



Grup Görgül Kip Ayrışım Yöntemi ile Epileptik EEG Sınıflandırma İçin Öz Kip Fonksiyonu Seçimi Selection of Intrinsic Mode Functions for Epileptic EEG Classification Using Ensemble Empirical Mode Decomposition

Özlem Karabiber Cura ve Aydın Akan
Biyomedikal Mühendisliği Bölümü
İzmir Kâtip Çelebi Üniversitesi
İzmir, Türkiye
{ozlem.karabiber, aydin.akan}@ikc.edu.tr

Sibel Kocaaslan Atli
Biyofizik Anabilim Dalı
İzmir Kâtip Çelebi Üniversitesi
İzmir, Türkiye
sibel.atli@ikc.edu.tr

Özetçe —Bu çalışmada, Grup Görgül Kip Ayrışımı (GGKA) yöntemi ile elde edilen Öz Kip Fonksiyonları (ÖKF) kullanılarak epileptik EEG verilerinin epilepsi atağı öncesi ve atak anını birbirinden en iyi şekilde ayırabilecek ÖKF'lerin seçilebilmesi amaçlanmıştır. Çalışmamızda çeşitli ÖKF seçme yöntemlerinden yola çıkarak yeni ve hibrit bir yöntem önerilmiş ve ilk 3 ÖKF'nin yüksek önceliğe sahip olduğu tespit edilmiştir. ÖKF seçiminin sınıflandırma başarısına katkısını tespit edebilmek amacıyla çeşitli spektral özellikler hesaplanmış ve Destek Vektör Makinaları, Naive Bayes, K-En Yakın Komşu ve Doğrusal Diskriminant Analiz yöntemleri kullanılarak sınıflandırılma işlemi gerçekleştirilmiştir. İlk 3 ÖKF kullanılarak elde edilen sınıflandırma sonuçları incelendiğinde, en yüksek önceliğe sahip olan 1. ÖKF kullanılarak elde edilen özellikler ile gerçekleştirilen sınıflandırma başarısının daha yüksek olduğu görülmüştür.

Anahtar Kelimeler—Grup Görgül Kip Ayrışımı, Öz Kip Fonksiyonu seçme, sınıflandırma.

Abstract—In this study, it is aimed to select the Intrinsic mode functions that can best distinguish pre-seizure and seizure segments of epileptic EEG signals by using the Intrinsic mode functions (IMF) obtained by Ensemble Empirical Mode Decomposition (EEMD) method. In our study, a hybrid method was proposed based on various IMF selection methods, and the first 3 IMFs were found to have the highest priority. In order to determine the contribution of IMF selection to the classification accuracy, various spectral features were calculated and the classification was performed by using Support Vector Machines, Naive Bayes, K-Nearest Neighbor, and Linear Discriminant Analysis methods. Upon checking the classification results obtained using the first 3 IMFs, it is observed that the classification accuracy is higher with the features obtained using first MF which was found to have the highest priority at the IMF selection process.

Keywords—Ensemble Empirical Mode Decomposition, Intrinsic mode functions selection, classification.

I. GİRİŞ

Günümüzde non-invaziv oluşu, erişilebilirliğinin kolay olması ve diğer yöntemlere göre maliyetinin düşük olması nedenleriyle EEG ölçüm yöntemi araştırmacılar tarafından beyin fonksiyonlarının incelenmesinde sıklıkla kullanılmaktadır [1], [2]. EEG kayıtlarının kullanılması bir çok avantaj sağlarken, uzun süreli kayıtların incelenmesi zaman alıcı ve zahmetlidir. Bu yüzden çeşitli sinyal işleme yöntemlerine başvurulması zorunlu hale gelmiştir.

Fourier Dönüşümü veya Dalgacık dönüşümü, spektral kestirim amacıyla sinyal işleme çalışmalarında uzun süredir kullanılan yöntemlerdir [3]. Ancak, zamanla değişen genlik ve frekans tepkileri üretecekleri için bu yöntemlerin durağan olmayan süreçlerin analizinde kullanılmaları çok uygun değildir. EEG gibi biyolojik sinyaller durağan olmayan süreçlerdir ve durağan olmayan süreçlerin analizinde Kısa Süreli Fourier Dönüşümü (KSFD) ve Sürekli Dalgacık Dönüşümü (SDD) gibi geleneksel zaman-frekans yöntemleri sıklıkla kullanılmaktadır. KSFD, sinyalin hangi zaman aralığında hangi frekans bileşenine sahip olduğu hakkında bilgi veren durağan olmayan süreçlerin analizinde kullanılabilir bir yöntemdir. Bu yöntemde sinyal küçük sabit pencerelere bölünmekte ve her parçanın Fourier dönüşümü alınmaktadır [4]. Ancak belirsizlik ilkesi nedeniyle, bu yöntemler zaman ve frekans salınım bileşenlerini aynı anda çözmek için temel olarak yetersizdir. Son zamanlarda, Görgül Kip Ayrışımı (GKA), Grup Görgül Kip Ayrışımı (GGKA) ve Çok Değişkenli Görgül Kip Ayrışımı (ÇDGKA) gibi birçok yöntem bu sorunların üstesinden gelmek için geliştirilmiş ve araştırmalarda büyük ilgi görmüştür [3]–[5]. GKA yönteminde doğrusal ve durağan olmayan sinyaller kendini oluşturan sıfır ortalamalı ve yaklaşık olarak durağan Öz Kip Fonksiyonlarına (ÖKF) ayrıştırılmaktadır. Ancak bu yöntemde elde edilen ÖKF'ler incelendiğinde kip karışımı problemi olarak bilinen, birbirine benzer genlikteki salınımların farklı kiplerde gerçekleştiği ya da aynı kipte farklı genliklerde salınımların gözlemlendiği problem meydana gelmektedir [5], [6]. Bu problemin üstesinden gelebilmek için geliştir-

ilmiş olan GGKA yönteminde analiz edilecek olan sinyale Gauss beyaz gürültü eklenmekte ve sonrasında bu sinyal GKA yöntemi kullanılarak ÖKF'lerine ayrıştırılmaktadır. Böylece beyaz gürültünün istatistiksel özelliklerinden dolayı sinyalin sürekliliği farklı frekans bölgelerinde de sağlanmakta ve kip karışımı problemi azaltılmaktadır [7], [8].

Yapılan çalışmada GGKA yöntemi kullanılarak epileptik EEG verilerinin epilepsi atağı öncesi ve atak anını birbirinden en iyi şekilde ayırabilecek Öz Kip Fonksiyonlarının seçilebilmesi amaçlanmıştır. Bu amaç doğrultusunda çalışmamızda öncelikle ÖKF seçme yönteminin uygulanması ardından da sınıflandırma başarısının farklı sınıflandırıcılar kullanılarak tespit edilmesi hedeflenmiştir.

II. MALZEME VE YÖNTEM

Çalışmamızda İzmir Kâtip Çelebi Üniversitesi Tıp Fakültesi Nöroloji Anabilim Dalında 16 epilepsi hastası bireyden yüzey elektrotları kullanılarak, 18 kanaldan, 10ms örnekleme frekansı ile kaydedilen epileptik EEG verileri kullanılarak GGKA yöntemi ile elde edilmiş olan Öz Kip Fonksiyonları için ÖKF Seçme işlemi gerçekleştirilmiştir. Bu EEG verilerinin çalışmamız kapsamında kullanılabilmesi için İzmir Kâtip Çelebi Üniversitesi Girişimsel Olmayan Klinik Araştırmalar Etik Kuruluna başvurulmuş ve 08.08.2019 tarihli ve 296 Karar numaralı Etik Onayı alınmıştır. Çalışmanın amacı epilepsi atağı öncesi ve atak anını birbirlerinden en iyi şekilde ayırabilecek ÖKF'lerin seçimi olduğu için Epileptik atakların en sık rastlandığı Fp1-F7, F7-T1, T1-T3, T3-T5, Fp1-F3, Fp2-F8, F8-T2, T2-T4, T4-T6, Fp2-F4 kanallarından kaydedilen EEG verileri kullanılmıştır.

A. Öz Kip Fonksiyonlarının Elde Edilmesi

Çalışmamızda ilk olarak nöbet öncesi ve nöbet anı olmak üzere belirli parçalara ayrılmış 10 farklı kanaldan kaydedilmiş olan EEG sinyalleri ayrı ayrı GGKA yöntemi kullanılarak ÖKF'lerine ayrıştırılmıştır. Bu işlem için MATLAB ortamında yazılmış olan algoritma kullanılmıştır [7], [8].

B. Öz Kip Fonksiyonu Seçme

GGKA sonrası elde edilen Öz Kip Fonksiyonlarının kimi yüksek frekans bilgisine sahipken kimileri düşük frekans bilgisi taşımaktadır ve bu ÖKF'lerden hangisi ile çalışılacağına karar vermek çalışmaya başlarken önemli bir adımı oluşturmaktadır. Literatürde yapılan çalışmalar incelendiğinde genellikle yüksek frekans bilgisi taşıyan ilk 5 ÖKF ile çalışılmış olduğu görülmektedir [9]–[12].

Yine literatür incelendiğinde farklı ÖKF seçimi için çeşitli yöntemlerinin de önerilmiş olduğu gözlenmektedir. Çalışmamızda ilk olarak en sık tercih edilen enerji tabanlı ÖKF seçme yöntemi kullanılmıştır. Bu yöntem kullanılarak 16 hastanın nöbet öncesi ve nöbet anı EEG verilerinden GGKA ayrışımı yöntemi ile elde edilen tüm ÖKF'lerinin enerjileri denklem (1) ile hesaplanmıştır [13], [14]. Bu yöntemde en yüksek enerjiye sahip olan ÖKF'nin orijinal sinyali en iyi temsil eden ÖKF olduğu düşünüldüğünden ÖKF'ler enerjisi yüksek olan ÖKF'den düşük olana doğru sıralanmıştır. Bu işlem her hastanın 10 kanalı için de tekrarlanmıştır.

$$E_{OKF_i} = \sum_{t=0}^T (|OKF_i|)^2 \quad (1)$$

Burada E_{OKF_i} i. ÖKF'nin enerjisini, OKF_i ise i. ÖKF'yi göstermektedir.

Sonrasında yine farklı bir yaklaşım kullanılarak her bir ÖKF'nin korelasyon katsayısı denklem (2) ile gösterildiği şekilde hesaplanmıştır. Bu yöntemde korelasyon katsayısı büyük olan ÖKF'nin orijinal sinyali en iyi temsil eden ÖKF olduğu düşünüldüğünden ÖKF'ler korelasyon katsayısı yüksek olan ÖKF'den düşük olana doğru sıralanmıştır [15]. Bu işlem her hastanın 10 kanalı için de tekrarlanmıştır.

$$\rho_{x,OKF_i} = \frac{C_{x,OKF_i}}{\sigma_x \sigma_{OKF_i}} \quad (2)$$

Burada ρ korelasyon katsayısını, C_{x,OKF_i} orijinal sinyal ile i. ÖKF'nin kovaryansını, σ_x, σ_{OKF_i} ise sırasıyla orijinal sinyal ve i. ÖKF'nin standart sapmalarını göstermektedir.

Çalışmamızda yine başka bir ÖKF seçme yöntemi olan Güç Spektral yoğunluğu (GSY) tabanlı ÖKF seçme yöntemi kullanılmış ve orijinal sinyal ve ÖKF'lerin güç spektral yoğunlukları Welch yöntemi kullanılarak hesaplanmıştır. Hesaplanan GSY'ler arasındaki mesafeler denklem (3) ile gösterildiği şekilde KLD yöntemi kullanılarak hesaplanmıştır. Orijinal sinyal ve ÖKF arasındaki mesafe ne kadar az ise o ÖKF'nin orijinal sinyali en iyi temsil eden ÖKF olduğu düşünüldüğünden ÖKF'ler GSY mesafesi küçük olan ÖKF'den büyük olana doğru sıralanmıştır [10], [16], [17]. Bu işlem her hastanın 10 kanalı için de tekrarlanmıştır.


$$d_{KLD}(x, OKF_i) = \sum \log \frac{GSY_x}{GSY_{OKF_i}} \quad (3)$$

Burada $d_{KLD}(x, OKF_i)$ orijinal sinyal ile i. ÖKF'nin güç spektrumları arasındaki mesafeyi, GSY_x orijinal sinyalin güç spektrumunu, GSY_{OKF_i} ise i. ÖKF'nin güç spektrumunu göstermektedir.

Literatürde yapılan çalışmalar incelendiğinde İstatistiksel olarak anlamlı ÖKF'lerin seçilebilmesi için t-testinin uygulanmış olduğu görülmüş ve her bir ÖKF'ye t-test uygulanmıştır. Burada elde edilen p değeri sinyalin istatistiksel olarak anlamlılık değerini gösterdiğinden ÖKF'ler p değeri büyük olan ÖKF'den küçük olana doğru sıralanmıştır [18]. Yine bu işlem her hastanın 10 kanalı için de tekrarlanmıştır.

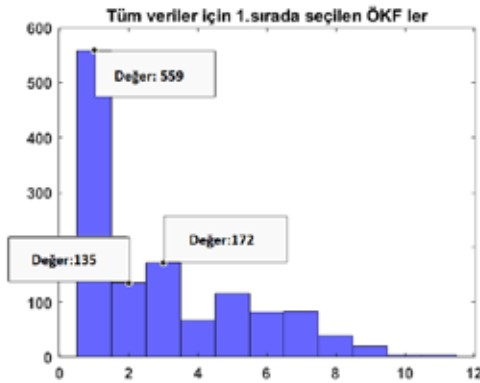
ÖKF sıralama işlemi her hastanın 10 kanalı için ayrı gerçekleştirilmiştir ve matrislerde tutulmuştur. Elde edilen bu matrisin tek hastanın tek bir kanalı için örneği Şekil (1) ile gösterilmektedir. GGKA yöntemlerinde farklı sinyallerden elde edilen ÖKF sayısı değişmektedir. Bu yüzden elde edilen en yüksek ÖKF sayısına göre oluşturulan matrislerin boyutu eşitlenmiş ve her hastaya ait farklı kanallardan elde edilen sıralama öznelikleri tek bir matriste birleştirilmiştir. Şekil (1)'de gösterilen örnek veride bir kanal için oluşan tüm ÖKF'lerden toplam 4x12 boyutunda bir sıralama matrisi oluşturduğu görülmektedir. Bu hasta için tüm kanallara aynı işlem uygulandığında 40x12 boyutunda bir matris oluşmuştur. Tüm

hastalara ait sıralama öznelik matris boyutları eşitlenip birleştirildiğinde nöbet öncesi ve nöbet anı verilerine ait 1280x16 boyutunda bir öznelik sıralama matrisi elde edilmiştir.



Şekil 1: ÖKF'lerin farklı özneliklere göre sıralanması

Elde edilen bu matris kullanılarak tüm sinyaller için 1. Öncelikli olarak seçilen ÖKF belirlenmeye çalışılmıştır. Bu işlem için öznelik sıralama matrisinin 1. sütununun histogramı hesaplanmıştır. Elde edilen histogram Şekil (2) ile gösterilmektedir. Bu histogram değerlendirildiğinde hesaplanan 1280 öznelik içinden 559 tanesinde 1. ÖKF'nin, 135 tanesinde 2. ÖKF'nin, yine 172 tanesinde ise 3. ÖKF'nin 1. sırada yer aldığı görülmektedir. Elde edilen bu bilgiler doğrultusunda 1., 2. ve 3. ÖKF'lerin çalışmamız kapsamında değerlendirilmesine karar verilmiştir.



Şekil 2: 1. Öncelikli olarak seçilen ÖKF'ler için histogram

C. Seçilen ÖKF'lerin Değerlendirilmesi için Öznelik Veri Seti Oluşturma

Öznelik veri setinin oluşturulması için sinyallerin periyodogram yöntemi ile hesaplanmış spektrumları kullanılmıştır. Bu spektrumdan yararlanarak Toplam güç, 1.moment, 2.moment ve 3.momentler [19] ve Spektral Entropi [20] sinyaller için hesaplanmıştır.

Bu hesaplamalar sonucunda GGKA yöntemi ile elde edilmiş her bir hastanın 3 ÖKF'si ve 10 farklı kanalı için 30x5 boyutunda, 16 hasta için nöbet öncesi 480x5, nöbet sonrası 480x5, toplamda ise 960x5 boyutunda öznelik veri seti oluşturulmuştur.

D. Sınıflandırma

GGKA yöntemi ile elde edilen 3 ÖKF kullanılarak oluşturulan öznelikler Destek Vektör Makinaları (SVM), Naive

Bayes, K En Yakın Komşuluk (KNN) ve Doğrusal Diskriminant Analiz (LDA) yöntemleri ile sınıflandırılmıştır. Elde edilen sınıflandırma sonuçlarına göre yöntemlerin birbirlerine göre başarıları değerlendirilmiştir [21]-[23].

E. Performans Değerlendirmesi

Bu çalışmada doğruluk (ACC), duyarlılık (SEN), seçicilik (SPE), kesinlik (PRE) olarak ifade edilen performans ölçütleri ve bunların kombinasyonu ile elde edilen F1-score değerleri kullanılmıştır. [24], [25]

III. SONUÇLAR

Çalışmamızda ilk olarak Grup Görgül Kip Ayrışımı yöntemi ile nöbet öncesi ve nöbet anı olmak üzere parçalanmış Epileptik EEG sinyallerinden Öz Kip Fonksiyonları elde edilmiştir. Sonrasında Enerji tabanlı, Korelasyon tabanlı, Güç Spektrumunu tabanlı ve İstatistiksel ÖKF seçme yaklaşımları uygulanarak orjinal sinyali en iyi temsil eden ÖKF tespit edilmeye çalışılmıştır. Kullanılan yaklaşımlar sonucunda İlk 3 ÖKF'nin seçilmesine karar verilmiştir. Seçilen bu ÖKF lerin sınıflandırma başarılarına katkısının değerlendirilebilmesi için çeşitli spektral öznelikler hesaplanmıştır. Hesaplanan öznelikler SVM, LDA, KNN ve Bayes gibi sınıflandırıcılar kullanılarak sınıflandırılmıştır. Elde edilen sınıflandırma sonuçları tablo (I) ile gösterilmektedir.

	Performans Değerlendirmesi %								
	SVM		LDA		KNN		Bayes		
Sınıf	0	1	0	1	0	1	0	1	
F1Score	94	93	65	58	96	96	94	93	1., 2., ve 3. ÖKF
ACC	93	93	62	62	96	96	94	94	
F1Score	96	96	72	66	96	95	94	94	1. ÖKF
ACC	96	96	70	70	95	95	94	94	
F1Score	93	92	59	61	95	95	93	92	1., 2. ÖKF
ACC	92	92	60	60	95	95	93	93	
F1Score	93	93	78	61	96	96	95	94	1., 3. ÖKF
ACC	93	93	72	72	96	96	95	95	

Tablo I: Elde edilen öznelikler ile gerçekleştirilen sınıflandırma sonucu

Tablo (I) incelendiğinde GGKA algoritması ile elde edilen ilk 3 ÖKF kullanılarak oluşturulan öznelik veri setinin sınıflandırılmasında nöbet öncesi veriler için %96, nöbet anı veriler için %96 F1_skor ve %96 doğruluk başarıları ile KNN algoritmasının en başarılı sınıflandırıcı olduğu görülmektedir. Yine nöbet öncesi veriler için %65, nöbet anı veriler için %58 F1_skor ve %62 doğruluk başarıları ile en başarısız sınıflandırıcının LDA olduğu görülmüştür. Sonrasında ÖKF seçme işleminin başarısının test edilebilmesi için sadece 1. ÖKF, 1.ve 2. ÖKF, 1.ve 3.ÖKF'den elde edilen öznelikler ile sınıflandırma işlemleri ayrı ayrı gerçekleştirilmiştir. Tablo (I)'de ilgili kısımlar incelendiğinde sadece 1.ÖKF'den elde edilmiş öznelikler ile gerçekleştirilen sınıflandırmanın SVM ve LDA algoritmalarındaki başarıları 3 ÖKF kullanılarak gerçekleştirilmiş olan sınıflandırma başarılarından daha yüksek bulunmuştur. Yine KNN ve Bayes sınıflandırma başarılarının ise değişmemiş olduğu görülmektedir.

IV. TARTIŞMA

Yapılan çalışmada Grup Görgül Kip Ayrışımı yöntemi ile elde edilen ÖKF'ler kullanılarak Epileptik verilerde atak öncesi



ve atak anı verileri birbirinden en iyi şekilde ayırabilecek ÖKF'lerin seçilebilmesi amaçlanmıştır. Literatürde GKA ve türevi olan GGKA gibi yaklaşımların kullanıldığı çalışmalar incelendiğinde genellikle yüksek frekans bilgisi taşıyan ilk 5 ÖKF ile çalışılmış olduğu görülmektedir [9]–[12]. Yaptığımız çalışmada literatürde sıklıkla kullanılan Enerji tabanlı, Korelasyon tabanlı, Güç Spektrumu tabanlı ve İstatistiksel ÖKF seçme yaklaşımları kullanılarak yüksek öncelikli ÖKF'ler seçilmeye çalışılmıştır. Çalışmalar incelendiğinde yaklaşımların tek başına kullanılmış olduğu bazı çalışmalarda ise sadece tecrübeye dayalı olarak yüksek frekans bilgisi taşıyan ilk 5 ÖKF'nin kullanılmış olduğu görülmektedir [9], [18].

Çalışmamızda 4 farklı yaklaşım ile sinyallerden elde edilmiş olan tüm ÖKF'lerden öznelilikler hesaplanmış ve bu yaklaşımlar doğrultusunda ÖKF'ler sıralanmıştır. Sıralama işlemleri sonrasında elde edilen 1280x16 boyutundaki öznelilik sıralama matrisinin ilk sütununun tüm sinyaller için yüksek önceliğe sahip ÖKF'ye ait olduğu bilindiğinden ilk sütunun histogramı hesaplanmış ve 1. öncelikli seçilen ÖKF'lerin histogramı elde edilmiştir. Şekil (2) ile verilen histogram incelenerek ilk 3 ÖKF'nin seçilmesine karar verilmiştir. Yapılan seçimin sınıflandırma başarısına katkısının değerlendirilebilmesi için ise bu 3 ÖKF'den çeşitli öznelilikler elde edilerek sınıflandırma işlemleri gerçekleştirilmiştir. Sınıflandırma sonucunda SVM için %93, LDA için %62, KNN için % 96 ve Bayes sınıflandırıcı için % 94 sınıflandırma başarısı elde edilmiştir. Sınıflandırma işlemleri sadece 1. ÖKF, 1. ve 2. ÖKF, 1. ve 3. ÖKF'den elde edilen öznelilikler için tekrarlanmış ve sınıflandırma başarısının sadece 1. ÖKF'den elde edilen öznelilikler ile gerçekleştirilen sınıflandırmada daha yüksek olduğu gösterilmiştir. Bu durum ÖKF seçme işlemi sonrası en yüksek Histogram değerine sahip olan 1. ÖKF'nin öznelilik eldesinde yalnız başına kullanılabilirliğini göstermektedir.

KAYNAKÇA

- [1] H. Zhang, J. Su, Q. Wang, Y. Liu, L. Good, and J. M. Pascual, "Predicting seizure by modeling synaptic plasticity based on eeg signals - a case study of inherited epilepsy," *Communications in Nonlinear Science and Numerical Simulation*, vol. 56, pp. 330 – 343, 2018. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S1007570417303088>
- [2] G. Janvale, S. Kendre, and S. Mehrotra, "Mental and behavioural disorders related to alcohol and their effects on eeg signals – an overview," *Procedia - Social and Behavioral Sciences*, vol. 133, pp. 116 – 121, 2014, international Conference on Trade, Markets and Sustainability (ICTMS-2013). [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S1877042814030857>
- [3] F. Auger, P. Flandrin, Y. Lin, S. McLaughlin, S. Meignen, T. Oberlin, and H. Wu, "Time-frequency reassignment and synchrosqueezing: An overview," *IEEE Signal Processing Magazine*, vol. 30, no. 6, pp. 32–41, Nov 2013.
- [4] S. Ali, M. J. Ferdous, E. Hamid, and K. Molla, "Time-frequency coherence of multichannel eeg signals: Synchrosqueezing transform based analysis," *International Journal of Computer Science Trends and Technology*, vol. 4, no. 3, pp. 40–48, 2016.
- [5] X. Zhao, T. H. Patel, and M. J. Zuo, "Multivariate emd and full spectrum based condition monitoring for rotating machinery," *Mechanical Systems and Signal Processing*, vol. 27, pp. 712–728, 2012.
- [6] P. Flandrin, G. Rilling, and P. Goncalves, "Empirical mode decomposition as a filter bank," *IEEE signal processing letters*, vol. 11, no. 2, pp. 112–114, 2004.
- [7] H. Ren, Y.-L. Wang, M.-Y. Huang, Y.-L. Chang, and H.-M. Kao, "Ensemble empirical mode decomposition parameters optimization for spectral distance measurement in hyperspectral remote sensing data," *Remote Sensing*, vol. 6, no. 3, pp. 2069–2083, 2014.
- [8] Z. Wu and N. E. Huang, "Ensemble empirical mode decomposition: a noise-assisted data analysis method," *Advances in adaptive data analysis*, vol. 1, no. 01, pp. 1–41, 2009.
- [9] S. Li, W. Zhou, Q. Yuan, S. Geng, and D. Cai, "Feature extraction and recognition of ictal eeg using emd and svm," *Computers in biology and medicine*, vol. 43, no. 7, pp. 807–816, 2013.
- [10] M. Lozano, J. A. Fiz, and R. Jané, "Performance evaluation of the hilbert–huang transform for respiratory sound analysis and its application to continuous adventitious sound characterization," *Signal Processing*, vol. 120, pp. 99–116, 2016.
- [11] Y. Jiang and G. Huang, "Short-term wind speed prediction: Hybrid of ensemble empirical mode decomposition, feature selection and error correction," *Energy Conversion and Management*, vol. 144, pp. 340–350, 2017.
- [12] A. R. Hassan and M. I. H. Bhuiyan, "Automatic sleep scoring using statistical features in the emd domain and ensemble methods," *Biocybernetics and Biomedical Engineering*, vol. 36, no. 1, pp. 248 – 255, 2016. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0208521615000844>
- [13] C. Junsheng, Y. Dejie, and Y. Yu, "Research on the intrinsic mode function (imf) criterion in emd method," *Mechanical systems and signal processing*, vol. 20, no. 4, pp. 817–824, 2006.
- [14] B. Karan, S. S. Sahu, and K. Mahto, "Parkinson disease prediction using intrinsic mode function based features from speech signal," *Biocybernetics and Biomedical Engineering*, 2019. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0208521618305564>
- [15] Z. Peng, W. T. Peter, and F. Chu, "A comparison study of improved hilbert–huang transform and wavelet transform: application to fault diagnosis for rolling bearing," *Mechanical systems and signal processing*, vol. 19, no. 5, pp. 974–988, 2005.
- [16] A. Komaty, A.-O. Boudraa, B. Augier, and D. Daré-Emzivat, "Emd-based filtering using similarity measure between probability density functions of imfs," *IEEE Transactions on Instrumentation and Measurement*, vol. 63, no. 1, pp. 27–34, 2013.
- [17] S. Kotan and A. Akan, "A new intrinsic mode function selection method based on power spectral density," in *2018 Medical Technologies National Congress (TIPTEKNO)*. IEEE, 2018, pp. 1–4.
- [18] A. Zahra, N. Kanwal, N. ur Rehman, S. Ehsan, and K. D. McDonald-Maier, "Seizure detection from eeg signals using multivariate empirical mode decomposition," *Computers in biology and medicine*, vol. 88, pp. 132–141, 2017.
- [19] Ö. K. Cura, S. K. Atli, R. Sadighzadeh, and A. Akan, "Classification of epileptic eeg data by using ensemble empirical mode decomposition," in *2018 26th Signal Processing and Communications Applications Conference (SIU)*. IEEE, 2018, pp. 1–4.
- [20] A. Zhang, B. Yang, and L. Huang, "Feature extraction of eeg signals using power spectral entropy," in *2008 international conference on BioMedical engineering and informatics*, vol. 2. IEEE, 2008, pp. 435–439.
- [21] A. Ibáñez, C. Bielza, and P. Larrañaga, "Cost-sensitive selective naive bayes classifiers for predicting the increase of the h-index for scientific journals," *Neurocomputing*, vol. 135, pp. 42–52, 2014.
- [22] Z. Liang, Y. Li, and P. Shi, "A note on two-dimensional linear discriminant analysis," *Pattern Recognition Letters*, vol. 29, no. 16, pp. 2122–2128, 2008.
- [23] J. Maillo, S. Ramírez, I. Triguero, and F. Herrera, "knn-is: An iterative spark-based design of the k-nearest neighbors classifier for big data," *Knowledge-Based Systems*, vol. 117, pp. 3–15, 2017.
- [24] E. Sayilgan, Ö. K. Cura, and Y. İşler, "Use of clustering algorithms and extreme learning machine in determining arrhythmia types," in *2017 25th Signal Processing and Communications Applications Conference (SIU)*. IEEE, 2017, pp. 1–4.
- [25] A. Baratlou, M. Hosseini, A. Negida, and G. El Ashal, "Part 1: simple definition and calculation of accuracy, sensitivity and specificity," 2015.