

Derleme



Yapay Zeka Teknikleri ve Radyolojiye Uygulanması

Selami SERHATLIOĞLU^{a1}, Fırat HARDALAC²

¹Fırat Üniversitesi Tıp Fakültesi, Radyoloji Anabilim Dalı, ELAZIĞ

²Gazi Üniversitesi Mühendislik Mimarlık Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, ANKARA

ÖZET

İnsanın düşünme yapısının benzerini bilgisayar işlemlerini geliştirerek yapmaya çalışmak olarak tanımlanmakta olan yapay zekâ günümüzde birçok alanda yaygın bir şekilde kullanılmaya başlanmıştır. Bu makalede yapay zekâ teknikleri tanıtılarak bu tekniklerin radyolojide kullanımlarına ilişkin görüşler ortaya konulması amaçlanmıştır.

Anahtar Sözcükler: Yapay zeka teknikleri, klinik uygulamalar, radyoloji

ABSTRACT

Techniques of Artificial Intelligence Network (Ann) and Applied to Radiology

Artificial Neural Network (ANN) have been begin by using in various field and worked to build by developing of computer process to similar thing of human. In this cases, Introducing of Neural network techniques were aimed to composed of estimation on relationship ideas by using radiology.

Key words: Artificial intelligence network, expert system, fuzzy logic, genetic algorithm, radiology

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 kararlar 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 olmayan 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, biyomedikal ve tıp alanları başta olmak üzere araştırmacıların büyük ilgisini çekmektedir (2,3).

Yapay zeka tekniklerine ilişkin ilk görüşler günümüzden yıllarca önce, 1965 yılında ortaya atılmış, 1969 yılında bulanık küme teorisinin tıp alanında kullanılabilirliği açıklanması ile pek çok çalışmalar yapılmaya başlanmış, 1975 yılında kardiyovasküler sistemlerin klinik uygulamalarda kullanılması önerilmiş, 1980'de kardiak fonksiyonlarının değerlendirilmesinde bulanık küme teorisinin kullanılmasında çalışmışlar 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 hastalığının 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 sınıflaması konusunda genetik bulanık kural tabanı kullanılarak %96 oranında başarı elde edilmiştir (8-15).

1999 yılında NEFCLASS sinirsel bulanık mantık sistemi ile akciğer kanseri bulgularının sınıflandırılmasında %95 oranında başarı sağlanmıştır (16).

2002 ve 2004 yıllarında bulanık mantık ve genetik tabanlı bulanık sınıflayıcı ile kardiak Doppler işaretlerinin sınıflandırılması başarılı bir şekilde gerçekleştirilmiştir (17,18).

2005 yılında yapılan bir çalışmada Doppler sonogram-

^a Yazışma Adresi: Dr. Selami SEHATLIOĞLU, Fırat Üniversitesi Tıp Fakültesi, Radyoloji Anabilim Dalı, ELAZIĞ

Tel: +90 424 2333555

Fax: +90 424 2376773

e-mail: sserhatlioglu@firat.edu.tr

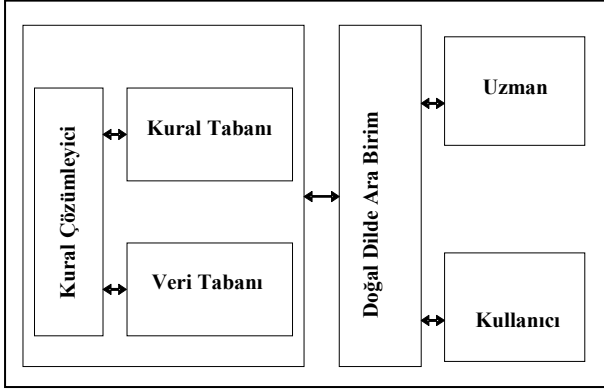
larından elde edilen parametrelerle sinir ağı eğitilmiş ve orta serebral arter darlığının dereceleri tahmin edilmeye çalışılmış, sistemin performansı veri boyutuna ve eğitim için seçilen parametrelere son derece bağımlı olduğu saptanmıştır (19).

YAPAY ZEKA TEKNİKLERİ

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 biyomedikal en başta gelen uygulama alanlarıdır (20,21).

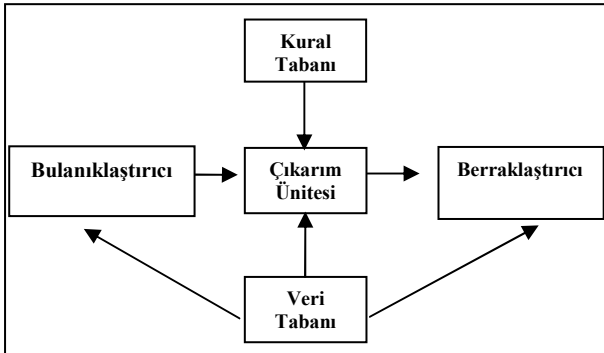
Bir uzman sistem; kural tabanı, veri tabanı ve kural çözümlenici olmak üzere üç bölümden oluşur. Şekil 1'de, bir uzman sistemin şematik yapısı görülmektedir.



Şekil 1: Bir Uzman Sisteminin şematik yapısı.

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, bulandırıcı, çıkarım ve berraklaştırıcı yazılımlar kullanılarak işlem gerçekleştirilir. Şekil 2'de bir bulanık mantık programının şematik yapısı görülmektedir.



Şekil 2: Bulanık mantık programının şematik yapısı.

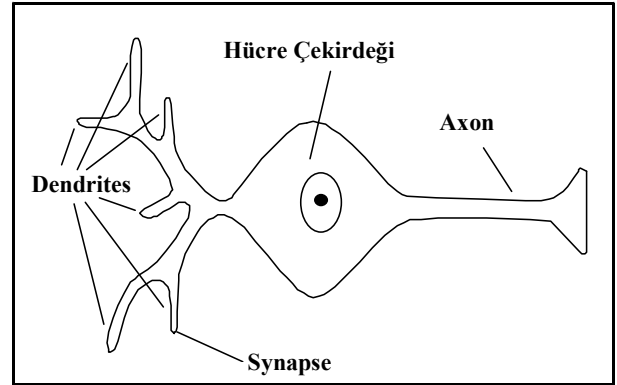
Bulanık mantık insan düşüncesinin esnek ve değişken yapısını dikkate alan bir algoritmadır. Bilgiler arasında sebep-sonuç ilişkisi kurarak doğru ve mantıksal bir sonuç üretir. Bu işlemin yapılabilmesi için ilk olarak verilerin belirlenmesi gerekmektedir. Bu veriler belirli sınırlar içerisinde gruplandırılarak bulanık kümeler haline getirilir, tüm olası durumlar dikkate alınarak kural tabanı oluşturulur. Bu kurallar bir kontrol algoritması ile değerlendirilerek çıkış bilgisi elde edilir (22).

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 (23).

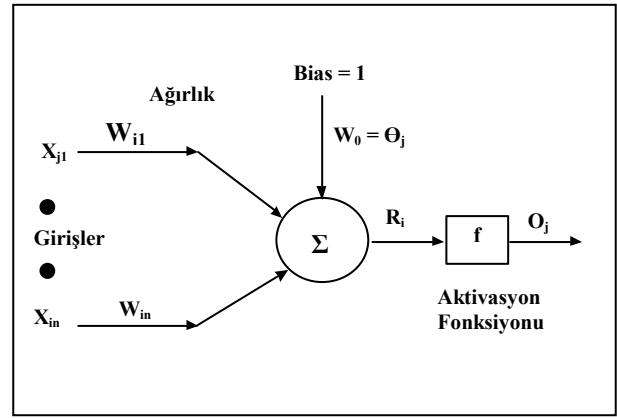
3. Yapay Sinir Ağları (Artificial Intelligence Networks)

Yapay sinir ağları örneklerle ilgili bilgiler toplamakta, genellemeler yapmakta ve daha sonra hiç görmediği örnekler ile karşılığınca öğrendiği bilgileri kullanarak o örnekler hakkında karar verebilmektedir. Yapay sinir ağları bu öğrenme 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 beynindeki nöronlara benzer olarak bir araya getirilen yapay nöronların değişik bağlantı geometrisi ile birbirlerine bağlanması sonucu oluşan sistemlerdir. Şekil 3a ve 3b'de doğal bir nöronun ve yapay bir sinir ağının şematik yapısı görülmektedir.

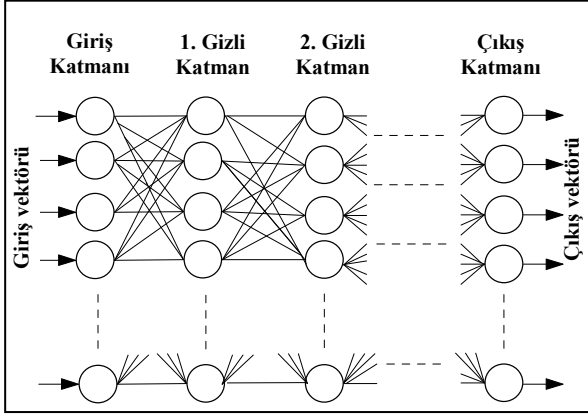


Şekil 3a: Biyolojik bir nöronun şematik yapısı



Şekil 3b: Bir yapay nöronun şematik yapısı

Sinir ağları paralel hesaplama tekniğini kullanan bir metottür. Programlama yerine doğrudan mevcut örnekler üzerinden eğitilerek işlem yapılır. Bağımsız değişkenler (giriş) ile bu değişkenlere ilişkin bağımlı değişkenler (çıkış) arasındaki matematiksel ilişki “öğrenebilen” sistemlerdir. Şekil 4’de İleri 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 (24,25).

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 araştırmalar da, endüstri de ve tıbbi uygulamalarda kullanılmaktadır. Literatürde sinir ağlarının kalp yetmezliği, miyokard enfarktüsü ve anjina pectoris tanısında bir çok klinik uygulamaları ve başarılı sonuçları bildirilmiştir (26-31).


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 yararlar 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 (32).

NEFCLASS sinirsel bulanık sistem; özel üç katmanlı ileri beslemeli bir sinir ağı gibi ilk katman giriş değişkenlerini, gizli katman bulanık kuralları, 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 tanıda yeterli görülmediği olgular, daha invaziv bir yöntem olan anjiyografiye tabii 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 olmuştur (33-36).



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

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 biyomedikal dahil birçok alana başarı ile uygulanmaktadır (37-50).

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 (48,51).

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 kullanılabildiği olması bu modelin yaygın kullanılmasının nedenidir.

Çok katmanlı algılayıcı ağlarında örnekler “giriş katmanı”na uygulanır, “ara katmanlar” da işlenir ve “çıkış katmanı”ndan da çıkışlar elde edilir. Kullanılan öğretim algoritmasına göre ağı 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 bir çok alanda başarılı bir şekilde uygulanmıştır(52).

5. Genetik algoritma (Genetic Algorithm)

Genetik algoritma konusunda ilk çalışmalarda canlılarda yaşanan genetik sürecin bilgisayar ortamında gerçekleştirilmesi düşünülmüştür (53,54).

Genetik algoritma parametre kümelerini kodlayarak çalışır. Genetik algoritma amaç fonksiyonu bilgisini kullanır. Genetik algoritma, doğal genetik ve doğal seçim mekanizmasına dayanan olasılıksal bir arama metodudur. Doğada iyi olanın hayatta kalması prensibine dayanır. Sezgisel bir metod olan genetik algoritma, geleneksel çözümlerle teknikleri ile çözülemeyen veya çözümü zor olan problemlere başarı ile uygulanmıştır (55-57).

60 hastanın mitral kapakçığından kaydedilen kardiyak Doppler sinyalleri bir 16 bitlik ses kartı ile bir bilgisayara aktarılan bir çalışmada; her bir hastadan kaydedilen sinyallere güç spektrum yoğunluğu analizi uygulanmış, daha iyi ve hızlı teşhis yapabilmek için, güç spektrum yoğunluğu değerleri çok katmanlı algılayıcı sinir ağı ve neuro-fuzzy sistem ile sınıflandırılmıştır. Çok katmanlı algılayıcı sinir ağı ile yapılan sınıflamalarda %93.33 başarı oranı, neuro-fuzzy sistem ile yapılan sınıflamalarda ise %90 başarı oranı elde edilmiştir. Sınıflama sonuçlarında Çok katmanlı algılayıcı sinir ağının teşhiste daha iyi sonuçlar verdiği görülmüştür. Neuro-fuzzy sistem bize sınıflama başarısından ziyade sistemin anlaşılabilirliğini arttırmıştır. Yapay sinir ağlarının sınıflamasının yorumlanması zordur. Neuro-fuzzy sistemde ise fuzzy sets'ler ve kurallar sayesinde yorumlanabilirlik ön plana çıkmaktadır (45).

Radyolojik Uygulamalara Örnekler

Diabetli 179 hastanın carotid arterlerinin Doppler parametrelerini sınıflamak için yapılan çalışmada; geleneksel istatistiksel bir metod olan lojistik regresyon ve çok katmanlı perseptron (MLP) sinir ağı olmak üzere iki farklı matematiksel model kullanılmış, Karotid arter Doppler sonogramlarından elde edilen parametreler üzerine bir istatistiksel model olan lojistik regresyon ve yapay sinir ağı modelleri ayrı ayrı kurularak sınıflama performansları incelenmiş, sonuçta; karotid arterden alınan Doppler sonogramlarının sinir ağları tarafından başarı ile sınıflandırılabilmesi gösterilmiştir (48).

Diabetli hastalara ait karotid ve oftalmik arterlerin kan akış hemodinamiği neuro-fuzzy sisteminde sınıflandırılarak incelenen iki çalışmada; karotid arter Doppler sonogramlarından elde edilen veriler, neuro-fuzzy sistemine uygulanarak sınıflama performansları incelenmiş, yapılan öğrenme ve test

işlemleri sonucunda karotid arterden alınan verilerde %85 oranında başarı elde edilmiş ve bu sonuçlarla karotid arterden alınan Doppler sonogramlarının başarı ile sınıflandırılabilmesini gösterilmiştir. Sağ ve sol oftalmik arterdeki kan akış hemodinamiği neuro-fuzzy sisteminde sınıflandırılarak diabetin oftalmik arterdeki etkisine bakılarak sağ ve sol oftalmik arter Doppler sonogramlarından elde edilen veriler neuro-fuzzy sistemine ayrı ayrı uygulanarak sınıflama performansları incelenmiştir. Yapılan öğrenme ve test işlemleri sonucunda sağ oftalmik arterden alınan verilerde %85, sol oftalmik arterdeki verilerde ise %87,5 oranında başarı elde edilmiştir. Bu sonuçlar ile gerek sol oftalmik arterden alınan gerekse sağ oftalmik arterden alınan Doppler sonogramlarının başarı ile sınıflandırılabilmesini göstermiştir (58,59).

NEFCLASS ve CANFIS'in sınıflama performansları karşılaştırıldığı bir çalışmada, 30 sağlıklı, 52 obeziteli kişilere ait farklı arterler ve vücut kitle indexi uzman sistemler ortamında sınıflandırılarak obezitenin etki ettiği bölgeler incelenmiş ve karşılaştırma sonucunda NEFCLASS'ın sınıflama performansının CANFIS'in sınıflama performansından daha üstün olduğu gözlenerek bu durumun nedenleri incelenmiştir. Aynı zamanda bu sınıflamalar obezitenin çeşitli arterler üzerindeki etkilerinden ziyade, vücut kitle endeksinin daha çok etkilediği görülmüştür. Bu sonuçlar obezite, arterler üzerindeki etkisinden ziyade, vücut kitle endeksinin daha çok etki ettiğini göstermiştir (60).

110 kişinin temporal bölgesine ait orta beyin arterlerinden kaydedilen transcranial Doppler işaretlerinin 16 bitlik bir ses kartı yardımıyla bir kişisel bilgisayara aktarılan bir çalışmada; her bir kişiden kaydedilen Transcranial Doppler fark frekansı, Fast Fourier Transform (FFT) spektral analizine uygulanmış, FFT'ye ait kan akış hız değerleri istatistiksel hale getirilerek YSA da hastalara ait kafa basınç tayinleri daha doğru tayin etmek amacıyla sınıflama yapılmıştır. Bu sınıflama esnasında YSA da biyomedikal dataları eğitim için BPNN (Back Propagation Neural Network) ve SOM (Self Organization Map) algoritmaları, öğrenme teknikleri olarak da momentum ve delta bar delta kullanılarak, sınıflama ve öğrenme açısından karşılaştırmalarında başarılı sonuçlar elde edilmiştir (61).

Benzer bir çalışmada ise; 30 hastanın karotid arterlerinden kaydedilen Doppler sinyalleri 16 bitlik bir ses kartı kullanılarak bir kişisel bilgisayara aktarılmıştır. Her bir hastadan kaydedilen Doppler fark sinyallerine ait sonogramlar hızlı Fourier Dönüşümü (FFT) ve least squares autoregressive (AR) metodları ile elde edilmiştir. Bu sonogramlar kullanılarak tıbbi değerlendirme açısından metodlar karşılaştırılmıştır (62).

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* 1989; 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.
13. 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.
14. 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.
15. 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.
16. Nauck D, Kruse R. Obtaining interpretable fuzzy classification rules from medical data. *Artificial Intelligence in Medicine* 1999; 16:149-169.
17. 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.
18. 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.
19. Uçman E. Transcranial Doppler İşaretlerinin Yapay Zeka Ortamında Sınıflandırılması. Gazi Üniversitesi Fen Bilimleri Enstitüsü Doktora Tezi 2005; 69.
20. Leung SC, Fulcher J. Classification of user expertise level by neural networks. *Int J Neural Syst* 1997; 8(2):155-71.
21. 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.
22. Atacak İ. Genel Amaçlı Bir Bulanık Mantık Denetleyicinin Tasarımı. Gazi Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Tezi 1998; 71.
23. Nauck D, Klawonn F, Kruse R. Foundations of neuro-fuzzy systems. Wiley Chichester 1997; 187-221.
24. Williams R, Neural Network Learning and Application. Addison-Wesley 1989; 1-212.
25. Ergün U, Hardalaç F, Güler İ. Geri yayılım sinir ağlarını kullanarak transcranial Doppler işaretlerinin sınıflandırılması. *Biyomedikal Mühendisliği Ulusal Toplantısı Biyomut* 2002; 111-114.
26. Basheer IA, Hajmeer M. Artificial neural networks: Fundamentals, computing, design, and application. *Journal of Microbiological Methods* 2000; 43:3-31.
27. 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.
28. Baxt WG. Use of an artificial neural network for the diagnosis of myocardial infarction. *Ann Intern Med* 1991; 1; 115(11): 843-8.
29. 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.
30. 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.
31. 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.
32. Nauck D, Kruse R. NEFCLASS-X: A soft computing tool to build readable fuzzy classifiers. *BT Technology Journal* 1998; 6(3):180-190.
33. Kaps M, Damian MS, Teschendorf U, Dorndorf W. Transcranial Doppler ultrasound findings in middle cerebral artery occlusion. *Stroke* 1990; 21:532-537.
34. 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.
35. Lupetin AR, Davis DA, Beckman I, Dash N. Transcranial Doppler sonography part 1. principles technique and normal appearances. *Radiographics* 1995; 15:179-191.
36. 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.
37. Haykin S. Neural Networks: A Comprehensive Foundation. Macmillan College Publishing Company 1994; 1-60.
38. Basheer IA, Hajmeer M. Artificial neural networks: fundamentals, computing, design, and application. *Journal of Microbiological Methods* 2000; 43:3-31.
39. Tafeit E, Reibnegger G. Artificial neural networks in laboratory medicine and medical outcome prediction. *Clinical Chemistry and Laboratory Medicine* 1999; 37(9):845-853.
40. 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.
41. 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.

42. 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.
43. 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.
44. Ergün U, Hardalaç F, Güler İ. Geri yayılım sinir ağlarını kullanarak transcranial Doppler işaretlerinin sınıflandırılması. *Biyomedikal Mühendisliği Ulusal Toplantısı Biyomut* 2002;111-114.
45. Barışcı N, Ergun U, Ilkay E, Serhatlyoglu S, Hardalac F, Guler I. Classification of mitral insufficiency and stenosis using MLP neural network and neuro-fuzzy system. *J Med Syst.* 2004; 28(5):423-36.
46. Akay M. Non-invasive diagnosis of coronary artery disease using a neural network algorithm. *Biological Cybernetics* 1992; 67:361-367.
47. 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.
48. Ergün U, Serhatlıoğlu S, Hardalaç F, Güler İ. 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.
49. 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.
50. Baxt WG. Application of artificial neural networks to clinical medicine. *Lancet* 1995; 346:1135-1138.
51. Güler İ, Hardalaç F, Ergun U, Barışcı N. Classification of aorta Doppler signals using variable coded-hierarchical genetic fuzzy system. *Expert Systems with Applications* 2004; 26:321-333.
52. 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.
53. Gosling RG, King DH. Arterial assessment by Doppler shift ultrasound. *Proceeding of the Royal Society of Medicine* 1974; 67:447-449.
54. Goldberg DE, Samanti MP. Engineering optimization via genetic algorithm. *Proceedings of the Ninth Conference on Electronic Computation* 1986; 471-482.
55. Goldberg DE. *Genetic Algorithms in Search, Optimization Machine Learning.* Addison-Wesley 1989; 1-411.
56. Booker LB, Goldberg DE, Holland JH. Classifier systems and genetic algorithms. *Artificial Intelligence* 1989;40:235-282.
57. 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.
58. Serhatlıoğlu S, Bozgeyik Z, Ozkan Y, Hardalac F, Guler I. Neurofuzzy classification of the effect of diabetes mellitus on carotid artery. *J Med Syst.* 2003; 27(5):457-64.
59. Serhatlıoğlu S, Hardalac F, Kiris A, Ozdemir H, Yilmaz T, Guler I. A neurofuzzy classification system for the effects of diabetes mellitus on ophthalmic artery. *J Med Syst.* 2004; 28(2):167-76.
60. Hardalac F, Ozan AT, Barisci N, Ergun U, Serhatlıoğlu S, Guler I. The examination of the effects of obesity on a number of arteries and body mass index by using expert systems. *J Med Syst.* 2004; 28(2):129-42.
61. Serhatlıoğlu S, Hardalac F, Guler I. Classification of transcranial Doppler signals using artificial neural network. *J Med Syst.* 2003; 27(2):205-14.
62. Serhatlıoğlu S, Burma O, Hardalac F, Guler I. Determination of coronary failure with the application of FFT and AR methods. *J Med Syst.* 200; 27(2):121-31.

Kabul Tarihi: 29.05.2008