

Doppler İşaretlerinin Dalgacık Dönüşümü ve Fraktal Boyut Kullanarak Yapay Sinir Ağları ile Sınıflandırılması Classification with Neural Network of Doppler Signals Using The Fractal Dimension and Wavelet Transformation

Esra Yıldız¹, Suat Toraman², İbrahim Türkoğlu³

¹Kayseri İl Milli Eğitim Müdürlüğü

esra.mutluay@hotmail.com

²Enformatik Bölümü, Fırat Üniversitesi

storaman@firat.edu.tr

³Yazılım Mühendisliği Bölümü, Teknoloji Fakültesi, Fırat Üniversitesi

iturkoglu@firat.edu.tr

Özetçe

Bu çalışmada, kalp hastalarından alınan doppler işaretlerinin sınıflandırılmasında hekimlere karar verme sürecinde yardımcı olacak bilgisayar destekli bir tanı sistemi tasarlanmıştır. Geliştirilen sistemde, doppler işaretlerinin durağan olmayan özellik sergilemesinden dolayı dalgacık dönüşümü ile durağan bileşenler elde edilmiştir ve bu durağan bileşenlerin içerdiği bilgilerde fraktal boyut hesaplaması kullanılarak elde edilmiştir. Doppler işaretinin tanımlayıcı bilgilerini içeren fraktal boyut değerleri bir özellik vektörü olarak yapay sinir ağlarına verilerek sınıflandırma yapılmıştır. 93 adet doppler işareti ile yapılan sınıflandırma uygulamasında %85 doğruluk oranına ulaşılmıştır.

Abstract

in this study, Computer based diagnosis system has been designed by using Doppler signals. Computer based diagnosis system aims to help doctors for their decision. In the developed system, Doppler signals which have nonstationary property were obtained the stationary components with wavelet transform. Then the information contained by stationary components obtained using fractal dimension calculation. Fractal dimension value of Doppler sign, that contains descriptive information, have been given and classified to artificial neural networks as feature vector. in this application, 93 doppler sign have been used and rate of 85% accuracy has been obtained.

1. Giriş

Örüntü tanıma, kendi aralarında ortak özellikleri olan nesnelere, bu özellikleri yardımıyla ile sınıflandırılma olarak tanımlanabilir. Temel amaç, önceden bilinenlerden bilinmeyenleri ortaya çıkarmaktır [1]. Örüntü tanıma sistemi üç aşamadan oluşmaktadır. Bunlar; işaret işleme, özellik çıkarma ve sınıflandırma aşamalarıdır. Örüntü tanımının ilk adımı işaret işlemedir. İşaret işleme, işaretlerin sayı dizileri şeklinde temsil edilmesi ve bu sayı dizilerinin, sayısal hesaplama yöntemleri ile dönüştürülmesi veya işlenmesidir [2]. İşaret işleme uygulamalarının kullanıldığı bazı alanlar şunlardır; Biyotıp alanında, kanın moleküler düzeydeki incelenmesinde ve spektral analiz çalışmalarında faydalanılmaktadır [3,4]. Tıp alanında elektrokardiyograf (EKG) sınıflama [5], EEG sınıflama [6] gibi birçok alanda


işaret işleme tekniklerinden yararlanılmaktadır. İşaret işleme adımından sonra özellik çıkarım aşamasında dalgacık dönüşümü ve fraktal analiz yöntemleriyle işaret verisi özellik vektörü çıkarımı yapılmaktadır. Dalgacık dönüşümü, işaret işleme uygulamalarında işaretten gürültüyü temizlemek için kullanılan bir işaret dönüşüm tekniğidir. Dalgacık dönüşümü, rüzgar karakteristiğinin ortaya konulması[7], sismik sinyallerin analizi[8], sinyallerin gürültülerinin giderilmesi [9], kalp hızı değişkenliğinin analizi [10] gibi birçok alanda kullanılmaktadır.

Fraktallar, Euclidean geometrisiyle tanımlanamayacak şekilleri karakterize etmede kullanılan düzensiz geometrik yapılardır. Fraktal boyut ise, ilk bakışta düzensiz gibi görünen yapıların özelliklerini yorumlamakta kullanılan özellik çıkarım aracıdır. Medikal alanda doku özelliklerini yorumlamakta kullanılan fraktal boyutu dokularda oluşan kütleyi belirlemede, göğüs ultrason imgelerinin sınıflandırılmasında, yaşlı insanların kalp atış değişkenliğinin ve ölüm oranının belirlenmesinde [11] kullanılan uygulamaları mevcuttur. Özellik çıkarım aşamasında elde edilen bilgiler kullanılarak verinin hangi sınıfa dahil olduğunun belirlendiği sınıflandırma aşamasında ise yapay sinir ağı (YSA) modelinin geri yayımlı öğrenme uygulaması kullanılmıştır. Uygulama için kalp hastalarından alınan Doppler işaretleri kullanılmıştır.

2. Teorik Bakış

2.1. Doppler İşaretleri

İşaret, gerçek dünyadan elde edilen büyüklüklerin zamanın bir fonksiyonu olarak ifade edilmesidir [1]. Bu işaret çeşitlerinden biride Şekil 1'de gösterilen Doppler Kalp Ses (DKS) işaretleridir.



Şekil 1: DKS işaret örüntüsü

Doppler Kalp Ses işaretleri, hastanın incelenen organı üzerine problemler yerleştirilmesi ile elde edilir. Doppler işaretleri kullanarak yapılan hastalık teşhisinde, kan damarına

Sinyal İşleme 3

3. Gün 27 Eylül 2014 Cumartesi (11.45-13.00)

gönderilen ses dalgası ve yansiyarak geri dönen dalganın frekansı arasındaki fark değerlendirilerek, kan akım hızı, kalp atışları ve bu hızda ortaya çıkan değişikliklerin izlenmektedir[1]. Öncelikle damar incelemesinde kullanılan doppler yöntemi, bu nedenle hemen hemen tüm damarların incelenmesinde kullanılabilir[2].

2.2. Dalgacık Dönüşümü

Dalgacık dönüşümü, gürültü temizleme gibi işaret işleme uygulamalarında başarılı sonuçlar veren bir işaret dönüşüm tekniğidir. Dalgacık dönüşümü, doppler işaretlerinde, zaman ve frekans bölgesi karakteristiklerinin tanımlanmasında kullanılmaktadır. Dalgacık dönüşümü analizinin kullanıldığı alanlar arasında görüntü işleme teknikleri, tıbbi uygulamalar, sismik sinyaller, veri sıkıştırma, gürültü giderme gibi alanlar sayılabilmektedir[1,8,12]. Dalgacık dönüşüm yöntemi, geç potansiyellerin saptanması, doppler işaretinin özelliklerinin saptanmasında, doppler gürültünün süzülmesinde ve işaret sıkıştırılmasında oldukça başarılıdır[2].

2.3. Fraktal Analiz

Fraktaller parçalanmış ya da kırılmış, kendi kendini tekrar ederek sonsuza kadar küçülen yapılardır. Fraktallerin her parçası büyütüldüğünde yine kendine benzeyen şekiller ortaya çıkar. Fraktal boyut ise, ilk bakışta düzensiz gibi görünen yapıların özelliklerini yorumlamakta kullanılan özellik çıkarım aracıdır. Fraktal boyut ve kendine benzerlik arasında önemli bir ilişki vardır. Bir doğru parçası tek boyutludur. Doğru parçası N eşit parçaya bölünerek $r = 1/N$ oranında küçültülebilir [11,13,15,16]. Genel olarak D boyutlu kendine benzeyen bir nesne ve ölçeklendirme faktörü r :

$$r = \frac{1}{D\sqrt{N}} \quad (1)$$


oranında küçültülerek N tane kendisinin küçük bir kopyası elde edilebilir. Bu ifadede benzerlik veya fraktal boyut olarak adlandırılan D çekişebilir:

$$N = \frac{1}{r^D} \Rightarrow D = \frac{\log(N)}{\log\frac{1}{r}} \quad (2)$$

Bu şekilde elde edilen D , benzerlik ya da fraktal boyut olarak adlandırılır.

2.4. Yapay Sinir Ağları

Sınıflandırma işlemi için yapay sinir ağlarının geri beslemeli ağ türü kullanılmıştır. Geri yayılım algoritmasında bilgi ileriye doğru akarken, hatalar geriye doğru çıkıştan girişe azalan bir şekilde gerçekleşmektedir. Geri yayımlı öğrenme kuralı, ağ çıkışındaki mevcut hata düzeyine göre her bir katmandaki ağırlıkları yeniden hesaplamak için kullanılmaktadır. Geri yayılım ağı giriş katmanı, giriş veri gruplarının ağına sunulduğu kısımdır. Gizli katman ise, giriş katmanından aldığı ağırlıklandırılmış veriyi probleme uygun bir fonksiyonla işleyerek bir sonraki katmana iletmektedir. Son olarak çıkış katmanının görevi ise gizli katmandan aldığı veriyi ağına kullandığı fonksiyonla işleyerek çıktı olarak vermektir. Şekil 2'de geri yayımlı bir yapay sinir ağı modeli gösterilmektedir[14].



Şekil 2: Geri yayımlı bir yapay sinir ağı modeli

3. Geliştirilen Yöntem

Şekil 3'de durağan olmayan doppler işaretlerinin sınıflandırılmasında hekime karar verme sürecinde yardımcı olması amacıyla geliştirilen bilgisayar destekli tanı sisteminin işleyiş şeması gösterilmektedir. İlk olarak Doppler Ultrason cihazı aracılığıyla işaret verilerinin elde edilmesi gerçekleştirilmektedir. Daha sonra işaret verisi üzerinde filtreleme ve normalizasyonu içeren işaret işleme tekniği gerçekleştirilir. İşaret işleme basamağında istenmeyen etkilerden arındırılan işaret verisinin sınıflandırma işlemine kullanılacak niceliklerinin elde edilmesi için Dalgacık dönüşümü ve Fraktal analiz teknikleriyle özellik çıkarımı gerçekleştirilmektedir. Son aşamada ise özellik çıkarım sürecinde elde edilen bilgiler ile işaret verisi üzerindeki değerlendirmenin yapılacağı yapay sinir ağları ile sınıflandırma yapılmaktadır.



Şekil 3: Doppler kalp ses işaretlerinin sınıflandırma süreci

3.1. İşaretin Elde Edilmesi

Uygulamada kullanılan Doppler Kalp Ses (DKS) işaretleri, Fırat Üniversitesi, Fırat Tıp Merkezi, Kardiyoloji kliniğinden kalp kapak hastalarından alınmıştır. DKS işaretleri, renkli Doppler ve Ultrasonografi cihazının problemlerinin, hastanın incelenmek istenen organının üzerine yerleştirilmesiyle elde edilmektedir. İşaretlerin alınmasında Acuson Sequoia 512 Model Doppler Ultrason cihazı kullanılmıştır. $V_{pp} = 1$ voltluk çıkış genliğine sahip cihazın Doppler ses çıkışından DKS işaretleri MATLAB ortamında geliştirilen bir yazılımla, 5 saniyelik olarak, işaretin gürültü seviyesi $SNR = 0$ dB

Sinyal İşleme 3

3. Gün 27 Eylül 2014 Cumartesi (11.45-13.00)

kazançlı ve 20 kHz 'lik örnekleme frekansı ile 16-bitlik A/D çözünürlüğüne sahip olan bir ses kartı üzerinden bilgisayara sayısal biçimde ve hekim gözetiminde alınmıştır.

3.2. Ön İşlem Süreci

Doppler Ultrason cihazı ile elde edilen işaretin bozucu etkilerden arındırmak için denklem 3'de transfer fonksiyonu verilen FIR filtreleme tekniği kullanılmaktadır.

$$H(z) = \sum_{n=0}^N h[n]z^{-n} e^{j\Omega} = z \quad (3)$$

Elde edilen işaret durağan olmadığı için pencereli FIR filtre kullanılmıştır. Bu işlem için seçilen uygun pencereleme fonksiyonu Hamming pencereleme tekniğidir. Pencere fonksiyonu $w[n]$ birim darbe cevabı $h[n]$ ve sayısal FIR filtrenin katsayıları denklem 4'de verilmiştir.

$$h[n] = h_{id}[n]w[n] \quad (4)$$

Kullanılan Hamming pencere fonksiyonu, aşağıdaki gibi tanımlanmıştır:

$$w[k] = 0.54 - 0.46 \cos\left(2\pi \frac{k}{n-1}\right), \quad k = 0, \dots, n-1 \quad (5)$$

$$w(n) = \begin{cases} w[k] & 0 \leq n \leq N-1 \\ 0 & \text{diğer} \end{cases} \quad (6)$$


FIR filtreleme ile işaret, gürültüden büyük oranda arındırılır ve DKS işaretleri denklem 7 kullanılarak normalize edilerek işaretin genliğinin hastanın göğüs kafesinin fizyolojik yapısından etkilenmeyecek seviyeye çekilmesi sağlanmaktadır [2].

$$DKS = \frac{DKS}{|DKS[n]|_{maksimum}} \quad (7)$$

3.3. Özelliklerin Çıkarılması

Özellik çıkarım aşaması işaretin tanımlayıcı anahtar özelliklerinin tespit edildiği aşamadır. Bu aşamada DKS işaretlerine Dalgacık dönüşümü yapılarak FIR filtre ile ayrıştırılmayan işaretin frekans bandındaki gürültü bileşenleri ayrıştırılır. Yapılan ön çalışmalarda en iyi sinyal ayrışımı sonucunu Daubechies-10 dalgacık filtresi verdiği görülmüş ve bu aşama için dalgacık paket ayrışımı Daubechies-10 dalgacık filtresi kullanılarak gerçekleştirilmiştir. Daubechies-10 dalgacık filtre için detay katsayısı cd_1 'den cd_{12} 'ye 12 adet ve son seviye için 1 adet ca_{12} yaklaşık katsayı elde edilmektedir. Bu katsayıların kullanıldığı eşikleme yöntemi ile belli bir seviyenin altındaki değerler yok edilerek DKS işareti yeniden elde edilmektedir. Yeniden elde edilen DKS işaretleri Şekil 4'de gösterilmektedir.

Elde edilen işaret verisi tek boyutlu bir veri olduğu için, denklem 8'deki Hurst Exponent yöntemiyle işaretin Fraktal boyutu hesaplanmaktadır. Hurst Exponent yöntemi ile elde edilen katsayı kullanılarak, $FB=2-H$ formülüyle fraktal boyuttaki değişim miktarı belirlenmektedir.



Şekil 4: DKS işaretinin dalgacık dönüşüm ağacında bulunan işaretleri

$$H = \lim_{t_2-t_1 \rightarrow 0} \left(\frac{\log[\text{Var}(s(t_2-t_1))]}{2 \log(t_2-t_1)} \right) \quad (8)$$

Tablo 1'de 13 DKS işaretinin işaret bileşeninin Hurst Exponent katsayılı fraktal boyut hesaplamaları verilmiştir. Bu değerler DKS işaretlerinin özellik vektörünü oluşturmaktadır.

Tablo 1: DKS için hurst exponent ile hesaplanan fraktal boyutlar

DD İşaretleri	Normal bir DKS işareti	Anormal bir DKS işareti
cd1	-0.0205	-0.2905
cd2	-0.0435	-0.0914
cd3	-0.1239	0.0192
cd4	0.0754	0.1073
cd5	0.0927	0.0974
cd6	0.1938	0.1468
cd7	0.2940	0.1022
cd8	0.3169	0.1371
cd9	0.4654	0.4398
cd10	0.6232	0.6210
cd11	0.7733	0.7718
cd12	0.7972	0.7929
ca12	0.7665	0.7578

3.4. Sınıflandırma

Sınıflandırma işleminin amacı, özellik çıkarım metodunun etkinliğini göstermektir. Bu amaçla özellik vektörü yardımıyla geri yayılım algoritmasıyla sınıflandırılma işlemi gerçekleştirilmiştir. Sınıflandırma işlemi için 58 hasta ve 35 sağlam kişiden işaretler elde edilmiştir. Sınıflandırma işleminin sonuçları, Tablo 2'de görülmektedir.



Sinyal İşleme 3

3. Gün 27 Eylül 2014 Cumartesi (11.45-13.00)

4. Sonuç

FIR filtre ile gürültüden arındırılan Doppler işaretlerin dalgacık dönüşümü ve fraktal analiz ile özellikleri çıkarılarak sınıflandırılması ile hekime karar verme sürecinde yardımcı olacak bilgisayar destekli tanı sisteminin geliştirilmiştir. Geliştirilen sistem ile doppler işaretlerinin yorumlanmasında kolaylık sağlanması hedeflenmektedir. Elde edilen bilgiler ışığında çeşitli hastalıkların tanı ve tedavi sürecinde hekimlere daha sağlıklı bilgi sunularak, tanı komaya önemli bir bilgisayar destekli yardımcı unsur olacağı düşünülmektedir. Geliştirilen sistem ile veri setlerinin çaprazlama eğitimi sonucu ortalama % 85.2 lik bir başarı oranı belirlenmiştir. Geliştirilen bu sistem, farklı tıbbi alanda işaretlerin analizine de uygulanabilecektir.

Tablo 2: DKS işaretlerinin sınıflandırma başarımları

Sınıflama Uygulamaları	YSA Test Sonuçları		
		Normal	Anormal
UYGLAMA I Veri seti – 2 ile YSA eğitilmiştir. Veri Seti - 1 ile YSA test edilmiştir.	DKS işaretleri	15	25
	Eğitim başarımları	%100	%100
	Doğru sınıflama	12	23
	Hatalı sınıflama	3	2
	En yüksek tanıma yüzdesi	%100	%100
	En düşük tanıma yüzdesi	%0.5	%0.3
	Başarımlar yüzdesi	%87.5	
UYGLAMA II Veri seti – 1 ile YSA eğitilmiştir. Veri Seti - 2 ile YSA test edilmiştir.	DKS işaretleri	20	33
	Eğitim başarımları	%100	%100
	Doğru sınıflama	15	29
	Hatalı sınıflama	5	4
	En yüksek tanıma yüzdesi	%99.86	%99.98
	En düşük tanıma yüzdesi	%0.6	%0.1
	Başarımlar yüzdesi	%83.01	
Ortalama başarımlar yüzdesi	%85.2		

5. Kaynaklar

- [1] Türkoğlu İ., Durağan olmayan işaretler için zaman frekans entropilerine dayalı akıllı örüntü tanıma, Doktora Tezi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, 2002.
- [2] Yıldız E., “Doppler İşaretlerinin Dalgacık Dönüşümü ve Fraktal Boyut Kullanarak Yapay Sinir Ağları ile Sınıflandırılması”, Yüksek Lisans Tezi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, 2009.
- [3] Sheng D., Wu Y., Wang X., Huang D., Chen X., Liu X., Comparison of serum from gastric cancer patients and from healthy persons using FTIR

spectroscopy, Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy 116, 365-369, 2013.

- [4] Ahmed S. S.S.J., Santosh W., Kumar S., Christlet T. H.T., Neural network algorithm for the early detection of Parkinson's disease from blood plasma by FTIR micro-spectroscopy. Vibrational Spectroscopy 53:2, 181-188, (2010).
- [5] Erdoğan P., Pekçakar A., “Dalgacık Dönüşümü ile EKG Sinyallerinin Özellik Çıkarımı ve Yapay Sinir Ağları ile Sınıflandırılması”, IATS'09, Karabük, 2009.
- [6] Akin, M., Arserim, M.A., Kıymık, M.K. and Türkoğlu, İ., 2001, “A new approach for diagnosing epilepsy by using wavelet transform and neural networks”, 23rd Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC2001), 25-28 October 2001, İstanbul, 4.2.6.(1).
- [7] Duran K., “Rüzgar Karakteristiklerinin Dalgacık Dönüşümü İle Ortaya Konması”, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, 2013.
- [8] Çolak Ö.H., “Dalgacık Dönüşümü Kullanılarak Sismik Sinyallerin Analizi”, Doktora Tezi, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, 2006.
- [9] Tepe C., “EKG Sinyalinde Gürültü Gidermede Dalgacık Dönüşümü Kullanılması”, Yüksek Lisans Tezi, Ondokuz Mayıs Üniversitesi, Fen Bilimleri Enstitüsü, 2009.
- [10] Süleyman B., “Kalp Hızı Değişkenliğinin Dalgacık Dönüşümü ve Yapay Sinir Ağları Kullanılarak Analizi”, Doktora Tezi, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, 2008.
- [11] Türkoğlu, İ., ve Toraman, S., “Karar Ağaçları ve Fraktal Analiz Kullanarak Histopatolojik İmgelerin Sınıflandırılması”, Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi, 22 (4), 753 - 758, Aralık-2007.
- [12] Ağaoglu E. A., “Sayısal Süzgeç Tasarımı ve Uygulamaları”, Yüksek Lisans Tezi, Başkent Üniversitesi, Fen Bilimleri Enstitüsü, 2008.
- [13] Foroutan-pour K., Dutilleul P., Smith D.L., “Advances in the implementation of the boxcounting method of fraktal dimension estimation”, Applied mathematics and computation, 105, 195-210, 1999.
- [14] Yavuz S., Deveci M., “İstatistiksel Normalizasyon Tekniklerinin Yapay Sinir Ağın Performansına Etkisi”, Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 40, 167-187, 2012.
- [15] Bauer W., Mackezie C.D., “Cancer detection via determination of fraktal cell dimension”, Pattern Formation and Solitons, 9506003, 07/1995.
- [16] Rangayyan R. M., Nguyen T. M., “Patternclassification of breast masses via fraktal analysis of their contours”, International Congress Series, 1281, 1041-1046, 2005.