


Araştırma Makalesi

EEG SİNYALLERİ İLE EPİLEPSİ KRİZİNİN TAHMİNLENMESİNDE RASSAL ORMAN ALGORİTMASI İLE HİPER PARAMETRE OPTİMİZASYONUN UYGULANMASI

Fatih Murathan YILMAZ[†], Mustafa Cem KASAPBAŞI^{††}

[†] İstanbul Ticaret Üniversitesi, Fen Bilimleri Enstitüsü., İstanbul, Türkiye

^{††} İstanbul Ticaret Üniversitesi, Mühendislik Fakültesi Bilgisayar Mühendisliği Böl., İstanbul, Türkiye
fmurathanyilmaz@gmail.com, mckasapbasi@ticaret.edu.tr

 0000-0001-9746-401X, 0000-0001-6444-6659

Atf/Citation: Yılmaz, F., M., Kasapbaşı, M., C., (2021). EEG Sinyalleri ile Epilepsi Krizinin Tahminlenmesinde Rassal Orman Algoritması ile Hiper Parametre Optimizasyonun Uygulanması. *Journal of Technology and Applied Sciences* 3(2), 189-201.

ÖZET

Dünyadaki 50 milyondan fazla kişiden oluşan tüm nüfusun yaklaşık % 1'i epilepsi ve epileptik nöbetlerden etkilenmektedir (Litt, Echauz 2002) (Kandel ve ark., 2000). Epileptik nöbetler, beynin elektriksel aktivitesindeki bir rahatsızlıktan kaynaklanır. Epilepsi nöbetinin saptanması genellikle elektroensefalografik (EEG) sinyal incelendikten sonra uzman görüşü tarafından gerçekleştirilir. Bu manuel bir süreçtir ve büyük ölçüde doktorun uzmanlığına dayanır. Bu nedenle, doktorların daha az hatayla teşhis koymasına yardımcı olmak için otomatik tanı veya yardım sistemleri gereklidir. Bu çalışmada, epileptik nöbetlerin varlığını sınıflandırmak için iyi bilinen (Andrzejak ve ark. 2001) bir veri kümesi kullanılmıştır. Veri setinin farklı konfigürasyonları literatürde bir kısmı Lojistik Regresyon, Dalgacık yöntemi, Karar Ağacı, Destek Vektör Makinesi, Yoğun Sinir Ağları, vb. birçok veri madenciliği ve makine öğrenme algoritması ile incelenmiştir. İyi tanı beklentisini karşılamak için Rassal Orman kullanılarak sınıflandırma modeli geliştirilmiştir ve sonuçlar aynı veri seti üzerinde incelenen farklı yöntemlerle karşılaştırılmıştır. Çalışılan deneylerin bazı vakalarında %99,78 oranında doğruluk, %99,95 özgüllük ve %99,61 hassasiyet elde edilmiştir ve sonuçlar modelinin başarılı şekilde sınıflandırdığını göstermektedir.

Anahtar Kelimeler: EEG, Hiper Parametre Optimizasyonu, Makine öğrenmesi

IMPLEMENTATION OF HYPER PARAMETER OPTIMIZATION WITH RANDOM FOREST ALGORITHM FOR THE ESTIMATION OF THE EPILEPTIC SEIZURES WITH EEG SIGNALS

ABSTRACT

About %1 of the whole population of the world which constitutes more than 50 million people are affected by epilepsy and epileptic seizures (Litt, Echauz 2002) (Kandel ve ark., 2000). Epileptic seizures are caused by a disturbance in the electrical activity of the brain. Detecting epileptic seizure is generally carried out by the expert opinion after examining the electroencephalographic (EEG) signal. This is a manual process and heavily relies on the expertise of the physician. Therefore automated diagnosis or aiding systems are required to assist physicians to diagnose with fewer errors. In this study, a well known (Andrzejak et al. 2001) dataset is used for classifying the existence of epileptic seizures. Different configurations of the data set have been studied with many data mining and machine learning algorithms in the literature, some of which are Logistic Regression, Wavelet Method, Decision Tree, Support Vector Machine, Dense Neural networks, etc.. In this study, a classification model was developed by using Random Forest to meet the good diagnosis expectation, and results were compared with different methods studied on the same data set. In some cases of the studied experiments above 99,78 percent of accuracy, 99,95% specificity, and 99,61% sensitivity are obtained, indicating a good sign of classification model.

Keywords: EEG, Hyper Parameter Optimization, Machine Learning.

Geliş/Received : 21.05.2020

Gözden Geçirme/Revised : 23.05.2020

Kabul/Accepted : 13.06.2020

1. GİRİŞ

Epilepsi, dünya genelinde yaklaşık 50 milyon insanın sahip olduğu nörolojik bir hastalıktır (Kandel ve ark., 2000). Epilepsinin en yaygın özelliği hastaların geçirdiği krizlerdir. Bu krizlerin kaynağı beyinde bulunan nöron gruplarının yapıları kontrolsüz elektrik boşaltımıdır (Acharya ve ark.,2018). Krizlere sebep olan bu elektrik boşalımının makineler yardımı ile gözlemlenmesi konusu 1970'li yıllarda başlamıştır (Viglione ve Walsh,1975). Fakat bu konu hakkında algoritmaların gelişmesi ve konunun fiziksel olarak çözümlenebilir bir probleme dönüşmesi yaklaşık olarak 30 sene sürmüştür (Litt ve Echauz,2002). Elektroensefalogram (EEG) teknolojisi beyin tarafından üretilen elektriksel potansiyeli kayıt etmeye yarar. EEG, beyindeki elektriksel anomalileri kaydetmek için yaygın olarak kullanılır. Nörolojik hastalıkların tanısında klinik olarak kullanılan en önemli cihazlardan biridir (Kannathal ve ark. 2005).

Epilepsi krizlerinin belirlenmesi için kullanılan EEG sinyalleri uzman kişilerin bu sinyallerin grafiklerinin gözle incelenmesi ve tecrübe ile karar verilmesi sürecine dayanmakta olup, uzman kişinin bilgi ve tecrübesi doğru kararlar verilmesinde önemli faktör olmaktadır. Bu sebeple alan uzmanlarına tahminleme sürecinde destek olabilecek sistemlere ihtiyaç duyulmakta, uzman hekimlere ulaşmayan hastalar için otonom karar verebilen gömülü sistemler için algoritmaların da geliştirilmesine ihtiyaç olduğu düşünülmektedir. Bu çalışmada bu ihtiyacı karşılamak için Rassal Orman kullanılarak bir sınıflandırma modeli geliştirilmiş, ve aynı veri seti üzerinde çalışılan farklı yöntemlerle kıyaslanması gerçekleştirilmiştir.

2. KISA LİTERATÜR ARAŞTIRMASI

Otomatik kriz tanısı konusunda 1995 yılında EEG sinyallerinden belirli özelliklerin dalgacık dönüşümü yardımıyla çıkartımı yapılmış ve elde edilen dönüştürülmüş veri yapay sinir ağları (ANN) yardımıyla sınıflandırılmış ve kayda değer sonuçlar elde edilmiştir (Kalayci ve Ozdamar,1995). Nigam ve Graupe (2004), çok katmanlı eğrisel ön işleme filtresi kullanarak iki özellik çıkartımı olarak pik değerleri genliği ve pik frekansı çıkartımını yapmıştır ve bu çıkartımı yapay sinir ağlarında işlemişlerdir. Jahankhani ve arkadaşları (2006) EEG sinyallerini dalgacık dönüşümü kullanarak farklı alt bantlara ayırtmış ve buradan dalgacık katsayıları elde etmiş, elde ettiği veriyi radyal temelli fonksiyon (RBF) ve çok katmanlı sınıflayıcı (MLP) kullanarak sınıflandırmıştır. Subasi (2005, 2006, 2007) EEG sinyallerini ayırık dalgacık dönüşümü (DWT) kullanarak zaman-frekans domeninde ayırtmıştır. Tzallas ve arkadaşları (2007) zaman-frekans analizi metodunu kullanarak EEG sinyallerinden özellik çıkarımını yapmışlar ve elde ettikleri özellikleri yapay sinir ağı yardımıyla sınıflandıracak modeli oluşturmuşlardır. Srinivasan ve arkadaşları (2007) yaklaşık entropi (ApEn) temelli yinelenen sinir ağlarının bir türü olan Elman sinir ağı modeli ile sınıflandırma yapan modeli kurgulamışlardır. Guo ve arkadaşları (2009) EEG sinyallerinde bulunan farklı frekans bantlarıyla ilişkili bağıl enerjiden, göreceli dalgacık enerjisi yöntemi ile özellik çıkartımı yaparak elde ettikleri özellikleri yapay sinir ağları yardımıyla sınıflandırma yapmak için kullanmışlardır. Subasi ve Gursoy (2010) temel bileşenler analizi, bağımsız bileşenler analizi ve doğrusal diskriminant analizi yöntemlerini kullanarak sınıflandırma yapmışlardır. Fernandez-Blanco ve arkadaşları (2012) zaman-frekans analizi yöntemini daha önce çalışılmış metotlardan farklı olarak yıldız graf topoloji indisleri ile ele almışlardır. Song ve Zhang (2013) permütasyon entropi, örnek entropi ve Hurst üssünü kullanarak farklı frekans bantlarından özellik çıkartımı yapmışlar ve genetik algoritma ile yaptıkları sınıflandırma yöntemiyle birlikte kullanmışlardır. Kaya ve arkadaşları (2014) tek boyutlu yerel ikili örüntü kullanarak EEG sinyallerinden özellik çıkartımı yaparak elde ettikleri özellikleri bayes ağı ile sınıflandırma yapmak için kullanmışlardır. Fu ve arkadaşları (2014) zaman-frekans analizi kapsamında Hilbert-Huang dönüşümüyle EEG sinyallerinden kalıplar elde etmişler ve bu yolla özellik çıkarımı yapmışlardır. Chen (2014) ikili ağaç karmaşık dalgacık dönüşümü metodu ile sınıflandırma yapmıştır. Zamir (2016) örnek tabanlı öğrenme algoritmaları ve C4.5 algoritması ile sınıflandırma yapmıştır. Hassan ve arkadaşları (2016) ayarlanabilir Q katsayılı dalgacık dönüşümü ile özellik çıkarımını yaparak elde ettikleri özellikleri torbalama yöntemi ile sınıflandırmada kullanmışlardır. Hussein ve arkadaşları (2018) EEG sinyalleri ile sınıflandırma yapmak için derin öğrenme yöntemini tercih etmişlerdir. Yavuz ve arkadaşları (2018) EEG sinyallerinden logaritmik spektrumun ters fourier dönüşümüne dayalı septrum analizi ile özellik çıkarımı yapmış ve elde ettikleri özellikleri yapay sinir ağ modellerinden genelleştirilmiş regresyon sinir ağında kullanmışlardır.

3. MATERİYAL VE METOD

3.1. Veri Seti

Bu çalışmanın konusu olan EEG veri seti, Bonn Üniversitesinde hazırlanmıştır (Andrzejak ve ark., 2001). Bu veri seti 5 farklı dizine ayrılmış ve her bir dizinde 100 adet kayıt bulunmaktadır. Z ve O olarak etiketlenmiş dizinlerde sağlıklı ve uyanık halde bulunan deneklerden elde edilen kayıtlar mevcuttur. Z dizinindeki kayıtlarda deneğin gözleri açık konumunda iken O dizinindeki kayıtlarda deneğin gözleri kapalı konumdadır. N, F ve S

olarak etiketlenen dizinlerdeki kayıtlar epilepsi hastalarından elde edilmiştir. N ve F dizinleri bu epilepsi hastası deneklerin kriz geçirmediği anlardaki kayıtlardan oluşmaktadır. N dizininin kayıtları beyin epilepsi krizlerine sebep olan elektriksel aktivitenin görülmediği bölgeden diğer bir deyiş ile epileptik olmayan bölgeden alınmıştır. F dizininde ise epileptik bölgeden elde edilmiş kayıtlar bulunmaktadır. S dizininde sadece epilepsi kriz esnasında elde edilen kayıtlar bulunmaktadır. Dizinlerdeki bütün kayıtlar 23.6 saniye boyunca 173.61 Hz örnekleme frekansı ile kaydedilen tek kanallı EEG sinyallerinden oluşmaktadır. Veriler zaman serilerine karşılık olarak 4097 veri noktasında örneklenebilir. Rochester Teknoloji Enstitüsü 4097 veri noktasını 23 adet yığına ayırmıştır. Yığınların her biri, 1 saniye için 178 veri noktasını veri noktasını göstermektedir (UCI Rep. 2020). Bu sayede makine öğrenmesi uygulamalarının eğitimi için mevcut veri sayısı 22 kat artırılmış olmaktadır. Son haliyle her bir dizin 2300 adet kayıt içermektedir ve toplam veri sayısı 11500 adete çıkmıştır.

3.2. Rassal Orman Algoritması

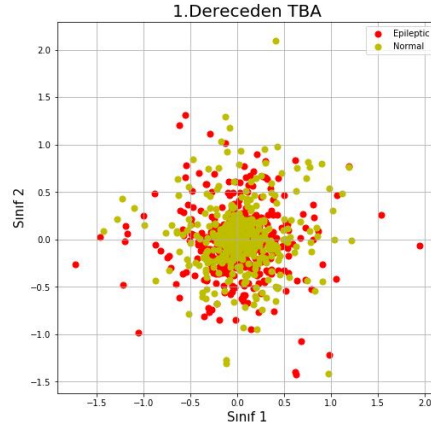
Morgan ve Sonquist (1963) ağaç temelli yaklaşımı ortaya çıkarmışlardır. Breiman ve ark. (1984) ağaç temelli yaklaşımı, kapsamını genişletip tahminleme mekanizmasını güçlendirerek sınıflandırma ve regresyon ağaçlarını (CART) geliştirmişlerdir. Sınıflandırma ve regresyon problemlerinde kullanılan karar ağacı yaklaşımını geliştiren Breiman (1996) torbalama adını verdiği yöntem ile birden fazla ağacın birlikte daha isabetli kararlar verebileceğini ispatlamıştır. Torbalama yöntemi, veri setinden rastgele olarak seçilen sınıflandırıcılardan bir ağaç kümesi kurgulamak üzerine kuruludur. Ho (1998) rassal alt uzaylar metodu ile rastgele seçilmiş alt veri kümeleri ile her bir ağacı dahil olduğu uzayın özellikleri ile geliştirmiştir. Rassal alt uzay metodu, torbalama yönteminden farklı olarak her bir ağaç için farklı sayıda sınıflandırıcı özelliği ağaçları yaratırken kullanır.

Breiman (2001) Rassal Orman algoritmasını tanımladığı çalışmasında, standart ağaç düğümü için en iyi bölünme belirlenirken tüm veri seti içerisindeki en iyi tahminleyici seçilmesi kuralını rassallık kuramıyla uyarlayarak her bir ağaç düğümü için en iyi bölünme ön yüklenme için hazırlanmış alt veri setinin içinden seçilecek rastgele bir özellik olması olarak geliştirmiştir. Çok sayıda ağacın oluşmasının ardından orman sınıflamaya uygun hale gelmiştir ve tekil olarak her biri kendi kurallarına uygun olan sınıfa oy verir. Rassal Orman algoritması sınıflandırma problemlerinde çoğunluğun haklılığı prensibine göre sınıflandırma yapar. Yani en çok oyu alan sınıf Rassal Ormanın tahminini işaret etmektedir. Regresyon problemlerinde ise Rassal Ormanın tahmini ormanda bulunan bütün ağaçların ortalaması alınarak bulunur. Olasılık kuramının büyük sayılar teoremine göre aynı deney defalarca tekrarlandığında elde edilen sonuç beklenen değere yakınsar (Dekking,2005). Bu teoremden yola çıkarak Rassal Orman algoritması için büyük sayılar asla aşırı öğrenmiş olmaz yorumu yapılabilmektedir. Rassal Orman algoritmasının temel diğer özelliklerinden biri de bir karar ağacı koleksiyonu olmasına rağmen tekil olarak hiç bir ağaç budanmaz. Tamamen rastgele seçilen sınıflandırıcı özelliklerden ve alt veri kümelerinden kurulan bu tümleşik ağaç sistemi diğer algoritmalarda ihtiyaç duyulduğu gibi özellik çıkarımına da ihtiyaç duymamaktadır. Bu algoritmanın hiper parametre optimizasyonu yapılabilecek noktaları karar ağaçlarının sayısı, ağaçların dallarının minimum ve maksimumları, düğümlerdeki bölünmeleri belirleyecek ayırma kriteri, kullanılacak sınıflandırıcı özellik adedinin maksimum ve minimumları ve eğer entropi temelli bir ağaç yapısı kurgulanacak ise bölünme ve dalların oluşmasında kullanılacak saflık değer sabitleri olarak ele alınabilir.

3.3. Hiper Parametre Optimizasyonu ve Temel Bileşenler Analizi

Hiper parametre optimizasyonu, makine öğrenmesi problemlerinde yaygın olarak kullanılan popüler araştırma konularından biridir (Bergstra ve ark.,2011). Temelde tahmin ve sınıflandırmaların daha isabetli, daha hassas veya özellik seçimlerinin daha başarılı yapılabilmesi için algoritmalara ait parametrelerin probleme uygun hale getirilmesini esas almaktadır. Hiper parametre optimizasyonunu ile başarılı sonuçlar elde etmek için öncelikle probleme en uygun algoritmanın seçilmesi önemli bir yer tutar (Bergstra ve Bengio,2011). Daha önce bu konuda yapılmış çalışmalardan da görülebileceği üzere Rassal Orman gibi algoritmalarda ağaç sayısı tahminleyici başarısını büyük ölçüde etkilemektedir (Tantithamthavorn ve ark.,2016). Jiang ve arkadaşları (2008) ile Tosun ve Bener (2009), yaptıkları çalışmalarda Rassal Orman algoritmasının varsayılan değerler ile uygulandığında sonuçların ideal seviyenin altında kaldıklarını görmüşlerdir. Tüm bunlardan çıkarımla bu çalışmada grid arama algoritması uygulanmıştır. Grid arama algoritması temelde hiper parametre uzayından elde edilen alt kümelerde iteratif olarak çalışan kapsamlı bir arama algoritmasıdır (Syarif ve ark.,2016). Grid aramada metot parametreler için başlangıç ve bitiş değerlerinin verilmesi ve başlangıç bitiş değeri arası kaç adımda tamamlanacak tanımlanması gereklidir. Üç farklı ölçek kullanılabilir. Bunlar lineer ölçek, kareli ölçek ve logaritmik ölçektir. Bu çalışmada ağaç sayısı ve sınıflandırıcı özellikler için grid arama ile hiper parametre optimizasyonu lineer ölçek ile uygulanmıştır. Ağaç sayısı 100 adetten başlamak üzere 8000 adete ağaca kadar ve sınıflandırıcı özellik sayısı 1 den başlamak üzere 178 adete kadar iteratif olarak denenmiştir. Sonuç olarak en ideal hiper parametrelerin 2000 ağaç ve 15 adet özellik olduğu görülmüştür.

Hiper parametre optimizasyonu tamamlandıktan sonra veri seti Temel Bileşenler Analizi (TBA) algoritması ile görselleştirilmiştir. Epileptik ve normal olarak iki sınıfa ayırmaya çalıştığımız veri seti 2 boyutlu düzlemde dağılımları gözlenmiş ve açıklanabilir varyans oranı hesaplanmıştır. Şekil 1’de verilerin herhangi bir işleme tabi tutulmadan saf halleri görülmektedir.

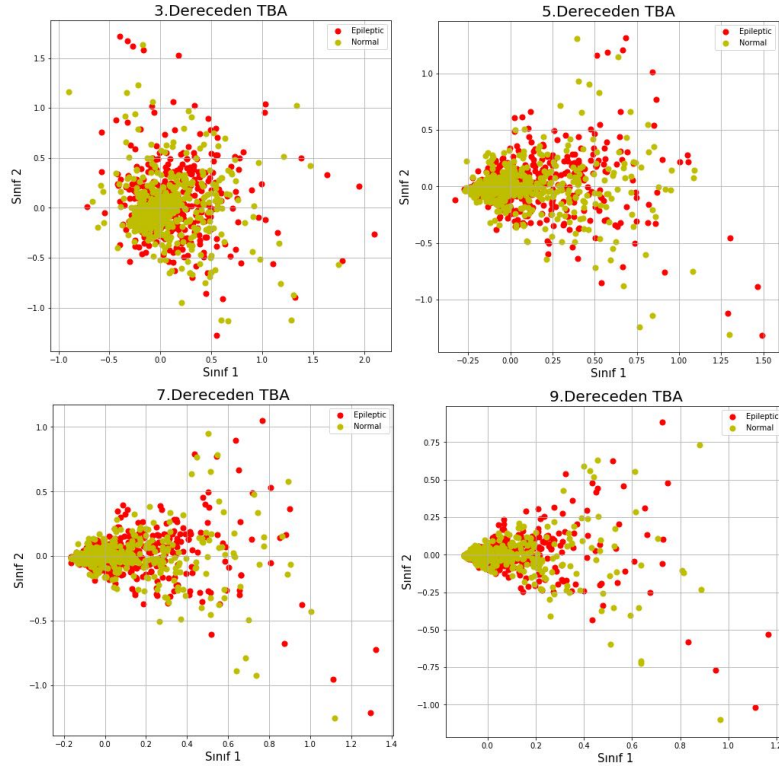


Şekil 1. Temel Bileşen Analizi ile 2 boyutlu uzayda veri dağılımının gösterimi.

Şekilde görüldüğü üzere sınıflamaya çalıştığımız bu verinin sınıf merkezleri birbirlerine çok yakın bir durumdadır. 2 boyutlu uzayda sınıflamaya çalıştığımız bu veri seti bir çok veri noktası için üst üste gözükmetedir. Burada sınıflama başarımını artırmak için veri üzerindeki sınıflandırıcı özelliklerin standart normalizasyon uygulandıktan sonra kuvvetlerini alarak veriyi bu şekilde manipüle etme yolu tercih edildi. Sınıflandırıcı özelliklerin kuvvetlerin alınmasındaki temel amaç, varyans farkını yani toplam varyans kazancını artırabilmektir. Her bir kuvvet uygulama iterasyonundan sonra sınıfların kendi bazında varyans kazançları kaydedilmiştir ve bu varyans kazançlarının farkının mutlak değeri alınarak toplam varyans kazancı elde edilmiştir. Sınıf özelliklerinin varyans değerleri, sınıfların varyans kazançları ve toplam kazanç değerleri Tablo 1’de görülebileceği şekilde kayıt edildi. Kuvvetler uygulandıktan sonra Şekil 2’de gibi dağılımlar oluşmuştur.

Tablo 1. Kuvvet uygulamaları sonrası sınıfların varyans değerleri.

TBA Uygulanan Kuvvet	Normal	Epileptik	Normal Kazanç	Epileptik Kazanç	Toplam Kazanç
1	0.06245396	0.0582515			
3	0.07090286	0.0636541	+0.00844	+0.00540	0.00304
5	0.10917716	0.0594337	+0.03827	-0.00422	0.04249
7	0.12033857	0.0537303	+0.01116	-0.00570	0.01686
9	0.11001304	0.0493376	-0.01032	-0.00439	0.00593



Şekil 2. Sınıflandırıcıların kuvvetleri alındıktan sonra veri dağılım grafikleri

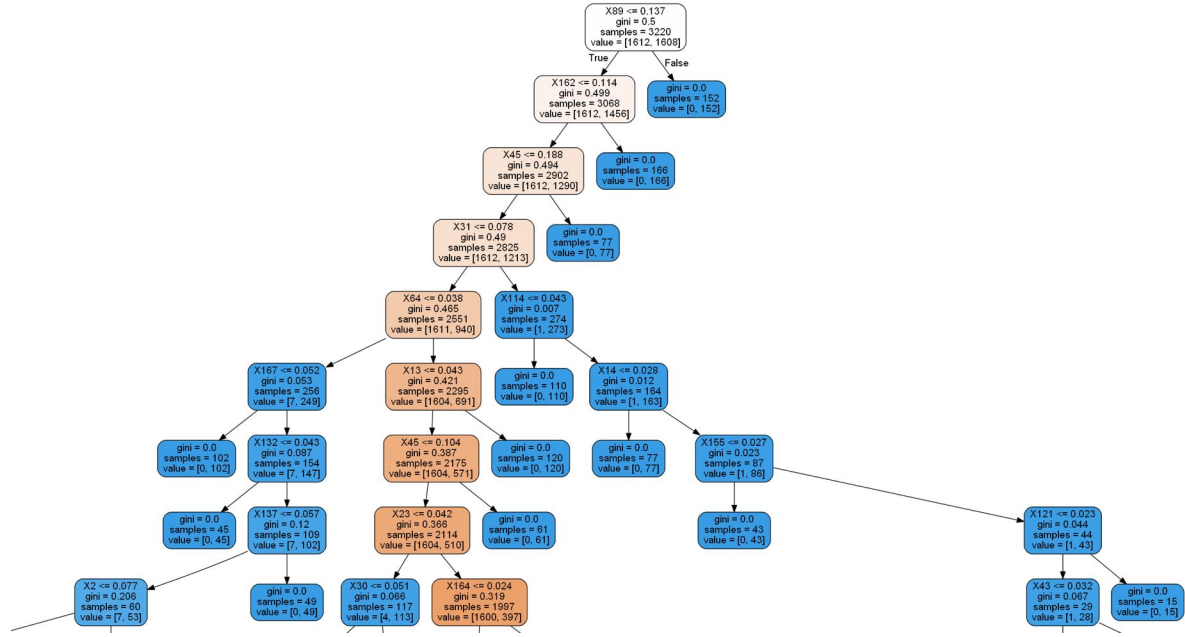
Tablodan görüleceği üzere sınıflandırıcı özelliklerin beşinci dereceden kuvveti alındığında normal sınıfının varyansı kayda değer bir biçimde artmış ve epileptik sınıfının varyansı yeterli seviyede azalmıştır ve tüm bunların sonucu olarak toplam varyans kazancı maksimum olarak hesaplanmıştır. Bu varyans kazancı, verilerin birbirinden kayda değer ölçülerde ayrılabilirdiğini ve sınıflandırma başarımının artacağını göstermektedir.

3.4. Makine Öğrenmesi Tekniğinin Uygulanması

Sınıflandırma uygulaması Python 3.6 versiyonu üzerinde gerçekleştirilmiştir. Pandas ve scikit-learn kütüphaneleri bu çalışmanın bağımlı olduğu ana kütüphanelerdir. Pandas (Pd) kütüphanesi veri setimizin veri çerçevesine dönüştürülmesi, kullanılmayacak verilerin elimine edilmesi işlerinde kullanılmıştır. Scikit-learn (Sklearn) kütüphanesi verinin normalize edilmesinde, algoritmanın yüklenmesinde, çapraz doğrulamanın gerçekleştirilmesinde, eğitim sonucunda oluşan modelin test verileriyle test edilmesinde ve tüm bu deney sonuçlarının karmaşıklık matrisi ve doğruluk raporlarının hesaplamasında kullanılmıştır. Uygulamanın işleyiş sırası aşağıda verilmiştir.

- 1- Veri bulunduğu dosya konumundan Pd *read_csv* fonksiyonu ile okunmuştur.
- 2- Veri setinde bulunan normal ve epileptik sınıfları dışında kalan sınıflar, Pd *map* fonksiyonu yardımıyla aynı sınıf etiketiyle işaretlenmişlerdir. Bu etiketlenen veri grubu Pd *drop* fonksiyonu ile veri setinden elimine edilmiştir.
- 3- Sınıflandırıcı özellikler ve sınıf etiketi ayrı birer veri çerçevesine atanmışlardır.
- 4- Sklearn altında bulunan *MinMaxScaler* sınıfıyla veri çerçevesi normalize edilmiştir.
- 5- Normalleştirilmiş veri beş kez kendi ile çarpılarak beşinci kuvveti alınmış ve yeni sınıflandırıcı özellikler olarak atanmıştır.
- 6- Sklearn *train_test_split* fonksiyonu yardımıyla tüm datanın %30'u test için ayrılmış, geri kalanı eğitim seti olarak atanmıştır.
- 7- Sklearn altında bulunan algoritmanın kurucu fonksiyonuna hiper parametre ayarları olan ağaç sayısı 2000 ve maksimum sınıflandırıcı özellik 15 olarak verilerek algoritma çağırımı yapılmıştır.
- 8- Algoritma eğitim seti ile eğitilmiş ve 5 iterasyon çapraz doğrulama uygulanmıştır.
- 9- Karmaşıklık matrisi, doğruluk, hassaslık ve özgüllük değerleri hesaplanmıştır.

Uygulamanın eğitim sonrasındaki adımlarında eğitilen modeldeki ağaçlardan rastgele seçim yaparak modelin oluşmasındaki aşamalar kontrol edilmiştir. Şekil 3'te oluşan ağaçlardan birinin örnek kesiti verilmiştir.



Şekil 3. Oluşan ağaçlardan alınan örnek kesit

4. DEĞERLENDİRME VE TARTIŞMA

Çalışmanın çıktıları bu bölümde iki farklı şekilde ele alınacaktır. İlk kısımda algoritma üzerinde hiper parametre optimizasyonu yapılmadığı ve verinin kuvvetinin değiştirilmediği senaryolar ile bütün hepsinin uygulandığı ideal senaryo karşılaştırılacaktır. İkinci olarak bu çalışmadan önce bu veri seti ile çalışmış araştırmacıların derlenen sonuçları ile karşılaştırma yapılacaktır. Başarım ölçüğümüz Denklem (1)de verilen formüle göre işletilecek doğruluk, Denklem (2) ile verilen hassasiyet ve Denklem (3) ile verilen özgüllük değerleri üzerinden karşılaştırılacaktır.

$$\text{Doğruluk} = \frac{\text{Doğru Pozitif} + \text{Doğru Negatif}}{\text{Tüm Durumlar Toplamı}} \quad (1)$$

$$\text{Hassasiyet} = \frac{\text{Doğru Pozitif}}{\text{Doğru Pozitif} + \text{Yanlış Negatif}} \quad (2)$$

$$\text{Özgüllük} = \frac{\text{Doğru Negatif}}{\text{Doğru Negatif} + \text{Yanlış Pozitif}} \quad (3)$$

Tablo 2’de ideal senaryo için 5 kat çapraz doğrulama sonuçları verilmektedir. Tablo 3’te ideal senaryoya ait karmaşıklık matrisi verilmektedir. Tablo 4’de ideal senaryo ile diğer durumların karşılaştırılması verilmiştir.

Tablo 2. İdeal senaryoya ait 5 katlı çapraz doğrulama sonuçları

Çapraz Doğrulama 1	Çapraz Doğrulama 2	Çapraz Doğrulama 3	Çapraz Doğrulama 4	Çapraz Doğrulama 5	Ortalama Doğruluk	Standart Sapma (+/- 0.0011)
99.78	99.67	100	99.67	99.78	99.78	

Tablo 3. İdeal senaryo çapraz doğrulamalar sonucu oluşan kümülatif karmaşıklık matrisi

	Normal	Epileptik	Toplam
Normal	2299	1	2300
Epileptik	9	2291	2300

Tablo 4. İdeal senaryonun diğer olası senaryolar ile başarımların karşılaştırılması

Senaryo	Doğruluk	Hassasiyet	Özgüllük
Varsayılan Parametreler	99.08	98.57	98.90
Hiper Parametreler	99.71	99.48	99.95
Varsayılan Parametreler ve Kuvvet uygulaması	98.97	98.62	99.43
İdeal Senaryo	99.78	99.61	99.95

Tablolardan da görülebileceği üzere varsayılan parametreler ile ideal senaryo arasında kayda değer bir farklılık söz konusudur. Hiper parametre optimizasyonu ve ideal senaryo arasındaki farklılık, varsayılan değer ile olan kadar önemli gözükmemektedir fakat parametre optimizasyonundan sonra doğruluk oranını artırdığı için varyans analizinden yaptığımız çıkarımda başarımda katkısının olduğu açıkça görülebilmektedir.

Tartışma bölümünün bundan sonraki safhasında çalışmamızın aynı veri seti üzerinde yapılmış önceki çalışmalar ile karşılaştırılması ele alınacaktır. Tablo 5'te derlenen öncü çalışmaların bu çalışma ile karşılaştırılması verilmektedir. Bu çalışma, diğer araştırmacıların Z ve S olarak etiketlediği iki sınıflı veri seti üzerinde yapılmış olan çalışmalar ile kıyaslanmıştır. Beyindeki doğrusal olmayan elektrik dalgalarının gözlenmesi üzerine oluşturulan bu veri setine dair normal ve epileptik olarak sınıflandırma çalışmalarının ilk örneğinin yapıldığı 2004 yılından günümüze kadar bir çok farklı yöntem ile sınıflandırmalar gerçekleştirilmiştir. Bu tablo detaylı olarak incelenirse görülecektir ki yapay sinir ağları ve türevlerini oluşturan sınıflandırma yöntemleri ağırlıklı olarak kullanılmıştır. Ve yine tüm çalışmalar incelendiğinde en yaygın tercih edilen ön işleme modeli ayrık dalgacık dönüşümü ve bunu takip eden dalgacık dönüşüm modellerinin türevlerinden oluşmaktadır. Veri setinde kategorik bir veri olmaması bu veri seti için yapay sinir ağı modelinin başarılı olması için ön görülebilir. Bu veri seti ile çalışan araştırmacılar bu yöntem ile gayet yeterli ve başarılı sonuçlar elde etmişlerdir. Yapay sinir ağı modelinin dışında en çok tercih edilen diğer algoritmalar destek vektör makineleri ve k-NN algoritmalarıdır. Dalgacık dönüşümleri ve radyal temelli fonksiyonlar çerçevesinde bu algoritmalarda da gayet yeterli ve başarılı sayılabilecek sonuçlar elde edilmiştir. Hassan ve arkadaşları (2016), bu çalışmada konusu olan bir grup sınıflandırıcının bir araya getirilerek sınıflandırma yapılması yaklaşımını başarılı bir şekilde gerçekleştirmişlerdir. Bu çalışma ile EEG sinyallerinin parçalara ayrılarak çoğaltılmış halinden %99.78 gibi oldukça başarılı, aşırı öğrenme sorunuyla asla karşı karşıya gelmeyecek ve paralel olarak çalışabilen bir yöntemin başarımlarını deneysel olarak ispatlamış oluyoruz.

Tablo 5. Aynı veri setinin kullanıldığı önceki çalışmalar ve yaptığımız çalışmanın karşılaştırılması

Yazar(lar)	Çalışma Başlığı	Metot	Doğruluk (%)
Nigam ve Graupe (2004)	A neural-network-based detection of epilepsy	Doğrusal olmayan ön işleme filtresi ile yapay sinir ağı	97.2
Srinivasan ve ark. (2005)	Artificial neural network based epileptic detection using time-domain and frequency-domain features	Zaman ve frekans alan özellikli yinelenen sinir ağı	99.6
Kannathal ve ark. (2005)	Entropies for detection of epilepsy in EEG	Entropi ölçümlü adaptif neuro-fuzzy çıkarım sistemi	92.22
Sadati ve ark. (2006)	Epileptic seizure detection using neural fuzzy networks	Ayrık dalgacık dönüşümlü adaptif neuro-fuzzy ağı	85.9
Polat and Güneş (2007)	Classification of epileptiform EEG using a hybrid system based on decision tree classifier and fast Fourier transform	Hızlı Fourier dönüşümü ve karar ağaçları	98.72
Subasi (2007)	EEG signal classification using wavelet feature extraction and amixture of expert model	Ayrık dalgacık dönüşümlü uzman model karışımı	95
Tzallas ve ark. (2007)	Automatic seizure detection based on time-frequency analysis and artificial neural networks	Zaman-frekans analizi ve yapay sinir ağı	100
Srinivasan ve ark. (2007)	Approximate entropy-based epileptic EEG detection using artificial neural networks	Yaklaşık entropi-Elman ağı (yinelenen sinir ağı)	100
Guo ve ark. (2009)	Classification of EEG signals using relative wavelet energy and artificial neural networks	Ayrık dalgacık dönüşümlü göreceli dalgacık enerjisi ve yapay sinir ağı	95.2
Ocak (2009)	Automatic detection of epileptic seizures in EEG using discrete wavelet transform and approximate entropy	Ayrık dalgacık dönüşümü ve yaklaşık entropi ile yapay sinir ağı	96
Guo ve ark. (2010)	Epileptic seizure detection using multiwavelet transform based approximate	Çoklu dalgacık dönüşümü entropi yaklaşımı ve çok katmanlı yapay	100

	entropy and artificial neural networks	sinir ağı	
Subasi ve Gursoy (2010)	EEG Signal classification using PCA, ICA, LDA and support vector machine	Temel bileşenler analizi (TBA), bağımsız bileşenler analizi (BBA) ve doğrusal diskriminant analizi (DDA) ile destek vektör makinesi	98.75 (TBA), 99.5 (BBA), 100 (DDA)
Kumar ve ark. (2012)	Epileptic seizures detection in EEG using DWT-based ApEn and artificial neural network	Ayrık dalgacık dönüşümü, yaklaşık entropi ile yapay sinir ağları	100
Fernandez-Blanco ve ark. (2012)	Automatic seizure detection based on star graph topological indices	Genelleştirilmiş diskriminant analizi	99
Dehuri ve ark. (2013)	Epileptic seizure identification from electroencephalography signal using DE-RBFNs ensemble	Radyal temelli fonksiyon ile yapay sinir ağları	100
Xie ve Krishnan (2013)	Wavelet-based sparse functional linear model with applications to EEGs seizure detection and epilepsy diagnosis	Dalgacık temelli ayrık doğrusal model ile k-NN	100
Song ve Zhang (2013)	Automatic recognition of epileptic EEG patterns via Extreme Learning Machine and multiresolution feature extraction	Aşırı Öğrenme Makineleri	94.20
Lee ve ark. (2014)	Classification of normal and epileptic seizure EEG signals using wavelet transform, phase-space reconstruction, and Euclidean distance	Dalgacık dönüşümü ile ağırlıklı fuzzy üyelik fonksiyon	98.17
Kaya ve ark. (2014)	1D-local binary pattern based feature extraction for classification of epileptic EEG signals	Tek boyutlu ikili desen temelli özellik çıkartımı ve bayes ağı	99.50
Zhu ve ark. (2014)	Epileptic seizure detection in EEGs signals using a fast weighted horizontal visibility algorithm	Hızlı ağırlıklı yatay görünür algoritma ve k-NN	100
Kumar ve ark. (2014)	Epileptic seizure detection using DWT based fuzzy approximate entropy and support vector machine	Ayrık dalgacık dönüşümü temelli fuzzy entropi yaklaşımı ile destek vektör makineleri	100
Fu ve ark. (2014)	Classification of seizure based on the time-frequency image of EEG signals using HHT and SVM	Hilbert-Hung dönüşümü temelli zaman-frekans kalıbı ile destek vektör makineleri	99.12
Chen (2014)	Automatic EEG seizure detection using dual-tree complex wavelet-Fourier features	Çift ağaç karmaşık dalgacık fourier özellikleri ile k-NN	100
Dhiman ve ark. (2014)	Genetic algorithms tuned expert model for detection of epileptic seizures from EEG signatures	Dalgacık paketi ve genetik algoritma ile destek vektör makineleri	100
Yuan ve ark. (2014)	Epileptic EEG classification based on kernel sparse representation	Radyal Temelli Fonksiyon ile destek vektör makineleri	98.63
Zhu ve ark. (2014)	Epileptic seizure detection in EEGs signals using a fast weighted horizontal visibility algorithm	Hızlı fourier dönüşümü ile k-NN	99
Kang ve ark. (2015)	An efficient detection of epileptic seizure by differentiation and spectral analysis of electroencephalograms	İkinci dereceden diskriminant analizi ve çok katmanlı yapay sinir ağı	99.78
Tawfik ve ark. (2015)	A hybrid automated detection of epileptic seizures in EEG records	Dalgacık dönüşümü ve ağırlıklı permütasyon entropi algoritması ile destek vektör makineleri ve yapay sinir ağları	99.5
Peker ve ark. (2016)	A novel method for automated diagnosis of epilepsy using complex-valued classifiers	Sürekli dalgacık dönüşümü ve evrimsel sinir ağları	99.5
Zamir (2016)	Detection of epileptic seizure in EEG signals using linear least squares preprocessing	Lojistik, LazyIB1, LazyIB5 ve J48 algoritmaları	100
Hassan ve ark. (2016)	Epileptic seizure detection in EEG signals using tunable-Q factor wavelet transform and bootstrap aggregating	Ayarlanabilir Q faktör dalgacık dönüşümü ile torbalama yöntemi	100
Bhardwaj ve ark. (2016)	A novel genetic programming approach for epileptic seizure detection	Ampirik mod ayrıştırması ile Kartezyen genetik programlama algoritmaları	98.64
Zhang ve Chen (2016)	LMD based features for the automatic seizure detection of EEG signals using SVM	Yerel ortalamalar ayrıştırması ile genetik algoritma ve destek vektör makineleri	100
Swami ve ark. (2016)	A novel robust diagnostic model to detect seizures in electroencephalography	Sürekli dalgacık dönüşümü ile genelleştirilmiş regresyon sinir ağı	100
Martinez-del-Rincon ve ark. (2017)	Non-linear classifiers applied to EEG analysis for epilepsy seizure detection	Ayrık dalgacık dönüşümü ve radyal temelli fonksiyon ile destek vektör makineleri	99.85
Chen ve ark. (2017)	Automatic epileptic seizure detection in	Ayrık dalgacık dönüşümü ile yapay	100 (YSA),

	EEG using non subsampled wavelet-Fourier features	sinir ağıları ve destek vektör makineleri	78 (DVM)
Bhattacharyya ve ark. (2017)	Tunable-Q wavelet transform based multiscale entropy measure for automated classification of epileptic EEG signals	Ayarlanabilir Q faktör dalgacık dönüşümü ile destek vektör makineleri	100
Sharma ve ark. (2017)	A new approach to characterize epileptic seizures using analytic time-frequency flexible wavelet transform and fractal dimension	Analitik zaman frekanslı esnek dalgacık dönüşümü ve destek vektör makineleri	100
Zhou ve ark. (2018)	Epileptic seizure detection based on EEG signals and CNN	Evrimsel sinir ağı	100
Hussein ve ark. (2018)	Epileptic Seizure Detection: A Deep Learning Approach	Uzun kısa bellek hücre temelli tekrarlayan sinir ağı	100
Yavuz ve ark. (2018)	An epileptic seizure detection system based on cepstral analysis and generalized regression neural network	Logaritmik spektrumun ters fourier dönüşümüne dayalı sepstral analiz ile geliştirilmiş regresyon yapay sinir ağı	99
Amin ve ark. (2020)	A novel approach based on wavelet analysis and arithmetic coding for automated detection and diagnosis of epileptic seizure in EEG signals using machine learning techniques	Ayrık dalgacık ve aritmetik kodlama ile destek vektör makineleri ve yapay sinir ağıları	100
Sharma ve ark. (2020)	Seizures classification based on higher order statistics and deepneural network	Derin sinir ağı	100
Bu Çalışma	EEG sinyalleri ile epilepsi krizinin tahminlenmesinde Rassal Orman algoritması ile hiper parametre optimizasyonunun uygulanması	Hiper parametre optimizasyonu ve Rassal Orman algoritması	99.78

Çalışılan deneylerin vakalarında % 99,78 oranında doğruluk, %99,95 özgüllük ve % 99,61 hassasiyet elde edilmiştir ve sonuçlar modelinin başarılı şekilde sınıflandırdığını göstermektedir. Özgüllük ve hassasiyet değerleri kıyaslanı tüm çalışmalarda verilmediği için tabloda yer almamıştır.

5. SONUÇLAR

Bu çalışmada epilepsi rahatsızlığı olan kişilerin belirlenmesi için, Rassal Orman algoritması ile hiper parametre optimizasyonu yaparak EEG sinyallerinden epilepsi krizi ve normal beyin durumlarını %99.78 doğruluk oranı ile tahmin edebilecek sistemin genel tasarımı ele alınmıştır ve bu veri setinde daha önce yapılmış çalışmalar incelendiğinde yapay sinir ağıları dahil olmak üzere bir çok farklı yöntem ile aynı seviyede sonuçlar elde edildiği görülmektedir. Somut rakamlar vermek gerekirse; çalışılan deneylerin vakalarında % 99,78 oranında doğruluk yanında, %99,95 özgüllük ve % 99,61 hassasiyet de elde edilmiştir. Rassal Ormanlar paralel olarak kurulabilen, eğitimde zaman maliyeti düşük ve doğruluk oranı yüksek, özellik çıkartımı ve veri ön işleme gibi ekstra işlemlere ihtiyaç duymayan bir algoritma olduğu görülmektedir. EEG verileri gibi sürekli verilerin işlenmesinde bir alternatif olarak değerlendirilebileceği çalışmamızın sonuçlarından biridir. Sonuçlar ve değerlendirmeler ışığında modelinin başarılı bir şekilde sınıflandırma yaptığı görülmektedir.

KAYNAKLAR

- Acharya U.R., Oh S.L., Hagiwara Y., Tan J.H., Adeli H. (2018). Deep convolutional neural network for the automated detection and diagnosis of seizure using EEG signals, *Computers in Biology and Medicine*, 100 270–278
- Amin H.U, Yusoff M.Z, Ahmad R.F , A novel approach based on wavelet analysis and arithmetic coding for automated detection and diagnosis of epileptic seizure in EEG signals using machine learning techniques. *Biomedical Signal Processing and Control* 56 (2020) 101707
- Andrzejak RG, Lehnertz K, Rieke C, Mormann F, David P, Elger CE (2001). Indications of nonlinear deterministic and finite dimensional structures in time series of brain electrical activity: Dependence on recording region and brain state, *Phys. Rev. E*, 64, 061907
- Bergstra J., Bardenet R., Bengio Y., Kegl B. (2011) Algorithms for hyper-parameter optimization. In *NIPS*
- Bergstra J. ve Bengio Y. (2012) Random search for hyper-parameter optimization.
- Bhardwaj A., Tiwari A., Krishna R., Varma V., A novel genetic programming approach for epileptic seizure detection, *Comput. Methods Programs Biomed.*124 (2016) 2–18.
- Bhattacharyya A., Pachori R.B., Upadhyay A., Acharya U.R., Tunable-Q wavelet transform based multiscale entropy measure for automated classification of epileptic EEG signals, *Appl. Sci.* 7 (4) (2017) 385.
- Breiman L., Friedman J. H., Olshen R. A., Stone C. J. (1984), *Classification and Regression Trees*. Belmont, CA: Wadsworth International.
- Breiman, L. (1996). Bagging predictors. *Machine Learning* 26(2), 123–140.
- Breiman, L. (2001). Random Forests. *Machine Learning* 45 (1): 5–32. Doi: 10.1023/A: 1010933404324.
- Chen G., Xie W., Bui T.D., Krzyzak A., Automatic epileptic seizure detection in EEG using non subsampled wavelet-Fourier features, *J. Med. Biol. Eng.* 37 (1)(2017) 123–131.
- Chen G., Automatic EEG seizure detection using dual-tree complex wavelet-Fourier features, *Expert Syst. Appl.* 41 (2014) 2391–2394.
- Dehuri S., Jagadev A.K., Cho S.-B., Epileptic seizure identification from electroencephalography signal using DE-RBFNs ensemble, *Procedia Comput.Sci.* 23 (2013) 84–95.
- Dekking, Michel (2005). *A Modern Introduction to Probability and Statistics*. Springer. pp. 181–190.
- Dhiman R., Saini J.S., Priyanka, Genetic algorithms tuned expert model for detection of epileptic seizures from EEG signatures, *Appl. Soft Comput.* 19(2014) 8–17.
- Fernandez-Blanco E., Rivero D., Rabuñal J., Dorado J., Pazos A., Munteanu C.R., Automatic seizure detection based on star graph topological indices, *J.Neurosci. Methods* 209 (2012) 410–419.
- Fu K., Qu J., Chai Y., Dong Y., Classification of seizure based on the time-frequency image of EEG signals using HHT and SVM, *Biomed. SignalProcess. Control* 13 (2014) 15–22.
- Guo L, Rivero D, Seoane J, Pazos A. Classification of EEG signals using relative wavelet energy and artificial neural networks. In: *Proceedings of the first ACM/SIGEVO Summit on Genetic and Evolutionary Computation*; 2009. p. 177–84.
- Guo L, Rivero D, Pazos A. Epileptic seizure detection using multiwavelet transform based approximate entropy and artificial neural networks. *Journal of Neuroscience Methods* 193 (2010) 156–163

- Hassan A.R., Siuly S., Zhang Y., Epileptic seizure detection in EEG signals using tunable-Q factor wavelet transform and bootstrap aggregating, *Comput.Methods Programs Biomed.* 137 (2016) 247–259.
- Ho T.K. (1998). The random subspace method for constructing decision forests. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 20(8), 832–844.
- Hussein R., Palangi H., Ward R., Wang Z.J., Epileptic Seizure Detection: A Deep Learning Approach, 2018, arXiv preprint arXiv:1803.09848.
- Jahankhani P, Kodogiannis V, Revett K. (2006). EEGsignal classification using wavelet feature extraction and neural networks. In: *IEEE John Vincent Atanasoff 2006 International Symposium on Modern Computing (JVA'06)*; p. 52–7.
- Jiang Y., Cukic B., Menzies T., Can Data Transformation Help in the Detection of Fault-prone Modules? In *Proceedings of the workshop on Defects in Large Software Systems*, pages 16–20, 2008.
- Kalayci T, Ozdamar O. (1995). Wavelet preprocessing for automated neural network detection of EEG spikes. *IEEE Engineering in Medicine and Biology Magazine*;14(2):160–6.
- Kandel E, Schwartz J, Jessell T. (2000). *Principles of Neural Science*. New York: McGraw-Hill,Health Professions Division
- Kang J.-H., Chung Y.G., Kim S.-P., An efficient detection of epileptic seizure by differentiation and spectral analysis of electroencephalograms, *Comput. Biol.Med.* 66 (2015) 352–356.
- Kannathal N., Choo M.L Acharya U.R., Sadasivana P.K. (2005). Entropies for detection of epilepsy in EEG, *Comput. Methods Programs Biomed.* 80 187–194
- Kannathal N, Choo M, Acharya U, Sadasivan P. Entropies for detection of epilepsy in EEG. *Computer Methods and Programs in Biomedicine* 2005;80(3):187–94.
- Kaya Y., Uyar M., Tekin R., Yıldırım S., 1D-local binary pattern based feature extraction for classification of epileptic EEG signals, *Appl. Math. Comput.* 243(2014) 209–219.
- Kumar Y., Dewal M., Anand R., Epileptic seizures detection in EEG using DWT-based ApEn and artificial neural network, *Signal Image Video Process.*(2012) 1–12.
- Kumar Y., Dewal M., Anand R., Epileptic seizure detection using DWT based fuzzy approximate entropy and support vector machine, *Neurocomputing*133 (2014) 271–279.
- Lee S.-H., Lim J.S., Kim J.-K., Yang J., Lee Y., Classification of normal and epileptic seizure EEG signals using wavelet transform, phase-space reconstruction, and Euclidean distance, *Comput. Methods Programs Biomed.*116 (2014) 10–25.
- Litt B, Echaz J (2002). Prediction of epileptic seizures, *The Lancet Neurology*, V1 (1) , pp 22-30,
- Martinez-del-Rincon J., Santofimia M.J., del Toro X., Barba J., Romero F., Navas P., Lopez J.C., Non-linear classifiers applied to EEG analysis for epilepsyseizure detection, *Expert Syst. Appl.* 86 (2017) 99–112, 2017/11/15.
- Morgan J. N. ve Sonquist J. A. (1963), Problems in the analysis of survey data, and a proposal, *J. Amer. Statist. Ass.*, vol. 58, pp. 415-434.
- Nigam V, Graupe D (2004). A neural-network-based detection of epilepsy. *Neurological Research*;26(1):55–60.
- Ocak H., Automatic detection of epileptic seizures in EEG using discrete wavelet transform and approximate entropy, *Expert Systems with Applications* 36 (2) (2009) 2027–2036.

- Peker M., Sen B., Delen D., A novel method for automated diagnosis of epilepsy using complex-valued classifiers, *IEEE J. Biomed. Health Inform.* 20(1) (2016) 108–118.
- Polat K, Günes, S. Classification of epileptiform EEG using a hybrid system based on decision tree classifier and fast Fourier transform. *Applied Mathematics and Computation* 2007;187(2):1017–26.
- Sadati N, Mohseni H.R., Magshoudi A., Epileptic seizure detection using neural fuzzy networks, in: *Proceedings of the IEEE International Conference on Fuzzy Systems, Canada, 2006*, pp. 596–600.
- Sharma M., Pachori R.B., Acharya U.R., A new approach to characterize epileptic seizures using analytic time–frequency flexible wavelet transform and fractal dimension, *Pattern Recogn. Lett.* 94 (2017) 172–179.
- Sharma M., Pachori R.B., Sircar P., Seizures classification based on higher order statistics and deep neural network. *Biomedical Signal Processing and Control* 59 (2020) 101921
- Song Y., Zhang J., Automatic recognition of epileptic EEG patterns via Extreme Learning Machine and multiresolution feature extraction, *Expert Syst. Appl.* 40 (2013) 5477–5489.
- Srinivasan V, Eswaran C, Sriraam N. Artificial neural network based epileptic detection using time-domain and frequency-domain features. *Journal of Medical Systems* 2005;29(6):647–60.
- Srinivasan V., Eswaran C., Sriraam N., Approximate entropy-based epileptic EEG detection using artificial neural networks, *IEEE Transaction on Information Technology in Biomedicine* 11 (3) (2007) 288–295.
- Subasi A. (2005). Epileptic seizure detection using dynamic wavelet network. *Expert Systems with Applications*;29(2):343–55.
- Subasi A. (2006) Automatic detection of epileptic seizure using dynamic fuzzy neural networks. *Expert Systems with Applications*;31(2):320–8.
- Subasi A. (2007) EEG signal classification using wavelet feature extraction and a mixture of expert model. *Expert Systems with Applications*;32(4):1084–93.
- Subasi A., Gursoy M.I., EEG Signal classification using PCA, ICA, LDA and support vector machine, *Expert Systems with Applications* 37 (2010) 8659–8666.
- Syarif, I., Prugel-Bennett, A., Wills G., SVM Parameter Optimization using Grid Search and Genetic Algorithm to Improve Classification Performance. *Telkomnika* 2016, 14, 1502–1509.
- Swami P., Gandhi T.K., Panigrahi B.K., Tripathi M., Anand S., A novel robust diagnostic model to detect seizures in electroencephalography, *Expert Syst. Appl.* 56 (2016) 116–130.
- Tantithamthavorn C., McIntosh S., Hassan A. E., and Matsumoto K. (2016). Automated parameter optimization of classification techniques for defect prediction models. *IEEE/ACM 38th IEEE International Conference on Software Engineering*
- Tawfik N.S., Youssef S.M., Kholief M., A hybrid automated detection of epileptic seizures in EEG records, *Comput. Electr. Eng.* (2015).
- Tosun A. ve Bener A., Reducing false alarms in software defect prediction by decision threshold optimization. In *Proceedings of the International Symposium on Empirical Software Engineering and Measurement*, pages 477–480, 2009.
- Tzallas A, Tsipouras M, Fotiadis D. Automatic seizure detection based on time–frequency analysis and artificial neural networks. *Computational Intelligence and Neuroscience* 2007;13, article ID 80510.
- UCI Machine Learning Repository, 2020 <https://archive.ics.uci.edu/ml/datasets/Epileptic+Seizure+Recognition> . son erişim tarihi 17 Mayıs 2020

Viglione SS, Walsh GO, (1975). Proceedings: Epileptic seizure prediction. *Electroencephalography and clinical neurophysiology*, 39 (4): 435–436.

Yavuz, E., Kasapbaşı, M. C., Eyüpoğlu, C., & Yazıcı, R. (2018). An epileptic seizure detection system based on cepstral analysis and generalized regression neural network. *Biocybernetics and Biomedical Engineering*, 38(2), 201-216.

Yuan Q., Zhou W., Yuan S., Li X., Wang J., Jia G., Epileptic EEG classification based on kernel sparse representation, *Int. J. Neural Syst.* 24 (2014) 1450015.

Xie S., Krishnan S., Wavelet-based sparse functional linear model with applications to EEGs seizure detection and epilepsy diagnosis, *Med. Biol. Eng.Comput.* 51 (2013) 49–60.

Zamir Z.R., Detection of epileptic seizure in EEG signals using linear least squares preprocessing, *Comput. Methods Programs Biomed.* 133 (2016)95–109.

Zhang T., Chen W., LMD based features for the automatic seizure detection of EEG signals using SVM, *IEEE Trans. Neural Syst. Rehabil. Eng.* 25 (8) (2016)1100–1108.

Zhou M., Tian C., Cao R., Wang B., Niu Y., Hu T., Guo H., Xiang J., Epileptic seizure detection based on EEG signals and CNN, *Frontiers Neuroinform.* 12(2018) 95.

Zhu G., Li Y., Wen P.P., Epileptic seizure detection in EEGs signals using a fastweighted horizontal visibility algorithm, *Comput. Methods Programs Biomed.* 115 (2014) 64–75.

TEŞEKKÜR ve BEYANLAR / ACKNOWLEDGEMENT and DECLARATIONS

Yazar(lar) tarafından potansiyel çıkar çatışması bildirilmedi. Yazar(lar) tarafından yazar katkı oranı belirtilmediği için, çalışmaya eşit oranda katkı sağlandığı kabul edilmiştir.

{ Özellikle Boş Bırakılmıştır }