

Yapay Zeka Teknikleri ve Radyolojiye Uygulanması

Selami Serhatlıoğlu¹, Ahmet Tefvik Ozan², Fırat Hardalaç³

¹sserhatlioglu@firat.edu.tr, ²atozan@firat.edu.tr, ³firat@gazi.edu.tr
Firat Üniversitesi Tıp Fakültesi ve Firat Üniversitesi Mühendislik Fakültesi

Yapay zeka insanlar tarafından yapıldığında zeka olarak adlandırılan akıllı davranışların cihazlar tarafından yapılmasıdır. Çoğunlukla insanın düşünme yeteneğini ve beynin çalışma özelliğini modellemeye çalışan yöntemlerden oluşur. Yapay zekanın amacı insanın zekasını bilgisayar aracılığı ile taklit etmek ve bu anlamda belli bir ölçüde bilgisayarlara öğrenme yeteneği kazandırabilmektir. Bilim adamları yıllardır yaptıkları çalışmalarla hayatımızı daha kolay hale getirmek için programlar geliştirmektedirler. Yapay zeka sistemleri bu programlara iyi bir örnektir (1).

Yapay zeka yöntemlerinin başlıcaları; uzman sistemler, bulanık mantık, yapay sinir ağları ve genetik algoritmalarından oluşur. Uzman sistemler kısaca bir kural tabanlı sistem olarak nitelendirilebilir. Burada kullanılan kurallar bir uzmanın görüşü veya deneyimine dayandırılarak oluşturulur. Oluşturulan bu kurallardan insanın neden-sonuç ilişkisine bağlı olarak bir karara varması gibi mantıksal işlemlerle bir çıkarım yapılır. Bulanık mantık ise bir kural tabanlı sistem olarak düşünülebilir. Fakat burada nitelendirmeler, uzman sistemlerden farklı olarak, insanların günlük hayatta yaptığı nitelendirmelerin büyük çoğunluğu gibi kesin değildir. Bulanık mantık bu şekilde kural tabanının günlük hayatta kullanılan kesin olamayan hükümlerle oluşturulmasına imkan sağlar. Yapay sinir ağları adından da anlaşılacağı gibi beynin çok basit bir nöron modelinin benzetimidir.

Beynin öğrenme kapasitesi nöronlar ve bunların birbiri ile olan bağlantısına bağlıdır. Bu şekilde elde edilen yapay ağ ile öğrenme olayı modellenir. Günümüzde yapay zeka kontrol, tasarım, biomedikal ve tıp alanları başta olmak üzere araştırmacıların büyük ilgisini çekmektedir (2, 3).

Bu çalışmada yapay zeka teknikleri tanıtılarak bu tekniklerin radyolojide kullanımlarına ilişkin görüşler ortaya konulması amaçlandı.

Yapay zeka tekniklerine ilişkin ilk görüşler günümüzden yıllarca önce, 1965 yılında ortaya

atılmış, 1969 yılında bulanık küme teorisinin tıp alanında kullanılabilirliğinin açıklanması ile pek çok çalışma yapılmaya başlanmış, 1975 yılında kardiyovasküler sistemlerin klinik uygulamalarda kullanılması önerilmiş, 1980'de kardiyak fonksiyonlarının değerlendirilmesinde bulanık küme teorisinin kullanılması ile ilgili çalışmalar yapılmış, 1989'da EKG verilerinin sınıflandırılması ve tanısı konusunda ilk çalışmalar yapılmış ve bu çalışmalarda elde edilen bilgiler, bulanık küme formuna getirilerek istatistiksel yaklaşımlarla sınıflandırılmıştır (4-7).

1990'lı yılların ortalarında kalp hastalıklarında bulanık küme ve hibrit sistemlerle tanısı ile ilgili çalışmalar yapılmış, 1994 yılında koroner arter hastalığı yapay sinirsel sistemle %89 doğruluk oranında sınıflandırılmış ve sonraki yıllarda da yapay zeka teknikleri ile çeşitli kalp hastalıklarında tanı koymada, büyük başarı kaydedilmiştir. 1996 yılında kalbin tomografik görüntüleri bulanık mantık ile %94 doğruluk oranında sınıflandırılmış, 1998 yılında koroner arter hastalıklarının bulanık mantıkla sınıflanması konusunda genetik bulanık kural tabanı kullanılarak % 96 oranında başarı elde edilmiştir (8-13).

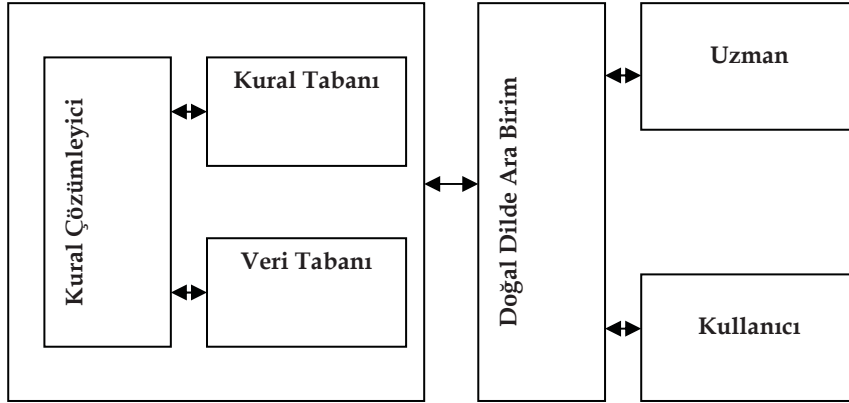
1999 yılında NEFCLASS sinirsel bulanık

mantık sistemi ile akciğer kanseri bulgularlarının sınıflandırılmasında % 95 oranında başarı sağlanmıştır (14).

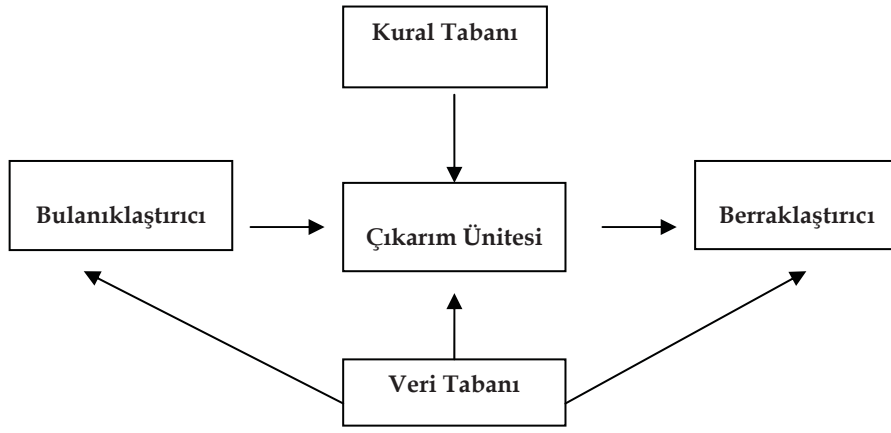
2002 ve 2004 yıllarında bulanık mantık ve genetik tabanlı bulanık sınıflayıcı ile kardiyak Doppler

işaretlerinin sınıflandırılması başarılı bir şekilde gerçekleştirilmiştir (15, 16).

2005 yılında yapılan bir çalışmada Doppler sonogramlarından elde edilen parametrelerle sinir ağı eğitilmiş ve orta serebral arter darlığının dereceleri tahmin edilmeye çalışılmış, sistemin performansının veri boyutuna ve eğitim için seçilen parametrelere son derece bağımlı olduğu saptanmıştır (17).



Sekil 1. Bir Uzman Sisteminin Sematik Yapısı



Şekil 2. Bulanık Mantık Programının şematik yapısı

Yapay Zeka Teknikleri

1. Uzman Sistemler (Expert Systems)

Yapay zekanın en önemli uygulama alanlarından biri uzman sistemlerdir. Bu tip sistem belli bir alanda uzman olan kişilerin uzmanlıklarına dayanarak çözüm arar. Bunu bir tür bilgisayarda düzenlenmiş danışma sistemi olarak düşünebiliriz. Uzman sistemlerin oluşturulmasında, sırasıyla; tanımlama, kavramsallaştırma, formüle etme (yazılım), test etme ve değerlendirme aşamaları uygulanır. Tıp ve biomedikal en başta gelen uygulama alanlarıdır (18, 19).

Bir uzman sistem; kural tabanı, veri tabanı ve kural çözümleyici olmak üzere üç bölümden oluşur. Şekil 1'de, bir uzman sistemin şematik yapısı görülmektedir.

2. Bulanık Mantık (Fuzzy Logic)

Bulanık mantık programının dayandığı temel nokta; uzman bir sistem operatörünün bilgi, deneyim, sezgi ve kontrol sonuçlarını bilgi tabanı olarak oluşturmaktır. İşlemler bilgi ve deneyime dayanan kurallarla gerçekleştirilir. Bulanık mantıkta deneyimler etkin bir şekilde kullanılır. Bilgisayar tabanlı uygulamalarında kural tabanı, veri tabanı, bulanıklaştırıcı, çıkarım ve berraklaştırıcı yazılımlar kullanılarak işlem gerçekleştirilir. Şekil 2'de bir bulanık mantık programının şematik yapısı görülmektedir.

Bulanık mantık, insan düşüncesinin esnek ve değişken yapısını dikkate alan bir algoritmadır. Bilgiler arasında sebep-sonuç ilişkisi kurarak doğru ve mantıksal bir sonuç üretir. Bu işlemin yapılabilmesi için ilk olarak verilerin belirlenmesi gerekmektedir. Bu veriler belirli sınırlar içerisinde gruplandırılarak bulanık kümeler haline getirilir, tüm olası durumlar dikkate alınarak kural tabanı oluşturulur. Bu kurallar bir kontrol algoritması ile değerlendirilerek çıkış bilgisi elde edilir (20).


Bulanık mantık teorisi bugüne kadar kalite kontrol, ürün planlanması, taşıma, ulaşım, network, oyunlar kuramı, bankacılık, finans, ziraat ve tıp gibi birçok bilim dalında başarı ile uygulanmıştır (21).

3. Yapay Sinir Ağları (Artificial Intelligence Networks)

Yapay sinir ağları örneklerle ilgili bilgiler toplamakta, genellemeler yapmakta ve daha sonra hiç görmediği örnekler ile karışılışınca öğrendiği bilgileri kullanarak o örnekler hakkında

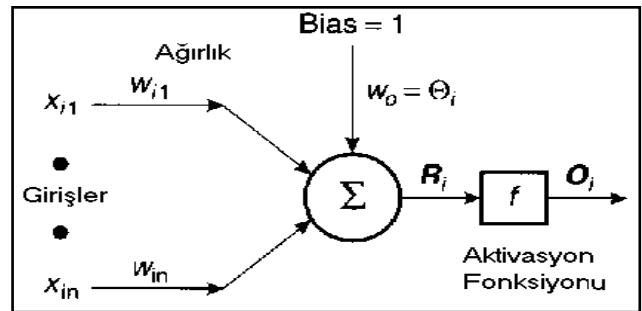
karar verebilmektedir. Yapay sinir ağları bu öğrenebilme ve genelleme özellikleri nedeniyle günümüzde birçok bilim alanında geniş uygulama olanağı bulmakta ve karmaşık problemleri başarı ile çözebilme yeteneğini ortaya koymaktadır (3).

Sinir ağları insan beyindeki nöronlara benzer olarak bir araya getirilen yapay nöronların değişik




Şekil 3a. Biyolojik bir nöronun şematik yapısı

bağlantı geometrisi ile birbirlerine bağlanması sonucu oluşan sistemlerdir. Şekil 3a,b' de doğal bir nöronun ve yapay bir sinir ağının şematik yapısı görülmektedir.



Şekil 3b. Bir yapay nöronun şematik yapısı

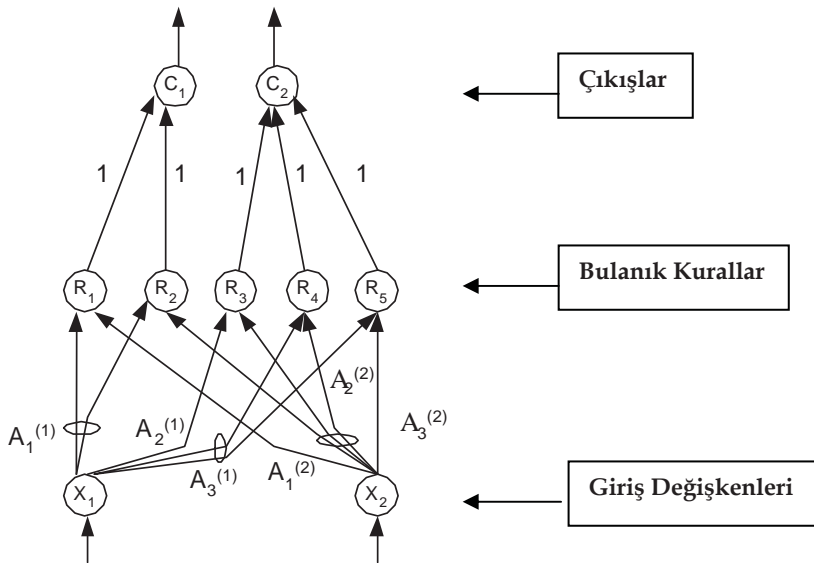
Sinir ağları paralel hesaplama tekniğini kullanan bir metottur. Programlama yerine doğrudan mevcut örnekler üzerinden eğitilerek işlem yapılır. Bağımsız değişkenler (giriş) ile bu değişkenlere ilişkin bağımlı değişkenler (çıkış) arasındaki matematiksel ilişki "öğrenilebilir" sistemlerdir. Şekil 4'de ileri beslemeli yapay sinir ağları şematik yapısı görülmektedir.



Şekil 4. İleri beslemeli giriş, gizli ve çıkış katmanlarından oluşan sinir ağı mimarisi

Bu çalışmalarda kullanılan ileri beslemeli ağ mimarisinde nöronlar katmanlar halinde yerleştirilir. İleri beslemeli sinir ağı en az üç katmandan oluşur. Bu katmanlı yapısından dolayı çok katmanlı algılayıcı (multilayer perceptron) olarak da isimlendirilmektedir. İleri beslemeli sinir ağları geniş bir uygulama alanına sahiptir. Radyolojik bulguların değerlendirilmesinde kendisini kanıtlamış olan ileri beslemeli sinir ağları transcranial Doppler parametrelerinin sınıflandırılmasında da kullanılmıştır (22, 23).

Hastalıklarda tanıya varma işlemi yapay zeka ile bir "şekil tanıma" görevi gibi ele alınabilir. Sinir ağları son 20 yıldır şekil tanıma problemleri için bir hesaplama aracı olarak birçok biçim ve öğrenme algoritması ile akademik araştırmalarda, endüstride ve tıbbi uygulamalarda kullanılmaktadır. Literatürde sinir ağlarının kalp yetmezliği, miyokard enfarktüsü ve anjina pectoris tanısında birçok klinik uygulamaları ve başarılı sonuçları bildirilmiştir (24-29).



Şekil 5. NEFCLASS modelin yapısı [R kuralları, A(X) ağırlıkları (W) ifade etmektedir]

4. Sinirsel Bulanık Sistemler ve NEFCLASS Modelin Yapısı

Sinirsel bulanık sistemler sinir ağları ile bulanık sistemlerin birleşimidir. Bu iki model ilk etapta kendi arasında bağımsız bir alana sahiptir. Ancak ikisinin birleşimi çoğu problemin çözümü için yarar sağlamaktadır.

Bir sinirsel bulanık sistem olan NEFCLASS, veriden bulanık sistem oluşturan dilsel bir yaklaşım metodu olup, yerel parametre değişimleri sezgisel (heuristic) veri sürme algoritması ile hesaplanır. NEFCLASS modelinin ana amacı okunabilir bir sınıflayıcı oluşturmak ve kabul edilebilir bir doğruluğu yakalamaktır (30).

NEFCLASS sinirsel bulanık sistem; özel üç katmanlı ileri beslemeli bir sinir ağı gibi ilk katman giriş değişkenlerini, gizli katman bulanık kurallarını, üçüncü katman ise çıkış değişkenlerini ifade eder ve her biri için bir ünite vardır. Şekil 5'de NEFCLASS modelin yapısı görülmektedir.

NEFCLASS ve sinir ağlarının literatürdeki örnek uygulamalarında Doppler hız parametrelerinin beyin arterlerindeki darlık derecelerini belirleyebileceği bildirilmektedir. Pratik uygulamalarda ultrasonografik Doppler bulguları tanıya yeterli görülmediği olgular, daha invaziv bir yöntem olan anjiyografiye tabi tutulmaktadır. Doppler parametrelerinin yapay zeka teknikleri ile gerçek zamanlı olarak yorumlanması klinik çalışmalarda transcranial Doppler tekniğini daha etkin kılacaktır. Bildirilen bu çalışmalarda transcranial Doppler parametreleri istatistiksel metoda dayalı bir yapay zeka yöntemi olan sinir ağı modeline uygulanarak sınıflandırılmasında başarılı olunmuştur (31-34).

Sinir ağları insan beynindeki nöronlara benzer olarak birleştirilen yapay nöronların bağlantı geometrisi ile birbirleriyle ilişkilendirilmesi sonucu oluşan sistemlerdir. İleri beslemeli sinir ağları, geniş bir uygulama alanına sahiptir. İleri beslemeli sinir ağı, transcranial Doppler ve kardiyak Doppler işaretlerinin sınıflandırılmalarında başarılı bulunmuştur. Bu tip ağ yapısı tıp ve biomedikal dahil birçok alana başarı ile uygulanmaktadır. (35-48).

Doppler ultrasonografi bulguları bir çalışmada ileri beslemeli geri yayımlı sinir ağı mimarisi ile, bir başka benzer çalışmada ise diğer bir yapay zeka yöntemi olan genetik algoritma sistemi kullanılarak başarılı bir şekilde sınıflandırılmıştır (49, 50).

5. Çok Katmanlı Algılayıcılar ve Öğrenme Algoritmaları

Çok katmanlı algılayıcı modeli bir giriş, bir veya daha fazla ara ve bir de çıkış katmanından oluşur. Bir katmandaki işlem elemanları bir üst katmandaki işlem elemanlarına bağlıdır. Birçok öğretim algoritmasının bu ağı eğitmede kullanılabilir olması bu modelin yaygın kullanımının nedenidir.

Çok katmanlı algılayıcı ağlarında örnekler "giriş katmanı"na uygulanır, "ara katmanlar" da işlenir ve "çıkış katmanı"ndan da çıkışlar elde edilir. Kullanılan eğitim algoritmasına göre ağın çıkışı ile arzu edilen çıkış arasındaki "hata" tekrar geriye doğru yayılarak minimuma düşünceye kadar ağırlıkları değiştirilir.

Anlaşılması kolay ve matematiksel olarak ispatlanabilir olmasından dolayı en çok tercih edilen öğretim algoritmasıdır. Bu algoritma hataları geriye doğru çıkıştan girişe azaltmaya çalışmasından dolayı geri yayılım ismini almıştır. Tipik çok katlı geri yayılım ağı, daima; bir giriş tabakası, bir çıkış tabakası ve en az bir gizli tabakaya sahiptir. Sinir ağı yapısının bulguları, daha başarılı bir şekilde sınıflandırılabilmesi için "Genetik Algoritma ve Sinir Ağı" yöntemi geliştirilmiş ve tıp dahil birçok alanda başarılı bir şekilde uygulanmıştır (51).

6. Genetik Algoritma (Genetic Algorithm)

Genetik algoritma konusunda ilk çalışmalarda canlılarda yaşanan genetik sürecin bilgisayar ortamında gerçekleştirilmesi düşünülmüştür (52, 53).

Genetik algoritma parametre kümelerini kodlayarak çalışır. Genetik algoritma amaç fonksiyonu bilgisini kullanır. Genetik algoritma, doğal genetik ve doğal seçim mekaniğine dayanan olasılıksal bir arama metodudur. Doğada iyi olanın hayatta kalması prensibine dayanır. Sezgisel bir metot olan genetik algoritma, geleneksel çözüm teknikleri ile çözülemeyen veya çözümü zor olan problemlere başarı ile uygulanmıştır (54-56).

Yapay zeka yöntemlerinin klinik uygulamalarda ortaya koyduğu başarılı sonuçlar, radyolojik görüntülerinin yorumlamalarına katkı sağlayacak ve radyologlara bu konuda da yardımcı olacaktır.

Sonuç olarak yapay zeka yöntemleri ile yapılan bu çalışmalarla, tanıya varmada gerçek zamanlı olarak uygulanabilir olmasının yanında radyolojik incelemelerde elde edilen bulgulara ait parametrelerin hızlı ve kesin bir şekilde değerlendirilebileceği görülmektedir.

Kaynaklar

1. Moe MC, Westerlund U, Varghese M, Berg-Johnsen J, Svensson M, Langmoen IA. Development of neuronal networks from single stem cells harvested from the adult human brain. *Neurosurgery* 2005;56(6):1182-90.

2. Baxt WG. Application of artificial neural networks to clinical medicine. *Lancet* 1995;346:1135-8.
3. Ergezer H, Dikmen M, Özdemir E. Yapay sinir ağları ve tanıma sistemleri. *PIVOLKA* 2003;2(6):14-17.
4. Zadeh, LA. Biological application of the theory of fuzzy sets and systems on Biocybernetics of the Central Nervous System, *Proc Int Sym* 1969;199-212.
5. Mobley BA, Schechter E, Moore WE, McKee PA, Eichner JE. Neural network predictions of significant coronary artery stenosis in men. *Artif Intell Med* 2005;34(2):151-61.
6. Rafiee A, Moradi MH, Farzaneh MR. Novel genetic-neuro-fuzzy filter for speckle reduction from sonography images. *J Digit Imaging* 2004;17(4):292-300.
7. Kalmanson D, Stegall HF. Cardiovascular investigations and fuzzy set theory. *American Journal of Cardiology* 1975 35:80-84.
8. Guo Z, Durand LG, Allard L, Cloutier G, Lee HC, Langlois YE. Cardiac Doppler blood flow signal analysis. Part II: The timefrequency distribution by using autoregressive modeling. *Med Biol Eng Comput* 1993;31:242-248.
9. Degani R, Bortolan G. Fuzzy decision-making in electrocardiography. *Artificial Intelligence in Medicine* 1898;87-91.
10. Kere EE. Outline of an expert system for ECG diagnosis using fuzzy sets. *Artificial Intelligence in Medicine* 1989;3:139-144.
11. Hudson DL, Cohen, ME, Deedwania PC. A hybrid system for diagnosis and treatment of heart disease. *Medicine Biology Society* 1994;1368-1369.
12. Baxt WG. Use of an artificial neural network for data analysis in clinical decision making: The diagnosis of acute coronary occlusion. *Neural Computation* 1990;2,480-489.
11. Akay YM, Akay M, Welkowitz W, Kostis J. Noninvasive detection of coronary artery disease. *Eng in Medicine and Biology Mag* 1994;9(5):761-764.
12. Cios KJ, Goodenday LS, Shah KK, Serpen G. A novel algorithm for classification of SPECT images of a human heart. *Proc. 9th IEEE Symp. on computer-based medical systems, IEEE Comput. Soc. Press, Los Alamitos* 1996;1-5.
13. Jain R, Mazumdar J, Moran W. Application of fuzzy classifier system to coronary artery disease and breast cancer. *Australasian Physical Engineering Sciences in Medicine* 1998;21(3):141-147.
14. Nauck D, Kruse R. Obtaining interpretable fuzzy classification rules from medical data. *Artificial Intelligence in Medicine* 1999;16:149-169.
15. Güler İ, Hardalaç F, Barışçı, N. Application of FFT analyzed Cardiac Doppler Signals To Fuzzy Algorithm. *Computers in Biology and Medicine* 2002;32:435-444.
16. Güler İ, Hardalaç F, Ergu, U, Barışçı N. Classification of Aorta Doppler signals using variable coded-hierarchical genetic fuzzy system. *Expert Systems with Applications* 2004;26:321-333.
17. Uçman E. Transcranial Doppler İşaretlerinin Yapay Zeka Ortamında Sınıflandırılması. *Gazi Üniversitesi Fen Bilimleri Enstitüsü Doktora Tezi* 2005;69.
18. Leung SC, Fulcher J. Classification of user expertise level by neural networks. *Int J Neural Syst* 1997;8(2):155-71.
19. Heiss JE, Held CM, Estevez PA, Perez CA, Holzmann CA, Perez JP. Classification of sleep stages in infants: a neuro fuzzy approach. *Eng Med Biol Mag* 2002;21(5):147-51.
20. Atacak İ. Genel Amaçlı Bir Bulanık Mantık Denetleyicinin Tasarımı. *Gazi Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Tezi* 1998;71.
21. Nauck D, Klawonn F, Kruse R. Foundations of neuro-fuzzy systems. *Wiley Chichester* 1997;187-221.
22. Williams R, *Neural Network Learning and Application*. Addison-Wesley 1989; 1-212.
23. Ergün U, Hardalaç F, Güler İ. Geri yayılım sinir ağlarını kullanarak transcranial Doppler işaretlerinin sınıflandırılması. *Biyomedikal Mühendisliği Ulusal Toplantısı Biyomut* 2002;111-114.
24. Basheer IA, Hajmeer M. Artificial neural networks: Fundamentals, computing, design, and application. *Journal of Microbiological Methods* 2000;43:3-31.
25. Baxt WG. Use of an artificial neural network for data analysis in clinical decision making: The diagnosis of acute coronary occlusion. *Neural Computation* 1990;2,480-489.

26. Baxt WG. Use of an artificial neural network for the diagnosis of myocardial infarction. *Ann Intern Med* 1991; 1;115(11):843-8.
27. Baxt WG. A neural network trained to identify the presence of myocardial infarction bases some decisions on clinical associations that differ from accepted clinical teaching. *Med Decis Making* 1994;14(3):217-22.
28. Baxt WG, Shofer FS, Sites FD, Hollander JE. A neural computational aid to the diagnosis of acute myocardial infarction. *Ann Emerg Med* 2002;39(4):366-73.
29. Hollander JE, Sease KL, Sparano DM, Sites FD, Shofer FS, Baxt WG. Effects of neural network feedback to physicians on admit/discharge decision for emergency department patients with chest pain. *Ann Emerg Med* 2004;44(3):199-205.
30. Nauck D, Kruse R. NEFCLASS-X: A soft computing tool to build readable fuzzy classifiers. *BT Technology Journal* 1998;6(3):180-190.
31. Kaps M, Damian MS, Teschendorf U, Dorndorf W. Transcranial Doppler ultrasound findings in middle cerebral artery occlusion. *Stroke* 1990;21: 532-537.
32. Demchuk AM, Christo I, Wein T, Felberg RA, Malkoff M, Grotta JC, Alexandrov AV. Specific transcranial Doppler flow findings related to the presence and site of arterial occlusion. *Stroke* 2000;31: 140-146.
33. Lupetin AR, Davis DA, Beckman I, Dash N. Transcranial Doppler sonography part 1. principles technique and normal appearances. *Radiographics* 1995;15: 179-191.
34. Bishop CCR, Powell S, Rutt D, Browse NL. Transcranial Doppler measurement of middle cerebral artery blood flow velocity: a validation study. *Stroke* 1986;17:913-915.
35. Haykin S. *Neural Networks: A Comprehensive Foundation*. Macmillan College Publishing Company 1994;1-60.
36. Basheer IA, Hajmeer M. Artificial neural networks: fundamentals, computing, design, and application. *Journal of Microbiological Methods* 2000;43:3-31.
37. Tafeit E, Reibnegger G. Artificial neural networks in laboratory medicine and medical outcome prediction. *Clinical Chemistry and Laboratory Medicine* 1999;37(9):845-853.
38. Lim CP, Harrison RF, Kennedy RL. Application of autonomous neural network systems to medical pattern classification tasks. *Artificial Intelligence in Medicine* 1997;11:215-239.
39. Baxt WG. Use of an artificial neural network for data analysis in clinical decision making: the diagnosis of acute coronary occlusion. *Neural Computation* 1990;2:480-489.
40. Allen J, Murray A. Development of a neural network screening aid for diagnosing lower limb peripheral vascular disease from photoelectric plethysmography pulse waveforms. *Physiological Measurement* 1993;14:13-22.
41. Allen J, Murray A. Prospective assessment of an artificial neural network for the detection of peripheral vascular disease from lower limb pulse waveforms. *Physiological Measurement* 1995; 16:39-42.
42. Ergün U, Hardalaç F, Güler İ. Geri yayılım sinir ağlarını kullanarak transcranial Doppler işaretlerinin sınıflandırılması. *Biyomedikal Mühendisliği Ulusal Toplantısı Biyomut* 2002;111-114.
43. Barışçı N, Ergün U, İlkey E, Serhatlıoğlu S, Hardalaç F, Güler İ. Classification of mitral insufficiency and stenosis using MLP neural network and neuro - fuzzy system", *Journal of Medical Systems* 2004;28(5) 423-436.
44. Akay M. Non-invasive diagnosis of coronary artery disease using a neural network algorithm. *Biological Cybernetics* 1992;67:361-367.
45. Mobley BA, Schechter E, Moore WE, McKee PA, Eichner JE. Predictions of coronary artery stenosis by artificial neural network. *Artificial Intelligence in Medicine* 2000;18: 187-203.
46. Ergün U, Serhatlıoğlu S, Hardalaç F, Güler I. Classification of carotid artery stenosis of the patients with diabetes by neural network and logistic regression. *Computers in Biology and Medicine* 2004;34:389-405.
47. Wright IA, Gough NAJ. Artificial neural network analysis of common femoral artery Doppler shift signals: Classification of proximal disease. *Ultrasound in Medical Biology* 1999;24(5):735-743.
48. Baxt WG. Application of artificial neural networks to clinical medicine. *Lancet* 1995;346:1135-1138.
49. Ergün U, Serhatlıoğlu S, Hardalaç F, Güler I. Classification of carotid artery stenosis of the patients with diabetes by neural network and logistic regression. *Computers in Biology and Medicine* 2004;34:389-405.
50. Güler I, Hardalaç F, Ergün U, Barışçı N. Classification of aorta Doppler signals using variable coded-hierarchical genetic fuzzy system. *Expert Systems with Applications* 2004;26:321-333.
51. Heckerling PS, Gerber BS, Tape TG, Wigton RS. Selection of predictor variables for pneumonia using neural networks and genetic algorithms. *Methods Inf Med* 2005;44(1):89-97.
52. Gosling RG, King DH. Arterial assessment by Doppler shift ultrasound. *Proceeding of the Royal Society of Medicine* 1974;67:447-449.
53. Goldberg DE, Samanti MP. Engineering optimization via genetic algorithm. *Proceedings of the Ninth Conference on Electronic Computation* 1986;471-482.
54. Goldberg DE. *Genetic Algorithms in Search, Optimization Machine Learning*. Addison-Wesley 1989;1-411.
55. Booker LB, Goldberg DE, Holland JH. Classifier systems and genetic algorithms. *Artificial Intelligence* 1989;40:235-282.
56. Rafiee A, Moradi MH, Farzaneh MR. Novel genetic-neuro-fuzzy filter for speckle reduction from sonography images. *J Digit Imaging* 2004;17(4):292-300.