



KONJESTİF KALP YETMEZLİĞİNİN HİLBERT-HUANG DÖNÜŞÜM İLE ANALİZİ

(ANALYSE OF CONGESTIVE HEART FAILURE USING HILBERT- HUANG TRANSFORM)

Gökhan ALTAN¹, Abdullah YAYIK², Yakup KUTLU³, Serdar YILDIRIM⁴, Esen
YILDIRIM⁵

ÖZET/ABSTRACT

Hilbert-Huang Dönüşümü (HHD) liner olmayan ve sabit olmayan sinyaller üzerinde öznitelik çıkartma, filtreleme gibi işlemlerde sıkça kullanılan bir yöntemdir. Bu çalışmada, HHD yönteminin kalp sinyallerine uygulanması sonucu özniteliklerin belirlenmesi ve belirlenen bu özniteliklerin Kongestif Kalp Yetmezliği (KKY) olan hastaların kontrol grubundan ayırt edilerek sınıflama yapılması üzerine bir çalışma yapılmıştır. Kalp hızı değişkenlerinden elde edilen RR sinyalleri, HHD işleminden geçirilerek içsel mod fonksiyonları (İMF) bileşenleri elde edilmiş, dönüşüm sonrası elde edilen sinyallerin istatistiksel bilgileri öznitelik olarak belirlenmiştir. Elde edilen öznitelikler, Yapay Sinir Ağları (YSA) kullanılarak sınıflandırma başarımı incelenmiştir. Sonuç olarak, RR sinyallerden elde edilen İMF bileşenlerin istatistiksel öznitelikleri kullanılarak sınıflama işleminde iyi sonuçlar alınabileceğini göstermiştir.

Hilbert-Huang Transform(HHT) is a method that is often used for feature extraction, filtering and similar processes on nonlinear and non-stationary signals. In this study, HHT is used for feature extraction that can be obtained from applying to Heart Rate variability signals and studied on classifying by distinguishing Congestive Heart Failure (CHF) patients from the control group of patients by selected features. Instrict Mode Functions (IMF) components are sifted by applying HHT to RR signals obtained from the heart rate variability, statistical informations of the signals obtained after the transformation have been set as features. Classification accuracy of Obtained statistical features are analyzed with Artificial Neural Networks (ANN). In conclusion, using statistical features of IMF components transformed from RR signals shows good classification results can be taken.

ANAHTAR KELİMELER/KEYWORDS

Konjestif kalp yetmezliği, Yapay sinir ağları, HHD, İMF
Congestive heart failure, Artificial neural network, HHT, IMF

¹ Bilgisayar Mühendisliği Bölümü, Mustafa Kemal Üniversitesi, HATAY, gokhanaltan@mku.edu.tr

² Kara Kuvvetleri Komutanlığı, ayayik@kkk.tsk

³ Bilgisayar Mühendisliği Bölümü, Mustafa Kemal Üniversitesi, HATAY, ykutlu@mku.edu.tr

⁴ Bilgisayar Mühendisliği Bölümü, Mustafa Kemal Üniversitesi, HATAY, serdar@mku.edu.tr

⁵ Bilgisayar Mühendisliği Bölümü, Mustafa Kemal Üniversitesi, HATAY, eyildirim@mku.edu.tr

1. GİRİŞ

Sinyal analizinde, birçok dönüşüm yöntemi kullanılmaktadır. Fourier Dönüşümü, Laplace Dönüşümü, Hilbert Dönüşümü, Wavelet Dönüşümü ve diğerleri bu integral dönüşümlerin en önemlilerindedir (Johansson, 1999). Gün geçtikçe artan çalışmalar sonrasında lineer ve sabit olmayan veriler üzerindeki imkânları genişleten tekniklere ihtiyaç duyulmuştur. HHD bunlardan biridir. HHD, veri analizi konusunda yeni sayılabilecek kullanıma sahip bir metottur. Bu dönüşüm lineer olmayan ve sabit olmayan sinyaller için uygulanabilir niteliktedir (Huang vd., 1998).

Literatürde her yıl artan ivmeyle çeşitli araştırmalarda HHD yöntemi kullanılmıştır. Bu çalışmaların bazılarını bakıldığında, HHD, EEG sinyalleriyle incelenerek şeker hastalığının tespiti, epileptik nöbet tahmini, ses sinyallerini HHD uygulanması filtreleme ve öznelik çıkarma işlemleri, spektrum algılamasına yönelik sayısal modülasyon sınıflandırması, EKG sinyallerinde kalp kulakçığı seğirmesi rahatsızlığının tespiti gibi birçok çalışmada kullanılan bir araç olmuştur (Bursikova, 2007; Duman vd., 2012; Vemer, 2007; Tanç ve Akan, 2013; Maji vd., 2013). Bu çalışmada HHD yöntemi, KKY hastalarını normal insanlardan ayırmak için kullanılacaktır. KKY, organizmanın metabolik ihtiyaçlarını karşılayacak yeterli kardiyak debinin kalp tarafından sağlanamaması halidir. Kalp, ihtiyaç duyduğu durumlarda debi kapasitesini % 200-600 oranında arttırabilir. Kalbin bu arttırılabilen debi kapasitesinin aşılması veya artan debi ihtiyacını karşılayamaması durumunda KKY rahatsızlığı teşhisi konur (İşler ve Kuntalp, 2007).

Bu çalışmada, KKY hastalığının teşhis edilmesinde HHD yöntemiyle elde edilen öznelikler incelenmiş, başarımlar değerleri belirlenmiş ve karşılaştırmalar grafiklerle gösterilmiştir.

2. YÖNTEM

2.1. Hilbert-Huang Dönüşümü (HHD)

HHD, doğrusal olmayan ve durağan olmayan süreçlerin analizi için kullanılan uyarlamalı bir yöntemdir. Algoritmanın matematiksel ifadesi durma değerlerinin esnekliği sebebiyle keskin ve net bir şekilde tanımlanamamıştır (Hou ve Tian, 2010). HHD, iki aşamalı bir analiz yöntemidir. İlk olarak Ampirik Mod Ayırma (AMA) ile sürece ilişkin sinyalin, her biri frekans modülasyonlu birer işaret olan İMF çıkartılır. Elde edilen her bir İMF'den Hilbert İzgesel Analizi (HİA) ile zaman-frekans alanında anlık frekans ve genlik değerleri elde edilir. HHD doğrusal olmayan ve durağan olmayan süreçlerin zaman-frekans-enerji gösterimlerinde, diğer yöntemlerden daha keskin, ayırt edici ve net sonuçlar verir (Huang vd., 1998).

2.1.1. Ampirik Mod Ayırımı (AMA)

Doğrusal olmayan ve durağan olmayan süreçlere ait veriler için kullanılan esnek bir analiz yöntemidir. Diğer dönüşümlerden ayrıldığı en önemli özelliği rasgele bir işaretin, kendine ait farklı frekanslardaki öz kip salınımlarından oluştuğu varsayımıyla sinyalden ayrı salınımlar üreten bir algoritma olmasıdır. Her salınım yerel uç noktalarıyla elde edilen yerel ortalamalarına göre simetriklerdir. Her bir farklı salınım İMF ile gösterilir. İMF aşağıdaki iki temel koşulu sağlayacak şekilde seçilir (Huang vd., 1998; Hou ve Tian, 2010). Tüm sinyalde, yerel uçdeğerlerin ve sinyalin sıfırdan geçişlerin sayısı ya aynı olmalı ya da farkları 1'e eşit olmalıdır.

Herhangi bir t anında, yerel maksimumların ve yerel maksimumların birleştirilmesiyle elde edilen üst ve alt zarfın ortalama değeri sıfır olmalıdır.

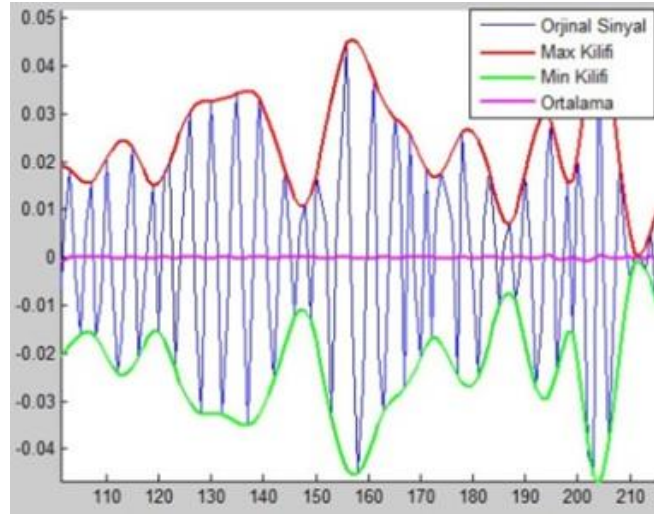
İMF'ler elde edilirken belirtilen şartları, HİA ile anlık frekans değerleri hesaplanırken negatif frekansların oluşmasını önlemek ve dar bantlı sinyallerin anlık frekans değerlerini, bantta tutmak için kullanılır.

AMA işleminde, yerel maksimumlar tarafından belirlenen üst zarf ile yerel minimumlar tarafından belirlenen alt zarfın ortalaması alınarak yerel ortalama değeri bulunur. Şekil 1'de görülmektedir.

Bulunan ortalama değer asıl sinyalden çıkarılarak elde edilen yeni sinyalin İMF olma koşulunu sağlayıp sağlamadığı kontrol edilir. Eğer sağlamıyorsa tekrar yerel maksimum ve yerel minimum değerleri kullanılarak yerel ortalama değeri tekrar hesaplanır. Bu işlem elde edilen sinyal İMF oluncaya kadar gerçekleştirilir. Bu sinyal, asıl sinyalden çıkarılarak artık sinyal elde edilir ve aynı İMF oluşturma işlemleri artık sinyal için yapılmaya devam edilerek tüm sinyal için monotonik bir fonksiyon elde edilinceye kadar devam eder.

Sinyal monotonik bir fonksiyon olduğunda ya da sinyalde yalnızca bir adet yerel uç değer olduğunda bu sinyalden İMF çıkarmak mümkün değildir ve AMA işlemine son verilir. AMA işleminden sonra elde edilen İMF içsel mod fonksiyonunu, $r(t)$ artık sinyal ve n algoritmadaki adım sayısını ifade eder (Duman vd., 2012).

$$x(t) = \sum_{i=1}^n \text{İMF}_i(t) + r_n(t) \quad (1)$$



Şekil 1. AMA uygulanan bir KKY sinyali

2.1.2. Hilbert İzgesel Analizi

Doğrusal olmayan sinyallerin en önemli özelliklerin başında tek bir salınım süresinde anlık frekans değerlerini gösteren içsel dalga frekans modülasyonudur. Sinyalin karakteristiğini en anlaşılır şekilde anlık frekans değerleri verir. Anlık frekans değeri Hilbert Dönüşümü (HD) sinyalin karakteristiğini belirlemeye yönelik frekans işlemidir (Huang vd., 1998).

Gerçek değerli $x(t)$ fonksiyonunun HD uygulanmış halinin karmaşık eşleniği $y(t)$ 'ye eşittir.

$$y(t) = H[x(t)] = \frac{1}{\pi} \int_{-\infty}^{\infty} \frac{x(\tau)}{t-\tau} d\tau \quad (2)$$

HD yardımıyla analitik $x(t)$ fonksiyonu aşağıdaki gibi yazılır:

$$z(t) = x(t) + jy(t) = a(t)e^{j\theta(t)} \quad (3)$$

Yukarıdaki ifadede anlık genlik ve faz fonksiyonu şu şekildedir:

$$a(t) = \sqrt{x^2(t) + y^2(t)} \quad (4)$$

$$\theta(t) = \arctan\left(\frac{y(t)}{x(t)}\right) \quad (5)$$

Yukarıdaki fonksiyondan anlık frekans bilgisi elde edilebilir:

$$\omega(t) = \frac{d\theta(t)}{dt} \quad (6)$$

$$f(t) = \frac{1}{2\pi} \frac{d\theta(t)}{dt} \quad (7)$$

$x(t)$ işaretine AMA işlemi uygulandıktan sonra her bir İMF'nin Hilbert Dönüşümü alınırsa $x(t)$ işaretinin analitik ifadesi elde edilebilir. Her bir İMF'nin anlık frekans ve genlik değerleri (4), (5), (6) ve (7) yardımıyla şu şekilde ifade edilir:

$$x(t) = \Re\left\{\sum_{i=1}^n a_i(t) e^{j\omega_i(t)t}\right\} \quad (8)$$

Genliğin frekans-zaman dağılımına $H(\omega, t)$ Hilbert İzgesi denir. Hilbert İzgesi kullanılarak, Marjinal İzgesi de hesaplanabilir (Huang vd., 1998; Duman vd., 2012).

$$h(\omega) = \int_0^T H(\omega, t) dt \quad (9)$$

Yukarıdaki denklem her bir İMF'nin genlik ya da frekans modülasyonlu işaretler olduğunu göstermektedir. AMA, işareti değişken genlik ve frekans ölçeklerinde analiz ederek durağan olmayan işaretler için oldukça iyi bir ayrıştırma işlemi gerçekleştirir (Huang vd., 1998; Duman vd., 2012).

2.2. Veritabanı

Bu çalışmada Physionet veritabanından KKY ve Normal grup RR kayıtları kullanılmıştır (Goldberger ve Amaral, 2000). Yaşları 34 ile 79 arasında değişen, KKY hasta veritabanı, 8 erkek, 2 bayandan alınmıştır. Normal grup veri tabanı yaşları 28 ve 76 arasında değişen 30 erkek ve yaşları 58 ile 73 arasında değişen 24 bayandan alınmıştır. Sinyallerin çok uzun olmasın ve EKG sinyallerinde hastanın anlık durumlarından kaynaklı fazla gürültüye sahip olmasından dolayı, gürültüsüz 3 saatlik formlar alınarak tüm analiz işlemlerinde kullanılmıştır.

2.3. Ön İşlemler ve Özniteliklerin Çıkarılması

Elde edilen sinyaller aynı frekans değerine getirilmiş ve her biri AMA işlemine tabi tutulmuştur. AMA işlemi uygulanmış sinyallerin tüm İMF'lerine HİA uygulanarak aynı sayıda HHD işlemleriyle elde edilmiştir. HHD uygulanmış bir KKY ve normal grup insan EKG RR sinyali ve bu sinyalden elde edilen bazı İMF dağılımı Şekil 2'de görülmektedir. 83 adet sinyale ait, her bir sinyalden 10 ile 14 arasında değişen İMF elde edilmiştir. Burada her kayıt için ilk 10 İMF Öznitelik çıkartmak için kullanılmıştır. Daha sonra Hilbert dönüşümü yapılarak, istatistiksel öznitelik çıkarma işlemleri gerçekleştirilmiştir. Her bir İMF dönüşümüne ait minimum, maksimum, orta değeri, ortalama, varyans, kovaryans, sık tekrar edilen değer, korelasyon katsayısı, enerji ve standart sapma gibi 10 adet öznitelik hesaplanmıştır.

2.4. Sınıflandırma ve Performans Ölçümü

YSA sınıflandırıcı olarak tercih edilmiştir. YSA'da giriş değerleri, ağırlıkları ya da rastgele alınan ağırlıklar ile çıkış değerleri elde edilmektedir. Bu işlem elde edilen çıkış değeri ile gerçek çıkış değeri arasındaki hatayı minimum yapana kadar kat sayıların değişimi sürer. Buna modelin eğitimi denir. Bu eğitimde nöronların ağırlıkları belirlenmiş yapı elde edilir. YSA'nın avantajlarından bazıları; doğrusal olmayan bir yöntem olması, bilinen durumlardaki sonuçları kullanarak bilinmeyen durumlar hakkında karar verebilmesi, paralel çalışması, eğitim sonrası bazen yavaş olmasa da eğitilmiş modelin hızlı olması söylenebilir (Duda vd., 2000).

Elde edilen EKG RR sinyalleri 3'er dakikalık pencereler halinde oluşturulmuştur. Her pencereye AMA işlemi uygulanmıştır. AMA işlemi sonrasında her pencerenin İMF leri belirlenmiştir. Elde edilen İMF'lere Hilbert izgesel analizi uygulanarak HHD işlemi tamamlanmış sinyal elde edilmiştir.

HHD uygulanmış KKY ve normal EKG RR sinyali ve bu sinyalden elde edilen bazı İMF dağılımı Şekil 2'de görülmektedir.

Bu sistemin başarımlarının değerlendirilmesinde, genel başarımlar, belirlilik ve hassasiyet ölçütleri kullanılmıştır (Maji vd., 2013, Duda vd., 2000).


Bir sistemin genel başarımlarının değerlendirilmesinde kullanılan önemli test karakteristikleridir (Duda vd., 2000):

$$\text{Genel Başarımlar} = \frac{TP+TN}{TP+TN+FP+FN} \quad (10)$$

$$\text{Hassasiyet} = \frac{TP}{TP+FN} \quad (11)$$

$$Belirlilik = \frac{TN}{TP+FN} \quad (12)$$

Sınıflandırıcının hasta olarak etiklediği ve gerçekten hasta olanların sayısı TP, gerçekte sağlam olanların sayısı FP olarak tanımlanmıştır. Yine sınıflandırıcının sağlam olarak etiklediği ve gerçekte hasta olanların sayısı, FN, gerçekte sağlam olanların sayısı, TN olarak tanımlanır. Böylece, her bir sınıflandırıcının tüm sağlam ve hasta grubunda doğru olarak verdiği tüm kararlar dikkate alınmıştır.



Şekil 2.KKY ve Normal EKG RR Sinyali ve İMF'leri


3. SONUÇ

Medikal teşhis sistemlerinde hassasiyet ve belirlilik, nüfusun genelindeki rahatsızlıkları belirlemeyen, test için esas alınan hâkim bağımsız test karakteristikleridirler (Bursikova, 2007; Duda vd., 2000). Bu durumlar göz önünde bulundurularak EKG sinyallerinden ele alınan 3 saatlik kalp hızı sinyallerden AMA işlemi sonucu İMF'ler elde edilmiştir. Elde edilen her İMF'nin dönüşüm yönteminden elde edilen öz nitelikleri birleştirilerek veri kümesi oluşturulmuştur. Oluşturulan veri kümesinin üçte biri test için geri kalan kısmı eğitim için kullanılmıştır. Eğitim kümesi için kullanılan değerlerin denekleri rastgele seçilmiş ve deneklerin geri kalanları test kümesi olarak seçilmiştir. Çalışmada Matlab paket program kullanılmıştır. 10 gizli katman, hiperbolik tanjant sigmoid fonksiyonu ile geriye yayılım ağı eğitim fonksiyonu kullanılarak YSA yapısı eğitilmiştir. Rastgele seçilen eğitim kümesinde bulunan öz nitelikler, YSA ile sınıflandırılmış hassasiyet, belirlilik ve genel başarımlar hesaplanmıştır. Bu işlem tüm İMF'ler için yapılmış ve 100 deneme sonucu elde edilen en iyi değerler Çizelge 1'de belirtilmiştir. sonuçlar kendi içerisinde değerlendirildiğinde 3 ve 4 numaralı İMF sinyallerinden elde edilen genel başarımları diğer İMF'lere göre oldukça yüksek olduğu saptanmıştır.

Çizelge 1. YSA Sınıflandırma Sonuçları

	İMF1	İMF2	İMF3	İMF	İMF5	İMF6	İMF	İMF8	İMF9	İMF10
Hassasiyet	71.42	78.57	100,0	92.85	92.85	85.71	85.71	85.71	78.57	78.57
Belirlilik	60.00	70.00	100,0	90,00	87.50	77.77	77.77	75.00	66.67	66.67
G.Başarı	69.56	78.27	95.65	95.65	86.95	82.60	82.60	78.26	73.91	69.56

% 95.65 gibi genel başarımları sonucu elde edildiği görülmüştür. Genel başarımların yanında sistemin güvenilirliğini ölçen Hassasiyet ve Belirlilik değerlerine göre de daha yüksek olduğu görülmektedir. Şekil 3'te performans grafiksel olarak gösterilmiştir. Elde edilen bu verilere göre, HHD yöntemi ile elde edilen istatistiksel öznitelikler ile KKY olup olmadığının belirlenmesi için sadece 3 numaralı İMF ile % 95.65 Genel Başarımları, % 100 Hassasiyette ve % 100 Belirlilikte tespit edilebilmektedir.



Şekil 3. Performans grafiği


HHD yöntemi uygulanan EKG sinyallerinden elde edilmiş her bir İMF tek başına ele alındığında sonuçların yanısıra İMF'lerin sırayla birlikte kullanılarak etkileri incelenmiştir (Şekil 3). Öncelikle sadece 1 nolu İMF ele alınarak elde edilen öznitelikler ile sistemin başarımları hesaplanmıştır. Sonrasında her İMF sırayla eklenerek yeni veri kümeleri Çizelge 2'de gösterildiği gibi oluşturulmuş ve sistemin başarımları her küme oluşumunda yeniden hesaplanmıştır. Elde edilen sonuçlar grafik olarak Şekil 4'de gösterilmiştir.

Şekil 4'te de görüldüğü gibi ilk İMF'lerden gelen öznitelikler sırayla alındığında başarımları İMF4'ten gelen özniteliklere kadar arttırırken sonraki İMF'lerden gelen öznitelikler başarımları değiştirmemiş veya düşürmüştür.

Bir diğer çalışma İMF seçim uygulaması gerçekleştirilmiştir. İleri yönlü öznitelik seçim algoritması temeline dayanan bu yöntemde bireysel olarak en iyi sonucu veren İMF'den alınan öznitelikler ile başlar. İlk seçilen İMF ile birlikte en iyi başarımları veren İMF (İMF'ten alınan öznitelikler) kümeye dahil edilir. Böylece ikinci İMF seçilmiş olur. Sonraki bu iki İMF ile birlikte en iyi başarımları veren İMF kümeye dahil edilir. Böylece üçüncü İMF seçilmiş olur. Bu şekilde seçim döngüsü tekrarlanarak Çizelge 3'te belirtildiği gibi kümeler oluşturulur ve sınıflandırma sonuçları ise grafik olarak Şekil 4'de gösterilmiştir.

Çizelge 2. Öznitelikleri birleştirilen İMF'lerin kümelere dağılımı


Küme 1	Küme 2	Küme 3	Küme 4	Küme 5	Küme 6	Küme 7	Küme 8	Küme 9	Küme 10
İMF1	Küme 1 ve İMF2	Küme 2 ve İMF3	Küme 3 ve İMF4	Küme 4 ve İMF5	Küme 5 ve İMF6	Küme 6 ve İMF7	Küme 7 ve İMF8	Küme 8 ve İMF9	Küme 9 ve İMF10



Şekil 4. İMF'lerin sırayla birlikte performans grafiği

Çizelge 3. İleri yönlü İMF seçim algoritması İMF'lerin kümelere dağılımı

Küme 1	Küme 2	Küme 3	Küme 4	Küme 5	Küme 6	Küme 7	Küme 8	Küme 9	Küme 10
İMF3	Küme 1 ve İMF6	Küme 2 ve İMF8	Küme 3 ve İMF9	Küme 4 ve İMF10	Küme 5 ve İMF1	Küme 6 ve İMF5	Küme 7 ve İMF2	Küme 8 ve İMF4	Küme 9 ve İMF7



Şekil 5. İleri yönlü İMF seçimi algoritması performans grafiği

Şekil 5'te gösterildiği gibi ileri yönlü İMF seçim algoritması, en iyi başarıyı veren 3 nolu İMF ile başlayıp, en iyi başarıyı verme durumuna göre sırasıyla 6, 8, 9, 10, 1, 5, 2, 4 ve 7

numaralı İMF'ler sırayla eğitim kümesine dahil edilerek sistemin başarımları hesaplanmıştır. Hesaplamalar sonunda başarımların değerleri 2 nolu Kümeden başlayarak % 11 ile % 2 aralığında düşüşe sebep olmuştur.

KKY hastalığını teşhisi için Şekil 4'e bakıldığında ilk dört İMF'ten gelen özniteliklerin en iyi başarımla sahip olması veya Şekil 5'e bakıldığında sadece İMF3 ile en iyi başarımları elde ediyor olmamız, ilk üç İMF elde edilmesiyle elde edilecek özniteliklerin yeterli olacağını göstermektedir.

Literatürde KKY hastalığını teşhisi için çok farklı yöntemler kullanılarak öznitelikler çıkartılmıştır. Bunlar içinde, % 96.39 genel başarımla poicare fark değerlerini ve istatistiksel değerleri, % 96.39 genel başarımla EKG sinyalinin öz değerleri, % 100 genel başarımla ikinci derece fark harita grafiği verileri, % 66 ile % 100 arasında değişen başarımlarla genlikte ve zamanda eşit frekans yöntemi, % 98.93 genel başarımla kalp hızı değişkenlerinin normalleştirilmesi gibi farklı değerlerini sınıflandırıcıda öznitelik olarak kullanmıştır (İşler ve Kuntalp, 2007; Ubeyli, 2009; Thuraisingham, 2009; Orhan, 2013; İşler ve Kuntalp, 2010).

HHD metodunun, işareti değişken genlik ve frekans ölçeklerinde analiz ederek durağan olmayan işaretler için oldukça iyi bir ayrıştırma işlemi gerçekleştirdiği gözlemlenmiştir.

KAYNAKLAR

- Bursikova S. (2007): "Application of Hilbert-Huang Transform to the Data of Blood Glucose Profile", Student's Conference STC 2007, Faculty of Mechanical Engineering, Czech Teknik Universitesi.
- Duda R. O., Hart P. E., Stork D. G. (2000): "Pattern Classification", 2. Basım, Wiley, New York, s.545,556.
- Duman F., Özdemir N., Yıldırım E. (2012): "Patient Specific Seizure Prediction Algorithm Using Hilbert-Huang Transform", IEEE-EMBS Intern. BHI 2012, s.705-708 .
- Goldberger A. L., Amaral L. A. N. (2000). "PhysioBank, PhysioToolkit, and PhysioNet", Cilt 101, No. 23, s.215-e220.
- Hou Y., Tian H. (2010): "An Automatic Modulation Recognition Algorithm Based on HHT and SVD", Image and Signal Processing(CTSP), Cilt 8, s.3577-3581.
- Huang A. B. N. E., Shen Z., Long S. R., Wu M. L., Shih H. H., Zheng Q. (1998): "The Empirical Mode Decomposition and Hilbert Spectrum for Nonlinear and Nonstationary Time Series Analysis", Londra A, Cilt 454, s.903-995.
- İşler Y., Kuntalp M. (2007): "Combining Classical HRV Indices with Wavelet Entropy Measures Improves to Performance in Diagnosing Congestive Heart Failure", Comput. Biol. Med., Cilt. 37, No. 10, s.1502-10.
- İşler Y., Kuntalp M. (2010): "Heart Rate Normalization in the Analysis of Heart Rate Variability in Congestive Heart Failure", Proceedings of the IMechE Part H: Journal of Engineering in Medicine, Cilt 224, No. 3, s.453-463.
- Johansson M. (1999): "The Hilbert Transform", Växjö University, Yüksek Lisans Tezi, Schweden, s.33.
- Maji U., Mitra M., Pal S. (2013): "Automatic Detection of Atrial Fibrillation Using Empirical Mode Decomposition and Statistical Approach", Cilt 10, s.45-52.
- Orhan U. (2013): "Real-time CHF Detection from ECG Signals Using a Novel Discretization Method.", Comput. Biol. Med., Cilt 43, No. 10, s.1556-1562.
- Tanç Y., Akan A. (2013): "Hilbert-Huang Dönüşümü İle Sayısal Modülasyon Türü Sınıflandırması", 21. Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SIU2013), s.1-4, DOI: 10.1109/SIU.2013.6531183.
- Thuraisingham R. A. (2009): "A Classification System to Detect Congestive Heart Failure Using Second-Order Difference Plot of RR Intervals", Cardiol. Res. Pract.

- Ubeyli E. D. (2009): "Adaptive Neuro-Fuzzy Inference System for Classification of ECG Signals Using Lyapunov Exponents", *Comput. Methods Prog Biomed.*, s:313-321.
- Verner M. (2007): "Hilbert-Huang Transform, its Features and Application to the Audio Signal", Student's Conference STC 2007, Mekanik Mühendisliği Fakültesi, Czech Teknik Üniversitesi.