ilaveten belirgin şekilde teta ve beta dalga boylarının varlığı da güç spektrumunda gözükmemektedir. Ancak, epilepsi nöbet anı verisini temsil eden işaretin model için seçilen parametre değerleri ile doğrudan gözlemlenemediği ortaya konmuştur.



Şekil 4.4 : Jansen Modeli için 4 farklı durum portresi sonucu: (a) Deterministik sistemde $C=135$ değeri için modelin durum portresi; (b) Deterministik sistemde $C=270$ değeri için modelin durum portresi; (c) Stokastik sistemde $C=135$ değeri için değeri modelin durum portresi ; ve, (d) Stokastik sistemde $C=270$ değeri için modelin durum portresi.

Zaman serisi ve frekans analiz ile modele ilişkin elde edilen sonuçlar yapılan çalışmalar [25] ile uyumlu olarak elde edildikten sonra, bu sonuçlara ilişkin durum portreleri de elde edilmiştir. Burada, Jansen Modeline ilişkin P değerinin stokastik ve deterministik seçilmesine bağlı olarak durum portrelerinin incelendiği çalışma üzerinde durulmuştur [25]. Modelin çıkışında bu bağlamda elde edilen sonuçlar Şekil 4.4 görülmektedir. Burada, deterministik değerler ile elde edilen sistem davranışında daha belirgin olan tuhaf çekiciler, stokastik değerler için elde edilen sistem davranışında benzer bir çekicinin perturbasyonu olarak elde edilmiştir.



5. SONUÇ

Bu tez çalışmasında temel olarak iki konu ele alınmıştır. İlk olarak ART yapısının farklı şekillerde gerçekleşmesi üzerine odaklanmıştır. ART aslında diferansiyel denklem takımları ile önerilmiş, doğrusal olmayan dinamik bir sistemdir. Yapı önerilirken bilişsel süreçlerdeki esneklik ve kararlılık özelliklerinin gerçekleştirilmesi hedeflenmiştir ve belli bir giriş için bir denge noktasına oturan sistemin ancak farklı bir giriş için bir başka kararlı denge noktası oluşturup o denge noktasında sonlanmasının sağlanması ile bu hedef gerçekleştirilmiştir. Bu tez çalışmasında da ilk olarak ART yapısını tanımlayan diferensiyel denklemler tek tek ele alınarak, öbeklemenin nasıl gerçekleştiği durum portreleride incelenerek açıklanmıştır. ART yapısının özellikle mühendislik uygulamalarında ve makine öğrenmesinde kullanılan algoritması da ele alınmış ve açıklanmıştır. Böylece tez çalışmasında ilk olarak ele alınan ART yapısı çok kullanılmayan bir açısı ile incelenmiştir.

Tez çalışmasının ikinci konusu epilepsi ile ilgili sonuçlar elde etmektir. Bunun için de farklı iki yol tutulmuştur. İlk olarak EEG ölçümü ile epilepsi tanısının konulması için makine öğrenmesinde yer alan çok katmanlı algılayıcı yapısı gerçekleştirilmiştir. Ancak bunun için EEG verilerinden öznitelikler çıkarılmıştır. Sonra bu öznitelikler kullanılarak veri seti tezin ilk kısmında ele alınan ART yapıları ile öbeklenmiştir. Epilepsi ile ilgili olarak ikinci olarak korteks için bir model ele alınarak bu model ile epilepsinin modellenmesi için çalışılmıştır.

Yapılan çalışmalara biraz daha detaylı olarak bakarsak, dinamik ART yapısının küçük boyutlu örüntü kümesi üzerinde öbekleme süreci durum portreleri ile ortaya konmuştur.

Dinamik ART yapısı için oluşturulan kodun etkinliğinin test edilmesi için, ikili tabanda oluşturulan harf örüntüleri ile harf öbekleme süreci ele alınmış ve başarılı bir şekilde gerçekleştirilmiştir. Ayrıca karşılaştırmak amaçlı Algoritmik ART modeli de kullanılmıştır. Dinamik ART yapısının Algoritmik ART yapısına kıyasla, bozuk harfleri öbeklemede çok daha başarılı sonuçlar verdiği ortaya konulmuştur.

Epilepsi veri seti üzerinde ayırık dalgacık dönüşümü, enerji, entropi, standart sapma gibi 12 farklı öznitelik çıkarılmıştır. Çıkan bu öznitelikler ÇKA ile sınıflandırma işlemine tabi tutulmuş hastalıklı ve sağlıklı veri setlerinin ayıştırılması noktasında başarılı sonuçlar elde edilmiştir.

12 boyutlu öznitelik uzayında farklı öznitelik kombinasyonları ile ÇKA'da sınıflandırma işlemine yapılmıştır. 12 boyutlu öznitelik uzayı ile elde edilen sınıflandırma başarısının 4 boyutlu öznitelik ile sağlanabileceği ortaya konmuştur.

Epilepsi veri setinden elde edilen öznitelikler ikili tabanda dönüşüm yapılarak her iki ART yapısı için öbekleme problemi olarak ele alınmıştır. Öbekleme başarısını gözeterek en etkili uyanıklık katsayısını aramak amaçlı farklı p değerleri için öbekleme sonuçları elde edilmiştir. Burada anlamlı bilgi taşıyan alt öbeklerin gözlemlenmesine olanak tanıyan uyanıklık katsayı değerleri araştırılmıştır.

Epilepsi işaretini oluşturan bir model üretmek amacıyla Jansen'in önermiş olduğu bir nöral kütle modeli olan Kortikal Kolonlar Modeli gerçekleştirilmiştir. EEG işaretlerine benzer nitelikte sonuçlar gözlemlenmiştir.

İleriye yönelik olarak, bu çalışmadan yola çıkılarak epilepsi gibi kompleks bir sürecin daha iyi anlaşılması adına, ART gibi öbekleyici sistemler ile analiz yapıp alt öbeklerden anlamlı bilgi keşfedip var olan modeller iyileştirilebilir.

KAYNAKLAR

- [1] **Andrzejak, R.G., Lehnertz, K., Mormann, F., Rieke, C., David, P. ve Elger, C.E.** (2001). Indications of nonlinear deterministic and finite-dimensional structures in time series of brain electrical activity: Dependence on recording region and brain state, *Physical Review E*, 64(6), 061907.
- [2] **Acharya, U.R., Chua, C.K., Lim, T.C., Dorothy ve Suri, J.S.** (2009). Automatic identification of epileptic EEG signals using nonlinear parameters, *Journal of Mechanics in Medicine and Biology*, 9(04), 539–553.
- [3] **Şen, B., Peker, M., Çavuşoğlu, A. ve Çelebi, F.V.** (2014). A comparative study on classification of sleep stage based on EEG signals using feature selection and classification algorithms, *Journal of medical systems*, 38(3), 18.
- [4] **Lee, P.C.**, (1991). Adaptations to environmental change: an evolutionary perspective, *Primate responses to environmental change*, Springer, s.39–56.
- [5] **Silver, D., Huang, A., Maddison, C.J., Guez, A., Sifre, L., Van Den Driessche, G., Schrittwieser, J., Antonoglou, I., Panneershelvam, V., Lanctot, M. ve diğerleri** (2016). Mastering the game of Go with deep neural networks and tree search, *nature*, 529(7587), 484.
- [6] **Ravi, D., Wong, C., Deligianni, F., Berthelot, M., Andreu-Perez, J., Lo, B. ve Yang, G.Z.** (2016). Deep learning for health informatics, *IEEE journal of biomedical and health informatics*, 21(1), 4–21.
- [7] **Deo, R.C.** (2015). Machine learning in medicine, *Circulation*, 132(20), 1920–1930.
- [8] **Nigam, V.P. ve Graupe, D.** (2004). A neural-network-based detection of epilepsy, *Neurological research*, 26(1), 55–60.
- [9] **Kannathal, N., Choo, M.L., Acharya, U.R. ve Sadasivan, P.** (2005). Entropies for detection of epilepsy in EEG, *Computer methods and programs in biomedicine*, 80(3), 187–194.
- [10] **Tzallas, A.T., Tsipouras, M.G. ve Fotiadis, D.I.** (2009). Epileptic seizure detection in EEGs using time–frequency analysis, *IEEE transactions on information technology in biomedicine*, 13(5), 703–710.
- [11] **Harshavarthini, S., Aswathy, M., Harshini, P. ve Priyanka, G.** (2019). Automated Epileptic Seizures Detection and Classification.
- [12] **Gautama, T., Mandic, D.P. ve Van Hulle, M.M.** (2003). Indications of nonlinear structures in brain electrical activity, *Physical Review E*, 67(4), 046204.

- [13] **Grossberg, S.** (1975). A neural model of attention, reinforcement and discrimination learning, *18*, 263–327.
- [14] **Carpenter, G.A. ve Grossberg, S.**, (2010), Adaptive resonance theory.
- [15] **Grossberg, S.** (2013). Adaptive Resonance Theory: How a brain learns to consciously attend, learn, and recognize a changing world, *Neural Networks*, *37*, 1–47.
- [16] **Carpenter, G.A. ve Grossberg, S.** (1987). A massively parallel architecture for a self-organizing neural pattern recognition machine, *Computer vision, graphics, and image processing*, *37*(1), 54–115.
- [17] **Carpenter, G.A. ve Grossberg, S.** (1988). The ART of adaptive pattern recognition by a self-organizing neural network, *Computer*, *21*(3), 77–88.
- [18] **Spencer, S.S., Williamson, P.D., Bridgers, S.L., Mattson, R.H., Cicchetti, D.V. ve Spencer, D.D.** (1985). Reliability and accuracy of localization by scalp ictal EEG, *Neurology*, *35*(11), 1567–1567.
- [19] **Subasi, A.** (2007). EEG signal classification using wavelet feature extraction and a mixture of expert model, *Expert Systems with Applications*, *32*(4), 1084–1093.
- [20] **Güler, I. ve Übeyli, E.D.** (2005). Adaptive neuro-fuzzy inference system for classification of EEG signals using wavelet coefficients, *Journal of neuroscience methods*, *148*(2), 113–121.
- [21] **Kaya, Y. ve TEKİN, R.** (2012). Epileptik Nöbetlerin Tespiti için Aşırı Öğrenme Makinesi Tabanlı Uzman Bir Sistem., *International Journal of InformaticsTechnologies*, *5*(2).
- [22] **Phung, D.Q., Tran, D., Ma, W., Nguyen, P. ve Pham, T.** (2014). Using Shannon Entropy as EEG Signal Feature for Fast Person Identification., *ESANN*, cilt 4, s.413–418.
- [23] **Guariglia, E.** (2016). Entropy and fractal antennas, *Entropy*, *18*(3), 84.
- [24] **Jansen, B.H. ve Rit, V.G.** (1995). Electroencephalogram and visual evoked potential generation in a mathematical model of coupled cortical columns, *Biological cybernetics*, *73*(4), 357–366.
- [25] **Ableidinger, M., Buckwar, E. ve Hinterleitner, H.** (2017). A stochastic version of the Jansen and Rit neural mass model: Analysis and numerics, *The Journal of Mathematical Neuroscience*, *7*(1), 1–35.

EKLER


EK A.1 : Uyanıklık Katsayısının Etkisi






EK A.1 :


1.1 Temel ART Yapısı için Uyanıklık Katsayısının Etkisi: Küçük boyutlu örnek




Şekil A.1 : Uyanıklık katsayısı $p=0.1$ için öbekleme başarısı




Şekil A.2 : Uyanıklık katsayısı $p=0.3$ için öbekleme başarısı




Şekil A.3 : Uyanıklık katsayısı $p=0.5$ için öbekleme başarısı




Şekil A.4 : Uyanıklık katsayısı $p=0.6$ için öbekleme başarısı



Şekil A.5 : Uyanıklık katsayısı $p=0.8$ için öbekleme başarısı




Şekil A.6 : Uyanıklık katsayısı $p=0.9$ için öbekleme başarısı




Şekil A.7 : Uyanıklık katsayısı $p=0.95$ için öbekleme başarısı

EK A.1 :


2.1 Temel ART Yapısı için Uyanıklık Katsayısının Etkisi: Harfler




Şekil B.1 : Uyanıklık katsayısına $p=0.2$ değerine bağlı harf öbeklemesi




Şekil B.2 : Uyanıklık katsayısına $p=0.3$ değerine bağlı harf öbeklemesi




Şekil B.3 : Uyanıklık katsayısına $p=0.4$ değerine bağlı harf öbeklemesi



Şekil B.4 : Uyanıklık katsayısına $p=0.5$ değerine bağlı harf öbeklemesi



Şekil B.5 : $p=0.6$ değerine bağlı harf öbeklemesi




Şekil B.6 : Uyanıklık katsayısına $p=0.7$ değerine bağlı harf öbeklemesi




Şekil B.7 : Uyanıklık katsayısına $p=0.95$ değerine bağlı harf öbeklemesi

EK A.1 :

3.1 Algoritmik ART Yapısı için Uyanıklık Katsayısının Etkisi: Harfler




Şekil C.1 : Uyanıklık katsayısına $p=0.2$ değerine bağlı harf öbeklemesi




Şekil C.2 : Uyanıklık katsayısına $p=0.3$ değerine bağlı harf öbeklemesi




Şekil C.3 : Uyanıklık katsayısına $p=0.4$ değerine bağlı harf öbeklemesi



Şekil C.4 : Uyanıklık katsayısına $p=0.6$ değerine bağlı harf öbeklemesi



Şekil C.5 : Uyanıklık katsayısına $p=0.8$ değerine bağlı harf öbeklemesi



Şekil C.6 : Uyanıklık katsayısına $p=0.9$ değerine bağlı harf öbeklemesi




Şekil C.7 : Uyanıklık katsayısına $p=0.95$ değerine bağlı harf öbeklemesi

EK A.1 :

4.1 Epilepsi veri seti Temel ART yapısı ilk durum için farklı p değerlerine ilişkin sonuçlar



Şekil D.1 : ilk durumda $p=0.2$ için elde edilen öbekleme sonuçları




Şekil D.2 : ilk durumda $p=0.3$ için elde edilen öbekleme sonuçları




Şekil D.3 : ilk durumda $p=0.4$ için elde edilen öbekleme sonuçları




Şekil D.4 : ilk durumda $p=0.6$ için elde edilen öbekleme sonuçları



Şekil D.5 : ilk durumda $p=0.7$ için elde edilen öbekleme sonuçları



Şekil D.6 : İlk durumda $p=0.8$ için elde edilen öbekleme sonuçları



Şekil D.7 : İlk durumda $p=0.9$ için elde edilen öbekeleme sonuçları

EK A.1 :

5.1 Epilepsi veri seti Temel ART yapısı durum 2 için farklı p değerlerine ilişkin sonuçlar




Şekil E.1 : 2.durumda $p=0.2$ için elde edilen öbeleme sonuçları




Şekil E.2 : 2.durumda $p=0.3$ için elde edilen öbeleme sonuçları




Şekil E.3 : 2.durumda $p=0.4$ için elde edilen öbekleme sonuçları




Şekil E.4 : 2.durumda $p=0.6$ için elde edilen öbekleme sonuçları



Şekil E.5 : 2.durumda $p=0.7$ için elde edilen öbekleme sonuçları




Şekil E.6 : 2.durumda $p=0.8$ için elde edilen öbekleme sonuçları



Şekil E.7 : 2.durumda $p=0.9$ için elde edilen öbekleme sonuçları

EK A.1 :


6.1 Epilepsi veri seti Temel ART yapısı durum 3 için farklı p değerlerine ilişkin sonuçlar




Şekil F.1 : 3.durumda $p=0.2$ için elde edilen öbekleme sonuçları




Şekil F.2 : 3.durumda $p=0.3$ için elde edilen öbekleme sonuçları




Şekil F.3 : 3.durumda $p=0.4$ için elde edilen öbekleme sonuçları




Şekil F.4 : 3.durumda $p=0.6$ için elde edilen öbekleme sonuçları



Şekil F.5 : 3.durumda $p=0.7$ için elde edilen öbekleme sonuçları




Şekil F.6 : 3.durumda $p=0.8$ için elde edilen öbekleme sonuçları



Şekil F.7 : 3.durumda $p=0.9$ için elde edilen öbekleme sonuçları

EK A.1 :


7.1 Epilepsi veri seti Algoritmik ART yapısı ilk durum için farklı p değerlerine ilişkin sonuçlar




Şekil G.1 : 1.durumda $p=0.2$ için elde edilen öbekleme sonuçları




Şekil G.2 : 1.durumda $p=0.3$ için elde edilen öbekleme sonuçları




Şekil G.3 : 1.durumda $p=0.4$ için elde edilen öbekleme sonuçları




Şekil G.4 : 1.durumda $p=0.6$ için elde edilen öbekleme sonuçları



Şekil G.5 : 1.durumda $p=0.7$ için elde edilen öbekleme sonuçları



Şekil G.6 : 1.durumda $p=0.8$ için elde edilen öbekleme sonuçları




Şekil G.7 : 1.durumda $p=0.9$ için elde edilen öbekleme sonuçları

EK A.1 :


8.1 Epilepsi veri seti Algoritmik ART yapısı durum 2 için farklı p değerlerine ilişkin sonuçlar




Şekil H.1 : 2.durumda $p=0.1$ için elde edilen öbekleme sonuçları




Şekil H.2 : 2.durumda $p=0.2$ için elde edilen öbekleme sonuçları




Şekil H.3 : 2.durumda $p=0.3$ için elde edilen öbekleme sonuçları




Şekil H.4 : 2.durumda $p=0.4$ için elde edilen öbekleme sonuçları



Şekil H.5 : 2.durumda $p=0.5$ için elde edilen öbekleme sonuçları




Şekil H.6 : 2.durumda $p=0.6$ için elde edilen öbekleme sonuçları



Şekil H.7 : 2.durumda $p=0.7$ için elde edilen öbekleme sonuçları



Şekil H.8 : 2.durumda $p=0.9$ için elde edilen öbekleme sonuçları




Şekil H.9 : 2.durumda $p=0.95$ için elde edilen öbekleme sonuçları




EK A.1 :


9.1 Epilepsi veri seti Algoritmik ART yapısı durum 3 için farklı p değerlerine ilişkin sonuçlar




Şekil I.1 : 3.durumda $p=0.1$ için elde edilen öbekleme sonuçları




Şekil I.2 : 3.durumda $p=0.2$ için elde edilen öbekleme sonuçları




Şekil I.3 : 3.durumda $p=0.3$ için elde edilen öbekleme sonuçları




Şekil I.4 : 3.durumda $p=0.4$ için elde edilen öbekleme sonuçları




Şekil I.5 : 3.durumda $p=0.5$ için elde edilen öbekleme sonuçları




Şekil I.6 : 3.durumda $p=0.6$ için elde edilen öbekleme sonuçları




Şekil I.7 : 3.durumda $p=0.7$ için elde edilen öbekleme sonuçları



Şekil I.8 : 3.durumda $p=0.8$ için elde edilen öbekleme sonuçları



Şekil I.9 : 3.durumda $p=0.9$ için elde edilen öbekleme sonuçları



Şekil I.10 : 3.durumda $p=0.95$ için elde edilen öbekleme sonuçları



ÖZGEÇMİŞ



Ad Soyad:Ahmet Hıfzı Bacaksız

Doğum Tarihi ve Yeri:1991 - Yozgat

E-Posta: ahbacaksiz at gmail com

ÖĞRENİM DURUMU:

- **Lisans:** 2015, Namık Kemal Üniversitesi, Mühendislik Fakültesi, Biyomedikal Mühendisliği
- **Y. Lisans:** 2015-, İstanbul Teknik Üniversitesi, Elektronik ve Haberleşme Mühendisliği Anabilim Dalı, Biyomedikal Mühendisliği Programı.

MESLEKİ DENEYİMLER:

- 2019 - 2019 SIMTEK Arge Mühendisi
- 2019 - MBIS Danışmanlık ve Yazılım Şirketi Arge Mühendisi

YAYINLAR

- Bacaksız, Ahmet Hıfzı and Sengor, Neslihan Serap, “Testing of the Jansen Cortical Columns Model to Simulate Different Brain Activities in MATLAB,” in *21st National Biomedical Engineering Meeting (BIYOMUT)*, 2017.
- Bacaksız, Ahmet Hıfzı and Esgin, Eren, “Extraction of Numerical data from Categorical Data Set and Artificial Neural Networks,” in *3rd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)*, 2019.