



Migren tanısında öncü sinyal ayrıştırma yöntemlerinin performanslarının karşılaştırılması

Comparison of Performance of Pioneering Signal Decomposition Methods in the Diagnosis of Migraine

Zülfikar ASLAN^{1*}

¹Gaziantep Üniversitesi, Teknik Bilimler Meslek Yüksek Okulu, zulfikaraslan@gantep.edu.tr

ORCID: <https://orcid.org/0000-0002-2706-5715>

MAKALE BİLGİLERİ

Makale Geçmişi:

Geliş 14 Nisan 2022
Revizyon 29 Temmuz 2022
Kabul 02 Eylül 2022
Online 30 Eylül 2022

Anahtar Kelimeler:

Migren Teşhisi,
Elektroensefalografi, Ayrıştırma Yöntemleri, Ampirik Mod Ayrıştırması, Ayarlanabilir Q Faktörü Dalgacık Dönüşümü, Ampirik Dalgacık Dönüşümü

ÖZ

Bu çalışma, migren hastalığını (MH) Elektroensefalogram (EEG) verisi kullanarak otomatik olarak teşhisini gerçekleştirmek amacıyla bir bilgisayar destekli tanı sistemi sunmaktadır. Ayrıca önerilen yöntemin farklı ayrıştırma yöntemleri ile test edilerek karşılaştırmalı analizi gerçekleştirilmiştir. EEG sinyalleri Çok Ölçekli Temel Bileşen Analizi (MSPCA) uygulanarak var olan gürültüler giderildikten sonra, Ayarlanabilir Q Faktör Dalgacık Dönüşümü (TQWT), Ampirik Mod Ayrıştırma (EMD) ve Ampirik Dalgacık Dönüşümü (EWT) ayrıştırma yöntemleri ile içsel mod fonksiyonları (IMF) bileşenlerine ayrılmıştır. Her bir IMF bileşeninden istatistiksel özellikler hesaplanarak özellik çıkarım işlemi gerçekleştirilmiştir. Sınıflandırma performansları, her bir IMF bileşeninin özellikleri, Rastgele Orman algoritması ile sınıflandırılarak test edilmiştir. En yüksek sınıflandırma doğruluğu IMF1 ve IMF2 bileşenlerinden elde edilmiştir. IMF1 bileşenine ait özelliklerin Rastgele Orman algoritması ile sınıflandırılmasıyla TQWT için 88.9%, EMD için 92.47% ve EWT için 81.41% sınıflandırma başarımı elde edilmiştir. Bu çalışmada gerçekleştirilen deneysel çalışmalar da EMD ayrıştırma yöntemi karşılaştırılan diğer yöntemlere göre MH ve sağlıklı kontrol deneklerin ayırt edilmesinde iyi bir performans sergilediği gözlemlenmiştir.

ARTICLE INFO

Article history:

Received 14 April 2022
Received in revised form 29 July 2022
Accepted 02 September 2022
Available online 30 September 2022

Keywords:

Migraine Diagnosis,
Electroencephalography,
Decomposition Methods, Empirical Mode Decomposition, Tunable Q Factor Wavelet Transform, Empirical Wavelet Transform

ABSTRACT

This study presents a computer aided diagnosis system to automatically diagnose migraine disease (MD) using Electroencephalogram (EEG) data. In addition, a comparative analysis of the proposed method was carried out by testing it with different decomposition methods. First of all, the noise is removed by applying Multiscale Principal Component Analysis (MSPCA) to the EEG data taken from each electrode. In the next step, the data received from each channel was decomposed into intrinsic mode functions (IMF) sub bands using the Tunable Q Factor Wavelet Transform (TQWT), Empirical Mode Decomposition (EMD) and Empirical Wavelet Transform (EWT) decomposition methods. Feature extraction was performed by calculating statistical features from each IMF component. The classification accuracy of the statistical features calculated for each IMF component was tested with the Random Forest classification algorithm. The highest classification accuracy was obtained from IMF1 and IMF2 components. Classification performances of 88.9% for TQWT, 92.47% for EMD and 81.41% for EWT were obtained by classifying the features of the IMF 1 component with the Random Forest classifier. In the experimental studies performed in this study, it was noticed that the EMD decomposition method performed well in differentiating MD and healthy control subjects compared to other compared methods.

Doi: 10.24012/dumf.1103391

* Sorumlu Yazar

Giriş

Migren hastalığı (MH), birden fazla belirti gösterebilen nörolojik bir hastalıktır. Genellikle şiddetli baş ağrıları ile ayırt edilir. Ayrıca kusma, bulantı, uyuşukluk ve ışığa duyarlılık gibi belirtilerle kendini gösterir. Uzman, bir dizi testi değerlendirerek ve hastanın klinik geçişini araştırarak migreni belirler. MH baş ağrısının en yaygın kategorileri aural ve aurasız migrendir [1]. EEG sinyallerinden MH tespiti bazen bir uzman için bile zor olabilir. Bu amaçla otomatik teşhis ve hastalığın nedenlerinin araştırılmasına yönelik çalışmalar devam etmektedir [2], [3].

Elektroensefalogram (EEG), manyetik rezonans (MRI), bilgisayarlı tomografi (BT), fonksiyonel manyetik rezonans görüntüleme (fMRI) gibi araçlar, migren tespitinde uzman görüşünü desteklemek için kullanılmaktadır. Bu araçlar arasında EEG hem düşük maliyet hem de düşük donanım gereksinimleri gerektirdiği için daha çok tercih edilmektedir. EEG sinyalleri beyindeki milyarlara nöronal ağına elektriksel ölçümünü sağlar. EEG, hastalıkları otomatik olarak tespit etmeyi amaçlayan makine öğrenimi ve makine öğrenimi tabanlı bilgisayar destekli tanı (CAD) sistemlerinde yaygın olarak kullanılan bir araçtır. Bu amaçla literatürde epilepsi, şizofreni, migren gibi birçok hastalığın tespiti için geliştirilmiş EEG tabanlı CAD sistemleri bulunmaktadır [4]–[8].

Yin ve ark. [9] yaptıkları çalışmada migrenin saptanmasında bir klinik karar destek sistemi önermişlerdir. Önerilen çalışmada gerilim tipi baş ağrısı ile olası migreni ayırt etmeyi amaçlamışlardır. Özellik olarak klinik gözlem ve değerlendirmelerden elde ettikleri sonuçları kullanmışlardır. Bu özellikler en yakın komşu (KNN) öğrenme algoritması ile sınıflandırılmış ve %90 sınıflandırma doğruluğuna ulaşmıştır. Başka bir çalışmada Krawczyk ve ark. [10], baş ağrısını tespit etmek için birkaç makine öğrenme algoritması kullanarak yöntemlerini test ettikleri bir klinik karar destek sistemi önermişlerdir. Önerdikleri yöntemle %81 sınıflandırma başarıları elde etmişlerdir.

Yukarıda bahsedilen migren tespiti için klinik karar destek sistemi tabanlı çalışmalara ek olarak, migren tespiti için EEG sinyallerini kullanan çalışmalar da bulunmaktadır. Bir çalışmada, Akben ve ark. [7], MH tespiti için her EEG kanalına Burg-AR yöntemini uygulayarak beta bandını işlemişlerdir. Bu banttan elde edilen öznelikleri Destek Vektör Makinaları (DVM) algoritması ile sınıflandırmışlar ve migreni %83,3 doğrulukla ayırt etmişlerdir. Subaşı et al. [11] çalışmalarında EEG sinyalinden migreni saptamak için bir yöntem önermişler ve çalışmalarında migren tespitinde fotik uyarının etkisini araştırmışlardır. Farklı öğrenme algoritmaları ile verilerine ayırık dalgacık dönüşümü uygulayarak elde ettikleri öznelikleri sınıflandırarak yöntemlerinin doğruluğunu test etmişlerdir. Bu algoritmalar arasında en yüksek sınıflandırma doğruluğu %85,95 ile Rastgele Orman algoritmasında elde edilmiştir. Akben et al. [12] başka bir çalışmada migren tespiti için flaş uyarısı altında EEG sinyallerini analiz etmeyi amaçlayan bir yöntem

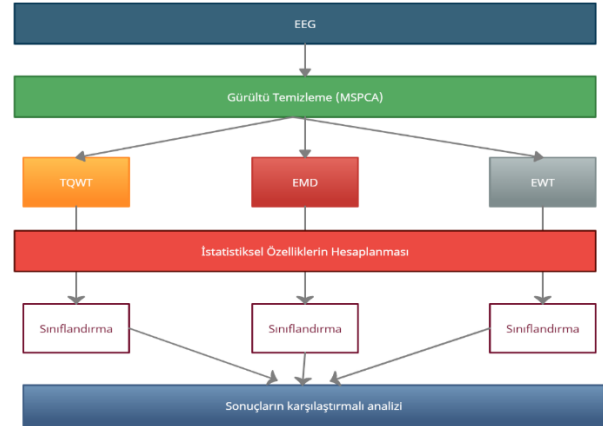
sunmuştur. Önerilen yöntem ile 6 Hz, 4 Hz ve 2 Hz flaş uyarı frekansları altında güç spektrumları elde edilmiştir. Bu değerleri yapay sinir ağı ile eğiterek %85 sınıflandırma performansı göstermişlerdir. İlgili literatür çalışmaları incelendiğinde sınıflandırma doğruluğunun iyileştirilmesi önemli bir ihtiyaç olarak görülmektedir.

Bu çalışma da EEG sinyallerinden migren tespiti için TQWT, EMD ve EWT ayrıştırma yöntemleri kullanılarak karşılaştırmalı analizi sunulmuştur. İlgili literatürde ilk kez EEG sinyallerinden MH teşhisinde ayrıştırma yöntemlerinin karşılaştırmalı analizi sunulmaktadır. Ayrıca Rastgele Orman (RO) makine öğrenme algoritması kullanılarak migren tespitindeki en iyi başarımları elde edilmeye çalışılmıştır.

Metot Ve Materyal

Bu başlık ilk olarak veri kümesi açıklamalarını, analiz yöntemini ve diğer ön işleme adımlarını sunmaktadır. Önerilen yöntem bir sonraki adımda sunulmuştur. Şekil 1, EEG sinyallerinden migreni tespit etmek için ayrıştırma yöntemlerini karşılaştıran önerilen yöntemin akış diyagramını göstermektedir. Sunduğumuz çalışma aşağıdaki adımları içermektedir:

- Sinyalden gürültünün giderilmesi (MSPCA yöntemi ile).
- EEG sinyallerinin her bir ayrıştırma yöntemi için ayrı değerlendirilecek alt bantlara ayrıştırılması.
- Elde edilen alt bantlardan istatistiksel özelliklerin hesaplanması.
- Her bir ayrıştırma yönteminin sınıflandırma performansının RO algoritması kullanılarak test edilmesi.



Şekil 1. Önerilen yöntemin akış diyagramı

Veri Toplama Ve Ön İşlem

Bu çalışmada kullanılan EEG kaydı, 21 baş ağrısı olmayan sağlıklı deneği (ortalama yaş 27.9 yıl, yaş Aralığı 19-54 yıl, 9 erkek ve 12 kadın) ve 18 yetişkin migren (ortalama yaş 27.6 yıl, yaş Aralığı 19-54.5, 6 erkek ve 12 kadın) verilerini içerir. EEG kayıtları Carnegie Mellon Üniversitesi tarafından açık kaynak olarak erişime sunulmuştur. Uluslararası Baş Ağrısı Derneği standartlarına göre migren denekler 6 aurasız migren ve 12 aural migren olarak sınıflandırılmıştır. EEG kayıtları,


24 bitlik bir A/D dönüştürücü ve 128 kanallı bir Bio Semi Active Two sistemi kullanılarak dinlenme durumunda kaydedilmiştir. Dinlenme durumunda yapılan kayıtlar 512 Hz örnekleme frekansına ve yaklaşık 6 dakikalık bir süreye sahiptir. Katılımcılardan EEG kaydı sırasında gözlerini açık tutmaları ve ortadaki siyah haç işaretine sabitlemeleri istenmiştir [13].

MSPCA, Dalgacık Analizi ile Temel Bileşen Analizinin (PCA) üstün özelliklerinin birleştirilmesiyle kullanılan bir analiz yöntemidir. Dalgacık analizi, sinyalin önemli özelliklerini çıkarmak için kullanılırken, PCA, sinyalin özellikleri arasındaki doğrusal ilişkileri belirlemek için uygulanır. MSPCA'nın çok ölçekli doğası nedeniyle, değişen sinyallerin analizi ve gürültü giderme işlemleri için kullanılabilir [14]. Bu nedenle önerilen yöntemimizde, MSPCA yöntemi kullanılarak ham EEG sinyalinin gürültüleri giderilmiştir.

Ayarlanabilir Q Faktör Dalgacık Dönüşümü

Salınımlı sinyal analizi için Ayarlanabilir Q Faktör Dalgacık Dönüşümü (TQWT) etkili bir araç olarak kullanılabilir [15]. Q, r ve j ayarlanabilir parametreleridir. Q parametresi Q faktörünü, r parametresi yüksek hızda örnekleme oranını ve j parametresi ise ayrışma seviyesini belirtmektedir. Q parametresi dalgacık salınımlarının sayısının kontrolü amacıyla kullanılır. Sinyal üzerinde istenmeyen aşırı salınım değerleri ise r tarafından denetlenir. TQWT yapısında bulunan temel filtre kümeleri frekans alanında belirtilebilir. Bu filtreler rasyonel olmayan aktarım işlevleridir ve zaman frekans analizinde etkili olarak kullanılabilir [16].

Salınımlı hiç olmayan veya çok az olan sinyaller için dalgacık dönüşümlerinin düşük bir Q faktörüne sahip olması gerekirken salınımlı sinyallerin analizinde yüksek bir Q faktör değeri gerekmektedir. TQWT yöntemi bu Q değerinin parametrik olarak ayarlanabilmesine izin vermektedir. Bunun yanında TQWT çeşitli fizyolojik sinyallerin analizinde yaygın olarak kullanılmaktadır [8], [17], [18]. Rasyonel transfer fonksiyonları kullanmasından dolayı filtreler hesaplama açısından başarılıdır. Bu durum sinyalin frekans alanında doğrudan temsilini elde edilmesine olanak sağlar. Şekil 2'de TQWT ayrıştırma yönteminin çalışma yapısı diyagram olarak gösterilmektedir.



Şekil 2. TQWT ayrıştırma yönteminin genel blok diyagramı.

Ampirik Mod Ayrıştırma

EEG sinyalinin periyodik olmayan ve durağan olmayan doğası, zaman-frekans analizinde anormal durumların tespit edilmesinde zorluklara neden olur. Bu nedenle,

sinyalin uygun şekilde analiz edilebilmesi için sinyalin durağan olması gerekir. EMD, periyodik olmayan ve durağan olmayan bir sinyali, genlik modülasyonu (AM) ve frekans modülasyonu (FM) ile sonlu sayıda içsel mod bileşenlerine (IMF'ler) ayrıştırır. Bu IMF bileşenleri, sabit sinyalli dar bant simetrik dalga yapıları olarak ele alınabilir. EMD tarafından ayrıştırılan sinyal, sonlu sayıda IMF ve artık değerin toplamı olarak ifade edilebilir.

$$x(t) = \sum_{m=1}^k IMF_m(t) + r_k(t) \quad (1)$$

Formül (1)'de k, IMF numarasıdır ve rk(t) nihai artık değerdir. Orijinal sinyal, IMF bileşenleri ve artık değer [4], [19] toplanarak geri kazanılabilir. EMD yöntemiyle elde edilen IMF bileşenlerinin yapısı, örnekleme frekansının karşılık gelen en yüksek frekansın yaklaşık beş katı olması koşuluyla frekans bantları olarak tanımlanabilecek bir filtre bankasına benzetilebilir [20]. EMD yöntemi öncelikle yüksek frekans bileşenlerini tahmin etmektedir.

Referans [21]'de yazarlar, IMF1 bileşeninin Gama bandı, IMF2 bileşeninin Beta bandı, IMF3 bileşeninin Alfa bandı, IMF4 bileşeninin Delta bandı ve IMF5 ile IMF6 bantlarının ise Theta bandı salınımlarını temsil ettiğini belirtmişlerdir. Ek olarak, birkaç başka çalışma, IMF1 bileşeninin sinyalin gama bandını temsil ettiği fikrini desteklemektedir [22], [23]. IMF1 bileşeninin seçilmesi, Fourier tabanlı yüksek geçişli filtreleme ile karşılaştırılabilir. Fourier filtrelemede, belirli bir kesme frekansının dışındaki bileşenler kaldırılır. Ancak, EMD yöntemi, Fourier filtrelemesinin aksine, bir kesim frekansının altındaki bileşenleri kaldırmaz. Bu nedenle, gama bandı değerleri IMF1 ve IMF2 bileşenleri arasında değişebilir [24].

Ampirik Dalgacık Dönüşümü

Jerome Gilles [25], belirli bir sinyali farklı modlara ayırtmak için açıkça ayarlanabilir bir dalgacık filtre bankası oluşturan Ampirik Dalgacık Dönüşümü adlı yeni bir ayarlanabilir veri analizi yöntemini tanıtmıştır. EWT ayrıca, bir sinyalden AM-FM bileşenlerini çıkarmayı EMD gibi amaçlar. EWT, zamansal uzayda çalışan EMD'nin aksine frekans uzayında çalışır; güçlü bir matematiksel altyapı tarafından desteklenen sezgisel, doğrudan ve ayarlanabilir bir algoritmadır.

EWT, işlenen sinyale uyarlanmış bir dalgacık ailesi oluşturmak için bir yöntem önerir. Fourier bakışı düşünülürken, bu yapı bir dizi bant geçiren filtre oluşturmaya eşdeğerdir. Fikir, iyi seçilmiş "Fourier desteklerine (yani sinyal spektrumunda ilgili modların seçilmesiyle) dayalı olarak bir N dalgacık filtresi (ayrıntı bileşenlerine karşılık gelen bir düşük geçiş ve N - 1 bant geçiş filtresi) tanımlamaktan ibarettir" [26].

İstatistiksel Özelliklerin Hesaplanması

Bu başlıkta, ayrıştırma yöntemi uygulanan sinyallerin istatistiksel özellikleri hesaplanmış ve bu özelliklerin sınıflandırma performansına etkileri araştırılmıştır.

İstatistiksel hesaplamalarla sinyalden çıkarılan özellikler şunlardır: medyan, minimum, maksimum, ortalama, varyans, standart sapma, ortalama karekök, aykırı değerler hariç ortalama (trimmean), çeyrek (Q1, Q2, Q3, Q4), çeyrekler arası aralık, basıklık, shannon entropisi, çarpıklık, log enerji entropisi, hjorth parametreleri (aktivite, hareketlilik, karmaşıklık).

Migren Ve Sağlıklı Deneklerinin Sınıflandırma Süreci

Her bir alt bileşenden çıkarılan istatistiksel özellikler Rastgele Orman sınıflandırıcıları ile sınıflandırılarak elde edilen sonuçların karşılaştırmalı analizi gerçekleştirilmiştir. Sınıflandırma işleminde çapraz doğrulama değeri 10 alınarak sınıflandırma performansı test edilmiştir. Sınıflandırma başarımının test edilmesi amacıyla Doğruluk, Duyarlılık (Geri Çağırma, TP Oran), Kesinlik, F-Ölçütü, ROC Alanı ve FP Oran, Matthews Korelasyon Katsayısı (MCC) değerlendirme metrikleri kullanılmıştır. Değerlendirme metriklerine ait hesaplamaların formülleri aşağıda gösterilmektedir.

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FP+FN} \times 100 \quad (1)$$

$$\text{Geri Çağırma} = \frac{TP}{TP+FN} \times 100 \quad (2)$$

$$\text{Özgüllük} = \frac{TN}{TN+FP} \times 100 \quad (3)$$

$$\text{Hassasiyet} = \frac{TP}{TP+FP} \times 100 \quad (4)$$

$$F1 \text{ Ölçütü} = 2 * \frac{\text{hassasiyet} * \text{geri çağırma}}{\text{hassasiyet} + \text{geri çağırma}} \times 100 \quad (5)$$

$$MCC = \frac{(TP \times TN) - (FP \times FN)}{\sqrt{(TP+FP)(TP+FN)(TN+FP)+(TN+FN)}} \quad (6)$$

Deneyel Çalışmalar

Bu çalışmada, deneklerin sinyallerini TQWT, EMD ve EWT yöntemiyle beş IMF bileşenine ayırarak MH ve sağlıklı deneklerin sınıflandırma performansları değerlendirilmiştir. IMF değerleri arttıkça sınıflandırma doğruluğunun azaldığı gözlemlendiğinden, daha fazla IMF bileşenine ayırtmaya gerek duyulmamıştır. EEG sinyalinin yapısına bağlı olarak, sinyalden elde edilen IMF sayısı değişmektedir. İlk IMF bileşeninin daha yüksek frekans bileşenlerini yakalayabildiği ve daha sonra IMF'lerin daha düşük ortalama frekanslara sahip olduğu genel olarak bilinmektedir [4].

EEG sinyallerine ait tüm kanallar öncelikle önerilen ayırtma yöntemleriyle alt bantlarına ayırılır. Deneyel çalışmalar sürecinde değerlendirmeler ilk beş alt bant göz önüne alınarak gerçekleştirilmiştir. TQWT ayırtma yönteminde Q=1, r=3 ve J=4 alınarak gerçekleştirilmiştir. EMD ve EWT ayırtma yöntemleri için ise Matlab yazılımının varsayılan parametreleri kullanılmıştır. EEG kayıtları arasındaki küçük zaman farkları nedeniyle, tüm kanalların veri uzunluğu 195.000 uzunluğunda bir vektör olarak alınmıştır. İlk olarak, EEG kayıtlarındaki gürültüyü ortadan kaldırmak için her bir

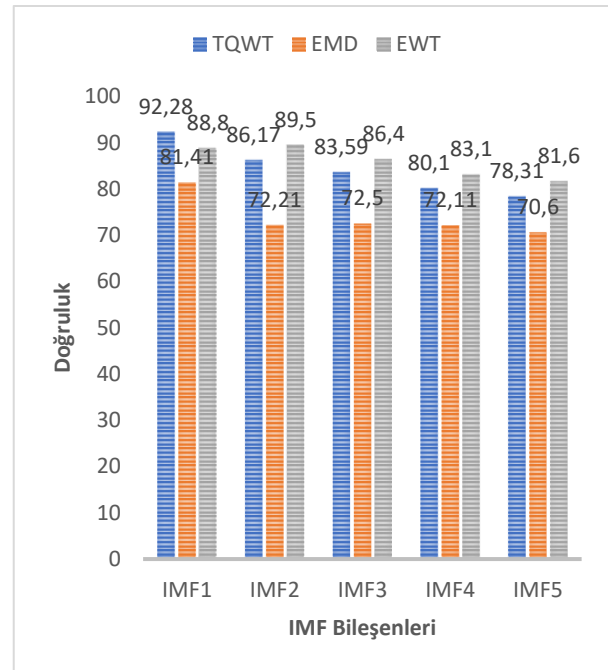
EEG kanalına MSPCA yöntemi uygulanmıştır. Ayırılan her bir kanaldan istatistiksel özellikler hesaplanarak özellik çıkarım işlemi yapılmıştır. Her bir alt bileşen için, migren denekler (18 migren x 128 kanal sayısı) ve sağlıklı denekler için (21 sağlıklı x 128 kanal sayısı) toplam uzunluğu (4492x20) olan bir matris elde edilmiştir. MH ve sağlıklı deneklerinin sınıflandırma performansı, her ayırtma yönteminin her bir alt bileşeni için ayrı ayrı değerlendirilmiştir. Tüm deneysel çalışmalar Matlab yazılımı kullanılarak gerçekleştirilmiştir.

Sonuçlar Ve Tartışma

Tablo 1.'de çalışmada kullanılan ayırtma yöntemleriyle farklı IMF bileşenlerinden elde edilen özelliklerin RO sınıflandırıcısı ile sınıflandırılmasıyla elde edilen doğruluk değerleri gösterilmektedir. Tablo 1 incelendiğinde MH ve sağlıklı deneklerin ayırtılmasında IMF1 ve IMF2 bileşenlerinin daha yüksek sınıflandırma performansına sahip olduğu açıkça görülmektedir. Şekil 3'de TQWT ve EMD, EWT ile elde edilen IMF bileşenlerinden hesaplanan özelliklerin sınıflandırılmasıyla elde edilen doğruluk değerleri grafik olarak gösterilmektedir.

Tablo 1. Farklı ayırtma yöntemlerine ait sınıflandırma doğrulukları.

| | IMF1 | IMF2 | IMF3 | IMF4 | IMF5 |
|------|-------|-------|-------|-------|-------|
| TQWT | 88.8 | 89.5 | 86.4 | 83.1 | 81.6 |
| EMD | 92.28 | 86.17 | 83.59 | 80.1 | 78.36 |
| EWT | 81.41 | 72.21 | 72.5 | 72.11 | 70.6 |



Şekil 3. Farklı IMF bileşenlerinden elde edilen özelliklerin RO sınıflandırıcısı ile sınıflandırılmasıyla elde edilen doğruluk değerleri.

Tablo 2. Farklı ayrıştırma yöntemlerinin IMF 1 bileşenlerine ait özelliklerin sınıflandırılmasıyla elde edilen değerlendirme metrikleri

| | TP Oranı | FP Oranı | Keskinlik | Duyarluluk | F Ölçütü | M CC | ROC Alanı | Doğruluk |
|----|----------|----------|-----------|------------|----------|------|-----------|----------|
| TQ | | | 0.88 | | | 0.7 | | |
| WT | 0.883 | 0.125 | 5 | 0.883 | 0.882 | 7 | 0.952 | 0.888 |
| EM | | | 0.92 | | | 0.8 | | |
| D | 0.923 | 0.081 | 3 | 0.923 | 0.923 | 45 | 0.975 | 0.922 |
| EW | | | 0.81 | | | 0.6 | | |
| T | 0.817 | 0.19 | 7 | 0.817 | 0.816 | 31 | 0.902 | 0.816 |


Tablo 3. EMD yöntemiyle elde edilen alt bantlara ait özelliklerin DVM algoritması ile sınıflandırılmasıyla elde edilen doğruluk değerleri

| | IMF1 | IMF2 | IMF3 | IMF4 | IMF5 |
|------|------|------|------|------|------|
| c=5 | 67.7 | 64.4 | 65.2 | 67.1 | 66.9 |
| c=10 | 69.4 | 64.8 | 65.1 | 67.4 | 67.3 |
| c=15 | 70.5 | 64.9 | 65.2 | 67.4 | 67.4 |
| c=20 | 71.2 | 65 | 65.2 | 67.6 | 67.4 |
| c=25 | 71.3 | 65.2 | 65.2 | 67.7 | 67.5 |

Tablo3'de EMD yöntemiyle elde edilen alt bileşenlere ait özelliklerin farklı c parametreleri kullanılarak DVM sınıflandırıcısı ile sınıflandırılarak elde edilen doğruluk değerlerini göstermektedir. Sonuçlar RO sınıflandırıcısının migren ve sağlıklı kontrolü ayırt etmede daha başarılı olduğunu açıkça ortaya koymaktadır.

| | | Tahmin | | | | Tahmin | | | |
|--------|------|--------|------|------|--------|--------|------|------|-----|
| | | HC | MD | | | HC | MD | | |
| Gerçek | TQWT | HC | 2506 | 182 | Gerçek | EWT | HC | 2303 | 385 |
| | MD | 375 | 1929 | MD | | 529 | 1775 | | |
| Gerçek | EMD | HC | 2568 | 120 | Gerçek | HC | 2568 | 120 | |
| | | MD | 256 | 2048 | | MD | 256 | 2048 | |

Şekil 4. Farklı ayrıştırma yöntemlerine ait IMF1 bileşenlerinin sınıflandırılmasıyla elde edilen karmaşıklık matrisleri.



Şekil 5. Farklı ayrıştırma yöntemlerine ait IMF1 bileşenlerinin sınıflandırılmasıyla elde edilen ROC eğrisi.

Tablo 2' de TQWT, EMD ve EWT ayrıştırma yöntemleriyle elde edilen IMF1 bileşenine ait özelliklerin RO sınıflandırıcısı ile sınıflandırılmasıyla elde edilen değerlendirme metrikleri gösterilmektedir. Her bir yöntem için özellikle IMF1 ve IMF 2 bileşenlerinin MH ve sağlıklı deneklerin ayırt edilmesinde daha yüksek sınıflandırma başarısına sahip olduğu görülmektedir. Ancak en yüksek sınıflandırma performansı, EMD ayrıştırma yönteminin IMF bileşeniyle 92.28% sınıflandırma doğruluğu elde edilmiştir.

Önerilen yöntemin sınıflandırma performansını daha net ifade edebilmek için Şekil 4, IMF1 bileşeninden elde edilen özneliklerin RO ile farklı ayrıştırma yöntemleri kullanılarak sınıflandırılmasıyla elde edilen Karmaşıklık Matrisi değerlerini göstermektedir. Sağlıklı deneklerinin en yüksek doğru tahmini 2586 (%95.5) ve MH deneklerinin en yüksek doğru tahmini 2048 (%88.9) olarak sınıflandırıldı. Aynı şekilde EMD yöntemi ile sağlıklı deneklerin en düşük yanlış tahmini 120 (%4,5),MH deneklerin yanlış tahmini ise 256 (%11,1) olarak hesaplanmıştır. Sınıflandırma performansını daha iyi analiz edebilmek için Şekil 5, farklı ayrıştırma yöntemleri kullanılarak IMF1 bileşeninden elde edilen ROC eğrisini göstermektedir. Şekil 5'da gösterilen ROC eğrisi, RO sınıflandırıcısı kullanılarak elde edilmiştir. ROC eğrisi ve altındaki alan (AUC) metrikleri, literatürde sınıflandırma performansını değerlendirmek için yaygın olarak kullanılan önemli bir değerlendirme metriğidir. Şekil 5'da görüldüğü gibi önerilen yöntemle EMD için en yüksek ROC Alanı (AUC) değeri %97,6 olarak elde edilmiştir. EMD yöntemi ile gerçek pozitif değer %92,5 olarak elde edilirken, yanlış pozitif değer %8 olarak elde edilmiştir. Deneysel çalışmalar, önerilen yöntemle MH ve sağlıklı deneklerinin ayırt edilmesinde EMD ayrıştırma yönteminin yüksek bir sınıflandırma doğruluğuna sahip olduğunu göstermektedir.

Tablo 3. İlgili literatürde bilgisayar destekli tanı sistemi kullanarak MH tespiti gerçekleştiren çalışmalar

| | Sınıflandırma | Özellik Çıkarımı | Veri Seti | Doğruluk |
|------------------------|--------------------------------|-------------------------------|---------------------------------|-----------------------------------|
| Yin ve ark. [9] | k-En Yakın Komşu(KNN) | ICA | Klinik Görüşme | 90% |
| Krawczyk ve ark.[10] | Rastgele Orman | ReliefF Greedy | Klinik Görüşme | 81% |
| Akben ve ark.[7] | Vektör Destek Makinaları (SVM) | AR Burg | EEG (30 MH, 30 sağlıklı) | 85% |
| Subasi ve ark. [11] | Rastgele Orman | DWT | EEG(15 MH, 15 sağlıklı) | 85.95% |
| Akben ve ark. [12] | Yapay Sinir Ağları (ANN) | AR Burg | EEG (15 MH, 15 sağlıklı) | 83.3% |
| Jackowski ve ark. [27] | LADTree NB NBTree RBFNetwork | Backward Feature Eliminasyonu | Klinik Görüşme | 75.9% |
| Önerilen Yöntem | Rastgele Orman | TQWT EMD EWT | EEG (18 MH, 21 sağlıklı) | 88.8% 92.28% 81.4% |

Bilinen ilgili literatür çalışmalarında EEG sinyallerinden MH tespiti gerçekleştiren çalışmalar da ayrıştırma yöntemlerinin performanslarını karşılaştıran bir çalışmaya rastlanmamıştır. Bu yönüyle bu çalışma önden gelen ayrıştırma yöntemlerinin MH ve sağlıklı deneklerin ayırt edilmesindeki performanslarının analizini ortaya koymaktadır. Çalışmada her ayrıştırma yöntemi için IMF1 ve IMF2 bileşenlerine ait özelliklerin MH tespitinde daha başarılı olduğu görülmektedir. Bu durum yüksek frekanslı bilgilerin MH ve sağlıklı deneklerin ayırt edilmesinde önemli bilgiler taşıdığını göstermektedir.

Sonuç

Bu çalışmada, EEG sinyallerinden MH ve sağlıklı deneklerinin sınıflandırılması ile ilgili literatürde ilk kez ayrıştırma yöntemlerinin karşılaştırmalı analizi sunulmaktadır. Öncelikle EEG sinyalinin her bir kanalına ait verilere gürültüleri gidermek amacıyla MSPCA yöntemi uygulanmıştır. Sonraki aşamada ise her ayrıştırma yöntemi için ilk beş IMF bileşeni elde edilmiştir. Elde edilen IMF bileşenleri üzerinde istatistiksel özellikler hesaplanarak özellik çıkarım işlemi gerçekleştirilmiştir. Elde edilen özellikler RO sınıflandırıcı ile sınıflandırılmış ve en yüksek sınıflandırma başarımlarının IMF1 ve IMF2 bileşenlerinden elde edilen özellikler ile elde edildiği gözlemlenmiştir. Gerçekleştirilen deneysel çalışmalar sonucunda EEG sinyallerinden migren teşhisinde EMD yöntemiyle gerçekleştiren sınıflandırma başarımlarının daha yüksek olduğu ortaya konulmuştur. Bu durum yüksek frekans bileşenlerinin MH ve sağlıklı deneklerin

ayırt edilmesinde önemli farklılıklar içerdiğini ortaya koymaktadır.

Etik Kurul Onayı Ve Çıkar Çatışması Beyanı

Hazırlanan makalede etik kurul izni alınmasına gerek yoktur.

Hazırlanan makalede herhangi bir kişi/kurum ile çıkar çatışması bulunmamaktadır.

Kaynaklar

- [1] D. Weatherspoon, "Everything You Want to Know About Migraine," 2017. [Online]. Available: <https://www.healthline.com/health/migraine>. [Accessed: 17-Sep-2021].
- [2] V. Ulrich, M. Gervil, K. O. Kyvik, J. Olesen, and M. B. Russell, "Evidence of a genetic factor in migraine with aura: a population-based Danish twin study," *Ann. Neurol. Off. J. Am. Neurol. Assoc. Child Neurol. Soc.*, vol. 45, no. 2, pp. 242–246, 1999. [https://doi.org/10.1002/1531-8249\(199902\)45:2%3C242::AID-ANA15%3E3.0.CO;2-1](https://doi.org/10.1002/1531-8249(199902)45:2%3C242::AID-ANA15%3E3.0.CO;2-1)
- [3] Z.-H. Cao, L.-W. Ko, K.-L. Lai, S.-B. Huang, S.-J. Wang, and C.-T. Lin, "Classification of migraine stages based on resting-state EEG power," in 2015 International Joint Conference on Neural Networks (IJCNN), 2015, pp. 1–5. <https://doi.org/10.1109/IJCNN.2015.7280582>
- [4] S. Siuly, S. K. Khare, V. Bajaj, H. Wang, and Y. Zhang, "A Computerized Method for Automatic Detection of Schizophrenia Using EEG Signals," *IEEE Trans. Neural Syst. Rehabil. Eng.*, 2020. <https://doi.org/10.1109/TNSRE.2020.3022715>
- [5] Z. ASLAN and M. AKIN, "A COMPARISON OF HEURISTIC SEARCH ALGORITHMS IN AUTOMATIC DETECTION OF SCHIZOPHRENIA," in 4TH INTERNATIONAL ENERGY & ENGINEERING CONGRESS, 2019, pp. 1248–1258.
- [6] Z. ASLAN and M. AKIN, "Automatic detection of schizophrenia by applying deep learning over spectrogram images of EEG signals," *Trait. du Signal*, 2020. <https://doi.org/10.18280/ts.370209>
- [7] S. B. Akben, D. Tuncel, and A. Alkan, "Classification of multi-channel EEG signals for migraine detection.," *Biomed. Res.*, vol. 27, no. 3, pp. 743--748, 2016.
- [8] A. R. Hassan, S. Siuly, and Y. Zhang, "Epileptic seizure detection in EEG signals using tunable-Q factor wavelet transform and bootstrap aggregating," *Comput. Methods Programs Biomed.*, vol. 137, pp. 247–259, 2016. <https://doi.org/10.1016/j.cmpb.2016.09.008>
- [9] Z. Yin, Z. Dong, X. Lu, S. Yu, X. Chen, and H. Duan, "A clinical decision support system for the

- diagnosis of probable migraine and probable tension-type headache based on case-based reasoning,” *J. Headache Pain*, vol. 16, no. 1, pp. 1–9, 2015. <https://doi.org/10.1186/s10194-015-0512-x>
- [10] B. Krawczyk, D. Simić, S. Simić, and M. Woźniak, “Automatic diagnosis of primary headaches by machine learning methods,” *Cent. Eur. J. Med.*, vol. 8, no. 2, pp. 157–165, 2013. <https://doi.org/10.2478/s11536-012-0098-5>
- [11] A. Subasi, A. Ahmed, E. Aličković, and A. R. Hassan, “Effect of photic stimulation for migraine detection using random forest and discrete wavelet transform,” *Biomed. Signal Process. Control*, vol. 49, pp. 231–239, 2019. <https://doi.org/10.1016/j.bspc.2018.12.011>
- [12] S. B. Akben, A. Subasi, and D. Tuncel, “Analysis of repetitive flash stimulation frequencies and record periods to detect migraine using artificial neural network,” *J. Med. Syst.*, vol. 36, no. 2, pp. 925–931, 2012. <https://doi.org/10.1007/s10916-010-9556-2>
- [13] M. Chaman Zar, Alireza; Haigh, Sarah; Grover, Pulkit; Behrmann, “Ultra high-density EEG recording of interictal migraine and controls: sensory and rest. Carnegie Mellon University. Dataset,.” 2020.
- [14] B. R. Bakshi, “Multiscale PCA with application to multivariate statistical process monitoring,” *AIChE J.*, vol. 44, no. 7, pp. 1596–1610, 1998. <https://doi.org/10.1002/aic.690440712>
- [15] I. W. Selesnick, “Wavelet transform with tunable Q-factor,” *IEEE Trans. signal Process.*, vol. 59, no. 8, pp. 3560–3575, 2011. <https://doi.org/10.1109/TSP.2011.2143711>
- [16] S. Patidar and R. B. Pachori, “Classification of cardiac sound signals using constrained tunable-Q wavelet transform,” *Expert Syst. Appl.*, vol. 41, no. 16, pp. 7161–7170, 2014. <https://doi.org/10.1016/j.eswa.2014.05.052>
- [17] V. Bajaj, S. Taran, S. K. Khare, and A. Sengur, “Feature extraction method for classification of alertness and drowsiness states EEG signals,” *Appl. Acoust.*, vol. 163, p. 107224, 2020. <https://doi.org/10.1016/j.apacoust.2020.107224>
- [18] S. K. Khare and V. Bajaj, “Constrained based tunable Q wavelet transform for efficient decomposition of EEG signals,” *Appl. Acoust.*, vol. 163, p. 107234, 2020. <https://doi.org/10.1016/j.apacoust.2020.107234>
- [19] C. Amo, L. De Santiago, R. Barea, A. López-Dorado, and L. Boquete, “Analysis of gamma-band activity from human EEG using empirical mode decomposition,” *Sensors*, vol. 17, no. 5, p. 989, 2017. <https://doi.org/10.3390/s17050989>
- [20] N. E. Huang et al., “The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis,” *Proc. R. Soc. London. Ser. A Math. Phys. Eng. Sci.*, vol. 454, no. 1971, pp. 903–995, 1998. <https://doi.org/10.1098/rspa.1998.0193>
- [21] F.-F. Tsai, S.-Z. Fan, Y.-S. Lin, N. E. Huang, and J.-R. Yeh, “Investigating power density and the degree of nonlinearity in intrinsic components of anesthesia EEG by the Hilbert-Huang transform: an example using ketamine and alfentanil,” *PLoS One*, vol. 11, no. 12, p. e0168108, 2016. <https://doi.org/10.1371/journal.pone.0168108>
- [22] H. Liang, S. L. Bressler, R. Desimone, and P. Fries, “Empirical mode decomposition: a method for analyzing neural data,” *Neurocomputing*, vol. 65, pp. 801–807, 2005. <https://doi.org/10.1016/j.neucom.2004.10.077>
- [23] C.-H. Hsu, C.-Y. Lee, and W.-K. Liang, “An improved method for measuring mismatch negativity using ensemble empirical mode decomposition,” *J. Neurosci. Methods*, vol. 264, pp. 78–85, 2016. <https://doi.org/10.1016/j.jneumeth.2016.02.015>
- [24] H. Liang, S. L. Bressler, E. A. Buffalo, R. Desimone, and P. Fries, “Empirical mode decomposition of field potentials from macaque V4 in visual spatial attention,” *Biol. Cybern.*, vol. 92, no. 6, pp. 380–392, 2005. <https://doi.org/10.1007/s00422-005-0566-y>
- [25] J. Gilles, “Empirical wavelet transform,” *IEEE Trans. signal Process.*, vol. 61, no. 16, pp. 3999–4010, 2013. <https://doi.org/10.1109/TSP.2013.2265222>
- [26] V. S. Geetikaverma, “Empirical Wavelet Transform & its Comparison with Empirical Mode Decomposition: A review,” *Int. J. Appl. Eng.*, vol. 4, no. 5, 2016.
- [27] K. Jackowski, D. Jankowski, D. Simić, and S. Simić, “Migraine diagnosis support system based on classifier ensemble,” in *International Conference on ICT Innovations*, 2014, pp. 329–339. http://www.doi.org/10.1007/978-3-319-09879-1_33