



T.C.

**BATMAN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**NÖROLOJİK KRİZLERDEN EPİLEPSİ
NÖBETİNİN KESTİRİMİ**

Süleyman DAL

YÜKSEK LİSANS TEZİ

Elektrik-Elektronik Mühendisliği Anabilim Dalı

**Temmuz-2020
BATMAN
Her Hakkı Saklıdır**

TEZ KABUL VE ONAYI

Süleyman DAL tarafından hazırlanan “Nörolojik Krizlerden Epilepsi Nöbetinin Kestirimi” adlı tez çalışması .../.../... tarihinde aşağıdaki jüri tarafından oy birliği / oy çokluğu ile Batman Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Unvanı Adı SOYADI

.....

Danışman

Unvanı Adı SOYADI

.....

Üye

Unvanı Adı SOYADI

.....

Üye

Unvanı Adı SOYADI

.....

Üye

Unvanı Adı SOYADI

.....

Yukarıdaki sonucu onaylarım.

Doç. Dr.
FBE Müdürü

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Süleyman DAL

Tarih: 23/07/2020

ÖZET

YÜKSEK LİSANS TEZİ

NÖROLOJİK KRİZLERDEN EPİLEPSİ NÖBETİNİN KESTİRİMİ

Süleyman DAL

Batman Üniversitesi Fen Bilimleri Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Necmettin SEZGİN

2020, 51 Sayfa

Jüri

Prof. Dr. Necmettin SEZGİN
Dr. Öğr. Üyesi Yılmaz KAYA
Dr. Öğr. Üyesi Emrullah ACAR

Toplumda sara adıyla bilinen epilepsi hastalığı Dünya Sağlık Örgütü (WHO) tahminlerine göre dünya nüfusunda %0,4-1 insanı etkileyen ciddi ve yaygın nörolojik bir hastalıktır. Anlık ve tekrarlayıcı nöbetlerle karakterize olan epilepsi hastalığı çocukluk ve yetişkinlik çağında daha sık ortaya çıkmasıyla beraber hemen her yaş grubunda insanı etkilemektedir. Genelde bilinç kaybı, hareket bozukluğu gibi sadece nöbet ve nöbeti takip eden birkaç saatlik zaman dilimini etkileyen ancak ilaçlarla kontrol altına alınabilen geçici durumlar oluşturmaktadır.

Epileptik nöbetlere benzer krizler geçiren epileptik olmayan (pseudo veya yalancı) nöbetlerin de olması teşhisi güçleştirmektedir. Epilepsi hastalarının nöbetlerinin epileptik olup olmadığı (bunun için sık ve güvenilir tanı yöntemi kriz anında video-EEG ölçümüdür) ve kullanılacak ilaçlarının dozu hasta geçmişine bağlı olarak belirlenmektedir. Epileptik nöbet geçirdiği şüphesi ile uzman hekime müracaat eden hastaların %10-20'sinin epilepsi hastası olmadığı belirlenmiştir. Hastanın epileptik ilaçlara verdiği tepki temel alınarak bunun tespitinin, tedavinin başladığından ortalama 7,2 yıl sonra belirlenebilmektedir.

Bu tez çalışmasında çeşitli sensörler (EMG, EKG, İvmeölçer gibi) yardımıyla epileptik nöbetlerin kestirimi için gelişen teknolojiyle entegre bir yaklaşım önerilmiştir. Çalışmanın ana amacı epileptik nöbetlerin kestirimi için yapılan işlem maliyetini azaltacak bir test rutini oluşturmaktır. Dicle Üniversitesi Tıp Fakültesi Nöroloji Bölümünde tedavi gören hastalardan epileptik bir nöbet sürecinde alınan veri seti kullanılarak çeşitli yöntemler ile optimize edilmiş ve daha sonra elde edilen özelliklerle beraber Aşırı Öğrenme Makineleri (ELM) ile sınıflandırılmıştır.

Anahtar Kelimeler: Epileptik nöbetler, epileptik olmayan nöbetler, nöbet kestirimi, makine öğrenmesi, giyilebilir sensörler.

ABSTRACT

MS THESIS

PREDICTION OF EPILEPSY SEIZURES FROM NEUROLOGICAL CRISES

Süleyman DAL

**THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF
BATMAN UNIVERSITY
THE DEGREE OF MASTER OF SCIENCE
IN ELECTRICAL-ELECTRONICS ENGINEERING**

Advisor: Prof. Dr. Necmettin SEZGİN

2020, 51 Pages

Jury

**Prof. Dr. Necmettin SEZGİN
Asst. Prof. Dr. Yılmaz KAYA
Asst. Prof. Dr. Emrullah ACAR**

Epilepsy disease, known in the community as ‘sara’, is a serious and widespread neurological disease affecting 0.4-1% of the world population according to the World Health Organization (WHO) estimates. Epilepsy disease, characterized by instantaneous and repetitive seizures, affects people in almost every age group, although it occurs more frequently in childhood and adulthood. In general, loss of consciousness, movement disorder, such as only seizures and seizures that affect a period of several hours following the seizure, but can be controlled by drugs creates temporary conditions.

It is also difficult to diagnose non-epileptic seizures (pseudo-or pseudo-seizures) that are similar to epileptic seizures. Whether the seizures of epileptic patients are epileptic (frequent and reliable diagnostic method is video-EEG measurement at the time of crisis) and the dose of the drugs to be used are determined based on the patient's history. It was determined that 10-20% of the patients who applied to the specialist physician with the suspicion of having epileptic seizure did not have. Based on the patient's response to epileptic drugs, its detection can be determined on average 7.2 years after the start of treatment.

In this thesis, an integrated approach with the developing technology is proposed for the prediction of epileptic seizures with the help of various sensors (such as EMG, ECG, Accelerometer). The main purpose of the study is to create a test routine to reduce the cost of the procedure for the prediction of epileptic seizures. Using a data set taken from patients treated in the Dicle University, Faculty of Medicine, Department of Neurology, during an epileptic seizure process, it was optimized by various methods and classified by over-learning machines (ELM) with later characteristics.

Keywords: Epileptic seizures, non-epileptic seizures, seizure prediction extreme machine learning, machine learning, wearable sensors.

ÖNSÖZ

Tez çalışması boyunca, Batman Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi tarafından desteklenen BTÜBAP-2019-YL-14 numaralı proje kapsamında satın alınan donanım ve yazılım araçları kullanıldı. Desteklerinden dolayı teşekkürlerimi sunuyorum.

Sadece bu tez çalışmamın özelinde değil bana her türlü desteği veren değerli vaktini ayırıp bilgi ve tecrübesini aktaran değerli danışmanım sayın Prof. Dr. Necmettin SEZGİN hocama her şey için çok teşekkür eder ve şükranlarımı sunarım.

Yüksek lisans eğitimim süresince büyük bir sabır ve özveriyle bana destek olan, beni araştırmaya yönelten ve desteğini hep hissettiğim bölüm başkanımız kıymetli hocam Doç. Dr. Ömer Faruk ERTUĞRUL 'a çok teşekkür ederim.

Tez çalışması sürecinde bana her türlü destek ve önerilerini sunan sayın hocam Dr. Öğr. Üyesi Davut İZCİ ve Dr. Öğr. Üyesi Yasin SÖNMEZ 'e teşekkürlerimi sunarım.

Eğitim hayatım ve tüm yaşantım boyunca bana maddi ve manevi desteklerini esirgemeyen her zaman yanımda olan ve aldığım kararlarda arkamda durup bana cesaret veren sevgili aileme en samimi duygularıyla teşekkürü bir borç bilirim.

Süleyman DAL
BATMAN-2020

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
SİMGELER VE KISALTMALAR	viii
ŞEKİLLER DİZİNİ.....	v
TABLOLAR DİZİNİ	vi
1. GİRİŞ	1
2. LİTERATÜR ARAŞTIRMASI	5
3. MATERYAL VE YÖNTEM.....	9
3.1. Veri Kümesi	9
3.2. Metot	15
3.2.1. Sinyalin pencerelenmesi	16
3.2.2. Nöbet tespiti	17
3.2.3. Nöbet ayrıştırılması.....	17
3.3. Kullanılacak Yöntem	18
3.3.1. Özellik çıkarma.....	19
3.3.2. İkiz-spektrum analizi	21
3.3.3. Aşırı öğrenme makineleri (ELM)	25
4. ARAŞTIRMA BULGULARI VE TARTIŞMA	27
4.1. Epileptik/Epileptik Olmayan Krizlerin Ayrıştırılması	27
4.2. Özellik Seçmeden Elde Edilen Başarı Sonuçları	27
4.3. Özellik Seçme ile Elde Edilen Sonuçlar	28
4.4. Tartışma.....	29
5. SONUÇLAR VE ÖNERİLER	32
5.1. Sonuçlar.....	32
5.2. Öneriler	33
KAYNAKLAR	34
EKLER	39
ÖZGEÇMİŞ	40

SİMGELER VE KISALTMALAR

Simgeler

E_s	: Enerji
$\mu(x)$	: Aritmetik ortalama
$\sigma(x)$	: Standart Sapma
K_s	: Basıklık Katsayısı
S_k	: Çarpıklık Katsayısı
$x(k)$	: Durağan Reel Değerli Ayrık Rastsal Değişkeni
m_r	: r. Dereceden Moment Değeri
c_1^x	: 1. Dereceden Kümülanı
c_2^x	: 2. Dereceden Kümülanı
c_3^x	: 3. Dereceden Kümülanı
$B(w_1, w_2)$	: Üçüncü Derece Kümülanı Fonksiyonun İkiz-Spektrum
$W(n1, n2)$	: İki Boyutlu Pencere Fonksiyonu
w_1, w_2, w_1, w_2, w_1	: Frekans Değerleri
*	: Karmaşık Eşleniği İfadesi
D	: EEG İşaretin İçinde Olası QPC Toplamı

Kısaltmalar

Hz	: Hertz
SD	: Güvenli Sayısal (Secure Digital)
RF	: Radyo Frekansı
TB	: Terabayt
EEG	: Elektroansefalogram
WHO	: World Health Organization
ELM	: Aşırı Öğrenme Makinaları
YSA	: Yapay Sinir Ağları
HFD	: Hızlı Fourier Dönüşümü
EGA	: Eşit Genişlikli Ayrıklaştırma
EKG	: Elektrokardiyografi
SVM	: Destek Vektör Makinesi
EMG	: Elektromiyografi
GPS	: Küresel Konum Belirleme Sistemi (Global Positioning System)
QPC	: Quadratic Phase Coupling
k-NN	: k-en Yakın Komşuluk
sEMG	: Surface Elektromiyografi
ÇKASA	: Çok Katmanlı Algılayıcı Sinir Ağı
1D-LBP	: Bir Boyutlu Yerel İkili Örüntüler
1B-MYİÖ	: Bir Boyutlu Medyan Yerel İkili Örüntü
ML	: Makine Öğrenmesi

ŞEKİLLER DİZİNİ

Şekil 1.1. Epileptik nöbet sürecinde EEG sinyali değişimi	1
Şekil 1.2. Epileptik olmayan nöbet sürecinde EEG sinyali değişimi	2
Şekil 3.1. Video EEG kayıt süreci	9
Şekil 3.2. Veri setinin oluşma süreci	10
Şekil 3.3. Sensörlerin bağlantısı	11
Şekil 3.4. Kullanılan sensörlerin entegre edilmiş görüntüsü	12
Şekil 3.5. Donanımın hastadan veri alma süreci.....	13
Şekil 3.6. Paket veri kayıt	13
Şekil 3.7. MYO Kol bandı	14
Şekil 3.8. MYO kol bandının hastanın kolundaki konumu	14
Şekil 3.9. MYO 'dan kaydedilen veri örneği.....	15
Şekil 3.10. Çalışma prosedürü	15
Şekil 3.11. Pencereleme örneği.....	16
Şekil 3.12. Nöbet tespiti için örnek.....	17
Şekil 3.13. Nöbet ayrıştırılması için örnek (a) Epileptik nöbet, (b) Epileptik olmayan nöbet.....	18
Şekil 3.14. Kullanılacak yapay öğrenme aşamaları	19
Şekil 3.15. Bir EEG işaretinin; a) epilepsi öncesi, b) epilepsi anında ve c) epilepsi sonrası ikiz spektrum gösterimi.	24
Şekil 3.16. Tek gizli katmanlı YSA (Ertuğrul vd., 2012).....	25

TABLÖLAR DİZİNİ

Tablo 3.1. Sensör düğümünde kullanılan düğümler ve kullanım amacı	11
Tablo 3.2. Kullanılan donanımlar ve kullanım amacı	12
Tablo 4.1. EKG ile kriz tespiti optimizasyon süreci.....	27
Tablo 4.2. Sınıflandırma doğruluğu (%).....	28
Tablo 4.3. Kriz tespitinde seçili özelliklerle elde edilen başarı oranları.....	29
Tablo 4.4. Kriz türü tespitinde seçili özelliklerle elde edilen başarı oranları	29
Tablo 4.5. Epileptik ve epileptik olmayan nöbetlerin ayrıştırılmasında elde edilen başarı oranları	30




1. GİRİŞ


Epilepsi, sinir sisteminin uyarıyı iletmekle görevli anatomik ve işlevsel birimi olan nöronlardaki normal olmayan ekstrem elektriksel deşarj sonucu ortaya çıkan anlık ve tekrarlayıcı nöbetlerle ayırıcı niteliği ortaya konmuş çocukluk ve yetişkinlik çağında daha çok olmak üzere erişkinlerde beyin damar hastalıklarından sonra ikinci sıklıkta görülebilen en yaygın ciddi bir beyin hastalığıdır (Bernal vd., 2003). Bu sebeple epileptik elektroansefalogram (EEG) ve epileptik olmayan elektroansefalogram (EEG) sinyallerinin ayrıştırılması için birçok yöntem önerilmiştir (Sezgin vd., 2013; Kaya vd., 2012). Dünya Sağlık örgütü (World Health Organization, WHO) tahminlerine göre epilepsi hastalığının prevansı %0,4-1 aralığındadır (Çakıl vd., 2013, Kanas vd., 2015).

Epilepsi iki gruba ayrılmakta olup daha yaygın olan idiopati (hastalığın nasıl geliştiği bilinmeyen) epilepsi grubunun nedeni bilinmemekte; sekonder epilepsiler ise bazı fizyolojik veya kalıtsal nedenlere dayanmaktadır. Epilepsi uzun süreli tedavi gerektiren bir hastalık olduğu için teşhisi büyük önem kazanmaktadır ve teşhis için en önemli belirti nöbetlerdir. Ancak eşzamanlı nöronal aktiviteyle ilişkili epileptik nöbetlerin yanında bir de santral sinir sistemi disfonksiyonu ile ilişkisi olmayan epileptik nöbetlere benzer semptomlar gösterebilen epileptik olmayan (pseudo veya yalancı) psikojenik veya fizyolojik nöbetlerin de olması teşhisi güçleştirmektedir (Arıkanoglu, 2011; Kanas vd., 2015).

Epileptik ve epileptik olmayan nöbetlerin ayrıştırılmasında en önemli sorun hastanın nöbet geçirdikten sonra hekim muayenesine gelmesi ve bazen epileptik olmayan nöbetlerin epilepsi nöbetleri geçiren hastalarda ortaya çıkmasıdır (Kotsopoulos vd., 2003; D'Alessio vd., 2006). Dicle Üniversitesi Tıp Fakültesi Nöroloji Bölümünde tedavi gören hastalardan epileptik bir nöbet sürecinde alınmış EEG sinyali ve epileptik olmayan bir nöbet sırasında alınmış EEG sinyalleri sırasıyla Şekil 1.1 ve Şekil 1.2’de gösterilmiştir.



Şekil 1.1. Epileptik nöbet sürecinde EEG sinyali değişimi



Şekil 1.2. Epileptik olmayan nöbet sürecinde EEG sinyali değişimi

Şekil 1.1 ve şekil 1.2’de de görüldüğü üzere epileptik ve epileptik olmayan nöbetler arasındaki temel fark epileptik nöbetler nöronal deşarjlarla beraber seyrederken; epileptik olmayan nöbetlerde EEG’de özel bir değişim gözlenmektedir (Arıkanoglu, 2011; Tatlı, 2004). Hastanın nöbet anında EEG kayıtlarının alınamaması ise ilk teşhisin hasta ile çevresinin anlatımları (tıbbi öykü) ve hastanın yaşına göre yapılması zorunluluğu doğurmaktadır (Çakıl vd., 2013; Arıkanoglu, 2011; Tatlı, 2004).

Bodde ve ark. (2009) yaptıkları derleme çalışmasında epileptik ve epileptik olmayan nöbetlerin ayrıştırılmasının kolay olmadığını ve yanlış teşhisin hasta başı maliyetinin 231,432 \$ mertebelerinde olduğu belirtmişlerdir. Sadece İngiltere’de yanlış epilepsi teşhisinden kaynaklı tahmin edilen yıllık kaybın 185 Milyon £ civarında olduğu ifade edilmiştir (Kanas vd., 2015).

Epileptik nöbet geçirdiği şüphesi ile bir hekime müracaat eden hastaların %10-20’sinin epilepsi hastası olmadığı (Cuthill ve Espie, 2005), yanlış teşhiste (epileptik olmayan nöbet geçiren hastaya epilepsi teşhisi konması) ise hastanın epileptik ilaçlara verdiği tepki temel alınarak tedavinin durdurulduğu ve bu sürecin hastanın tedaviye başladığından ortalama 7,2 yıl sonra konduğu belirtilmiştir (Çakıl vd., 2013; Reuber ve Elger, 2003). Bu süreçte hastaya gereksiz birçok anti epileptik ilaç verildiği, bu ilaçlardan kaynaklı hastalarda birçok yan etkinin oluştuğu, önemli oranda iş gücü, zaman ile maliyete neden olduğu ve hastanın yaşam kalitesinin düştüğü göz önüne alındığında epileptik olmayan nöbetlerin erken dönemde epileptik nöbetlerden ayrıştırılmasının ne kadar önemli olduğu görülmektedir (Çakıl vd., 2013; Arıkanoglu, 2011; Kanas vd., 2015).

Tüm bu sebeplerden dolayı epileptik ve epileptik olmayan nöbetlerin iyi bir ayırıcı yöntemle kestirimi hayati önem taşımaktadır (Çakıl vd., 2013; Arıkanoglu, 2011; Araz vd., 2009). Ayırıcı tanının belirlenmesi için ucuz maliyeti nedeniyle birçok EEG temelli ayırıcı test önerilmiş ve bu testlerle %60-90 oranlarında başarı raporlanmıştır (Çakıl vd., 2013). Öte yandan henüz epileptik ve epileptik olmayan nöbetlerin ayrıştırılmasında video-EEG hariç yeterli bir yöntem önerilememiştir (Kotsopoulos vd., 2003; Bodde vd., 2009; Cuthill ve Espie, 2005; Reuber, 2008; Çakıl vd., 2013). Ancak video-EEG hastayı rahatsız eden pahalı ve uzun dönemli bir test rutini. Video-EEG’de ayırt edici sonuçlar alınması için hastanın kayıtların alındığı süreç içerisinde nöbet geçirmesi gerekmektedir.

Video-EEG’ye ilaveten yaşa bağlı olarak otonom sinir sistemi testleri, serum prolaktin düzeyleri, nörokardiyojenik ve psikolojik testler de bu amaçla kullanılmaktadır (Çakıl vd., 2013; Arıkanoglu, 2011; Tatlı, 2004; Araz vd., 2009; Bodde vd., 2009; Cuthill ve Espie, 2005; Cragar vd., 2002; Reuber ve Elger, 2003; Reuber, 2008). Önerilen bu testler temelde hastaların fizyolojik özellikleri veya elde edilen test sonuçlarının istatistiksel olarak irdelenmesine dayanmaktadır (Kotsopoulos vd., 2003; D’Alessio vd., 2006; Turner vd., 2011). Örneğin hastaların epileptik ilaçlara verdiği tepki, nöbet sıklığı, genetik epileptik geçmiş, nöbet özellikleri, fizyolojik ve nörofizyolojik testler ve benzeri parametreler bu amaçla kullanılmıştır (Cragar vd., 2002; Reuber ve Elger, 2003; Reuber, 2008).

Bu tez çalışmasında ki temel gerekçe epilepsi ayırıcı tanısının hasta ve yakınlarını daha az rahatsız edecek ve düşük maliyetlerle uygulanabilecek bir test rutini ortaya koyabilmektir. Böyle bir test yönteminin geliştirilmesi sadece epileptik ve epileptik olmayan nöbetlerin ayrıştırılmasında değil, ayrıca nöbetlerin ve nöbet karakteristiklerinin dijital olarak kayıt altına alınabilmesine olanak sağlayacak ve epilepsi hastalarının yaşam kalitesini artıracak birçok olasılığa kapı açacaktır.

Ayrıca, nöbet tespiti (Gonzalez-Velldn vd., 2003; Yadav vd., 2009), hastalığın tespiti ve tedavisi için önemli bir süreç olmasının yanı sıra hastanın ve hasta yakınlarının yaşam kalitesini artırmak için önemli bir çıktı elde etmemize yardımcı olacaktır. Çünkü hasta yakınları hastanın nöbet geçirme olasılığı bulunduğu hastanın göz önünde bulundurulma isteği nedeniyle hastanın ve kendi ekonomik ve sosyal yaşantılarına limit koymaktadır. Tüm bu durumlar göz önüne alındığında hastaların psikolojik açıdan kendilerini kötü hissetmeleri, strese bağlı depresyonların yaşanması ve sosyalleşmeme gibi sorunlarından dolayı doğal olarak yaşam kaliteleri düşmektedir. Hastanın epilepsi

geçirme anının tespit edilebilmesi, nöbet sayısı ve karakteristiği hastalığın seyri açısından da önemli bilgiler içermektedir.

Bu çalışmanın hedefleri arasında epilepsi ayırıcı tanısı olarak giyilebilir sensörler kullanılarak epileptik ve epileptik olmayan nöbetlerin kestirimi için yeni bir yaklaşım önermektir. Epileptik ve epileptik olmayan nöbetlerin ayrıştırılarak epilepsi teşhisinde başarının artırılması ve epileptik olmayan nöbet geçirenlerin hastalara yanlış teşhis (epilepsi tanısı) konması durumunda:

- Hastaya gereksiz birçok anti epileptik ilaç verilmesi,
- Anti epileptik ilaçlardan kaynaklı hastalarda birçok yan etkinin olması,
- Hastalara ekstra mali külfete neden olması,
- Hastalarda önemli oranda iş gücü kaybına neden olması,
- Hastanın yaşam kalitesinin düşmesi, gibi olumsuz durum olabilmektedir.

Olumsuz bu gibi olası durumlardan epileptik olmayan nöbet geçiren hastaları korumaktır. Epileptik olmayan nöbet geçiren hastalara epilepsi teşhisi konmasının hastaya olan etkilerinin yanında ayrıca ilaç maliyetleri nedeniyle ülke ekonomisine de yüküdür. Ayrıca giyilebilir sensörlerin tıp uygulamalarında kullanımını artırılarak, hastaya özgü tedavi süreçleri için örnek teşkil etmektedir.

2. LİTERATÜR ARAŞTIRMASI

Biyomedikal işaretlerin işlenmesi ile ilgili çalışmalar ilerleyen teknoloji ile beraber gelişme göstermeye başlamıştır. Bu durumla beraber tıp alanında da kullanılmaya başlayan işaret işleme yöntemleri uzman hekime yardımcı olma özelliği taşımaktadır. Nörolojik bir hastalık olan epilepsi hastalığı bu grubun en yaygın olanıdır (Kanas vd., 2015; Andaç vd., 2017). Epilepsi hastalarının nöbetlerinin epileptik olup olmadığının belirlenmesi oldukça zordur.

Epileptik nöbet geçirdiği şüphesi ile bir hekime müracaat eden hastaların önemli bir kısmı (%10-20) epilepsi hastası olmadığı (Cuthill ve Espie, 2005) ve buna bağlı olarak yanlış teşhis konması durumunda ise hastanın epileptik ilaçlara verdiği tepki temel alınarak tedavinin durdurulduğu ve bu sürecin hastanın tedaviye başladığından ortalama 7,2 yıl sonra konduğu belirtilmiştir (Çakıl vd., 2013). Tüm bu sebeplerden dolayı epilepsi nöbetlerinin saptanması için birçok bilimsel araştırma yapılmıştır.

Mormann ve ark. Nöbetin önceden tahmini üzerine yaptıkları çalışmada farklı EEG kanalları arasındaki faz senkronizasyonunun, nöbet öncesini tespit etmek için kullanılabileceğini söylemişlerdir. Çalışmada 14 epileptik seyreden hastanın 12' sinde nöbeti önceden tahmin etmeyi başarmışlardır (Mormann vd., 2000).

Andrzejak ve ark. Yaptıkları derleme çalışmada MIT üniversitesi veri setini EEG işaretlerinin eğitim ve test sürecinde kullanmışlardır. Krizin kestirimi ile ilgili yapılan bu çalışmada, EEG işaretlerini (DWT-db2) yöntemini kullanarak ayrıştırılan her frekans bandı için enerji, entropi ve standart sapmayı incelemişlerdir. Çalışmada %92,2 oranında doğruluk oranı ile başarıyı yakalamışlardır (Andrzejak vd., 2001).

Akın vd. Yaptıkları çalışmada yeni bir yaklaşım sunarak EEG sinyallerini sınıflandırmak için YSA ve dalgacık dönüşümünü kullanmışlardır. Öncelikle dalgacık dönüşümünü kullanarak EEG sinyallerini alfa, beta, teta, delta olarak ayırdıktan sonra yapay sinir ağının giriş bilgisi olarak kullanmışlardır. Çalışma sonunda epileptik olan bireyleri %97, sağlıklı bireyleri ise %98 oranla sınıflandırmayı başarmışlardır (Akın vd. 2001).

Zijlmans vd. Yaptıkları çalışmada EEG ile eş zamanlı alınan EKG verileri inceledi ve epileptik nöbet esnasında kardiyak anormallikler olduğunu belirlemişlerdir. Çalışmada toplam 81 hastadan alınmış 1499 nöbetten 281 tanesi incelenmiş. Yaşları 11-64 bandında olan hastaların %60 kadınlardan oluşmaktaydı. Nöbetlerin %73'ünde (hastaların %93'ü) kalp atış hızında en az 10 atım / dakika bir artış vardı ve bu en sık nöbet başlangıcı etrafında meydana geldiğini bildirmişlerdir. EKG anormallikleri nöbetlerin %26'sında

(hastaların %44'ü) tespit ettiler. Kalp atış hızı değişiklikleri sıklıkla ve hatta en erken EEG değişiminden önce meydana geldiğini gösterdiler (Zijlmans vd.,2002).

Zarjam ve ark. Yaptıkları çalışmada yeni doğan bireylerden kaydedilen EEG verilerinden kriz olaylarını seçmek için otomatik bir metot önermişlerdir. Eğitim ve test grupları 2 günlükten 2 haftalığa kadar değişen yaş aralıklarında ki 5 yeni doğandan alınan EEG verilerinden elde etmişlerdir. Üç katlı ileri beslemeli ağı kullanarak bütün krizli verilere '1' hedef değeri ve kriz olmayan verilere '-1' hedef değeri verilmiştir (Zarjam vd., 2003).

Güler ve ark. Yaptıkları çalışmada dalgacık dönüşümü ile EEG işaretlerinden çıkardıkları öznitelik vektörleri üzerinde istatistiksel işlemlerin gerçekleştirilmesi ile ilgili bir çalışma yapmışlardır. Bu çalışmada, dalgacık sinir ağı ile yapılan EEG sınıflandırmasının daha iyi sonuçlar verdiği ve bu sonuçların hastalığın kestiriminde kullanılabileceğini söylemişlerdir (Güler vd., 2004).

Batar (2005) çalışmasında, EEG işaretlerini uyanıklık, uyuklama ve uyku hallerinde gösterdikleri farklılıkları değerlendirip YSA kullanarak bilgisayar destekli bir otomatik sınıflandırma amaçlamış ve bunu başarı ile sağlamıştır.

Toprak vd. Yaptıkları çalışmada EEG işaretlerini otomatik olarak inceleyip, epilepsi teşhisini yapmayı hedeflemişlerdir. Epilepsi kestirimi yaparken öznitelik çıkarma/seçme ve sınıflandırma şeklinde iki basamaktan oluşmaktadır. Öznitelik vektörlerinin belirlenmesi için ayrık dalgacık dönüşümü ve sınıflandırma için yapay sinir ağları yöntemini kullanmıştır. Çalışma sonunda %99.62 oranında doğruluk oranıyla sınıflandırmayı başarmışlardır (Toprak vd. 2007).

Sirinivasan ve arkadaşları (V. Sirinivasan vd., 2007) çalışmada entropi ölçümünü bir öznitelik olarak kullanmış ve EEG işaretlerinden alınan verilerdeki nöbeti kestirmek için yapay sinir ağı ile başarı bir şekilde sınıflandırmışlardır.

Panda ve ark. Yaptıkları çalışmada işaretleri farklı frekans bantlarına ayırmak için dalgacık dönüşümü ve epileptik verilerini ayırmak için Destek Vektör Makinaları sınıflandırıcısı kullanarak başarı yakalamışlardır (Panda vd. 2010).

Kaya ve ark. Yaptıkları çalışmada Bonn Üniversitesi Epitoloji bölümün sağladığı 5 gruptan meydana gelen (A-E) 23,6 saniyeli ve 173,6 Hz. örnekleme frekansı ile her biri 100 satırdan oluşan EEG verileri kullanmışlardır. Bu veri setinden daha sonra Ayrık Dalgacık Dönüşümü ile özellikler elde edilmiş ve bu özelliklerden karar ağaçları ve karar kuralları metotları ile %99,6 ile %99,7 bandı arasında sınıflandırmayı başarmışlardır (Kaya vd. 2012).

Behbahani vd. Yaptığı çalışmada epileptik nöbet geçiren hastalardan alınan eş zamanlı EKG verilerinin incelenmesi ile nöbet sırasında hatta öncesinde de anormalliklerin başladığını bildirmiştir (Behbahani vd., 2012).

Bayram vd. Yaptıkları derleme çalışmada sağlıklı ve nöbet anındaki EEG işaretlerini birbirinden ayıran bir sistem tasarlamışlardır. Bonn Üniversitesi Epileptoloji bölümünden aldıkları 50 adet sağlıklı, 50 adet krizli olmak üzere toplam 100 adet EEG verileri kullanılmıştır. Çalışmada sınıflandırıcı olarak destek vektör makinalarını kullanmış ve %98 gibi bir başarı ile sınıflandırmayı başarmışlardır (Bayram vd. 2013).

Ahammad ve ark. Yaptıkları çalışmada ise epileptik nöbet kestirimi ve nöbetin başlangıcını tespit etmek amacıyla MIT üniversitesi veri setini ve CHB-MIT veri tabanını kullanmışlardır. Çalışmada EEG özellikleri, ortalama, standart sapma, entropi, güç spektral yoğunluğunun yanı sıra dalga aralığı ve ortalama mutlak sapma gibi bazı istatistiksel özelliklerin üzerinde çalışılmıştır. Çalışma sonunda %85,6 doğruluk oranı ve %84,2 duyarlılık oranı yakalamışlardır (Ahammad vd., 2014).

Kusmakar ve ark. Yaptıkları çalışmada 34 nöbete ait ivmeölçer sinyalleri kullanarak epileptik ve epileptik olmayan sinyalleri ayırtmışlardır. Sinyallerden öncelikle dalgacık (wavelet) özellikleri çıkarılmış daha sonra ise bu özellikler destek vektör makineleri ile %89 oranında doğrulukla sınıflandırılmıştır (Kusmakar vd. 2015).

Gubbi ve ark. Yaptıkları çalışmada 27 nöbete ait ivmeölçer sinyallerini kullanarak epileptik ve epileptik olmayan sinyalleri ayırtmışlardır. Sinyallerden öncelikle dalgacık özellikleri çıkarılmış daha sonra ise bu özellikler destek vektör makineleri ve k en yakın komşuluk ile %93,3 oranında doğrulukla sınıflandırılmıştır (Gubbi vd. 2015).

Sezgin (2016) yaptığı çalışmada epileptik seyreden hastalardan kaydedilmiş EEG sinyallerini nöbet öncesi, anı ve sonrası olacak şekilde sınıflandırmıştır. Çalışmasında ortalama yaşları 35 (25-45 yaş bandında) olan 8 sara hastasından 16 kanallı yüzey elektrotu ile 200 Hz. örnekleme frekansına sahip EEG sinyalleri almıştır. Alınan bu sinyaller daha sonra ikiz spektrum analizi ile sinyallerden özellikler çıkarmış ve bu özellikleri aşırı öğrenme makinaları (ELM) ile %98,60 oranında sınıflandırmayı başarmıştır.

Yıldırım ve ark. Yaptıkları derleme çalışmada Boon Üniversitesi veri tabanından daha önce epilepsi nöbeti geçirmiş ve herhangi bir epileptik krizi olmayan sıhhatli bireylerden (A, B, C, D, E) alınmıştır. Bu sinyallerden yalnızca A ve E grupları kullanılarak 23,6 saniye 4096 örnek boyuna sahip bu EEG sinyalleri öncelikle bölütlere ayırarak güç spektral yoğunluk yöntemi olan Peridogram ve Welch yöntemleri

kullanılarak spektralleri bulunmuştur. Daha sonra bu EEG işaretlerinin boyutunu küçülmek amacıyla aritmetik ortalamaları alınıp 5-katlı çapraz doğrulama kullanılarak k-en yakın komşuluk (k-NN), destek vektör makinesi (SVM), aşırı öğrenme makinesi (ELM) sınıflandırmışlardır. Bu sınıflandırmalar sonucunda en yüksek olarak %100 sınıflandırma sonucu almayı başarmışlardır (Yıldırım vd. 2017).


Türk ve ark. Yaptıkları çalışmada Bonn Üniversitesi Epileptoloji bölümünün deneysel çalışmalar için sunduğu toplamda 5 veri kümesinden (A-B-C-D-E) meydana gelen Elektroansefalogram (EEG) kayıtları kullanmışlardır. Bir boyutlu medyan yerel ikili örüntü (1B-MYİÖ) yöntemi ile özellik çıkartılmıştı. Ve daha sonra k-En yakın komşuluk (k-NN) sınıflandırmışlardır. Yaptıkları çalışma sonucunda A-E veri gruplarında %100 olarak sınıflandırmayı başarmışlardır. Diğer gruplarda ise A-D %99.00, D-E %98, E-CD %99,50 ve A-D-E veri gruplarında ise %96.00 oranlarında sınıflandırmayı başarmışlardır. Çalışmada da görüldüğü üzere maksimum (100) sınıflandırma oranına ulaşarak 1B-MYİÖ yönteminin uygulanması ile daha önce literatürde kullanılan yöntemlerden daha iyi sonuç aldıklarını gözlemlemişlerdir (Türk vd., 2017).

3. MATERYAL VE YÖNTEM

3.1. Veri Kümesi

Epileptik ve epileptik olmayan nöbetler sırasında deneklerden alınmış rutin video-EEG testleri sürecinde alınan 18 kanallı EEG, EKG ve EMG sinyalleri ile kol ve bacaklara bağlanmış giyilebilir algılayıcılardan alınan sinyaller ve uzman nöroloğun teşhisi (epileptik veya epileptik olmayan nöbet) bilgisi ile beraber kaydedilmesi safhasıdır. Rutin olarak teşhis ve tedavi için Dicle Üniversitesi Hastanesi Nöroloji Bölümüne başvuran ve geçirdiği nöbetlerin epileptik veya epileptik olmayan nöbet olarak ayrıştırılması diğer uygulanan testler ile anlaşılmayan hastalar video-EEG testine tabii tutulmaktadır.

Bu testte hastaların şekil 3.1’ de görüldüğü formatta hem EEG, EKG ve EMG kaydı alınmakta hem de video ile kayıt altına alınmaktadır. Bu süreçte hastanın nöbet geçirmesine müteakip bu nöbet sürecine ait görüntüler ve kaydedilen EEG, EKG ve EMG sinyalleri incelenerek hastanın epilepsi hastası olup olmadığı ile ilgili teşhiste bulunmaktadır.



Şekil 3.1. Video EEG kayıt süreci

Bu rutin teste ilaveten tez çalışmasında hastanın vücudunun 4 farklı noktasına (her bir kol ve bacağına birer tane) 3 boyutlu (B) ivmeölçere ilaveten: 3B jiroskop, 3B

manyetometre, kalp atış hızı ölçer, bağlandığı kasın EMG kaydı, konum ve zaman sensörleri içeren kablosuz haberleşmeyi destekleyen sensör düğümleri kullanılmıştır. Sensör düğümlerinden alınan sinyallerden veri seti oluşturulup ve bu sinyallerden çeşitli zaman, frekans ve zaman-frekans düzlemi özellikleri çıkarılacak yapay öğrenme yöntemleri ile öncelikle nöbet durumu (var veya yok), daha sonra ise nöbet var ise nöbetin epileptik olup olmadığına göre sınıflandırılacaktır. Ayrıca bu bilgiler kullanılarak epileptik veya epileptik olmayan nöbetlerle veya bunların oluşma süreçleri ile ilgili yeni bilgiler elde edilebilmesi hedeflenmektedir. Şekil 3.2’de görüldüğü gibi hastaya takılan sensör düğümü ile hastadan ilave bilgiler de kayıt altına alınacaktır. Elde edilen sensör kayıtları bilgisayarda saklanacak ve belli bir sürede bir yedeklenecektir. Ayrıca söz konusu kayıt ile ilgili uzman nöroloğun teşhisi de ilişkilendirilerek kaydedilecektir.



Şekil 3.2. Veri setinin oluşma süreci

Sensörlerin boyutlarının, maliyetlerinin ve enerji ihtiyaçlarının düşmesi ile haberleşme ve işlemci teknolojilerindeki gelişmeler ile beraber giyilebilir sensörler birçok alanda kullanılmaya başlanmıştır. Literatür incelenmesi ile elde edilen bilgilere göre giyilebilir sensörlerden elde edilmiş verilerin çeşitli yapay zekâ yöntemleri ile anlamlandırılmasıyla uzman hekime yardımcı olması ve hastalığın tedavisine ışık tutacak çeşitli bilgiler vermektedir.


Bu tez çalışmasında mümkün olabilecek en geniş içerikli veri setini oluşturmak amacıyla nöbet sırasında hastanın hareket değişimini incelemek için 3B ivmeölçer ve 3B jiroskop, zaman ve konum olarak eş zamanlılığı sağlamak için GPS modülü, Nöbet sırasında kalp ritim durumunu incelemek için kalp atış hız sensörü, nöbet sırasında hareket değişimini incelemek için kaslardan alınan ve elektriksel sinyali incelemek için EMG sensörü ve nöbet anında vücut sıcaklığını belirlemek için vücut sıcaklık ölçer

kullanılmıştır. Aşağıdaki tabloda kullanılan sensörlerin adı ve kullanılma amacı yer almaktadır.

Tablo 3.1. Sensör düğümünde kullanılan düğümler ve kullanım amacı

Sensör Adı	Kullanım amacı
3B ivmeölçer	Her üç ekseninde (X, Y, Z) sensör düğümünün statik ve dinamik ivme ölçümü; Nöbet sırasındaki hareket değişimini incelemek için kullanılacaktır.
3B jiroskop	Her üç ekseninde (X, Y, Z) sensör düğümünün yön ölçümü; Nöbet sırasındaki hareket değişimini incelemek için kullanılacaktır.
GPS modülü	Zaman ve konum ölçümü; 4 adet sensör düğümünde eşzamanlılığın sağlanması için kullanılacaktır.
Grove Kalp Atışı Hızı Sensörü	Damardaki insan kanı hareket varyasyonunu ölçümü; Nöbet sırasındaki kalp atışı değişimini incelemek için kullanılacaktır.
EMG sensörü (yüzey elektrotlu)	Sinirler ve kaslardan alınan elektriksel sinyallerin ölçümü; Nöbet sırasındaki hareket değişimini incelemek için kullanılacaktır.
Vücut sıcaklık ölçer	Vücut sıcaklığı ölçümü; Nöbet sırasındaki vücut sıcaklığı değişimini incelemek için kullanılacaktır.

Yapılan literatür taramasında yukarıda belirtilen sensörlerden ivme ve kalp atış hızının (Nei, 2009; Zijlmans vd., 2002; Behbahani vd., 2012) nöbet ve nöbet türü tespitinde başarıyla kullanıldığı görülmüştür. Sensörlerin bağlantısı Şekil 3.3'te gösterilmiştir.



Şekil 3.3. Sensörlerin bağlantısı

Verilerin sağlıklı olarak alınması amacıyla her sensör düğümüne aşağıdaki tabloda belirtilen donanımlar bulunacaktır.

Tablo 3.2. Kullanılan donanımlar ve kullanım amacı

Donanım Adı	Kullanım amacı
Arduino Nano mikrodnetleyici	Sensörlerden verilerin alınması, SD karta yedeklenmesi ve iletiminin denetlenmesi için kullanılacaktır.
RF alıcı-verici	Sensör düğümleri ile ana alıcı arasındaki bağlantı için kullanılacaktır.
Mini SD kart modülü	Oluşabilecek iletişim sorunları sırasında sensörlerden algılanan değişkenlerin kaydedilmesi veya ileride sensör düğümünün kendi başına çalışabilmesine olanak sağlanması için sensör düğümüne dâhil edilecektir.

Ayrıca sensör düğümlerinden gelen veriler bir adet Arduino Due ve RF alıcı-verici ile taşınabilir bilgisayara aktarılacaktır. Verilerin depolanması ve taşınması için 1 adet 4TB kapasiteli harici disk kullanıldı. Sensör düğümlerinin enerji ihtiyacı şarj edilebilir lipo pil sağlanmıştır. Şekil 3.4 ve 3.5’de görüldüğü üzere kullanılan tüm sensörlerin birbiriyle uyumlu bir şekilde çalışması için entegre edilmiş donanımın bir görseli bulunmaktadır.

**Şekil 3.4.** Kullanılan sensörlerin entegre edilmiş görüntüsü



Şekil 3.5. Donanımın hastadan veri alma süreci

Kullanılan bu cihazda; EMG, ivmeölçer, jiroskop, kalp atış sensörü, vücut sıcaklık sensörlerinden arduino Nano mikrodenetleyici yardımıyla birbiriyle entegre edilmiş eş zamanlı 500 Hz. örnekleme frekansı ile şekil 3.6’ da görüldüğü üzere paket veri kaydı alınmıştır.

```
*****
85
344
Accel X: -0.81    Y: 9.59    Z: 2.07    m/s^2
Magn. X: 0.26    Y: -0.44    Z: -0.03    gauss
Gyro  X: 1.89    Y: -1.28    Z: -5.87    dps
Temp: 26.62 *C
*****

85
344
Accel X: -0.83    Y: 9.58    Z: 2.07    m/s^2
Magn. X: 0.26    Y: -0.44    Z: -0.03    gauss
Gyro  X: 0.81    Y: -1.08    Z: -6.55    dps
Temp: 26.62 *C
*****
```

Şekil 3.6. Paket veri kayıt

Yukarıdaki sensör verilerine ek olarak Şekil 3.7’de görüldüğü üzere 8 tıbbi yüzey Elektromyografi (sEMG) sensörüne sahip olan MYO kol bandı ile sEMG sinyalleri kaydedildi. MYO kol bandı üzerinde bulunan 8 adet paslanmaz medikal EMG sensörleriyle kaslarda oluşan biyoelektrik sinyallerini ölçerek elimizin hangi hareketi yapacağını algılar. Ayrıca üç eksenli jiroskop, üç eksenli ivmeölçer, üç eksenli manyetometre içeren 1 adet 9 eksenli Atalet Ölçüm Ünitesi (IMU) ile kolumuzun açısını ve hareket yönünü anlayabilir. MYO kol bandı EMG sensörleri için 200 Hz, IMU sensörleri için 50 Hz. örnekleme frekansına sahiptir (Visconti vd., 2018).



Şekil 3.7. MYO Kol bandı

Verileri kaydederken MYO kol bandının kol üzerindeki konumu Şekil 3.8’de gösterilmektedir.



Şekil 3.8. MYO kol bandının hastanın kolundaki konumu

Şekil 3.9’da MYO kol bandından alınmış 14 kanallı veri kümesi örneği verilmiştir. Kaydedilen bu verilerin tümü daha sonra gerekli ön işlemlerden geçip optimum hale getirilmiştir. Tüm bu safhaların sonunda veri seti oluşturulmuştur.

```


-5 6 -6 0 4 7 5 2 0.0751953 0.79541 0.555176 -6 1.1875 5.25
-2 -2 3 1 11 15 8 12 0.0947266 0.78418 0.556152 -2.375 2.375 2.375
3 3 -7 1 2 0 5 0 0.09375 0.780273 0.549805 -2.6875 2.6875 2.6875
-4 -3 -1 17 11 -1 -2 -8 0.074707 0.806152 0.550293 0.5625 7.8125 1.125
-5 -5 -11 -6 -9 -10 -8 -3 0.027832 0.812012 0.436035 -11.25 72.125 23.6875
71 -14 -9 -15 -15 -8 -5 -73 0.0332031 0.816406 0.562988 16.0625 49.6875 33.8125
29 -9 -21 -7 -3 -1 2 -30 -0.00683594 0.967773 0.494141 -29.0625 28.25 12.9375
1 -14 -42 -8 -7 -14 -12 9 0.11377 0.871582 0.411133 -30.5625 46.4375 45.5
-68 -8 -9 -6 -7 -9 -6 4 -0.187012 0.915039 0.931152 -18.0625 86.6875 46.0625
59 31 -11 2 -5 -4 -8 4 -0.361816 0.339355 0.680176 -0.875 45.4375 19.25
58 93 17 -27 -19 3 -2 -28 -0.413574 0.832031 0.719727 -29.1875 -12.25 -4.5

```

Şekil 3.9. MYO 'dan kaydedilen veri örneği

3.2. Metot

Oluşturulmuş olan veri setinin analizi Şekil 3.10'da çalışma prosedürü verilmiş şekilde yapılacaktır. Öncelikle belirlenmiş olan hasta gruplarından (epileptik veya epileptik olmayan) alınan sinyaller kaydedilecektir. Daha sonra pencereleme yöntemi ile bu sinyalleri optimize edip 10 saniye uzunluğa sahip karakteristik olarak nöbet olduğuna işaret eden sinyal kesitleri alınmıştır. Alınan sinyal kesitlerinden nöbetin olup olmadığına karar verilmiştir. Burada ki amaç eğer nöbet varsa bu nöbetin epileptik mi veya epileptik olmayan nöbet mi yani nöbet türü tespiti yaparak epileptik olmayan ama epilepsiye benzer seyreden nöbet geçiren kişilerin belirlenmesidir.




Şekil 3.10. Çalışma prosedürü

Şekil 3.10'da gösterilen süreç aşağıdaki bölümlerde adımlar halinde gösterilmiştir.

3.2.1. Sinyalin pencerelemesi

Sensörler vasıtasıyla algılanan sinyalden yürüyen pencereler yöntemi ile Şekil 3.11'te gösterildiği gibi kesitler alınacaktır.




Şekil 3.11. Pencereleme örneği

Sinyal kesitleri, sonsuz olmayan uzunluklara sahip işaretlerin zaman bölgesinde dikkörtgen şeklinde bölütler ile çarpılması sonucu ortaya çıkar. Sinyallerden alınan kesitlerin sayımlama olarak hareketsiz olduğuna bu nedenle önemli özelliklere sahip olduğu varsayılır. Sinyal kesitlerinin uzunluğu, sensörlerden alınan sinyallerin kendine has özelliklerine göre belirlenir. Eğer sinyal düşük frekansa sahipse uzun kesitler, yüksek frekansa sahipse daha kısa kesitler kullanılır.

Yadav ve ark. Göre EEG sinyalleri nöbet etkinliklerinin zemin etkinlikleri ile kıyaslama yapıldığında dar bant bir sinyal olduğu varsayılır (Yadav vd. 2012). Epileptik diken dalga uygulamalarının özellikleri açısından 0,5 saniyeden uzun olması beklenir, bu eşik uzunluğun altındaki kesitler parazit olarak görülebilir. Bu çalışmada tüm bu durumlar göz önünde bulundurularak sinyal kesitleri 10 saniye uzunlukta belirlenmiştir.

3.2.2. Nöbet tespiti

Giyilebilir sensörler ile elde edilen sinyaller video-EEG ile alınan sinyaller ile eşzamanlı incelenerek nöbet tespiti yapılmıştır. Örneğin, Dicle Üniversitesi Tıp Fakültesi Nöroloji Bölümünde tedavi gören hastalardan alınmış bir örnek sinyal için hastanın EEG ve EMG sinyalleri Şekil 3.12’de gösterilmektedir.




Şekil 3.12. Nöbet tespiti için örnek

Hastalara ait video-EEG sinyalleri ile sensörlerden alınan sinyallere paralel olarak kullanılarak oluşturulacak veri kümesine yapılacak ön işlemler ve yapay zekâ metotları bir sonraki bölümde ayrıntılı olarak açıklanacaktır.

3.2.3. Nöbet ayrıştırılması

Epileptik ve epileptik olmayan sinyallerin ayrıştırılması için veri setinin oluşturulmasına müteakip yapay öğrenme kullanılarak ayrıştırılma yapılacaktır. Şekil

3.13’de Dicle Üniversitesi Tıp Fakültesi Nöroloji Bölümünde tedavi gören hastalardan alınmış örnek bir epileptik nöbet ve epileptik olmayan nöbet sürecine ait EEG sinyalli bulunmaktadır.



Şekil 3.13. Nöbet ayrıştırılması için örnek (a) Epileptik nöbet, (b) Epileptik olmayan nöbet

3.3. Kullanılacak Yöntem

Önerilen yaklaşımda nöbet tespiti ve nöbet ayrıştırılma işlemleri yapay öğrenme yöntemleri ile Şekil 3.14’de gösterilen işlem blokları ile yapılacaktır.



Şekil 3.14. Kullanılacak yapay öğrenme aşamaları

Birinci blokta kayan pencereler yöntemi ile sinyalden alınmış olan kesitleri analiz için kullanılacaktır. Bu aşamada her bir sinyal türüne uygun pencere genişliği belirlenecek ve ona göre kaydırılacaktır. Burada esas olan nöbet tespiti ya da nöbet ayrıştırılması işlemlerinin yapılabilmesi için en küçük sinyal boyutunun tespitidir.

İkinci blokta sinyal pencerelerinin fazsal ilintilerini ortaya çıkarmak için ikiz spektrum analizi yapılacaktır. Üçüncü ve dördüncü blokta elde edilen sinyal kesitinden etkin özelliklerin çıkarılması sürecinde sinyalden zaman, frekans ve zaman frekans düzlemlerinde aşağıda sayılan özellikler çıkarılacaktır.

3.3.1. Özellik çıkarma

Sinyaller ölçülürken sinyal ile beraber elektriksel aygıtlardan, ortamdaki, sarsıntı ve sinyalin kararsızlığından kaynaklanan gürültülerde ölçülmektedir. Özellikle gürültünün frekans özelliği rastgele olduğunda sinyallerin sınıflandırma başarısı düşmektedir. Sınıflandırma başarısı doğrudan özellik çıkarma işlemine bağlıdır. Bu sebeple öznel özellik çıkarma yöntemi uygun bir biçimde seçilmelidir (Phinyomark vd., 2009).

Özellik çıkarma işlemi sinyali gürültülerden temizlemek, önemli verileri vurgulamak ve yeni sinyali özellik vektörü adı verilen ilgili veri yapısına dönüştürmek için uygulanan işlemidir. Çalışmada zaman düzlemi, frekans düzlemi ve zaman-frekans düzlemi olmak üzere öznel özellik çıkarma yöntemi kullanılmıştır.

İkiz spektrumdan alınmış sinyallerden çıkarılan istatistiksel özellikler aşağıda listelenmiştir.

1. Enerji
2. Aritmetik ortalama
3. Standart sapma
4. Basıklık
5. Çarpıklık
6. Entropi
7. Varyans

8. Kovaryans

Enerji:

$$E_s = \int_{-\infty}^{\infty} |x^2| dt \quad (3.1)$$

Aritmetik Ortalama:

$$\mu(x) = \frac{1}{N} \sum_{i=1}^N x(i) \quad (3.2)$$

Standart Sapma:

$$\sigma(x) = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2} \quad (3.3)$$

Basıklık Katsayısı:

$$K_s = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^4}{\sigma^4} \quad (3.4)$$

Çarpıklık Katsayısı:

$$S_k = \frac{N}{(N-1)(N-2)} \sum_{i=1}^N \left(\frac{x_i - \bar{x}}{\sigma} \right)^3 \quad (3.5)$$

Entropi:

$$Entropi = \sum_{i=1}^N \frac{x_i}{Enerji} \ln\left(\frac{x_i}{Enerji}\right) \quad (3.6)$$

Varyans:

$$VAR_k = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2 \quad (3.7)$$

Kovaryans:

$$Cov(x, y) = \frac{\sum (x_i - \bar{x})(y_j - \bar{y})}{n} \quad (3.8)$$

3.3.2. İkiz-spektrum analizi

İki farklı frekanstaki işaretin ya da bir işaretin farklı frekanslara sahip bileşenleri arasında ister doğrusal olsun ister olmasın herhangi bir fazsal ilinti varsa ikiz spektrum bu ilintiyi ortaya çıkarıp sergilemek için geliştirilen istatistiksel bir işaret işleme yöntemidir (Hinich ve Clay, 1968; Sigl ve Chamoun, 1994; Nikias ve Petropulu, 1993). Epilepsi tanısında kullanılan en önemli işaretlerden beyin gibi durağan ve doğrusal olmayan, karmaşık sistemlerin dinamiği ya da ürettiği işaretlerin bileşenleri arasında olası ikinci dereceden faz eşleşmelerini (QPC – quadratic phase coupling) ortaya çıkarmak için ikiz spektrum kullanılmaktadır (Sezgin, 2010; Tagluk ve Sezgin, 2011). İkiz spektrum, türevlenebilir bir sistem dinamiğinin üçüncü derece kümülantın Fourier dönüşümü olarak tanımlanmıştır (Ning ve Bronzino, 1989). Herhangi bir durağan reel değerli ayrık rastsal $x(k)$ sürecinin r . derece momentleri:

$$m_r^x(n_1, n_2, \dots, n_{r-1}) = E\{x(k)x(k+n_1) \dots x(k+n_{r-1})\} \quad (3.9)$$

Şeklinde ifade edilebilir (Raghuveer ve Nikias, 1985). Burada E beklenti değeri anlamına gelmektedir. Genel manada $x(k)$ 'nın 1., 2. ve 3. kümülantı momentler serisi cinsinden sırasıyla:

$$c_1^x = m_1^x = E\{x(k)\} \quad (3.10)$$

$$c_2^x(n_1) = m_2^x(n_1) - (m_2^x)^2 \quad (3.11)$$

$$c_3^x(n_1, n_2) = m_3^x(n_1, n_2) - m_1^x[m_2^x(n_1) + m_2^x(n_2) + (n_2 - n_1)](m_1^x)^3 \quad (3.12)$$

Şeklinde ifade edilirler. Gauss olmayan reel değerli durağan ve sıfır ortalamaya sahip bir ayrık $x(k)$ sürecinin 3. Kümülantını:

$$c_3^x(n_1, n_2) = Cum\{x(k), x(k + n_1), x(k + n_2)\} \quad (3.13)$$

Veya

$$c_3^x(n_1, n_2) = E\{x(k)x(k + n_1)x(k + n_2)\} \quad (3.14)$$

Şeklinde ifade edilir. Buna göre üçüncü derece kümülant fonksiyonun spektrumu veya İkiz–spektrum:

$$B(w_1, w_2) = \sum_{n_1=-\infty}^{\infty} \sum_{n_2=-\infty}^{\infty} c_{3x}(n_1, n_2) W(n_1, n_2) e^{-j(w_1 n_1 + w_2 n_2)}, \quad |w_1|, |w_2| \leq \pi \quad (3.15)$$

Şeklinde ifade edilir. Burada $W(n_1, n_2)$, ikiz–spektrumun değişkenliğini azaltmak için iki boyutlu pencere fonksiyonudur; bu değer 1’e eşitlenebilir. Çalışmada ikiz–spektrum hesabı için 0,5 saniye aralığında Hanning penceresi kullanıldı. $x(k)$ ’nın ω_1 ve ω_2 frekansları bazında elde edilen spektrumları cinsinden aşağıdaki gibi de ifade edilebilir;


$$B(w_1, w_2) = E\{X(w_1)X(w_2)X^*(w_1 + w_2)\} \quad (3.16)$$

Denklemdaki * işareti karmaşık eşleniği belirtmektedir. İkiz-spektrumun simetri özelliğinden dolayı üzerinde çalışılan EEG işaretine ait bütün ikiz-spektrum bilgisi $0 \leq w_2 \leq w_1$ ve $w_1, w_2 \leq \pi$ tanımlı üçgensel bölgede yoğunlaşmaktadır. Fazları ikinci dereceden eşleşen bileşenler sürecin üçüncü derece kümülanına söz konusu bölgede QPC şeklinde katkı sağlar ve böylece işaret hakkında ekstra bilgi sunar. İkiz-spektrum, $B(\omega_1, \omega_2)$ düzlemindeki diğer bölgeler tanımlı üçgenin simetrisi olarak ortaya çıkmaktadır. Bu çalışmada, ikiz-spektrumun bu özelliğinden yararlanarak, EEG işaretin içinde olası QPC toplamını:

$$D = \sum_{(w_1, w_2)} |B(w_1, w_2)| \quad (3.17)$$

Şeklinde niceleyici olarak hesaplayıp buna göre epilepsi hastalığının derecesi belirlenmeye çalışılabilir. Ayrıca ikiz-spektrumu elde edilen işaretten yukarıda verilen istatistiksel yöntemler ile çıkarılan özelliklerin sınıflandırma girişine verilmesi ile de epilepsi kestirimi gerçekleştirilebilmektedir.

Epileptik bir EEG işaretinde nöbet öncesi, nöbet anı ve nöbet sonrası ikiz-spektruma bağlı olarak elde edilen QPC miktarını göstermek için örnek olarak Şekil 3.15'te verilmiştir. QPC miktarının büyüklüğü EEG işaretinin ilgili bölgesinde lineer ve Gauss olmayan bileşenlerin oranının büyüklüğünü ifade etmektedir. Şekilden de görüldüğü gibi epilepsi öncesi çok az sayıda QPC var iken epilepsi anında QPC miktarı artmış ve sonrasında azalmıştır.



Şekil 3.15. Bir EEG işaretinin; a) epilepsi öncesi, b) epilepsi anında ve c) epilepsi sonrası ikiz spektrum gösterimi


Dördüncü blokta her bir sinyalden çıkarılan özelliklerden etkin olanları filtreleme metoduyla belirlenecektir. Bu şekilde sadece özellik indirgenmesi değil aynı zamanda sensör düğümü, sensör ve hastadan alınan diğer biyolojik sinyallerden etkin olmayanlarının kaydedilmesine gerek kalmayacaktır.

Bu da ihtiyaç duyulan donanım miktarı ve türünü azaltacağı gibi ayrıca verilerin kaydı için hafıza ve verilerin işlenmesi sürecindeki fonksiyonel yükü azaltacaktır (Ertuğrul vd,2017). Etkin olan özelliklerin belirlenmesi için birçok yöntem önerilmiştir. Bu çalışmada çıkarılacak özellik sayısı çok olduğu için filtreleme metoduyla özellik seçimi yapılacaktır (Ertuğrul, 2016-a).

Beşinci blokta sınıflandırma amacıyla aşırı öğrenme makineleri yöntemi kullanılacaktır.

3.3.3. Aşırı öğrenme makineleri (ELM)

Aşırı Öğrenme makineleri sadece tek gizli katmanı bulunan ileri beslemeli yapay sinir ağlarının eğitiminde kullanılmak üzere geliştirilmiş bir yöntemdir (Huang ve ark, 2006). Aşağıdaki şekilde ELM ile eğitilen bir YSA'nın yapısı gösterilmiştir.



Şekil 3.16. Tek gizli katmanlı YSA (Ertuğrul vd., 2012)

Şekil 3.16'da verilen yapay sinir ağına ait çıkış denklemi:

$$Y(p) = \sum_{j=1}^m \beta_{j,k} g\left(\sum_{i=1}^n w_{i,j} x_i + b_j\right) \quad (3.15)$$

ile hesaplanması gerçekleştirilmektedir. Burada $x_{1...n}$ giriş vektörlerini, $y_{1...p}$ çıkış vektörlerini, $\beta_{1...m}$ çıkış katmanı ağırlıklarını, $W_{1...n,1...m}$ giriş katmanı ve gizli katman arasındaki bağlantı ağırlık değerini, $b_{1...m}$ eşik değişkenlerini ve $g(.)$ aktivasyonunu belirtmektedir (Ertuğrul ve ark, 2014).

Geleneksel ileri beslemeli bir YSA'da ağı eğitilmesi defalarca tekrarlanırken, bu süreç ELM'de analitik bir denkleme dönüştürülmüş ve bu sebeple çok hızlı bir öğrenme yeteneği kazanılmıştır. Ayrıca, ELM'de çıkış ağırlıkları genelleştirilmiş ters Moore-Penrose matrisi ile hesapladığından, yerel minimuma takılma veya en uygun öğrenme parametresi (örneğin momentum, öğrenme katsayısı) belirlenmesi gibi performansı doğrudan etkileyen sorunları yoktur ve genelleştirme kabiliyeti daha yüksektir (Ertuğrul, 2016-b ve c).

Yapay sinir ağının başarılı bir şekilde öğrenimini gerçekleştirebilmesi için verilecek ağırlıkların, transfer fonksiyonu ve eşik değerleri modellenen sistemin yapısına en uygun parametrelerin seçiminin yapılması ile gerçekleştirilir. Gradyan temelli yaklaşımlarda eğitim esnasında oluşacak hatayı en düşük seviyeye indirmek için verilen ağırlık değerleri ve eşik değerlerinin en uygun değerlerini sağlayan parametre elde edilinceye kadar değiştirilme işlemi devam eder. Buda eğitimin hata oranının yüksek değerlere çıkmasına sebep olmaktadır.

ELM yönteminde giriş katmanındaki ağırlıklar ile eşik değerleri rastgele verilmekte, buna bağlı olarak çıkıştaki ağırlık değerleri hesaplanmaktadır (Ertuğrul ve Altun, 2017). n adet girdi nöronu, m adet gizli katman nöronu bulunan bir yapay sinir ağın giriş katmanı ağırlık değerleri $(W_{i,j})$ ve eşik değerleri (b_i) rastgele belirleme işlemi gerçekleştiğinde, atanmış olup türevlenemeyen ya da kesikli aktivasyon fonksiyonları da ek olarak rastgele bir transfer fonksiyonu $(g(.))$ için çıkış katmanının giriş denklemi:

$$H = \begin{bmatrix} g(w_{1,1}x_1 + b_1) & \dots & g(w_{1,m}x_m + b_m) \\ g(w_{n,1}x_n + b_1) & \dots & g(w_{n,m}x_m + b_m) \end{bmatrix} \quad (3.16)$$

olarak bulunur. Böylelikle elde edilen çıkış denklemi:

$$y = H\beta \quad (3.17)$$

olmaktadır. H matrisinin ters matrisinin hesaplanma işlemi genelleştirilmiş Moore-Penrose matrisi ile gerçekleştirilir. Bunun sebebi olarak eğitim kümesi gözlem sayısı ile özellik sayısı düşük seviyede bir olasılıkla birbirine eşit olması kabul edilebilir. Böylece çıkış ağırlıkları (β) :

$$\beta = H^\dagger y \quad (3.18)$$

olarak hesaplanır. Denklem 3.18'de yer alan $H^\dagger$, genelleştirilmiş ters Moore-Penrose matrisi ile hesaplanmış H matrisini ve β çıkış katmanı ağırlıklarını belirtmektedir (Huang ve ark, 2012).

4. ARAŞTIRMA BULGULARI VE TARTIŞMA

4.1. Epileptik/Epileptik Olmayan Krizlerin Ayırıştırılması

Bispektrumu alınmış sinyallerden: (1) aritmetik ortalama, (2) standart sapma, (3) entropi, (4) enerji, (5) varyans, (6) kovaryans, (7) basıklık ve (8) çarpıklık istatistiksel özellikleri çıkarılmıştır. Tüm sınıflandırma sonuçları 5-parçalı çapraz doğrulamaya göre elde edilmiştir. Tüm deneylerde öncelikle kullanılan ELM ile optimize edilmiş ve en uygun gizli katmandaki nöron sayısı ve transfer fonksiyonu kullanılarak elde edilen doğruluk sonuçları paylaşılmıştır. Yapılan simülasyonlar da aşağıdaki sınıflandırma işlemleri yapılmıştır.

- Kriz Tespiti: hastanın kriz (epileptik veya epileptik Olmayan) geçirip geçirmediğinin tespittir.
- Kriz Türü Tespiti: Epileptik /Epileptik olmayan kriz ayırıştırılması,
- Tüm verilerin ayırıştırılması: Normal/Epileptik/Epileptik Olmayan ayırıştırılması,

Optimizasyona örnek olarak EKG sinyallerinin kriz tespiti, kriz türü tespiti ve tüm verilerin ayırıştırılması sürecinde elde edilen sonuçlar aşağıdaki şekildedir.

Tablo 4.1. EKG ile kriz tespiti optimizasyon süreci

Gizli Katmandaki Nöron Sayısı	Aktivasyon Fonksiyonu				
	'sig'	'sin'	'hardlim'	'tribas'	'radbas'
5	0,00	0,00	0,00	100,00	100,00
10	0,00	100,00	0,00	100,00	100,00
20	0,00	0,00	0,00	100,00	100,00
25	0,00	100,00	0,00	100,00	100,00
50	0,00	0,00	0,00	100,00	100,00
75	0,00	100,00	0,00	100,00	100,00
100	0,00	100,00	0,00	100,00	100,00

Optimum parametreler olarak doğruluğun en yüksek olduğu gizli katmandaki nöron sayısı ve aktivasyon fonksiyonudur.

4.2. Özellik Seçmeden Elde Edilen Başarı Sonuçları

Analizler sırasında 3 farklı EEG kanalının alınması kriz bölgesine ve EEG probuna bağlı başarının değişip değişmeyeceğini göstermektedir. 3 farklı

elektroansefalografi (EEG) kanalı, elektrokardiyografi (EKG) ve Elektromiyografi (EMG) ile elde edilen başarı oranları aşağıdaki tabloda özetlenmiştir.

Tablo 4.2. Sınıflandırma doğruluğu (%)

Veri seti	Kriz Tespiti	Kriz Türü Tespiti	Tüm verilerin ayrıştırılması
Tek kanal EEG (EEG1)	100	100	100
EKG	100	100	100
EMG	100	100	100
EKG + EMG	100	100	100

Tablo incelendiğinde EKG ve EMG verileri analizi sonucunda kriz tespiti ve kriz türü tespitinde yeterli sonuçlar verdiği görülmüştür.

4.3. Özellik Seçme ile Elde Edilen Sonuçlar

Makine öğrenmesi (ML) yöntemleri temel olarak girdi verilerini kullanarak bir çıktı değeri üretme ilkesiyle çalışır. Bu nedenle girdi verileri makine öğrenmesi uygulamalarında oldukça önemlidir, özellik sayısı çok fazla olduğunda daha da önemli hale gelir. Yapay zekâ yöntemleriyle algoritma oluşturmak için her özelliği kullanmamıza gerek yoktur. Sadece önemli özellikleri besleyerek algoritmayı başarılı ve hızlı bir hale getirebiliriz. Çok büyük verilerin anlamlı bir şekilde azaltılması özellik seçme algoritmalarının temel işlevidir (Ertuğrul vd., 2017, Chandrashekar ve Sahin, 2014).

Özellik seçimi, veri kümesini temsil eden en iyi alt kümenin seçilmesini sağlayarak; modelin başarısını artırır, daha iyi tahmin performansı sağlar, eğitim süresini azaltır, algoritmayı hızlandırır, gereksiz özellikleri ortadan kaldırır, verilerin daha iyi anlaşılmasını sağlar ve yorumu kolaylaştırır (Ertuğrul ve Tağluk, 2017, Ertuğrul vd., 2020).

Literatürden de görülebileceği üzere daha az özellikle daha yüksek başarılar elde etmek mümkündür. Bunun nedeni olarak karmaşık, gürültülü veya alakasız özellikler kullanılmayarak daha yüksek başarıların elde edilebilmesidir. Ayrıca daha az özellik kullanmak işlevsel yükün ve hafıza ihtiyacının düşmesi ve bu da daha az veri ve işlemci kapasitesi ile daha başarılı ve gerçek zamanlı kullanılabilir donanım geliştirilmesine olanak sağlamaktadır. Kriz tespiti etkin özellik ve elde edilen başarı oranları Tablo 4.3'de verilmiştir.

Tablo 4.3. Kriz tespitinde seçili özelliklerle elde edilen başarı oranları

Veri seti		Parametre							
EEG1	Özellik Sıralaması	Basıklık	Çarpıklık	Aritmetik Ortalama	Kovaryans	Varyans	Entropi	Standart Sapma	Enerji
	Başarı	100	100	100	100	100	100	100	100
EKG	Özellik Sıralaması	Çarpıklık	Standart Sapma	Basıklık	Aritmetik Ortalama	Kovaryans	Varyans	Entropi	Enerji
	Başarı	100	100	100	100	100	100	100	100
EMG	Özellik Sıralaması	Basıklık	Çarpıklık	Entropi	Varyans	Kovaryans	Aritmetik Ortalama	Standart Sapma	Enerji
	Başarı	100	100	100	100	100	100	100	100

Tablo 4.3 incelendiğinde kriz tespitinde EEG, EKG, EMG veri setleri ile yapılan sınıflandırmada kullanılan; basıklık, çarpıklık, aritmetik ortalama kovaryans, varyans, standart sapma ve enerji tüm özelliklerin etkin olduğu görülmektedir. Ayrıca nöbet sırasındaki hareket değişimini incelemek için kullanılan EMG ve nöbet sırasında kalp atış değişimini incelemek için kullanılan EKG verilerinin kriz tespitinde başarı bir şekilde sınıflandırıldığı görülmektedir.

Tablo 4.4. Kriz türü tespitinde seçili özelliklerle elde edilen başarı oranları

Veri seti		Parametre							
EEG1	Özellik Sıralaması	Çarpıklık	Basıklık	Varyans	Kovaryans	Entropi	Aritmetik Ortalama	Standart Sapma	Enerji
	Başarı	100	100	100	100	100	100	100	100
EKG	Özellik Sıralaması	Çarpıklık	Basıklık	Standart Sapma	Entropi	Aritmetik Ortalama	Kovaryans	Varyans	Enerji
	Başarı	100	100	100	100	100	100	100	100
EMG	Özellik Sıralaması	Çarpıklık	Basıklık	Varyans	Kovaryans	Aritmetik Ortalama	Entropi	Standart Sapma	Enerji
	Başarı	100	100	100	100	100	100	100	100

Tablo 4.4 incelendiğinde kullanılan tüm özelliklerin etkin bir şekilde %100 başarı oranı ile sınıflandırıldığı görülmektedir. Ayrıca tablo 4.3’ te kriz tespitinde görüldüğü gibi EKG ve EMG verilerinin de kriz türü tespitinde yeterli olduğu görülmüştür.

4.4. Tartışma

Giyilebilir sensörler boyutları ve maliyetlerinin azalmasıyla beraber sağlık uygulamaları dâhil birçok alanda kullanılmaya başlanmıştır (Akbulut ve Akan, 2015). Ayrıca tanı olarak nöbet sürecinde giyilebilir algılayıcılardan (özellikle ivmeölçer) alınan sinyaller kullanılarak başarılı sonuçlar elde edildiği raporlanmıştır (Gubbi vd., 2015;

Kusmakar vd., 2015-a, 2015-b). Epileptik ve epileptik olmayan nöbetlerin ayrıştırılması için literatür de önerilen metotlar ve elde edilen başarı oranları Tablo 4.5’de özetlenmiştir.

Tablo 4.5. Epileptik ve epileptik olmayan nöbetlerin kestirimi için önerilen metotlar ve başarı oranları

Referans	Denek	Veri	Özellik Çıkarma	Yöntem	Başarı
Kanas vd. (2015)	11 farklı hastadan alınan: 105 epileptik nöbet 21 epileptik olmayan nöbet	EEG	Tensör Ayrıştırma	Destek Vektör Makineleri	Doğruluk: %96
Xu vd. (2014)	25 denekten alınan: 10 epileptik nöbet 15 epileptik olmayan nöbet	EEG	Ağırlık bağlantılı Ortak konumsal model tabanlı ağırlıklı bağlantı ağı	Destek Vektör Makineleri	Doğruluk: %92 Duyarlılık: %100 Özgüllük: %80
Pippa vd. (2014)	11 denekten (4 epilepsi, 7 epilepsi olmayan hasta): 123 epileptik nöbet 82 epileptik olmayan nöbet	EEG	Zaman ve frekans düzlemi özellikleri	Bayes Ağları	Doğruluk: %86 Duyarlılık: %92 Özgüllük: %78
Gubbi vd. (2015)	27 denek: 10: epilepsi hastası, 3: epileptik olmayan nöbet geçiren denek, 1: epileptik ve epileptik olmayan nöbet geçiren denek 13: Normal denek	İvmeölçer	Dalgacık düzlemi özellikleri	k ortalama ve Destek Vektör Makineleri	Duyarlılık: %100 Doğruluk: %93,3
Kusmakar vd. (2015-a)	34 nöbet: 15 epileptik nöbet 19 epileptik olmayan nöbet.	İvmeölçer	Dalgacık düzlemi özellikleri	Destek Vektör Makineleri	Duyarlılık: %93,33 Doğruluk: %89
Kusmakar vd. (2015-b)	34 nöbet: 15 epileptik nöbet 19 epileptik olmayan nöbet.	İvmeölçer	Yönlendirilmiş hareket histogramı	Destek Vektör Makineleri	Duyarlılık: %93,33 Doğruluk: %80

Tablo 4.5 incelendiğinde EEG sinyalleri kullanıldığında ayrıştırıcı tanının yüksek başarıyla ulaşıldığı gözlemlenmektedir. Ancak, ayırıcı tanı için alınan EEG sinyallerinin nöbet anında olması gerektiğinden bu yöntem ile epileptik veya epileptik olmayan nöbetlerin kestirimi kolay değildir. Öte yandan giyilebilir algılayıcılar birçok farklı amaçla insanın yaşam konforunu azaltmadan akıllı saatler veya cep telefonları gibi birçok sisteme entegre olarak kullanılmaktadır.

Günümüzde geçirdiği nöbetin epilepsiden kaynaklı olmadığı halde epileptik tedavilere maruz kalan ayrıca anti epileptik ilaç kullanmak zorunda kalan bireyler bulunmaktadır. Bu tip durumlarda anti epileptik ilaçların hastalar üzerinde birçok yan

etkileri görülmektedir. Ayrıca hasta ve ailesine ciddi bir mali külfete neden olmakla beraber kişilerin yaşam kalitesinin düşmesine sebep olmaktadır.

Bu tip olumsuzlukların önüne geçebilmek için epilepsi ayırıcı tanısı olarak giyilebilir sensörler kullanılarak epileptik ve epileptik olmayan nöbetlerin kestirimi için yeni bir yaklaşım önermektedir. Epileptik ve epileptik olmayan nöbetlerin ayrıştırılarak epilepsi teşhisinde başarının artırılması ve epileptik olmayan nöbet geçirenlerin hastalara yanlış teşhis (epilepsi tanısı) konmasını engellenmesi için uzman hekime yardımcı veriler sunulmaktadır.



5. SONUÇLAR VE ÖNERİLER

5.1. Sonuçlar

Nörolojik hastalıklar arasında en yaygın olarak görülen epilepsi hastalığı bireylerin yaşam kalitelerinde ciddi sorunlar yaşanmasına sebep olmaktadır. Rakamlar açısından dünyada yüksek hasta sayısı olan epilepsi, hastalar üzerinde sadece nöbet ve nöbeti takip eden birkaç saatlik sorunlar dışında hastanın normal yaşamına sürdürmesine engel bir durum olmadığından geçirdiği nöbetin epileptik olup olmadığına saptamak ve epileptik ve epileptik olmayan işaretlerin ayrıştırılması hastanın doğru tedavi edilmesi çok önemlidir.

Epileptik ve epileptik olmayan nöbetlerin ayrıştırılmasında kullanılan video-EEG laboratuvarı yüksek maliyet ve uzmanlık gerektirdiğinden her ilde bulunmamaktadır. Bu tez çalışmasında temelde düşük maliyetli sensörler yardımı ile epilepsi hastaları için uzman hekime yardımcı olacak ayırıcı tanı yöntemi önerilmiştir.

Yapılan çalışmalarda görüldüğü üzere epilepsinin kestirimi ile beraber ilaç tedavileri epileptik seyreden bireylerin önemli bir kısmında nöbetlerin hemen hemen tamamının kontrol altına alınmasının mümkün olduğunu göstermiştir. Ancak epilepsi hastalığı olmamasına rağmen geçirdiği nöbetlerin benzer özellikler göstermesi ve yanlış tanı konmasından dolayı birçok insana epileptik tedaviler uygulanmaktadır. Kullanılan anti epileptik ilaçlar ve bu ilaçların bireyler üzerinde görülen ciddi yan etkileri ayrıca hastanın yaşam kalitesini düşüren sebepler doğurmaktadır. Bu durumla beraber hasta ve ailesinin ciddi iş gücü ve mali yükü taşımasına sebebiyet vermektedir.

Gelişen teknoloji ve buna entegre olan yapay zekâ metotları ile hemen her alanda olduğu gibi tıp alanında da kullanılmaya başlanmıştır. Buna karşın şekil 1.2 incelendiğinde epileptik nöbet ve epileptik olmayan nöbete ait EEG işaretlerinin birbirine benzer karakteristikleri olduğu bu nedenden ötürü epileptik nöbetlerin tespiti oldukça zordur. Tüm bu durumların bir sonucu olarak yanlış teşhisin hasta başı maliyeti çok ciddi rakamlara ulaşmaktadır.

Bu tez çalışmasında epileptik/epileptik olmayan nöbetleri birbirinden ayıracak içerisinde bölüm 3’ te ayrıntılı bir şekilde anlatılan sensörler yardımıyla epileptik aktiviteyi izleyerek ölçülen sinyallerin analizi yapılmıştır. Dicle Üniversitesi Tıp Fakültesi Nöroloji Bölümünde tedavi gören hastalardan alınmış sinyallerin ikiz spektrumları alındıktan sonra bu sinyallerden aritmetik ortalama, standart sapma, entropi,

enerji, varyans, kovaryans, basıklık ve çarpıklık istatistiksel özellikleri çıkarılmıştır. Daha sonra özellik seçimi yapılmış ve ELM ile sınıflandırma işlemi yapılmıştır. Hastanın kriz (epileptik veya epileptik Olmayan) geçirip geçirmediğinin tespiti için kriz tespiti, epileptik /epileptik olmayan krizlerin ayrıştırılması için kriz türü tespiti, normal/epileptik/epileptik olmayan krizlerin tespit edilmesi için tüm veriler ayrıştırılmıştır.

Analizler sırasında 3 farklı EEG kanalı, EKG ve EMG'den oluşan veri grupları ile kriz tespiti, kriz türü tespiti ve tüm verilerin ayrıştırılması olacak şekilde sınıflandırılmıştır. Bu veri gruplarından hepsinde Tablo 4.2' de görüldüğü üzere özellik seçmeden %100 sınıflandırma doğruluğu elde edilmiştir. Tablo 4.2 incelendiğinde EMG ve EKG verileri grupları kriz tespiti ve kriz türü tespitinde yeterli oldukları görülmektedir. Tablo 4.3 ve 4.4 incelendiğinde kriz tespiti ve kriz türü tespitinde etkin özellikler seçilerek %100 başarı oranları elde edilmiştir. Tablo 4.3'ten görüleceği gibi çarpıklık (8. özellik) tek başına kriz tespitinde yeterli iken basıklıkta kriz türünün tespiti için yeterlidir. Ayrıca kriz ve kriz türü tespitinde EKG ve EMG'nin yeterli olduğu görülmüştür.

5.2. Öneriler

Epileptik krizlerin kestirimi üzerine yapılan bu tez çalışmasında önerilen yöntemler sadece epilepsi değil farklı hastalıkların teşhisinde ve işaret işleme uygulamaları için uyarlanabilir. Ayrıca uzman hekimin daha hızlı ve yüksek başarı ile karar vermesine yardımcı olabilecek klinik uygulamalara öncülük edebilir. Ancak çalışmanın konusu olan epileptik kriz kestirimi özelinde ise ilerdeki benzer çalışmalarda hastaların günlük yaşantısına devam ederken kolay taşıyabileceği sensörler ile nöbet anında sinyal kaybına neden olmayacak düşük maliyetli ölçüm cihazları geliştirilebilir. Ayrıca epileptik ve epileptik olmayan nöbetler ayrımı için yapay zekâ destekli yeni ayırıcı tanı sistemlerinin geliştirilmesine yardımcı olarak ve giyilebilir sensörlerin tıp uygulamalarında kullanımını artırılarak teşhis ve hastaya özgü tedavi ve takibinin yapılabilmesinin önü açılabilir. Epileptik krizler hastalar üzerinde nöbet ve nöbeti takip eden birkaç saatlik zaman dilimi dışında kullanılan anti epileptik ilaçlar ile hastanın normal yaşantısına devam etmesine engel bir durum olmadığından dolayı kriz anının tespiti ve önsel tahmin ile hastanın kriz geçirmesi tıbbi müdahale ve psikolojik açıdan rahatlama ile engellenebilir.

KAYNAKLAR

- Akbulut, F. P., Akan, A., 2015, Akıllı Giyilebilir Hasta Takip Sistemleri, *Vogue*, 15(18), 440-443.
- Akın, M., Arserim, M. A., Kıymık, M. K. ve Türkoğlu, I., 2001, A New approach for diagnosing epilepsy by using wavelet transform and neural networks, *Proceedings of the 23rd Annual EMBS International Conference*, İstanbul, 1596-1599.
- Ahammad, N., Fathima, T., & Joseph, P. 2014, Detection of epileptic seizure event and onset using EEG. *BioMed research international*, 114-125.
- Araz, N. Ç., Yılmaz, K., Ölmez, A., Kılınç, M., 2009, Epilepsi ayırıcı tanısında üç olgu ile kardiovasküler nedenler, *ADÜ Tıp Fakültesi Dergisi*, 10(2), 37 – 40.
- Arıkanoğlu, A., 2011, Epileptik nöbet ve psödonöbetlerin ayırıcı tanısına güncel yaklaşım, *Journal of Clinical and Experimental Investigations*, 2(3), 330-334.
- Andrzejak, R. G., Lehnertz, K., Mormann, F., Rieke, C., David, P., 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.
- Batar, H., 2005, EEG İşaretlerinin Dalgacık Analiz Yöntemleri Kullanılarak Yapay Sinir Ağları ile Sınıflandırılması, Kahramanmaraş Sütçü İmam Üniversitesi Fen Bilimleri Enstitüsü, Kahramanmaraş.
- Bayram, M., Acar, H., 2013, EEG sınıflandırma amaçlı bir kompozit sistem, *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 4(1), 5-12.
- Behbahani, S., Dabanloo, N. J., Nasrabadi, A. M., Attarodi, G., Teixeira, C. A., Dourado, A., 2012, Epileptic seizure behaviour from the perspective of heart rate variability, *IEEE Computing in Cardiology (CinC)*, 117-120.
- Bernal, B., Altman, N. R., 2003, Evidence-based medicine, neuroimaging of seizures. *Neuroimaging Clinics of North America*, 13(2), 211-224.
- Bodde, N. M. G., Brooks, J. L., Baker, G. A., Boon, P. A., Hendriksen, J. G., Aldenkamp, A. P., 2009, Psychogenic non-epileptic seizures diagnostic issues a critical review, *Clinical neurology and neurosurgery*, 111(1), 1-9.
- Chandrashekar, G., Sahin, F., 2014, A survey on feature selection methods, *Computers & Electrical Engineering*, 40(1), 16-28.
- Cragar, D. E., Berry, D. T. R., Fakhoury, T. A., Cibula, J. E., Schmitt, F. A., 2002. A review of diagnostic techniques in the differential diagnosis of epileptic and nonepileptic seizures, *Neuropsychology Review*, 12(1), 31-63.

- Cuthill, F. M., Espie, C. A., 2005, Sensitivity and specificity of procedures for the differential diagnosis of epileptic and non-epileptic seizures: A systematic review, *Seizure*, 14(5), 293-303.
- Çakıl, D., İnanır, S., Baykan, H., Aygün, H., Kozan, R., 2013. Epilepsi ayırıcı tanısında psikojenik non-epileptik nöbetler, *Göztepe Tıp Dergisi*, 28(1), 41-47.
- D'Alessio, L., Giagante, B., Oddo, S., Wa, W. S., Solis, P., Consalvo, D., Kochen, S., 2006, Psychiatric disorders in patients with psychogenic non-epileptic seizures with and without comorbid epilepsy, *Seizure*, 15(5), 333-339.
- Ertuğrul, Ö.F., 2016-a, Determining the order of risk factors in diagnosing heart disease by extreme learning machine, *International Conference on Natural Science and Engineering (ICNASE'16)*, 10-19.
- Ertuğrul, Ö. F., 2016-b, forecasting electricity load by a novel recurrent extreme learning machines approach. *International Journal of Electrical Power & Energy Systems*, 78: 429–435.
- Ertuğrul, Ö. F., 2016-c, Aşırı öğrenme makineleri ile biyolojik sinyallerin gizli kaynaklarına ayrıştırılması, *Dicle Üniversitesi Mühendislik Dergisi*, Diyarbakır, 7:41-40.
- Ertuğrul, Ö. F., Altun, Ş., 2017, Developing correlations by extreme learning machine for calculating higher heating values of waste frying oils from their physical properties, *Neural Computing and Applications*, 28-11.
- Ertuğrul, Ö. F., Kaya, Y., 2017, Determining the optimal number of body-worn sensors for human activity recognition, *Soft Computing*, 5053-5060.
- Ertuğrul, Ö. F., Kaya, Y., Tekin, R., 2016-a, A novel approach for SEMG signal classification with adaptive local binary patterns. *Medical & Biological Engineering & Computing*, 54(7): 1137-1146.
- Ertuğrul, Ö.F., Tağluk, M.E., Kaya, Y., 2012, Enerji iletim hatlarında wigner ville dağılımı, Gri Düzey Eş Oluşum Matrisi ve Örüntü Tanıma Yöntemleri ile Arıza Analizi, 20. Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SIU2012), 1-4.
- Ertuğrul, Ö.F., Tağluk, M.E., Kaya, Y., Tekin, R., 2013, EMG sinyallerinin aşırı öğrenme makinesi ile sınıflandırılması, 21. Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SIU2013), 1-4.
- Ertuğrul, Ö. F., and Kaya Y., 2014, A detailed analysis on extreme learning machine and novel approaches based on ELM, *American Journal of Computer Science and Engineering*, 43-50.
- Ertuğrul, Ö. F., Dal, S., Hazar, Y., & Aldemir, E., 2020, Determining relevant features in activity recognition via wearable sensors on the MYO Armband. *ARABIAN JOURNAL FOR SCIENCE AND ENGINEERING*.

- Gonzalez-Velldn, B., Sanei, S., Chambers, J. A., 2003, Support vector machines for seizure detection, *3rd IEEE International Symposium on Signal Processing and Information Technology*, 126-129.
- Gubbi, J., Kusmakar, S., Rao, A. S., Yan, B., O'Brien, T. J., Palaniswami M., 2015, Automatic detection and classification of convulsive psychogenic non-epileptic seizures using a wearable device, *IEEE Journal of Biomedical and Health Informatics*, 582-585.
- Güler, İ., ve Übeyli, E. D., 2004, Dalgacık Dönüşümü ile EEG İşaretlerinden Çıkarılan Öznitelik Vektörleri Üzerinde İstatistiksel İşlemlerin Gerçekleştirilmesi, *Elektrik-Elektronik-Bilgisayar Mühendisliği Sempozyumu ELECO-2004*, 230-234, Bursa.
- Hinich, M.J., and Clay, C.S., 1968, The application of the discrete fourier transform in the estimation of power spectra, coherence and bispectra of geophysical data, *Reviews of Geophysics*, 6(3):347-363.
- Huang G. B., Zhu Q. Y. Siew C. K., 2006, Extreme learning machine, Theory and applications, *Neurocomputing*, 70:489–501.
- Kanas, V. G., Zacharaki E. I., Pippa, E., Tsirka, V., Koutroumanidis, M., Megalooikonomou, V., 2015, Classification of epileptic and non-epileptic events using tensor decomposition, *IEEE 15th International Conference on Bioinformatics and Bioengineering (BIBE)*, 1-5.
- Kaya, Y., Ertuğrul, Ö. F., 2016, A novel approach for spam email detection based on shifted binary patterns, *Security and Communication Networks*, 9(10): 1216–1225.
- Kaya, Y., Ertuğrul, Ö. F., Tekin, R., 2012, Epileptik EEG işaretlerinin sınıflandırılmasında karar kuralları ve karar ağaçlarının kullanılması, *Yaşam Bilimleri Dergisi*, 1(2):403-413.
- Kotsopoulos, I. A. W., de Krom, M. C. T. F. M., Kessels, F. G. H., Lodder, J., Troost, J., Twellaar, M., van Merode, T., Knottnerus, A. J., 2003, The diagnosis of epileptic and non-epileptic seizures, *Epilepsy research*, 57(1), 59-67.
- Kusmakar, S., Gubbi, J., Rao, A. S., Yan, B., O'Brien, T. J., Palaniswami, M., 2015-b, Classification of convulsive psychogenic non-epileptic seizures using histogram of oriented motion of accelerometry signals, *37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 586-589.
- Kusmakar, S., Gubbi, J., Yan, B., O'Brien, T. J., Palaniswami, M., 2015-a, Classification of convulsive psychogenic non-epileptic seizures using muscle transforms obtained from accelerometry signal, *37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 582-585.
- Mormann, F., Lehnertz, K., David, P., Elger, C. E., 2000, Mean phase coherence as a measure for phase synchronization and its application to the EEG of epilepsy patients. *Physica D: Nonlinear Phenomena*, 144(3-4), 358-369.

- Nei, M., 2009, Cardiac Effects of Seizures, *Epilepsy Currents*, 9:(4), 91–95.
- Nikias, C.L., and Petropulu, A.P., 1993, Higher order spectral analysis: A nonlinear signal processing framework, *IEEE transactions on signal processing*, 41(6), 2088-2095.
- Ning, T., and Bronzino, J.D., 1989, Bispectral analysis of the rat EEG during various vigilance states, *IEEE Trans Biomed Eng*, 36(4):497–499.
- Türk, Ö., Özerdem, M. S., 2017, Epileptik EEG Sinyallerinin Sınıflandırılması için Bir Boyutlu Medyan Yerel İkili Örüntü Temelli Öznelik Çıkarımı, *Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji*, 5(3), 97-107.
- Panda, R., Khobragade, P. S., Jambhule, P. D., Jengthe, S. N., Pal, P. R., Gandhi, T. K., 2010, Classification of EEG signal using wavelet transform and support vector machine for epileptic seizure diction. In *2010 International conference on systems in medicine and biology* 405-408.
- Pippa, E., Zacharaki, E. I., Mporas, I., Megalooikonomou, V., Tsirka, V., Richardson, M., Koutroumanidis, M., 2014, Classification of epileptic and non-epileptic EEG events, *IEEE 4th International Conference on Wireless Mobile Communication and Healthcare (Mobihealth)*, 87-90.
- Raghuveer, M.R., and Nikias, C.L., 1985, Bispectrum estimation: A parametric approach, *IEEE Trans. Acoust., Speech, Signal Processing*, 33(4):1113-1230.
- Reuber, M., 2008, Psychogenic nonepileptic seizures: answers and questions, *Epilepsy & Behavior*, 12(4), 622-635.
- Reuber, M., Elger, C. E., 2003, Psychogenic nonepileptic seizures: review and update, *Epilepsy & Behavior*, 4(3), 205-216.
- Phinyomark, A., Limsakul, C., & Phukpattaranont, P., 2009, A novel feature extraction for robust EMG pattern recognition, arXiv preprint arXiv:0912.3973.
- Sezgin, N., 2010, Estimation and classification of sleep apnea in adults by developed preprocessing–neural network models, *PhD thesis, Inonu University, Malatya, Turkey*.
- Sezgin, N., Tağluk, M. E., Ertuğrul, Ö. F., Kaya, Y., 2013, Epileptik EEG işaretlerinin ikiz-spektrum analizi, *21. Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SIU2013)*, 1-4.
- Sezgin, N. (2016). Epileptik EG İşaretlerin Aşırı Öğrenme Makineleri ile Sınıflandırılması. *DÜMF Mühendislik Dergisi*, 7(3), 481-490.
- Srinivasan, V., Eswaran, C., Sriraam, N., 2007, Approximate entropy-based epileptic EEG detection using artificial neural networks. *IEEE Transactions on information Technology in Biomedicine*, 11(3), 288-295.

- Sigl, J.C., and Chamoun, N.G., 1994, An introduction of bispectral analysis for the electroencephalogram, *Journal of Clinical Monitoring*, 10(6):392-404.
- Tagluk M.E., Sezgin N., 2011, A new approach for estimation of obstructive sleep apnea syndromel, *Expert Systems with Applications*, 38(5);5346-5351.
- Tatlı, B., Aydınli, N., Çalışkan, M., Özmen, M., 2004, Non epileptik paroksizmal olaylar: olgu sunumları ile derleme, *Türk Pediatri Arşivi*, 39(2), 58-64.
- Toprak, İ. B., Çağlar, M. F., & Merdan, M., 2007, Ayırık dalgacık dönüşümü ve yapay sinir ağları kullanarak EEG sinyallerinden otomatik epilepsi teşhisi, *IEEE*.
- Turner, K., Piazzini, A., Chiesa, V., Barbieri, V., Vignoli, A., Gardella, E., Tisi, G., Scarone, S., Canevini, M. P., Gambini, O., 2011, Patients with epilepsy and patients with psychogenic non-epileptic seizures: video-EEG, *clinical and neuropsychological evaluation*, *Seizure*, 20(9), 706-710.
- Xu, P., Xiong, X., Xue, Q., Li, P., Zhang, R., Wang, Z., Valdes-Sosa, P. A., Wang, Y., Yao, D., 2014, Differentiating between psychogenic nonepileptic seizures and epilepsy based on common spatial pattern of weighted EEG resting networks, *IEEE Transactions on Biomedical Engineering*, 61(6), 1747-1755.
- Visconti, P., Gaetani, F., Zappatore, G. A., & Primiceri, P., 2018, Technical features and functionalities of Myo armband: An overview on related literature and advanced applications of myoelectric armbands mainly focused on arm prostheses. *International Journal on Smart Sensing and Intelligent Systems*, 11(1), 1-25.
- Yadav, R., Agarwal, R., Swamy, M. N. S., 2009, A new improved model-based seizure detection using statistically optimal null filter, *Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 1318-1322.
- Yıldırım, M., Yıldız, A., 2017, Farklı zaman ölçekli EEG işaretlerinden epilepsi nöbetinin otomatik tespiti, *DÜMF Mühendislik Dergisi*, 8(4), 745-757.
- Zarjam, P., Mesbah, M., Boashash, B., 2003, Detection of Newborn EEG Seizure using Optimal Features Based on Discrete Wavelet Transform. *IEEE*, 265–268.
- Zijlmans, M., Flanagan, D., Gotman, J., 2002, Heart rate changes and ECG abnormalities during epileptic seizures: prevalence and definition of an objective clinical sign. *Epilepsia*, 43(8), 847-854.

EKLER

EK-1 Etik kurul Raporu

DİCLE ÜNİVERSİTESİ TIP FAKÜLTESİ GİRİŞİMSSEL OLMAYAN KLİNİK ARAŞTIRMALAR ETİK KURULU DİCLE UNIVERSITY MEDICAL FACULTY ETHICS COMMITTEE FOR NONINTERVENTIONAL STUDIES					
352					
KARAR					
Yrd. Doç. Dr. Ö. Faruk ERTUĞRUL, Doç. Dr. Eşref AKIL, Doç. Dr. Necmettin SEZGİN, Yrd. Doç. Dr. M. Ata AKIL isimli araştırmacılar tarafından planlanan "Giyilebilir sensörlerle epileptik ve epileptik olmayan nöbetlerin değerlendirilmesi" başlıklı araştırmaya <i>Dicle Üniversitesi Tıp Fakültesi Etik Kurul'u</i> tarafından toplantıda hazır bulunan üyeler tarafından oy birliği ile onay verilmiştir.					
Klinik araştırma tamamlanıp yayın aşamasına geldiğinde, yayına sunulan bildiri veya makalenin bir örneğinin Etik Kurul'a verilmesi zorunludur.					
DECISION					
The project titled as "Assessment of epileptic seizures and nonepileptic seizures via wearable sensors" planned by Ö. Faruk ERTUĞRUL, Eşref AKIL, Necmettin SEZGİN, M. Ata AKIL has been approved by Ethics Committee of Dicle University Faculty of Medicine.					
Oturum No (Meeting number) :		Tarih (Date): 16.12.2016		Saat (Hour): 14:00-15:00	
KURUL BAŞKANI (CHIEF)		Prof. Dr. Hüseyin BÜYÜKBAYRAM			
KURUL ÜYELERİ / MEMBERS					
	ÜNVANI	ADL-SOYADI	KURUMU	BRANŞI	İMZA
1	Prof. Dr.	Hüseyin BÜYÜKBAYRAM	Dicle Üniversitesi Tıp Fakültesi	Patoloji	
2	Prof. Dr.	Levent ERDİNÇ	Dicle Üniversitesi Tıp Fakültesi	Biyokimya	
3	Prof. Dr.	Zeki AKKUŞ	Dicle Üniversitesi Tıp Fakültesi	Biyoistatistik	
4	Doç. Dr.	Aziz KARABULUT	Dicle Üniversitesi Tıp Fakültesi	Kardiyoloji	
5	Doç. Dr.	İlker KELLE	Dicle Üniversitesi Tıp Fakültesi	Tıbbi Farmakoloji	
6	Doç. Dr.	Hakkı KARAMAN	Dicle Üniversitesi Tıp Fakültesi	Anesteziyoloji ve Reanimasyon	
7	Doç. Dr.	Zihfikar YILMAZ	Dicle Üniversitesi Tıp Fakültesi	İç Hastalıkları	
8	Doç. Dr.	Cemil GÖYA	Dicle Üniversitesi Tıp Fakültesi	Radyoloji	
9	Doç. Dr.	Ezeli AZARKAN	Dicle Üniversitesi Halk Sağlığı Fakültesi	Öğretim Görevlisi	
10	Yrd. Doç. Dr.	M. Veyis BAHADIR	Dicle Üniversitesi Tıp Fakültesi	Genel Cerrahi	
11	Yrd. Doç. Dr.	Diclehan ORAL	Dicle Üniversitesi Tıp Fakültesi	Tıbbi Biyoloji	

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Süleyman DAL
Uyruğu : T.C.
Doğum Yeri ve Tarihi : BATMAN / 07.01.1993
Telefon : 0551 438 89 95
Faks : -
e-mail : Suleymanndal@gmail.com

EĞİTİM

Derece	Adı, İlçe, İl	Bitirme Yılı
Lise	: Atatürk Anadolu Lisesi, Merkez, SİİRT	2011
Üniversite	: Çukurova üniversitesi, Merkez, ADANA	2018
Yüksek Lisans:	Batman Üniversitesi, Merkez, BATMAN	2020

İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
2019	SAGTEK Biyomedikal Bilişim Güvenlik Yenilenebilir Enerji Eğitim Pazarlama Sanayi ve Ticaret Limited Şirketi	Elektrik-Elektronik Mühendisi

UZMANLIK ALANI

Makine Öğrenmesi, Sinyal İşleme,

YABANCI DİLLER

İngilizce