

Kalp Üfürümlerinin İzlenmesi için Walsh-Hadamard Dönüşümü Tabanlı Otomatik Sınıflandırma Sistemi

The Walsh-Hadamard Transform Based Automated Grading System For Monitoring of Heart Murmurs

Ayşe Arslan¹, Ahmet Çağrı Bağbaba², Baha Şen¹, Berna Örs²

¹Mühendislik ve Doğa Bilimleri Fakültesi, Bilgisayar Mühendisliği Bölümü
Ankara Yıldırım Beyazıt Üniversitesi
aarslan@ybu.edu.tr, bsen@ybu.edu.tr

²Elektrik-Elektronik Fakültesi, Elektronik ve Haberleşme Mühendisliği Bölümü
İstanbul Teknik Üniversitesi
bagbaba@itu.edu.tr, siddika.ors@itu.edu.tr

Özet

Kardiyak oskültasyon kalp hastalıkları tarafından indüklenen kalp üfürümlerini teşhis etmek için hala yaygın olarak kullanılan bir tekniktir. Bu methodun oldukça subjektif ve zaman alıcı olduğu dikkate alınarak, tanı tekniklerinin iyileştirilmesi klinik oskültasyon sürecine önemli ölçüde katkıda bulunacaktır. Daha objektif, güvenilir ve hızlı sonuçlar veren bilgisayar destekli oskültatif tanı sistemlerinin geliştirilmesi; kardiyovasküler hastalıkların teşhisinde oluşabilecek sınıflandırma hatalarını azaltacaktır. Böyle bir otomatik oskültatif tanı yazılımı sinyal işleme ve makine öğrenmesi algoritmaları kullanılarak gerçekleştirilebilir. Sunulan çalışma kalp sesi sinyallerini sınıflandırmak için Walsh-Hadamard dönüşümü (WHD) ve Saklı Markov Model (SMM) tekniklerinin birleşimini kullanır. Bu çalışma açıkça göstermiştir ki; klinik karar verme sürecinde hekimlere yardımcı olmak üzere başarılı otomatik üfürüm tanı kiti geliştirilebilir.

Abstract


Cardiac auscultation that is a still widely used technique to diagnose heart murmurs induced by heart disorders. Due to the fact that this method is quite subjective and time consuming, the enhancement of diagnosis techniques would contribute significantly to clinical auscultation. Development of computer-aided auscultative diagnosis systems, which provide more objective, reliable and faster results, would reduce the classification errors that may be occurred in the cardiovascular disorder diagnosis. Such an automated auscultative diagnostic software can be implemented by using signal processing and machine learning algorithms. The presented study uses a combination of the Walsh-Hadamard transform (WHT) and Hidden Markov Model (HMM) techniques. This study clearly shows that; successful automatic murmur diagnosis kits can be developed for assisting the doctors in clinical decision making process.

1. Giriş

Normal bir kalp sesi sinyali (fonokardiyogram) S1 ve S2 olmak üzere ardışık iki ayrı birincil aktiviteden oluşur. S1 ve S2 arasında duyulan ikincil sinyal aktiviteleri anormal ses sinyalleri olarak bilinir [1] (Şekil 1). Üfürüm olarak adlandırılan bu sinyaller karakteristiklerine göre farklı kalp rahatsızlıklarına işaret eder. Yüksek doğrulukta üfürüm tanısı koyabilmek, olası ciddi kardiyak hastalıkların erken tanısında fayda sağlar.

Kardiyak oskültasyon süreci, bir hekimin hastanın kalp seslerini stetoskop ile dinlemesi ve geçmiş tecrübelerine dayanarak bir tanı koyması adımlarından oluşur. Günümüzde, hastaların kardiyak işlevlerinin klinik değerlendirmesinde ve anomalilerin saptanmasında halen öncelikli ve yaygın olarak kullanılmaktadır. Ancak bu metot ile elde edilen sonuçların doğruluğu doğrudan hekimin uzmanlığına, yorumlama ve algılama yeteneğine bağlıdır, dolayısıyla hatalı tanıları koyulabilmektedir. Otomatik karar destek sistemlerinin geliştirilmesi klinik uygulamalarda, evde bakımda, yeterince deneyimli hekim veya modern tekniklerden yoksun olan yerlerde kullanım için oldukça yararlı olacaktır. Bu tür sistemlerden kardiyoloji eğitiminde öğrenim aracı olarak da faydalanılabilir.

Kardiyovasküler hastalıklar gibi ciddi rahatsızlıkların erken ve doğru teşhisi çok önemlidir. Bu amaçla daha kararlı ve doğru çalışan tanı sistemleri geliştirilmesi üzerine pek çok çalışma yapılmış ve yapılmaktadır [2-6]. WHD, sinyal ve görüntü işlemede [7-10], SMM fonokardiyogram sinyallerinin segmentasyonu ve sınıflandırılmasında başarılı sonuçlar vermiştir [11-15]. Bu algoritmaların birlikte kullanımı ile yüksek doğrulukta bir sınıflandırıcı sistem geliştirilebilir. Yürütülen çalışmanın amacı; geçmiş çalışmalarda kullanılan nitelik sayısını azaltmak ve buna rağmen sistemin tanıma başarısını da artırmaktır.




Şekil 1: Normal (a) ve anormal (b) fonokardiogram sinyal örnekleri [2].

2. Materyal ve Metotlar

2.1. Fonokardiogram Veriseti

Çalışmada kullanılan veriseti tanınmış bir medikal malzeme firması tarafından [16] araştırmacıların kullanımına açık sunulmakta olan bir verisetidir [17]. Veri seti, güçlü bir elektronik stetoskop tarafından alınan normal ve üç farklı üfürüm-erken diyastolik, holo sistolik, geç sistolik- tipinde fonokardiogram verilerini içerir (Şekil 2).



Şekil 2: Önişlemeden geçirilmiş fonokardiogram verileri; (a) erken diyastolik, (b) holo sistolik, (c) geç sistolik, (d) normal.

2.2. Otomatik Tanı Sistemi

2.2.1. Önişleme

Önişleme tekniklerinin sistemin tanıma başarısı üzerinde doğrudan etkili olduğu bilinmektedir. Bu çalışmanın önişleme aşaması, ilk haliyle birden fazla kardiyak döngüden oluşan fonokardiogram sinyallerin segmentasyonu işlemini içerir. Segmentasyon yapılarak üfürüm sinyalleri tüm fonokardiogram sinyal içerisinde kesilerek çıkarılmış ve hekim denetiminde uygun üfürüm tipi ile etiketlenmiştir.

2.2.2. Walsh-Hadamard Dönüşümü

Öznitelik çıkarma işlemi, üfürüm sinyallerini karakterize edecek öznitelik vektörlerinin saptanması işlemidir. Bu çalışmada önişleme sürecinden geçirilen verilerin öznitelik vektörleri WHD tekniği kullanılarak çıkarılmıştır. WHD geçmiş çalışmalarda matematik [7], görüntü sıkıştırma ve kodlama [8], hüresel ağlarda iletişim [9], sıkıştırılmış algılama [10] alanlarında başarılı bir şekilde uygulanmıştır.

WHD dikdörtgen şekilde dalgalar kullanılan tam ortogonal +1 ya da -1 değerlerini alan fonksiyonlar kümesidir. WHD formülü Eşitlik 1’de görülmektedir:

$$H(u, v) = \frac{1}{N} \sum_{x=0}^{N-1} \sum_{y=0}^{N-1} f(x, y) (-1)^{pow \sum_{i=0}^{N-1} [bi(x)bi(u)bi(y)bi(v)]} \quad (1)$$

N boyutu, bi(x) x sayısının ikili düzen ifadesinde i. Değeri gösterir [18]. Walsh dönüşüm matrisleri ortogonal, gerçel simetrik, 2’nin kuvveti kadar satır-sütun için oluşturulabilen, başlangıç satır ve sütunu +1’lerden oluşan matrislerdir. Bu nitelikler Hadamard matrisinin satırları düzenlendiğinde sağlanmalıdır [18]. Hadamard matrise uygulanan bu dönüşüm WHD olarak adlandırılır.

Hızlı Walsh-Hadamard dönüşümü (HWDH), WHD tekniğinin böl-fethet yaklaşımına dayanarak özyinelemeli bir şekilde uygulanmasını sağlayan ve bu sayede hızlı bir hesaplama yeteneğine sahip olan etkin bir algoritmadır [19]. Gerçek zamanlı bir uygulama geliştirilmesi amaçlandığından öznitelik vektörleri HWDH algoritması ile çıkarılmıştır.

Ortaya çıkarılan HWDH öznitelik vektörleri SMM sınıflandırıcıya verilmek üzere Baum-Welch eniyileme algoritması kullanılarak yeniden oluşturulmuştur. Öznitelik vektörünü daha küçük bir boyutta ifade edebilen yeni parametreler ortaya çıkarılmıştır.

2.2.3. Saklı Markov Model

SMM durum ve geçişler arasındaki bir olasılık dağılımı tarafından belirlenen ağırlıklara göre karar verebilen istatistiksel bir sınıflandırma yaklaşımıdır [20]. Bilinmeyen model parametreleri öznitelik vektörleri üzerinde Baum-Welch beklenti en iyileme algoritması uygulanarak saptanmıştır. Bu sayede tüm öznitelik vektörünün saklanması yerine bu vektörü tam olarak ifade edebilecek daha küçük boyutta bir vektör elde edilmiş, böylece sınıflandırma performansının iyileştirilmesi amaçlanmıştır.

$q_t = S_i$ ifadesi bir sistemin t anında S_i durumunda olduğunu gösterir, ve bir sistem her zaman N farklı durumdan birindedir ($S_1, S_2, \dots, S_N$).

$P(q_t=S_j | q_{t-1}=S_i, q_{t-2}=S_k, \dots)$ ifadesinde sistemin bir durumdan diğer bir duruma geçmesi olasılığı önceki durumun ne olduğuna bağlıdır.

$$P(q_{t+1}=S_j | q_t=S_i, q_{t-1}=S_k, \dots) = P(q_{t+1}=S_j | q_t=S_i) \quad (2)$$

Eşitlik 2 göstermektedir ki; $t+1$ anındaki durum sadece t anındaki duruma bağlıdır.

N modeldeki durum sayısı; $S=\{S_1, \dots, S_N\}$, M gözlemlerin sayısı; $V=\{v_1, \dots, v_M\}$ olmak üzere A, durum geçiş olasılıkları matrisi Eşitlik 3’te görülmektedir:

$$A=[a_{ij}], a_{ij}=P(q_{t+1}=S_j, | q_t=S_i) \quad (3)$$


B gözlem olasılık matrisi Eşitlik 4’te verilmiştir:

$$B=[b_j(m)], b_j(m)=P(O_t=v_m | q_t=S_j) \quad (4)$$

π , ilk durum olasılıkları vektörü olmak üzere:

$$\pi=[\pi_i], \pi_i=P(q_i=S_i) \quad (5)$$

N ve M belirlendikten sonra, $\lambda = (A, B, \pi)$ ifadesi ile model oluşturulur (Şekil 3).



Şekil 3: 5 durumlu soldan sağa SMM

3. Deneysel Çalışma

3.1. Sistemin Eğitimi

Çalışmada kullanılan veri seti gürültülü data içermemekte olduğundan önileme aşamasında herhangi bir filtreleme işlemine ihtiyaç duyulmamıştır. Bu aşamada manüel segmentasyon işlemi ile üfürüm sinyalleri çıkarılmış ve etiketleme yapılmıştır. Etiketlenen veriler sistemin öğrenme aşamasında kullanılmıştır.

Otomatik üfürüm tanı sisteminin akış şeması Şekil 4'te verilmiştir.



Şekil 4: Çalışmanın akış şeması.

Öznitelik çıkarma aşamasında, WHD algoritmasına giriş olarak verilen üfürüm sinyalinin ayrık WHD katsayıları elde edilir. WHD, sinyal uzunluğu 2'nin üssü olduğu durumlarda çalışır. Öznitelik vektörünü ifade eden katsayılar normal Hadamard sırasında elde edilir.

Bilinmeyen asıl SMM sınıflandırıcı parametreleri Baum Welch algoritması ile daha doğru ve daha küçük boyutta elde

edilmiştir. Bu çalışmada soldan sağa SMM uygulanmış, model içerisindeki durum sayısının efektif değeri deneysel çalışmalar sonucunda 5 olarak belirlenmiştir. Modelin öğrenmesi sağlandıktan sonra sistemin test aşamasına geçilmiştir.

3.2. Sistemin Test ve Geçerlemesi

Veri setinin küçük olduğu durumda birden fazla öğrenme ve geçerleme kümesi kombinasyonları oluşturulur. Bu amaçla çalışmada kullanılan veri kümesi k adet alt kümeye bölünür ve çapraz geçerleme yöntemi uygulanır. Bu çalışmada k değeri 3 olarak seçilmiştir. Böylece her bir alt küme farklı adımlarda olma koşuluyla hem eğitim hem de test kümesi olarak kullanılmış olur.

Bu şekilde her bir üfürüm tipine ait 15'er veri kümesi üç eşit alt kümeye ayrılmıştır; iki küme sistem eğitiminde kalan bir küme sistem testinde kullanılmıştır. Her bir alt küme test kümesi olarak kullanılacak şekilde sınıflandırma işlemi üç kez tekrar edilmiştir. Sistemin başarısını bu üç ayrı başarının ortalaması oluşturur. Ayrıca 3-kat ve 5-kat çapraz geçerleme uygulandığında sonucun aynı olduğu görülmüştür.

Test aşaması da eğitim aşamasında olduğu gibi test verilerinin önilemesi, öznitelik vektörlerinin çıkarılması ve sınıflandırıcı modelin uygulanması adımlarından oluşur. Bilinmeyen üfürüm tipi yani etiketin tahmin işlemi; SMM Viterbi algoritması ile bulunur. Viterbi algoritması test verisi ile önceden öğrenilmiş veriler arasında karşılıklı değerlendirme yapar. Test verisi için en yüksek benzerlik değerini veren etiketi saptayarak test verisinin etiketini tahmin eder. Otomatik üfürüm tanıma sistemi böylece yeni gelen bir hastanın yalnızca kalp sesini dinleyerek bir hekim gibi sınıflandırma sonucunda koyduğu tanıyı sunabilmektedir.

Sistemin başarısı Çizelge 1'de görülmektedir.

Çizelge 1: 3-kat çapraz geçerleme sonucunda sistemin performansının değerlendirilmesi

Üfürüm Tipi	Eğitim Kümesi Tanıma Başarısı	Test Kümesi Tanıma Başarısı
Erken	15/15	15/15
Diyastolik	15/15	14/15
Geç Diyastolik	15/15	15/15
Holo Sistolik	15/15	15/15
Normal	15/15	15/15
Toplam:	60/60 (100%)	59/60 (98%)

4. Sonuçlar

Mevcut oskültasyon yönteminin sübjektif olması ve tekrarlanabilir olmaması nedeniyle yüksek başarılı otomatik tanı araçlarının geliştirilmesi klinik kardiyovasküler analize önemli ölçüde katkı sağlayacaktır. Sunulan sistemin başlıca yeniliği geçmiş çalışmalardan daha az nitelik kullanılmasına rağmen yüksek bir sınıflandırma başarısı sağlamasıdır. Gerçek zamanlı bir sistem geliştirmek için veri setinin kalitesi, nitelik sayısı, sınıflandırıcı modelin asıl parametrelerinin saptanması ve bunların sistemin performansı üzerine etkisinin analizi kritik önem taşır. Bu önemli noktalar henüz tam olarak keşfedilmemişken, bu alanda yürütülen geçmiş çalışmaların

pek çoğu doğrudan öznelilik çıkarma ve sınıflandırma algoritmalarına odaklıdır. Bu çalışmada, hassas bir elektronik stetoskop ile kaydedilmiş güvenilir bir fonokardiyogram veri seti üzerinde çalışılmıştır. Sunulan sistem açıkça göstermektedir ki; ideal fonokardiyogram sinyaller üzerinde

doğru model parametreleri belirlenerek bilgisayarlı teknikler uygulandığında gerçek hayatta kullanılabilir düzeyde başarılı oskültatif tanı kitleri geliştirilebilir. Geliştirilen sistemin performansı geçmiş çalışmalarla karşılaştırılması Çizelge 2’de verilmiştir.

Çizelge 2: Geliştirilen sistem başarısının geçmiş çalışmalarla karşılaştırılması

Çalışma	Sınıflandırma	Metot	Başarı
(21)	Kalp üfürümlerinin tanısı: Sürekli Üfürüm Diyastolik Üfürüm Sistolik Üfürüm Normal	Öznelilik Çıkarma: •Fourier Dönüşüm (FD) •Mel frekansı kepsturm katsayıları (MFKK) Sınıflandırma: •SMM -5 durumlu	Duyarlılık: FD: 0.93 MFKK: 0.97 Belirleyicilik: FD: 0.94 MFKK: 0.96
(22)	Kalp hastalıklarının tanısı	Öznelilik Çıkarma: •MFKK Sınıflandırma: •SMM -4durumlu	95.08% maksimum doğru sınıflandırma oranı
(16)	Kalp üfürümlerinin tanısı: Holo Sistolik Üfürüm Orta Sistolik Üfürüm Normal	Sınıflandırma: •Yapay Sinir Ağları (YSA) •Levenberg-Marquardt Algoritması	96.7% ortalama doğru sınıflandırma oranı
Sunulan Çalışma	Kalp üfürümlerinin tanısı: Erken Diyastolik Üfürüm Holo Sistolik Üfürüm Geç Sistolik Üfürüm Normal	Öznelilik Çıkarma: •WHD Sınıflandırma: •SMM -5 durumlu -Baum Welch Algoritması	98.3% ortalama doğru sınıflandırma oranı

5. Kaynaklar

- [1] Bereksi, F. ve Debbal, S. M., “Computerized Heart Sounds Analysis”, *Computers in Biology and Medicine*, 38:2, 263-280, 2008.
- [2] Abdel, I. ve Akula, R., “Artificial Intelligence Algorithm for Heart Disease Diagnosis Using Phonocardiogram Signals,” *IEEE Transaction on Biomedical Engineering*, 51:7, 1196-1202, 2012.
- [3] Uğuz, H., “A Biomedical System Based on Artificial Neural Network and Principal Component Analysis for Diagnosis of the Heart Valve Diseases”, *Journal of Medical Systems*, 36:1, 61-72, 2012.
- [4] Phatiwuttipat, P., Kongprawechon, W., Tungpimolrut, K., Yuenyong, S., “Cardiac Auscultation Analysis System with Neural Network and SVM Technique”, *Signal Processing Medical Signal Processing & Medical Imaging*, 1027-1030, 2011.
- [5] Rios-Gutierrez, F., Alba-Flores, R., Strunic, S., “Recognition and Classification of Cardiac Murmurs Using ANN and Segmentation”, *Electrical Communications and Computers (CONIELECOMP) 22nd International Conference*, 219-223, 2012.
- [6] Salman, A.H., Mengko, T.R., Mengko, R.K.W., Langi, A.Z.R., “Review of Digital Heart Sound Classification Methods Via Artificial Neural Networks”, *Instrumentation, Communications, Information Technology, and Biomedical Engineering (ICICI-BME) 2013 3rd International Conference*, 425-430, 2013.
- [7] Hedayat, A. ve Wallis, W. D., “Hadamard matrices and their applications,” *Annals Statistics.*, 6:6, 1184–1238, 1978.
- [8] Pratt, W., Kane, J., ve Andrews, H. C., “Hadamard transform image coding,” *Proc. IEEE*, 57:1, 58–68, 1969.
- [9] 3GPP, Spreading and Modulation (FDD), 3rd Generation Partnership Project (3GPP), document Rec. TS 25.213, Sep. 2014.
- [10] Haghighatshoar, S. ve Abbe, E., “Polarization of the Rényi information dimension for single and multi terminal analog compression”, [Online]. Available: <http://arxiv.org/abs/1301.6388>, 2013
- [11] Zhuravlev, Y. I., editor., *Pattern Recognition and Image Analysis*, Russia:Springer; 2007.
- [12] Schmidt, S.E., Holst-Hansen, C., Graff, C., Toft, E., Struijk, J.J. “Segmentation of heart sound recordings from an electronic stethoscope by a duration dependent hidden markov model”, *Physiological Measurement*, 2010; 31: 513-29.

- [13] Ricke, A.D., Johnson, M.T., Povinelli, R.J. "Automatic segmentation of heart sound signals using hidden markov models", *Computers in Cardiology*, 2005; 32: 953–6.
- [14] Hermansky, H, Malayath, N. "Data-driven spectral basis functions for automatic speech recognition", *Speech Communication*, 2003; 40: 449-66.
- [15] Hussain, S., Salleh Kamarulafizam, I., Noor, A.M., Harris, A.A., Oemar, H., Yusoff, K. "Classification of heart sound based on multipoint auscultation system", *WoSSPA 2013 Systems, Signal Processing and their Applications 8th International Workshop*; 2013, Zeralda: Algeria; 2013, 174-9.
- [16] Liu, J., Liu, W., Wang, H., Tao, T., Zhang, J., "A novel envelope extraction method for multichannel heart sounds signal detection", *ICCIT 2011 International Conference on Computer Science and Information Technology*; South-Korea; 2011. 630-638.
- [17] 3M littman heart sounds data set information, 2016. Available: http://www.littmann.com/wps/portal/3M/en_US/3M-Littmann/stethoscope/littmann-learning-institute/heart-lung-sounds/
- [18] Pehlivanoglu, M. ve Duru, N., "Walsh Hadamard Dönüşümü Uygulanmış Görüntülerin AES Şifreleme Algoritmasıyla Şifrelenmesi", *24. Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SİU 2016)*, 2016.
- [19] Scheibler, R., Haghighatshoar, S. ve Vetterli, M., "A Fast Hadamard Transform for Signals With Sublinear Sparsity in the Transform Domain," *IEEE Transactions on Information Theory*, 61:4, 2115-2132, 2015.
- [20] Ellis, D., ve Mandel, M., "Automatic Analysis Of Heart Sounds Using Speech Recognition Techniques", *Speech Communications*, 48:9, 1162-1181, 2005.
- [21] Wang P, Lim CS, Chauhan S, Foo JY, Anantharaman, V., "Phonocardiographic Signal Analysis Method Using a Modified Hidden Markov Model", *Annals of Biomedical Engineering* 2007; 35: 367-74.
- [22] Hang W. Sahong K. Keunsung B., "Hidden Markov Model With Heart Sound Signals For Identification of Heart Diseases", In: Burgess, M, editor. *ICA 2010. Proceedings of 20th International Congress on Acoustics*; 2010; Sydney: Australia; 2010.