

See discussions, stats, and author profiles for this publication at: <https://www.researchgate.net/publication/274696224>

Migren Tanısında Öz Bağımlı BURG ve Alt Uzay Temelli MUSIC Yöntemlerin Destek Vektör Makineleri ile Karşılaştırılması

Conference Paper · April 2010

CITATIONS

2

READS

198

3 authors, including:



Selahaddin Batuhan Akben
Osmaniye Korkut Ata university

50 PUBLICATIONS 156 CITATIONS

[SEE PROFILE](#)



Abdulhamit Subasi
Effat University

201 PUBLICATIONS 6,285 CITATIONS

[SEE PROFILE](#)

Some of the authors of this publication are also working on these related projects:



PhD Thesis [View project](#)



Comparison of Different Feature Extraction and Machine Learning Techniques in EEG-Based Wireless BCI System in a Cloud [View project](#)

Migren Tanısında Öz Bağlanımlı BURG ve Alt Uzay Temelli MUSIC Yöntemlerin Destek Vektör Makineleri ile Karşılaştırılması

Comparison of Sub-Space Based MUSIC and AR BURG Methods in Diagnosis of Migraine By Support Vector Machines

Selahaddin Batuhan AKBEN¹, Abdülhamit Subaşı², Mahmut Kemal Kıymık³

1. Bahçe Meslek Yüksek Okulu
Osmaniye Korkut Ata Üniversitesi
batu130@hotmail.com.tr

2. Department of Computer Engineering,
International Burch University
asubasi@ibu.edu.ba

3. Elektrik ve Elektronik Mühendisliği Bölümü
Kahramanmaraş Sütçü İmam Üniversitesi
mkemal@ksu.edu.tr

Özetçe

Migren henüz tam olarak sebebi bilinmeyen zonklayıcı ve ağrılı bir beyin hastalığıdır. Migren hastalığının biyomedikal cihazlarla teşhisine dair son zamanlarda önemli çalışmalar yapılmıştır. Bu çalışmalarda genelde hastalığı tetikleyici bir etken olan flaş ışığı uyarıtısı sıkça kullanılıp bu ışık uyarıtısı sonucu hastalardaki EEG sinyallerinin değişimi izlenmiştir. Işık uyarıtısı ile elde edilen bu sonuçlardan en önemlisi ise ışık uyarıtısı altında migren hastalarının 13-30Hz frekans aralığındaki sinyallerinde genlik artışının görülmesidir. Bu çalışmada ise ışık uyarıtısı ile tetiklenmiş migren hastalarından alınan EEG işaretlerinin frekansa göre genlik artışını belirlemede kullanılacak frekans-genlik analizi metotları incelenmiştir. Çalışmamızda sağlıklı ve migren hastalarından alınan EEG işaretleri Öz bağlanımlı metot olan (AR) Burg metodu ve Alt Uzay temelli metot olan MUSIC metodu ile frekans eksenine dönüştürülmüştür. Elde edilen sonuçlar güç spektral yoğunluk grafikleri ile karşılaştırılmış ve destek vektör makinesi sınıflandırma metoduyla bu karşılaştırma sonuçları incelenmiştir. Elde edilen bu performans sonuçlarına göre hangi frekans-genlik oluşturma yönteminin migren hastalığının teşhisinde daha verimli olduğu belirlenmiştir.

Abstract

Migraine disease is a painful and throbbing brain disorders. Important studies have done about automatic diagnose method of migraine by biomedical equipment. In these studies Flash stimulation which is a triggering factor of migraine used as a triggering factor and EEG signals of migraine

patient obtained results by flash stimulation is observed. Most important result of these flash stimulation based analyze method is magnitude increasing have observed at the 13-30Hz ranged frequency EEG signals of migraine patient. In this study performance of frequency domain transform methods which can be used for determining the magnitude increasing of migraine patient's EEG signals are researched. In our study EEG signals obtained from both migraine patients and healthy subjects are transformed to frequency domain by using (AR) Burg method which is a Autoregressive based method and (MUSIC) method which is a Sub-space based method. Obtained results by using these methods are compared by observing the power spectral density (PSD) graphics and support vector machine classification method is used again for performance analysis of these methods again. According to obtained performance result of these methods which transform method is more useful for diagnosis of migraine is determined.

1. Giriş

Migren insan hayatını zorlaştıran önemli bir beyin hastalığıdır. Migren hastalığının sebebi tam olarak bilinmemekle beraber teşhisi de güçtür [1]. Çünkü migren yalnızca hastanın ağrı tarifine dayanarak teşhisi koyulan bir hastalıktır. Bu nedenle son zamanlarda biyomedikal cihazlar ile otomatik migren teşhisi koymaya yönelik birçok çalışma yapılmıştır [2,3]. Bu çalışmalarda en çok kullanılan yöntem ise göze flaş ışığı verilerek suni bir şekilde migren hastalığı belirtilerini oluşturmak ve bu ışık uyarıtısı altında elektroensefalograf (EEG) işaretlerinin

değişimi gözlemlemektir [2,3,4]. Çünkü ışık migren hastalığı için önemli bir tetikleyici faktördür ve migren hastalığı ışık miktarı ve ışığın değişimine göre başlayabilen bir hastalıktır. Yapılan bu çalışmalarda kullanılan EEG cihazı beyindeki elektriksel aktiviteyi ölçme işlemi yapar. EEG işaretleri genelde 0-500 Hz arasındadır. Ancak bu işaretlerin 0 ile 30 Hz frekans aralığındaki verileri incelenir. Çünkü bu aralıktaki sinyaller klinik ve fizyolojik olarak önem taşır. Bu frekans aralığı ise belirli frekans bantlarına ayrılmıştır. İncelenen bu frekans aralığı ise temelde delta (0.5-4Hz), teta (4-8Hz), alfa (8-13 Hz) ve beta (13-30Hz) şeklinde dört frekans bandına ayrılmıştır. Işık uyarıtısı kullanılarak yapılan migren teşhisine yönelik araştırmaların en önemlisi ise ışık uyarıtısı verilen migren hastalarının EEG işaretlerinin beta bandındaki (13-30 Hz) genliklerinde artış olurken sağlıklı insanlarda bu artışın meydana gelmediğidir [2]. Bu metoda dayalı migren teşhisinde EEG işaretlerinin frekans spektrumu görsel Burg (AR) metodu ile belirlenmeye çalışılmıştır. Ancak hangi frekans spektrumu oluşturma yönteminin migren teşhisi için daha kullanılabilir olduğu incelenmemiştir. Bu nedenle çalışmamızda Öz Bağlanımlı Burg (AR) ve Alt Uzak temelli (MUSIC) yöntemleri ile elde edilen EEG işaretlerinin güç spektrumları incelenmiş ve hangi yöntemin daha kullanılabilir olduğu belirlenmiştir. Bu yöntemlerin performans analizi için öncelikle yöntemlerden elde edilen güç spektral yoğunluk grafikleri incelenmiş ve sonrasında destek vektör makinesi sınıflandırma metodu ile hangi yöntemin daha yüksek başarı sağladığı bulunmuştur.

2. Materyal ve Metot

2.1. EEG Veri Toplama

Bu çalışmada 20-35 yaş arasındaki sağlıklı ve migrenli kişilere ait kullanılan EEG verileri kullanılmıştır. Bu veriler Kahramanmaraş Sütçü imam Üniversitesi Nöroloji bölümünden alınmıştır. Sağlıklı kişilerde herhangi bir beyin rahatsızlığı bulunmamaktadır. Migrenliler ise migren teşhisi IHS (International Headache Society) kriterlerine göre konulmuştur. Migrenlilerin migrenin dışında herhangi bir hastalığı bulunmamaktadır. Çekim sırasında ve çekimden 1 gün öncesine kadarki sürede migren hastalarında migren atağı meydana gelmemiştir. Her iki migrenli ve sağlıklı kişiler çekimden 1 hafta öncesinde herhangi bir ilaç kullanmamıştır. Analiz için seçilen kanal bipolar T5-T3 kanalıdır. Uluslararası 10-20 elektrot yerleştirme sistemine göre elektrotlar, yerleştirilmiştir. Uyarıcı olarak kullanılan flaş ışığının frekansı 4 Hz olarak seçilmiştir. Alınan işaretler 256 Hz örnekleme frekansıyla örneklenecek sayısalştırılmıştır.

2.2. Öz Bağlanımlı (AR) parametre tahmini

Bir $x(n)$ veri dizisinin rasyonel bir sistem tarafından karakterize edilen, lineer bir sistemin çıkışı olarak modellenmesi temeline dayanan model-tabanlı yöntemler aynı zamanda parametrik yöntemler olarak da bilinir. Model tabanlı metotlarda güç spektral yoğunluğu (PSD) tahmini, veri dizisi ve tahmin edilen metot parametreleri

kullanılarak hesaplanır. AR modelleme yönteminde, işaretin belli bir anındaki genliği daha önceki örneklenmiş kısımların örneklerinin genliklerinin farklı oranlarda toplanması ve bu toplama bir tahmin hatasının eklenmesi sonucu elde edilir. AR metodu çok yaygın kullanıma sahiptir Çünkü AR model parametreleri lineer denklemlerin çözümüyle elde edilir. Veri, girişi beyaz gürültü olan nedensel, tüm-kutuplu ayırık filtre çıkışı olarak modellenebilir. Derecesi p olan AR model,

$$x(n) = -\sum_{k=1}^p a(k)x(n-k) + w(n) \quad (1)$$

İfadesiyle verilir. Burada $a(k)$ AR katsayıları ve $w(n)$ varyansı σ^2 olan beyaz gürültüdür. AR(p) modeli, $\{a[1], a[2], \dots, a[p], \sigma^2\}$ AR model parametreleriyle karakterize edilir. Bu durumda güç spektral yoğunluğu

$$P_{(AR)}(f) = \frac{\sigma^2}{|A(f)|^2} \quad (2)$$

İfadesi ile bulunur burada

$$A(f) = 1 + a_1 e^{-j2\pi f} + \dots + a_p e^{-j2\pi p f} \quad (3)$$

Şeklinde dir. Genlik oranlarını belirleyen AR katsayıları çeşitli yöntemler kullanılarak hesaplanabilir. Levinson-Durbin ve Burg algoritmaları bu yöntemler arasındadır. Burg yönteminde AR katsayıları işaretten alınan örneklere dayanan ileri-geri hataları ile bulunur. Filtrenin, yani modelin derecesi AR katsayılarının sayısı ile belirlenir[7].

2.3. Burg Metodu

Burg metodu AR model parametrelerinin tahmininde ileri geri yöndeki tahmin hatalarının minimize edilmesine ve yansıma katsayısı tahminine dayanır. Bu metotta doğrudan yansıma katsayısı tahmini yapılır. p . derece model için ileri ve geri tahmin hataları aşağıdaki gibi tanımlanır.

$$\hat{e}_{f,p}(n) = x(n) + \sum_{i=1}^p \hat{a}_{p,i} x(n-i), \dots, n = p+1, \dots, N \quad (4)$$

$$\hat{e}_{b,p}(n) = x(n-p) + \sum_{i=1}^p \hat{a}_{p,i}^* x(n-p+i), \dots, n = p+1, \dots, N \quad (5)$$

Yansıma katsayısı \hat{k}_p ile ilişkili AR katsayıları eşitlik (6)'de verilmiştir.

$$\hat{a}_{p,i} = \begin{cases} \hat{a}_{p-1,i} + \hat{k}_p \hat{a}_{p-1,p-i}^*, & i = 1, \dots, p-1 \\ \hat{k}_p, & i = p \end{cases} \quad (6)$$

Yansıma katsayısı tahmini

$$\hat{k}_p = \frac{-2 \sum_{n=p+1}^N \hat{e}_{f,p-1}(n) \hat{e}_{b,p-1}^*(n-1)}{\sum_{n=p+1}^N \left[\left| \hat{e}_{f,p-1}(n) \right|^2 + \left| \hat{e}_{b,p-1}^*(n-1) \right|^2 \right]} \quad (7)$$

İfadesi ile verilir. İleri ve geri yöndeki tahmin hataları aşağıda verildiği gibi olup, bu ifadeler AR katsayılarının tahmininde kullanılır.

$$\hat{e}_{f,p}(n) = \hat{e}_{f,(p-1)}(n) + \hat{k}_p \hat{e}_{b,p-1}(n-1) \quad (8)$$

$$\hat{e}_{b,p}(n) = \hat{e}_{b,(p-1)}(n-1) + \hat{k}_p^* \hat{e}_{f,p-1}(n) \quad (9)$$

AR parametrelerinin tahmininden, güç spektral yoğunluğu (PSD) aşağıdaki şekilde hesaplanır.

$$\hat{P}_{BURG}(f) = \frac{\hat{e}_p}{\left| 1 + \sum_{k=1}^p \hat{a}_p(k) e^{-j2\pi fk} \right|^2} \quad (10)$$

Burada $\hat{e}_p = \hat{e}_{f,p} + \hat{e}_{b,p}$ toplam en küçük karesel hatadır [7,8,9]. Parametrelerin tahmin edilmesinde Burg metodu işlemsel olarak verimli bir metot olup, kararlı bir AR metodu verir. Bu metotta en önemli nokta model derecesinin seçilmesidir. Bunun için pek çok öneri literatürde bulunmaktadır. Fakat bunlardan en çok tercih edileni ise Akaike information criterion (AIC) dir [9]. Çalışmamızda AIC ölçütüne göre model derecesi 10 olarak seçilmiştir.

2.4 Alt Uzak Metotları

Yüksek çözünürlük metotları olarak da bilinen alt uzak metotlarında bir işaretin korelasyon matrisinin eigen analizi temelli frekans bileşeni tahminleri yapılır. Bu kategoride yer alan metotlar başlıca katlı işaret sınıflandırma(MUSIC) ve eigen vektör(EV) metotlarıdır. Bu metotlar özellikle sinüzoidal işaretlerin spektrumlarının oluşturulmasına uygundur ve özellikle düşük işaret gürültü oranlı, gürültüye gömülmüş sinüzoidlerin belirlenmesinde etkilidirler.

2.5 MUSIC metodu

Gürültü alt uzayına karşılık gelen tüm eigen vektörlerin ortalaması alınmış spektrumunu kullanarak şüpheli sınıfların etkisini ortadan kaldıran MUSIC (multiple signal classification) metodu Schmidt [10] tarafından önerilmiş bir alt uzak frekans tahmincisi olup, güç spektral yoğunluğu (PSD) aşağıdaki ifadeye gösterilmiştir.

$$P_{MUSIC}(f) = \frac{1}{1/K \sum_{i=0}^{K-1} |A_i(f)|^2} \quad (11)$$

Burada K gürültü alt uzayının boyutudur, $A_i(f)$ ise gürültü alt uzayının tüm öz vektörlerine karşılık gelen istenen polinomdur.

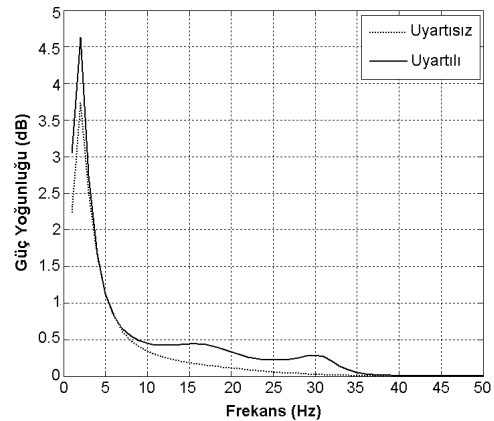
2.6 Destek Vektör Makineleri

Destek vektör makineleri (Support Vector Machine - SVM), son yıllarda yaygın olarak kullanılan bir sınıflandırma algoritmasıdır. Temelde doğrusal olarak ayrıştırılabilir iki sınıfın karar yüzeyinin destek vektörler


olarak tanımlanan ve sınıf sınırlarını belirleyen örnekler arasında maksimum uzaklığın oluşturulması ilkesine dayanır. Uzaklığın en büyükleştirilmesi işlemi bir kuadratik sınırlamalı optimizasyon problemi şeklinde yazılır ve dual forma dönüştürülür. Doğrusal problemler için geliştirilen bu yaklaşım doğrusal olmayan ayrıştırma problemleri için kernel dönüşümleri kullanılarak genelleştirilebilir [11]. SVM algoritması kullanılan verinin geometrik dağılımına dayalı olarak uzaklığı en büyük ölçüye taşır. SVM normalde ikili sınıflandırma problemlerini çözebilen bir algoritmadır. Çoklu sınıflandırmanın gerekli olduğu uygulamalarda ise biri-diğeri (one vs one) ve biri-diğerleri (one vs rest) şeklinde iki çerçeve tanımlanarak ikili sınıflandırıcı SVM yapısı çoklu sınıflandırıcı olarak kullanılabilir. Çalışmamızda doğrusal SVM kullanılmıştır. SVM sınıflandırıcının girişlerinde her iki migrenli ve sağlıklı kişilerin ışıklı ve ışısız işaretlerinden BURG ve MUSIC yöntemleriyle elde edilen güç frekans spektrum değerleri kullanılmıştır. Hedef değerler sağlıklı kişiler için [0], migren hastaları için [1] olarak belirlenmiştir. Ve performans ölçütü olarak karşılıklı geçerlilik hata oranı kullanılmıştır.

3. Sonuçlar

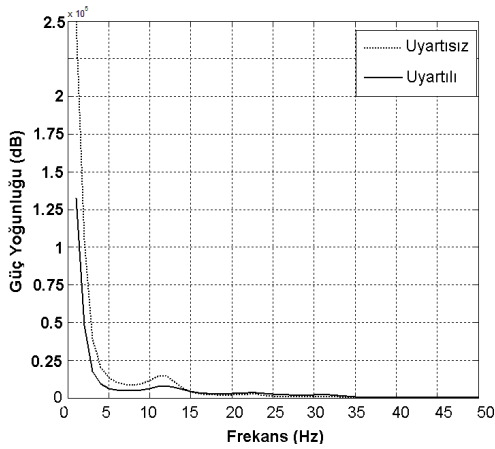
Şekil 3 ve şekil 4'ten görüldüğü gibi MUSIC yöntemi ile elde edilen grafiklerde bir genlik atışının varlığı gözükmediğinin yanı sıra, bu yöntemde elde edilen grafiklerde birçok yanlış pik'e rastlanmıştır. Örneğin Şekil 3'e bakıldığında uyarısız durumdaki sağlıklı kişisi EEG sinyalinde alfa bandında hatalı bir pik gözükmektedir. Şekil 4'e bakıldığında ise migren hastasının uyarısız durumdaki EEG sinyalinde teta bandında bir hatalı pik gözükmektedir. Ve yine Şekil 4'e bakıldığında migren hastasının EEG işaretinde ışık uyarıtısı ile oluşması gereken genlik artışı çok küçük kalmıştır. Oysa Şekil 1'e bakıldığında hatalı pikler yoktur ve ışık uyarıtısı altındaki migren hastasının EEG sinyalindeki genlik artışı net bir şekilde görülmektedir. Yine Şekil 2'ye bakıldığında da hatalı pik olmadığı ve ışık uyarıtısının normal kişide herhangi bir genlik artışı meydana getirmedeği görülmektedir.




Şekil 1: Migren hastası için BURG metoduyla oluşturulmuş güç-frekans spektrumu



Şekil 2: Sağlıklı kişi için BURG metoduyla oluşturulmuş güç-frekans spektrumu



Şekil 3: Migren hastası için MUSIC metoduyla oluşturulmuş güç-frekans spektrumu



Şekil 2: Sağlıklı kişi için MUSIC metoduyla oluşturulmuş güç-frekans spektrumu

Çizelge 1 SVM algoritmasıyla sınıflandırılmış sağlıklı ve migrenli veriler için elde edilen performans değerlerini göstermektedir. Sonuçlara bakıldığında BURG yönteminin MUSIC yöntemine göre daha kullanışlı olduğunu ve MUSIC yönteminin migren teşhisi için başarısız olduğunu göstermektedir. Bu sonuçlar aynı zamanda PSD grafiklerini doğrular niteliktedir.

Çizelge 1. SVM Sınıflandırıcı Performansı (%)

	Migreni Doğru Tespit Oranı	Sağlıklı Doğru Tespit Oranı	Doğruluk
BURG	86,7	93,3	90
MUSIC	73,3	86,7	80

4. Tartışma

Bu çalışmada migren hastalığı teşhisinde EEG işaretlerinin spektrumlarının incelenmesi için model-tabanlı metotlardan öz bağımlı (AR) Burg metodu kullanılmıştır ve alt uzay metotlarından MUSIC (Multiple Signal Classification) metodu kullanılmıştır. Elde edilen spektrumlarla frekans çözünürlüğü ve migren hastalığının teşhisini belirlemek amacıyla karşılaştırılmıştır. BURG metoduyla elde edilen spektrumların MUSIC metoduyla elde edilen spektrumlara göre migrendeki ışık uyarıtısı altındaki genlik artışını daha iyi gösterdiğini ortaya koymuştur. Aynı zamanda MUSIC metodunda birçok hatalı pikler bulunduğu da belirlenmiştir.

5. Kaynakça

- [1] W. E. Waters, P. J. O'Connor, Prevalence of migraine, Journal of Neurology, Neurosurgery, and Psychiatry. Jun 38 (1975) 613-616.
- [2] S.B. Akben, A. Subasi, D. Tuncel, Analysis of EEG Signals Under Flash Stimulation for Migraine and Epileptic Patients, Journal Of Medical Systems. DOI: 10.1007/s10916-009-9379-1.
- [3] M. De Tommaso, D. Marinazzo, M. Guido, G. Libro, S. Stramaglia, L. Nitti, G. Lattanzi, L. Angelini, M. Pellicoro, Visually evoked phase synchronization changes of alpha rhythm in migraine: correlations with clinical features, Int. J. Psychophysiol. 57 (3) (2005) 203–210.
- [4] Y. Ozkul, B. Gurler, S. Bozlar, A. Uckardes, S. Karadede, Flash visual evoked potentials and electroretinograms in migraine, Neuro-Ophthalmology. 25 (3) (2001) 143–150.
- [5] Ubeyli E D, Guler I. "Comparison of eigenvector methods with classical and model-based methods in analysis of internal carotid arterial Doppler signals", Computers in Biology and Medicine. 33 (2003) 473–493.
- [6] Proakis, J., Manolakis, D., Digital Signal Processing Principles, Algorithms, and Applications. Prentice Hall, USA, 1996.
- [7] P. Stoica, and R. Moses, Introduction to spectral analysis, Prentice-Hall, New Jersey, 1997.
- [8] Signal Processing Toolbox User's Guide– 1988-2002 by The MathWorks, Inc.
- [9] H. Akaike, A new look at the statistical model identification, IEEE Trans. Autom. Control AC. 19 (1974) 716–723.
- [10] R.O. Schmidt., "Multiple emitter location and signal parameter estimation", IEEE Trans. Antennas Propag. AP. 34 (3) (1986) 276–280.
- [11] Cristianini, N., & Shawe-Taylor, J. "An introduction to support vector machines." Cambridge: Cambridge University Press, 2000.