

Kalp Kateterizasyonu ile Hemodinamik Ölçümleri Saptanmış Atriyal Septal Defekt ve Ventriküler Septal Defektli Olguların Genetik Algoritmalar ve Çok Katmanlı Yapay Sinir Ağı ile Sınıflandırılması

Classification of Atrial Septal Defect and Ventricular Septal Defect with Documented Hemodynamic Parameters via Cardiac Catheterization by Genetic Algorithms and Multi-Layered Artificial Neural Network

Mustafa Yıldız¹, Ayhan Yüksel², Mehmet Korürek², Ahmet Çağrı Aykan³,
Banu Şahin Yıldız⁴, Alparslan Şahin⁵, Hakan Hasdemir⁶, Mehmet Özkan¹

¹ Kartal Koşuyolu Yüksek İhtisas Eğitim ve Araştırma Hastanesi, Kardiyoloji Kliniği, İstanbul, Türkiye
¹ Department of Cardiology, Kosuyolu Heart Center, Kartal, Istanbul, Turkey

² İstanbul Teknik Üniversitesi Elektrik-Elektronik Mühendisliği Anabilim Dalı, İstanbul, Türkiye
² Department of Electrical-Electronic Engineering, Istanbul Technical University, Istanbul, Turkey

³ Ahi Evren Göğüs ve Kalp Damar Cerrahisi Eğitim ve Araştırma Hastanesi, Kardiyoloji Kliniği,
Trabzon, Türkiye

³ Department of Cardiology, Ahi Evren Thoracic and Cardiovascular Surgery Training and Research Hospital,
Trabzon, Turkey

⁴ Dr. Lütfi Kırdar Kartal Eğitim ve Araştırma Hastanesi, İç Hastalıkları Kliniği, İstanbul, Türkiye

⁴ Department of Internal Medicine, Dr. Lutfi Kırdar Kartal Training and Research Hospital, Istanbul, Turkey

⁵ Dr. Sadi Konuk Eğitim ve Araştırma Hastanesi, Kardiyoloji Kliniği, İstanbul, Türkiye

⁵ Department of Cardiology, Dr. Sadi Konuk Training and Research Hospital, Istanbul, Turkey

⁶ Dr. Siyami Ersek Göğüs ve Kalp Damar Cerrahisi Eğitim ve Araştırma Hastanesi, Kardiyoloji Kliniği,
İstanbul, Türkiye

⁶ Department of Cardiology, Dr. Siyami Ersek Thoracic and Cardiovascular Surgery Training and
Research Hospital, Istanbul, Turkey

Yazışma Adresi/
Correspondence

Dr. Mustafa Yıldız
Bayar Caddesi

Gülbahar Sokak Emniyet Sitesi D6
Kozyatağı, İstanbul-Türkiye

e-posta
mustafayildiz@yahoo.com

ÖZET

Giriş: Bu çalışmada ventriküler septal defekt ve atriyal septal defekti, çeşitli hemodinamik verilerden faydalanarak ayırt edebilecek bir sınıflama yöntemi geliştirmektedir.

Hastalar ve Yöntem: Kalp kateterizasyonu ile hemodinamik ölçümleri alınmış 30 atriyal septal defekt ve 13 ventriküler septal defektli toplam 43 (26 kadın, 17 erkek) hasta çalışmaya dahil

edildi. Sınıflandırma amacıyla hastaya ait çeşitli kan basıncı değerlerinin yanı sıra, cinsiyet, yaş bilgileri ve Qp/Qs oranları kullanılmıştır. Öncelikle, sınıflandırmada işe yarar öznitelikler diverjans analizi yöntemiyle elde edilmiştir. Bu öznitelikler sırasıyla; i) Pulmoner arter diyastolik basıncı, ii) Qp/Qs oranı, iii) Sağ atriyum basıncı, iv) Yaş, v) Pulmoner arter sistolik basıncı, vi) Sol ventrikül sistolik basıncı, vii) Aort ortalama basıncı, viii) Sol ventrikül diyastolik basıncı, ix) Aort diyastolik basıncı ve x) Aort sistolik basıncı olarak belirlenmiştir. Daha sonra, hastalardan elde edilmiş olan bu öznitelikler çok katmanlı yapay sinir ağına sunulmuş ve ağ genetik algoritma kullanılarak eğitilmiştir.

Bulgular: Eğitim kümesi, atriyal septal defekt ve ventriküler septal defekt sınıflarından yedişer adet olmak üzere toplam 14 eleman içermektedir. Tüm başarı ortalaması %79.2 olup; yapay sinir ağının uygun eğitilmesiyle %89'a kadar çıkabilmektedir.

Sonuç: Yapay sinir ağına ait ve klasik yöntemlerde kullanıcı tarafından girilmesi gereken parametreler genetik algoritmaların yardımıyla otomatik olarak bulunabilmektedir. Genetik algoritmalar ile yapay sinir ağının eğitilmesi sırasında hem ağın topolojisi hem de ağa ait ağırlıklar belirlenebilir. Test aşamasında, eğitim kümesi dışında kalan elemanlar test kümesi olarak belirlenmiş ve çalışma sonucunda çok katmanlı yapay sinir ağının başarılı bir biçimde eğitildiği ve sınıflama yapabildiği gözlemlenmiştir.

Anahtar Kelimeler: Kalp kateterizasyonu, ventriküler septal defekt, atriyal septal defekt, genetik algoritma, çok katmanlı yapay sinir ağı.

Geliş Tarihi: 25.06.2012 • **Kabul Tarihi:** 12.07.2012

ABSTRACT

Introduction: We aimed to develop a classification method to discriminate ventricular septal defect and atrial septal defect by using several hemodynamic parameters.

Patients and Methods: Forty three patients (30 atrial septal defect, 13 ventricular septal defect; 26 female, 17 male) with documented hemodynamic parameters via cardiac catheterization are included to study. Such parameters as blood pressure values of different areas, gender, age and Qp/Qs ratios are used for classification. Parameters, we used in classification are determined by divergence analysis method. Those parameters are; i) pulmonary artery diastolic pressure, ii) Qp/Qs ratio, iii) right atrium pressure, iv) age, v) pulmonary artery systolic pressure, vi) left ventricular systolic pressure, vii) aorta mean pressure, viii) left ventricular diastolic pressure, ix) aorta diastolic pressure, x) aorta systolic pressure. Those parameters detected from our study population, are uploaded to multi-layered artificial neural network and the network was trained by genetic algorithm.

Results: Trained cluster consists of 14 factors (7 atrial septal defect and 7 ventricular septal defect). Overall success ratio is 79.2%, and with a proper instruction of artificial neural network this ratio increases up to 89%.

Conclusion: Parameters, belonging to artificial neural network, which are needed to be detected by the investigator in classical methods, can easily be detected with the help of genetic algorithms. During the instruction of artificial neural network by genetic algorithms, both the topology of network and factors of network can be determined. During the test stage, elements, not included in instruction cluster, are assumed as in test cluster, and as a result of this study, we observed that multi-layered artificial neural network can be instructed properly, and neural network is a successful method for aimed classification.

Key Words: Heart catheterization, heart septal defects, ventricular; heart septal defects, atrial; algorithms; neural networks.

Received: 25.06.2012 • **Accepted:** 12.07.2012

Kosuyolu Kalp Derg 2012;15(2):45-50 • doi: 10.5578/kkd.3972

GİRİŞ

Konjenital kalp hastalıkları en sık görülen doğumsal anomalilerdendir. En sık rastlanan konjenital kalp hastalığı ise ventriküler septal defekt (VSD)'tir. İki ventrikül arasındaki basınç farkından dolayı sağ ventriküle ve pulmoner artere olan kan akımı artar ve sonuçta pulmoner hipertansiyon ve kalp yetersizliği gelişebilir^(1,2). İki atriyum arasındaki septumda defekt oluşması sonucu oluşan atriyal septal defekt (ASD)'te de aşırı volüm yüklenmesine bağlı olarak zamanla pulmoner basınçta artma, pulmoner hipertansiyon ve kalp yetersizliği gelişebilir⁽²⁾. ASD ve VSD tanı ve takibinde ekokardiyografi ve kalp kateterizasyonu oldukça önemlidir.

Genetik algoritma, temelde bir araştırma yöntemidir⁽³⁾. Genetik havuz olarak adlandırılan doğal ortamda, nesiller sonra o ortama en iyi uyum sağlayacak genler baskın çıkarken, bu canlı türü bu ortama en iyi ayak uydurabilecek özelliklere sahip olmuş olur. Genetik algoritmalar doğada bulunan bu süreci taklit eden bir doğal optimizasyon yöntemidir. Birçok parametreye sahip olan bir sistemin bazı durumlarda en iyi parametrelerini bulmak çok zor olabilir. Böyle durumlarda çözüm, olası parametre değerlerinin araştırılması şeklindedir. Rastgele bir araştırma yöntemi ise çoğu zaman oldukça zaman alıcıdır. Bu durumda genetik algoritma istenilen çözümü kısa bir sürede üretebilir. Sınıflandırmada kullanılan yapay sinir ağları da, birçok

parametreden (ağırlıklardan) oluşmuş yapay nöronlar kümesidir. Bu çalışmanın amacı, sık görülen konjenital kalp hastalıklarından VSD ve ASD'yi, kalp kateterizasyon verilerinden faydalanarak, ayırt edebilecek bir sınıflama yöntemi geliştirmektir.

HASTALAR ve YÖNTEM

Hasta Popülasyonu

Çalışmaya klinik ve ekokardiyografik olarak tanı konulmuş ve hemodinamik çalışma yapılmış 30 ASD'li ve 13 VSD'li toplam 43 (26 kadın, 17 erkek) hasta dahil edilmiştir. Hastalara ait hemodinamik veriler ortalama \pm standart sapma olarak gösterilmiştir.

Diverjans Analizi ve Veri Azaltma

Çalışmada, sınıflandırma amacıyla aşağıdaki öznitelikler kullanılmıştır:

1. Cinsiyet (26 kadın, 17 erkek),
2. Yaş (31.7 ± 15.7 yıl),
3. Sağ atriyal basınç (8.55 ± 3.43 mmHg),
4. Sağ ventrikül sistolik basıncı (54.46 ± 29.71 mmHg),
5. Sağ ventrikül diyastolik basıncı (0.39 ± 1.84 mmHg),
6. Sağ ventrikül ortalama basıncı (11.74 ± 7.54 mmHg),
7. Pulmoner arter sistolik basıncı (50.79 ± 31.68 mmHg),
8. Pulmoner arter diyastolik basıncı (20.06 ± 21.91 mmHg),
9. Pulmoner arter ortalama basıncı (30.93 ± 23.75 mmHg),
10. Sol ventrikül sistolik basıncı (129.95 ± 22.25 mmHg),
11. Sol ventrikül diyastolik basıncı (1.86 ± 12.19 mmHg),
12. Sol ventrikül ortalama basıncı (18.74 ± 17.79 mmHg),
13. Aortik sistolik basınç (126.25 ± 20.52 mmHg),
14. Aortik diyastolik basınç (74.18 ± 12.30 mmHg),
15. Aortik ortalama basınç (91.51 ± 15.26 mmHg),
16. Pulmoner kan akımı/Sistemik kan akımı (Qp/Qs) (2.26 ± 1.07).

Hemodinamik olarak Qp/Qs hesaplanması:

$Qp/Qs = (\text{Sistemik aorta } O_2 \text{ miktarı} - \text{Mikst venöz } O_2 \text{ miktarı}) / (\text{Pulmoner venöz } O_2 \text{ miktarı} - \text{Pulmoner arter } O_2 \text{ miktarı})$

Daha verimli sınıflandırma yapabilmek amacıyla, sıralanan özniteliklerden en önemli 10 tanesi kullanılmıştır. Bu amaçla, diverjans analizi yöntemiyle en işe yarar öznitelikler aşağıdaki sıraya göre belirlenmiştir:

1. Pulmoner arter diyastolik basıncı,
2. Qp/Qs,

3. Sağ atriyal basınç,
4. Yaş,
5. Pulmoner arter sistolik basıncı,
6. Sol ventrikül sistolik basıncı,
7. Aortik ortalama basınç,
8. Sol ventrikül ortalama basıncı,
9. Aortik diyastolik basınç,
10. Aortik sistolik basınç.

Genetik Algoritmalar

Genetik algoritma, temelde bir araştırma yöntemidir⁽³⁾. Doğada, çevreye uyum sağlayan canlı türleri hayatta kalırken, diğerlerinin yok olması olarak bilinen doğal seçim süreci sonucunda, çevre koşullarına uyum sağlayabilen canlılar sonraki nesillere sağlıklı genler aktarabilir. Canlıların sahip oldukları özellikler ortamın değişen şartlarına uyum sağlayacak biçimde baskın çıkarlar ya da yok olurlar. Bir doğal ortamda, bir canlı türünün çeşitli özelliklere sahip birçok üyesi bulunabilir. Genetik havuz olarak adlandırılan bu doğal ortamda, nesiller sonra o ortama en iyi uyum sağlayacak genler baskın çıkarken, bu canlı türü bu ortama en iyi ayak uydurabilecek özelliklere sahip olmuş olur. Genetik algoritmalar doğada bulunan bu süreci taklit eden bir doğal optimizasyon yöntemidir. Birçok parametreye sahip olan bir sistemin bazı durumlarda en iyi parametrelerini bulmak çok zor olabilir. Böyle durumlarda çözüm, olası parametre değerlerinin araştırılması şeklindedir. Rastgele bir araştırma yöntemi ise çoğu zaman oldukça zaman alıcıdır. Bu durumda genetik algoritma istenilen çözümü kısa bir sürede üretebilir. Sınıflandırmada kullanılan yapay sinir ağları da, birçok parametreden (ağırlıklardan) oluşmuş yapay nöronlar kümesidir.

Genetik Çok Katmanlı Yapay Sinir Ağının Yapısı

Çok katmanlı bir ağın eğitimi esnasında çeşitli sorunlarla karşılaşmaktadır:

1. Ağın topolojisini en iyi belirleyecek bir yöntem mevcut değildir; katman sayısı ve katmanlardaki düğüm sayıları tasarımcı tarafından belirlenmek zorundadır.

2. Ağın eğitiminde kullanılan geriye yayılım algoritması hem diğer yapay sinir ağlarının eğitim algoritmalarına göre yavaştır hem de ağı yerel minimum noktasına götürebilmektedir.

3. Çok katmanlı ağda düğüm sayısı bir defa belirlendikten sonra eğitim sırasında ihtiyaca göre artırılmaz. Genetik algoritmalarla ağa ait ve klasik yöntemlerde kullanıcı tarafından girilmesi gereken değerler en iyi biçimde bulu-

nurken, genetik algoritmaların sunduğu araştırma yöntemi sayesinde yerel minimumda kalma riski olmaz. Genetik algoritmalar ile yapay sinir ağının eğitilmesi sırasında hem ağın topolojisi hem de ağı ait ağırlıklar belirlenebilir.

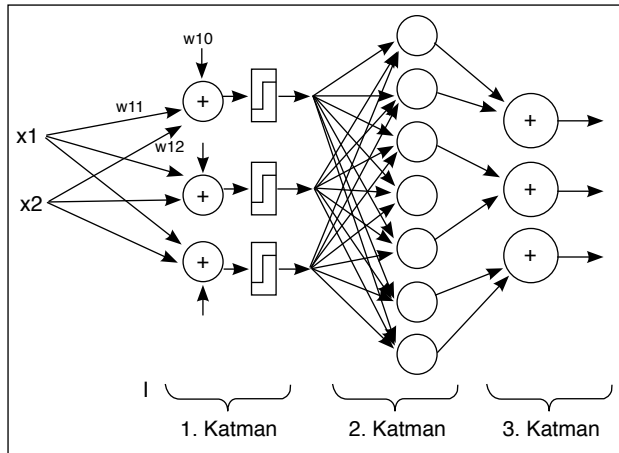
Genetik çok katmanlı ağ, üç katmandan oluşur (Şekil 1)⁽⁴⁾. Birinci katman, uzayı bölmeleyen hiper düzlemleri bulundurur. Bu katmandaki düğümler ağırlıkları ile uzayı farklı bölgelere ayırır. Uzay, ne kadar çok bölgeye ayrılırsa, sınıf dağılımı o kadar iyi temsil edilir. Genetik çok katmanlı ağın eğitilmesi bu katmanda bulunan ağırlıkların değiştirilmesiyle olur. Bu katmandaki düğümlerin çıkışları basamak fonksiyonuna aşağıdaki biçimde uygulanır.

$$y_j = \sum_{i=0}^N x_i w_{ji} \quad x_0 = 1$$


$$y_j = f(y_j) = \begin{cases} 1 & y_j \geq 0 \\ -1 & y_j < 0 \end{cases} \quad (1)$$

Birinci katmanın çıkış düğümleri, ikinci katman için bir bölge adresi olarak giriş olmaktadır. Şekil 2'de bu bölgeler gösterilmiştir. Görüldüğü gibi başarılı bir bölmelemede her bölgede yalnızca bir sınıfa ait eleman bulunmalıdır.

İkinci katman, birinci katman çıkışındaki bölge adresini alıp, bunun hangi bölgeye karşı düştüğünü belirtir. Bu katmanda, düğümler eğitim sırasında belirlenmiş adreslere sahiptir. Birinci katman çıkışının kendisine "hamming mesafesi" olarak en yakın olduğu düğüm bu katmanda kazanan düğüm olur ve ikinci katman çıkışında bu düğüm "1" değerini alırken, diğer düğümler "0" değerini alır. Şekil 2'de görüldüğü gibi bir sınıfa ait örnekler birden fazla bölgede bulunabilir. Bu yüzden, ikinci katman sınıf kararını üretmez, ancak incelenen örneğin hangi bölgede olduğunu belirler. İkinci katmandaki düğüm adedi en fazla birinci



Şekil 1. Genetik çok katmanlı ağın yapısı.



Şekil 2. Birinci katmanın uzayı bölgelere ayırması.

katmandaki düğümlerin sayısına bağlı olarak oluşan ayrık bölge sayısı kadardır. Sınıf kararını üretme işi üçüncü katmana bırakılır.

Üçüncü katman, ikinci katmandan aldığı bölge bilgisini ve eğitim sırasında oluşturulmuş olan ikinci katmana olan bağlantıları kullanarak sınıf kararını üretir. Üçüncü katmandaki düğüm sayısı, sınıf sayısı kadardır. Bu katman, basit bir "veya" işlemi yapar. Bir sınıf birden çok bölgede bulunabileceğinden, sınıfın bulunabileceği bölgelerin çıkışları "veya"lanarak sınıf kararı üretilmiş olur.

Genetik Çok Katmanlı Yapay Sinir Ağı'nın Eğitimi

Genetik çok katmanlı ağın eğitilmesi sırasında birinci katmandaki düğümlerin sayıları ihtiyaca göre belirlenecektir. Her düğüm ilavesi ile uzay daha fazla bölgeye ayrılabilir, böylece sınıflama yeteneği artacaktır. Uygulanacak olan uyumluluk fonksiyonu, ağın eğitim kümesindeki elemanları öğrendiği zaman maksimum değerine ulaşacaktır. Ağın, eğitim kümesini öğrenmesi demek, eğitim kümesindeki farklı sınıfa ait örnekleri farklı bölgelere ayırabilecek hiperdüzlemlerin belirlenmesi demektir. Şekil 2'de üç sınıflı birbirinden ayırmak için üç düğüm kullanılmış ve iki boyutlu uzay yedi bölgeye ayrılmıştır. Ağın eğitimi sırasında birinci katmanın düğümleri bu şekilde bir ayırım yapılanaya kadar genetik yöntemlerle en uygun ağırlıkları kazanır ve gerektiği zaman düğüm sayısı artırılır. Uyumluluk fonksiyonu aşağıdaki biçimde tanımlanmıştır.

$$\{E\} = \bigcup_{i=1}^M c_i$$

$$\{c_i\} = \bigcup_{k=1}^S \{c_{ik}\} = \{c_{i1}\} \cup \{c_{i2}\} \dots \cup \{c_{is}\} \quad (2)$$

$$\text{MAX}_i = \text{Max} (\# \{c_{i1}\}, \# \{c_{i2}\}, \dots, \# \{c_{is}\})$$

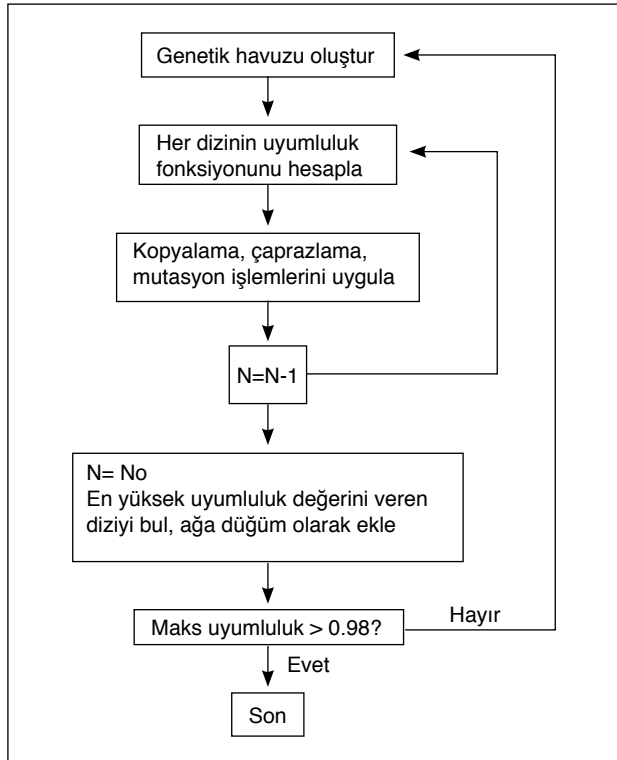
$$\text{UF} = \sum_{i=1}^M \frac{\text{MAX}_i}{\#\{E\}}$$

$\{E\}$; eğitim kümesini, $\{c_{ik}\}$; i. bölgede k. sınıfa ait vektörlerin kümesini, M; vektör içeren bölge sayısını göstermektedir.

Birinci katman genetik algoritmayla bulunduktan sonra; oluşan bölgelerin içerdiği sınıflara bakarak ikinci ve üçüncü katmanlar hesaplanır ve ağ eğitilmiş olur. Şekil 3'te, eğitim yönteminde kullanılan adımlar algoritmik olarak verilmiştir.

BULGULAR

Algoritmalar Matlab® ortamında kodlanmış olup 2.2 GHz İntel Centrino işlemcili bilgisayarda çalıştırılmıştır. Eğitim kümesi, ASD ve VSD sınıflarından yedişer adet olmak üzere toplam 14 eleman içermektedir (Tablo 1,2). Tüm başarı ortalaması %79.2 olup; yapay sinir ağının uygun eğitilmesiyle %89'a kadar çıkabilmektedir.



Şekil 3. Genetik çok katmanlı ağın eğitimi.

Tablo 1. Beş deneme için genetik çok katmanlı ağın çalışma aşaması sonuçları

1. katmana ait düğüm sayısı	2. katmana ait düğüm sayısı	Eğitim süresi	Genel yüzde (doğru/test kümesi)
4	6	7.25 sn	82
4	6	7.93 sn	75
3	6	4.88 sn	68
5	9	9.23 sn	82
4	8	6.58 sn	89

Tablo 2. Genetik çok katmanlı ağ ile elde edilen sınıflandırma sonucu

Gerçek\Bulunan	ASD	VSD
ASD	21	2
VSD	1	5

ASD: Atriyal septal defekt, VSD: Ventriküler septal defekt.

TARTIŞMA

ASD ve VSD en sık rastlanan konjenital kalp hastalıklarındandır. Bu hastalıkların zamanında tanınip tedavi edilmesi ileride gelişebilecek kardiyak komplikasyonlar açısından oldukça önemlidir. Bu patolojilerin tanı, tedavi ve takibinde hemodinamik ölçümler oldukça yararlıdır^(1,2,5). Genetik algoritmalar ve yapay sinir ağları çeşitli hastalıkların sınıflandırılmasında önemli yöntemler olarak kullanılabilir^(3,4). Yapay sinir ağına ait ve klasik yöntemlerde kullanıcı tarafından girilmesi gereken parametreler genetik algoritmaların yardımıyla otomatik olarak bulunabilmektedir. Genetik algoritmalar ile yapay sinir ağının eğitilmesi sırasında hem ağın topolojisi, hem de ağa ait ağırlıklar belirlenebilir. Çalışmamızda, test aşamasında, eğitim kümesi dışında kalan elemanlar test kümesi olarak belirlenmiş ve çalışma sonucunda genetik çok katmanlı ağın başarılı bir biçimde eğitildiği ve sınıflama yapabildiği gözlemlenmiştir. Sonuç olarak, hemodinamik verilerden yararlanarak, genetik algoritmalar ve çok katmanlı yapay sinir ağları yardımıyla, ASD ve VSD tanınması özellikle eğitim sürecindeki klinisyenlere büyük kolaylık sağlayacaktır.

Kalp Kateterizasyonu ile Hemodinamik Ölçümleri Saptanmış Atriyal Septal Defekt ve Ventriküler Septal Defektli Olguların Genetik Algoritmalar ve Çok Katmanlı Yapay Sinir Ağı ile Sınıflandırılması

Classification of Atrial Septal Defect and Ventricular Septal Defect with Documented Hemodynamic Parameters via Cardiac Catheterization by Genetic Algorithms and Multi-Layered Artificial Neural Network

KAYNAKLAR

1. Korurek M, Yildiz M, Yuksel A, Sahin A. Simulation of Eisenmenger syndrome with ventricular septal defect using equivalent electronic system. *Cardiol Young* 2012;22:301-6.
2. McDaniel NL. Ventricular and atrial septal defects. *Pediatr Rev* 2001;22:265-70.
3. Jamshidi M. Tools for intelligent control: fuzzy controllers, neural networks and genetic algorithms. *Philos Transact A Math Phys Eng Sci* 2003;361:1781-808.
4. Dokur Z. Segmentation of MR and CT images using a hybrid neural network trained by genetic algorithms. *Neural Processing Letters* 2002;16:211-25.
5. Di Sessa TG, Friedman WF. Echocardiography in congenital heart disease. *Cardiovasc Clin* 1983;13:41-65.