

T.C.
KIRIKKALE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK – ELEKTRONİK ANABİLİM DALI
YÜKSEK LİSANS TEZİ

OBEZİTENİN KAROTİD ARTERLERİN LÜMEN ÇAPI, İNTİMA MEDİA
KALINLIKLARI VE AKIŞ HIZLARI ÜZERİNDEKİ ETKİLERİNİN ÇOK
KATMANLI ALGILAYICILAR VE JORDAN ELMAN SİNİR AĞLARI İLE
ANALİZ EDİLMESİ

ALMILA ÖZCAN

EYLÜL 2008

Fen Bilimleri Enstitüsü Müdürünün onayı

.../.../2008

Doç. Dr. Burak BİRGÖREN

Müdür V.

Bu tezin Yüksek Lisans tezi olarak Elektrik–Elektronik Anabilim Dalı standartlarına uygun olduğunu onaylarım.

Doç. Dr. Ediz POLAT

Anabilim Dalı Başkanı

Bu tezi okuduğumuzu ve Yüksek Lisans tezi olarak bütün gerekliliklerini yerine getirdiğini onaylarız.

Yrd. Doç. Dr. Fırat HARDALAC

Danışman

Jüri Üyeleri:

Prof. Dr. Cengiz TAPLAMACIOĞLU

.....

Yrd. Doç. Dr. Fırat HARDALAC

.....

Yrd. Doç. Dr. Necaattin BARIŞCI

.....

ÖZET

OBEZİTENİN KAROTİD ARTERLERİN LÜMEN ÇAPI, İNTİMA MEDİA KALINLIKLARI VE AKIŞ HIZLARI ÜZERİNDEKİ ETKİLERİNİN ÇOK KATMANLI ALGILAYICILAR VE JORDAN ELMAN SİNİR AĞLARI İLE ANALİZ EDİLMESİ

ÖZCAN, Almıla

Kırıkkale Üniversitesi

Fen Bilimleri Enstitüsü

Elektrik-Elektronik Anabilim Dalı, Yüksek Lisans Tezi

Danışman: Yrd. Doç. Dr. Fırat HARDALAÇ

Eylül 2008, 49 sayfa

Doppler yöntemi hastaya direkt müdahalede bulunulmadığı için anjiyografi ve manyetik rezonansa alternatif bir yöntemdir. Bu sayede obezitenin damarlara etkileri olduğu bulunmuş ve konuda çok çeşitli çalışmalar ortaya çıkmıştır. Bu çalışmada 71 kişiden alınan Doppler Ultrasonografi ile Karotid Arterler incelenmiş ve obezitenin bu arterler üzerindeki etkileri incelenmiştir.

Doppler sinyallerinin önce istatistiksel analizi yapılmıştır. Böylece Doppler verilerinin giriş katmanında ve gizli katman/larda kullanılacak nöron sayısı da azaltılmaktadır ve Doppler verilerinin sınıflandırılması daha az karmaşık sinir ağı yapıları ile gerçekleştirilir ve işlem yükü ve zamanı azalmaktadır. Anlamlı bulunan

veriler sınıflama yapılması için Çok katmanlı Algılayıcı ve Jordan – Elman Sinir Ağlarına uygulanmıştır.

Her iki Yapay sinir ağı modelinin bulguları irdelenmiştir. Anlamlı parametrelerin ve örneklem sayısının az olması sebebiyle Jordan – Elman yönteminin Çok katmanlı algılayıcılara göre daha yüksek performans gösterdiği ortaya konmuştur.

Anahtar Kelimeler: Obezite, Karotid arterler, Çok katmanlı Algılayıcılar, Jordan Elman Sinir Ağları.

ABSTRACT

**THE ANALYSIS OF THE EFFECTS OF THE OBESITY DISEASE ON
LUMINAL DIAMETER, FLOW VELOCITY AND INTIMA-MEDIA THICKNESS
OF CAROTID ARTERIES USING MULTILAYER PERCEPTRONS AND
JORDAN-ELMAN NEURAL NETWORK**

ÖZCAN, Almıla

Kırıkkale University

Graduate School of Natural and Applied Sciences

Department of Electrical and Electronics Eng., M. Sc. Thesis

Supervisor: Assist. Prof. Dr. Fırat HARDALAÇ

September 2008, 49 pages

The Doppler examination technique is an alternative non-invasive diagnosis method in comparison with angiography and magnetic resonance methods. The effects of obesity on arteries had found by this method and various studies on this. In this study the Doppler sonography of karodit arteries of 71 people obtained and the effects of obesity on these arteries studied.

The Doppler sonography results first analyzed statistically. In this wise the number of the neurons which will be used both in the input layer and hidden layers will be diminished and a better classification of carotid Doppler signals by neural network structure and more efficient classification performance in comparison with the traditional neural networks is obtained by both selecting neural network

inputs and the optimization of network parameters. Then these significant data applied to Multilayer Perceptions and Jordan Elman Neural Networks for classification.

Both Artificial Neural Network method results analyzed. Jordan – Elman neural network has a better performance then Multilayer Perceptions because of a few amounts significant parameters and sample.

Keywords: Obezite, Carotid arteries, Multilayer Perceptions, Jordan Elman Neural Networks.

TEŐEKKÜR

Çalıőmalarım boyunca bana her türlü desteęi veren, gerekli yönlendirmeleri yapan, bilgi ve deneyimi ile her zaman yol gösteren deęerli hocam Yrd. Doç. Dr. Fırat Hardalaç'a, tezimde son őeklini vermede yardımcı olan Yrd. Doç. Dr. Necaattin Barıőçı'ya teőekkürlerimi sunarım.

SİMGELER DİZİNİ

AKA	Ana Karotid Arterler
İKA	İç Karotid Arterler
AH	Akım Hızı
İMK	İntima-Media Kalınlıkları
YSA	Yapay Sinir Ağları
VKE	Vücut Kitle Endeksi
EKG	Elektroensefalogram
EKG	Elektrokardiyogram
ÇKA	Çok Katmanlı Algılayıcılar
İÇE	İşlem Elemanı Çıkışı
OKH	Ortalama Karesel Hata
DP	Doğru Pozitif
DN	Doğru Negatif
YP	Yanlış Pozitif
YN	Yanlış Negatif
DPO	Doğru Pozitif oranı
DNO	Doğru Negatif oranı
ROC	Alıcı İşlem Karakteristiği
OKH	Ortalama Karesel Hata
DOKH	Düzgelenmiş Ortalama Karesel Hata
OMH	Ortalama Minimum Hata

ŞEKİLLER DİZİNİ

ŞEKİL

2.1. Frekansın damara gönderilmesi ve yansıyan dalgalar.....	10
2.2. İleri beslemeli giriş, gizli ve çıkış katmanlarından oluşan sinir ağı mimarisi.....	17
2.3. Çok katmanlı Algılayıcıların Yapısı.....	18
2.4. Gradyan girişleri ve Momentum Etkisi.....	21
2.5. Yinelemeli Sinir Ağları modelinin yapısı a) Elman Ağları b) Jordan Ağları.....	23
3.1. Doppler işaretlerinden ÇKA Ağına uygulanması.....	37
3.2. ÇKA Öğrenme Eğrisi.....	38
3.3. ÇKA ROC analizi.....	40
3.4. Doppler işaretlerinin Jordan Elman ağına uygulanması.....	41
3.5. Jordan-Elman Öğrenme Eğrisi.....	41
3.6. Jordan Elman ROC analizi.....	44

ÇİZELGELER DİZİNİ

ÇİZELGE

2.1. Sınıflama tablosu.....	30
2.2. Sınıflama tablosu kullanılarak elde edilen parametreler.....	31
3.1. Doppler hız parametrelerinin karakteristikleri	33
3.2. Öğrenme ve test amacıyla kullanılan veri setlerinin dağılımı.....	34
3.3. Normal ve Obezite veri setlerini tanımlayıcı istatistikler.....	35
3.4. Eğitim en iyi değerleri.....	38
3.5. Test sonuçlarının sınıflama tablosu.....	39
3.6. ÇKA Ağının Sınıflandırma Performansı sonuçları	39
3.7. İstatistiksel analiz.....	39
3.8. Eğitim en iyi değerleri.....	42
3.9. Test sonuçlarının sınıflama tablosu.....	42
3.10. ÇKA Ağının Sınıflandırma Performansı sonuçları.....	43
3.11. İstatistiksel analiz	43

İÇİNDEKİLER

ÖZET	i
ABSTRACT	iii
TEŞEKKÜR.....	v
SİMGELER DİZİNİ	vi
ŞEKİLLER DİZİNİ.....	vii
ÇİZELGELER DİZİNİ	viii
İÇİNDEKİLER	ix
1. GİRİŞ	1
2. MATERYAL VE YÖNTEM.....	6
2.1. Materyaller	6
2.1.1. Ultrasonik Doppler Prensipleri	7
2.1.2. Doppler Etkisi	8
2.2. Yapay Sinir Ağları	11
2.2.1. Yapay Sinir Ağlarının Özellikleri	12
2.2.2. YSA'nın Uygulama Alanları.....	15
2.2.3. İleri Beslemeli Sinir Ağları	15
2.2.4. Çok Katmanlı Algılayıcı	17
2.2.5. Geri Yayılım Algoritması	20
2.2.6. Jordan-Elman Metodu.....	22
2.2.7. Karotid Arter Doppler Sinyallerinin Jordan Elman Sinir Ağı ile Sınıflandırılması.....	26
2.2.8. ÇKA ve Jordan – Elman YSA Performanslarının Değerlendirmesi..	28

3. ARAŐTIRMA BULGULARI	32
3.1. Doppler parametrelerinin İstatistiksel Analizi	32
3.2. Karotid arterlerin iki farklı kategoride incelenmesi	34
3.2.1. Çok katmanlı algılayıcılar ađı analizine ait bulgular	36
3.2.2. Jordan Elman ađı analizine ait bulgular	40
4. TARTIŐMA VE SONUÇ	45
KAYNAKLAR	47

1. GİRİŞ

Obezite, gelişmiş ülkelerin en önemli sağlık problemlerinden biridir. Aşırı kilo ve obezitenin yaygınlığı dünya çapında bir düzeye erişmiştir. 1,1 milyar insanın aşırı kilolu olduğu tahmin edilmektedir⁽¹⁾. Bu durum metabolik düzensizlik, yangı yolaklarına, engelleyici uyku apnesi veya diğer mekanizmalar yoluyla büyük damarların fonksiyon bozukluğuna yol açar^(2,3).

Obezite inme için büyük bir risk faktörü olarak kabul edilmektedir. Doppler Ultrasonografi Karotid damarlarda kan akışının müdahale etmeden değerlendirilmesine olanak verir. Ve inmenin tanısına yardımcı olmaktadır^(5,6).

Bu ilişkilerden yararlanılarak ultrasonik sistemi tanımlarsak; 20 KHz'den daha büyük olan frekanslara ultrasonik frekans denir ve insan kulağı bu frekansları duyamaz. Ultrasonik Doppler, hareketli yapıların ve özellikle vücuttaki kan akış hızının insan vücuduna zarar vermeden vücut dışından ölçümünde ve belirlenmesinde kullanılan önemli bir tekniktir. Bu amaçla ilk olarak yaklaşık 40 yıl önce kullanılmasına rağmen, taşınabilir Doppler kan akış ölçme cihazları ancak son 20 yıllık bir süre içinde geliştirilmiştir. Geliştirilen bu cihazlar sayesinde çok ince damarlarda bile kan akış hızı ve damar çapı ölçülebilmekte, damarda bir tıkanıklık veya genişleme varsa bu kolaylıkla tespit edilebilmektedir⁽⁷⁾.

2. Dünya savaşı sırasında, uçakların yerinin radarla tespit edilmesinden ilham alan birçok ilim adamı, yansıyan ultrasonik dalganın, insan vücudundaki iç organların ve yapıların belirlenmesinde kullanabileceğini düşünmüştür. 1950'li

yıllarda Amerika ve Avrupa’da farklı guruplar birbirinden bağımsız olarak oldukça farklı gayelerle değişik sahalarda arařtırmalara bařlamıřtır.⁽⁸⁾

Normal bir hekimin bilgisini ařan klinik durumlarda uzman hekime bařvurmak gerekir. Fakat danıřılacak uzman hekimi her zaman bulunamaz. Bunu ařmak iin son yıllarda tıbbi tanıda ngrlerin elde edilmesinde yapay sinir ađlarının kullanıldıđı alıřmalar literatrde yer almaktadır. Yapay zek bilgisayarın insan gibi dřnmesini ve karar vermesini sađlayan bilgisayar alt bilimidir. zellikle tıp alanında kullanım alanı ok geniř olan bir daldır.

Yukarıda ifade edildiđi gibi; Yapay Zek konusuna deđinilmiřken Yapay zek konusunda, ilk alıřmalardan biri McCulloch ve Pitts⁽⁹⁾ tarafından yapılmıřtır. Bu arařtırmacıların nerdiđi, yapay sinir hcrelerini kullanan hesaplama modeli, nermeler mantıđı, fizyoloji ve Turing’in hesaplama kuramına dayanmaktadır. Her hangi bir hesaplanabilir fonksiyonun sinir hcrelerinden oluřan ađlarla hesaplanabileceđini ve mantıksal “ve” ve “veya” iřlemlerinin gerekleřtirilebileceđini gstermiřlerdir. Bu ađ yapılarının uygun řekilde tanımlanmaları halinde đrenme becerisi kazanabileceđini Hebb⁽¹⁰⁾ tarafından ileri srlmřtir. Bu ađdaki sinir hcreleri arasındaki bađlantıların řiddetlerini deđiřtirmek iin basit bir kural nerilmiřtir ve bylece đrenebilen yapay sinir ađları gerekleřtirilmiřtir.

Yapay sinir ađlarının tarihsel geliřimi 1969–1972 yılları arasında dođrusal iliřkilendiriciler geliřtirilmesi ile bařlamıřtır. 1972’de kolerasyon Matriks belleđi⁽¹¹⁾ geliřtirilmiřtir. 1974’te geriye yayılım modelinin⁽¹²⁾ (ok katmanlı algılayıcıların) ilk alıřmaları geliřtirilmiřtir. Eđitmensiz đrenmenin alt algoritmalarından Adaptif

Rezonans Teorisi (ART) modeli⁽¹³⁾ 1978’de, Kohonen öğrenmesi ve Kendinden Özdüzenleyici Haritalar (Self Organizing Map - SOM) modellemesi⁽¹⁴⁾ ise 1982’de geliştirilmiştir. Aynı yıl Hopfield ağları⁽¹⁵⁾ ile çok katmanlı algılayıcılar⁽¹⁶⁾ ve 1984’te Boltzman makinesi⁽¹⁷⁾ geliştirilmiştir. 1985’te Çok katmanlı algılayıcılara delta öğrenme kuralı⁽¹⁸⁾ geliştirilmiştir. 1988’de Radyal Tabanlı Fonksiyon⁽¹⁹⁾ (Radial Basis Function-RBF) ve Olasılıksal Sinir Ağları⁽²⁰⁾ (Probabilistic Neural Network - PNN) modellemesi geliştirilmiştir. 1991’de de Genel Regresyonlu Sinir Ağları⁽²¹⁾ (Generalized Regression Neural Network, GRNN) modellemesi geliştirilmiştir. Bu güne kadar da sayısız çalışma ve uygulama geliştirilmiştir.

Günümüzde yapay sinir ağları artık teorik ve laboratuvar çalışmaları olmaktan çıkmış ve günlük hayatta kullanılan sistemler oluşturmaya ve pratik olarak insanlara faydalı olmaya başlamışlardır.

Sinir Ağları, insan beynindeki nöronlara benzer olarak birleştirilen yapay nöronların değişik bağlantı geometrisi ile birbirlerine bağlanması sonucunda oluşan karmaşık sistemlerdir. İler beslemeli sinir ağları, geniş uygulama alanına sahiptir. Bu tip ağ yapısı biyomedikal dâhil birçok alana başarıyla uygulanmıştır^(22,23). Bu çalışmada kullanılan İleri beslemeli geri yayımlı sinir ağı Doppler işaretlerinin sınıflandırılmasında başarı göstermiştir. Bu çalışma kullanılan ileri beslemeli geri yayımlı sinir ağı mimarisi ile Jordan- Elman Yöntemi Ana Karotid Arter ve İç Karotid arterlerdeki akım hızlarına Doppler hız parametreleri başarılı bir şekilde sınıflandırılmıştır.

Doppler verilerinin yapay sinir ağları ile sınıflandırması çok geriye gitmemektedir. 1996 yılından sonra yapay sinir ağları ile çalışmalar hız kazanmıştır.

Yapay sinir ağlarının kullanımı başka konular üzerinde yoğunlaşmıştır. Daha öncesinde Doppler verilerini sınıflandırmak için Bulanık mantık kümeleri kullanılmıştır. Parametre sayısı arttıkça Bulanık mantık kümelerinin öğrenmesi yapay sinir ağlarının öğrenmesine göre çok daha uzun sürer. Az parametrede ise Bulanık mantık kümelerinde performans önemli ölçüde düşer. Yapay Sinir ağlarının tıbbi Doppler sinyallerini sınıflandırması 90'lı yılların ortasını bulmuştur^(24,25). 1997'de Wright ve arkadaşları Yapay sinir ağlarını kullanarak bir pilot uygulama yapmıştır⁽²⁶⁾. Hardalaç ve arkadaşları, yapay zekâ teknikleri kullanarak Karotid damarlarındaki darlığı %87,5 doğrulukla tespit etmiştir⁽²⁷⁻²⁹⁾.

Doppler parametrelerinin gerçek zamanlı olarak yorumlanmasıyla birlikte klinik çalışmalarda Doppler tekniği daha etkin bir şekilde kullanılabilir. Bu nedenle, obeziteye ait Doppler parametreleri Tansiyon Sistol değeri (TA/Sistol), Tansiyon Diyastol değeri (TA/Diastol), Sağ Ana Karotid Arter Lümen Çapı (RCC), Sağ İç Karotid Arter Lümen Çapı (RCI)) kullanılarak, bir matematiksel sınıflayıcı olan yapay zekâ modeline ait sinir ağı modeline uygulanarak sınıflama yapılmıştır. Bu sınıflama sonucunda Doppler parametrelerinden yola çıkılarak bu kişilerin obezite olup olmadıkları, aynı zamanda arterler üzerindeki olumsuz yöndeki etkilerini araştırılması amaçlanmıştır.

Bu amaçla Fırat Üniversitesi Tıp Fakültesi Radyoloji anabilim dalı ünitesinde hastalar üzerinde Karotid–Doppler cihazıyla çalışılmıştır. Çalışılan damarlar ana Karotid Arterler (AKA) ve iç Karotid Arterler (İKA) akım hızı (AH), lümen çapı ve intima-media kalınlıkları (İMK) üzerindeki etkileri araştırılmıştır⁽³⁰⁾.

Bu çalışmayla elde edilen veriler bu tez çalışmasında kullanılmaktadır. Karotid–Doppler Cihazı pratik olarak kullanan doktorlarla cihazı kullanım yerleri, avantajları ve dezavantajlarıyla ilgili çeşitli çalışmalar yapılmıştır. Bu çalışmayla kurulacak sistemin yapım aşamasında kendi görüşlerine de başvurulmuştur. Genele olarak kurulması düşünülen Karotid–Doppler cihazının daha etkin bir şekilde kullanılması şeklinde görüşlerini bildirmişlerdir.

Bu tez çalışmasının ikinci bölümünde Doppler Ultrasonografi Prensipleri, İleri beslemeli geri yayımlı Sinir ağları ve Jordan Elman yöntemi açıklanacaktır.

Üçüncü bölümde ise karotid Doppler işaretlerinin yapay zekâ modelleri olan ileri beslemeli geri yayımlı yapay sinir ağları ve Jordan Elman yöntemlerine uygulanması sonucu elde edilen sonuçları irdelenmiştir.

Dördüncü bölümde karotid Doppler işaretlerinin yapay zekâ modelleri olan ileri beslemeli geri yayımlı ve Jordan Elman yöntemlerine uygulanması sonucu elde edilen sonuçları tartışılmıştır. Bu sonuçların incelendiğinde Jordan-Elman Yönteminde, İleri Beslemeli Geri yayılım yönteminden daha iyi bir sonuç elde edilmiştir.

2. MATERYAL VE YÖNTEM

2.1. Materyaller

Bu çalışmada kullanılan veriler Hüseyin Özdemir ve Fırat Hardalaç tarafından 2005 – 2006 yılları arasında Fırat Üniversitesi Tıp Fakültesi Radyoloji Anabilim Dalı ünitesinde sağlıklı ve obezite hastalar üzerinde Doppler ultrasonografi cihazıyla çalışılmıştır.

Bu çalışmaya gereç olarak yaşları 25 ile 58 (ortalama yaş: $40,61 \pm 8,13$ yıl) arasında değişen 71 erişkin kişiye prospektif olarak ekstrakraniyal Karotid arter renkli Doppler ultrasonografi yapılmıştır. Vücut Kitle Endeks (VKE) değerleri 20 ile 24,99 arasında değişen gönüllüler grup 1'e, 25'ten yukarı olanlar ise grup 2'ye dâhil edilmiştir. Yetmiş bir kişiden 24'ünün VKE değerleri normal (grup 1: 11 erkek ve 13 kadın; ortalama yaş $39,29 \pm 8,5$ yıl), 47 kişinin VKE değerleri ise yüksek çıkmıştır (grup 2: 22 erkek ve 25 kadın; ortalama yaş $41,23 \pm 7,88$ yıl). Ortalama BMI değerleri grup 1'de $23,17 \pm 1,53$ kg/m² ve grup 2'de $27,62 \pm 1,71$ kg/m²'dir.

Tüm kişiler sağlıklıdır ve aktif olarak yaşamlarını sürdürmekteydiler. Kişilerden bilgilendirilmiş onay formu ve çalışma için yerel etik kurul onayı alınmıştır.

Tüm kişilerden bir önceki akşam saat 21'den itibaren aç olunacak şekilde sabah 8 ve 10 saatleri arasında kan örnekleri alınmıştır. Kan almadan önceki 15 dakikada kişiler istirahat ettirilmiştir. Tüm kişilerin incelemeden en az 3 saat öncesinde ağır egzersiz yapması, sigara içmesi, alkol veya kafein içeren maddeler alması yasaklanmıştır. Kişilerin beyaz küre, hemoglobin, trombosit, kan şekeri,

kolesterol ve trigliserid incelemeleri Olympus AU 600 (Opticus co Ltd. Japonya) otoanalizöründe ile gerçekleştirilmiştir.

Kan basıncı ölçümleri oturur pozisyonda 5 dakika dinlenmeyi takiben yapılmıştır ve 5 dakika sonra tekrarlanmıştır. Ölçümleri aynı donanımı kullanan, aynı hemşire tarafından gerçekleştirmiştir (Sabah 7:30 ve 9 saatleri arasında). Her kişi 5 ila 10 dk arasında dinlenmeyi takiben sırtüstü yatar pozisyonda, karanlık ve sessiz bir odada Doppler US incelemesine tabi tutulmuştur. Ana Karotid arterler (AKA) ve İç Karotid arterler (İKA) 7,5 MHz lineer proba (Toshiba SSH 140A, Toshiba, Tokyo, Japonya) kullanılarak yapılmıştır. Kişiler sırtüstü yatar pozisyonda başları hafifçe kaldırılmış olarak, başları karşı tarafa AKA için 10°, İKA için ise 25°–40° döndürülmüş olarak incelenmiştir. Akım hızı (AH) ölçümleri en sık AKA'da Karotid bulbusun 1,5–2 cm aşağısından, İKA'da ise Karotid bulbusun 1–2 cm yukarisından yapılmıştır. Örneklem aralığı arter düzleminin ortasına yerleştirilmiştir ve Doppler sinyallerinin sabitleşmesini takiben AH'ları kaydedilmiştir. AKA ve İKA'da insonasyon açısının damarın geçiş yerine göre 45° ile 60° arasında ayarlanmasını takiben pik-sistolik ve diyastol sonu AH'ları ölçülmüştür.

2.1.1. Ultrasonik Doppler Prensipileri

Ultrasonik Doppler, cerrahi bir işlem gerektirmeden, vücuttaki hareketli yapıların hızını belirleme ve ölçmede kullanılan önemli bir tekniktir. Bu amaç için yaklaşık olarak kırk yıl önce kullanılmaya başlanmış ve son yirmi yıl içerisinde ise Doppler cihazlarının kullanımı yaygınlaşmıştır. Ultrasonik Doppler'in tıptaki ilk kullanımı, doğumda fetalın kalp atışlarını görüntüleme ve Karotid arterindeki kan akısını değerlendirmek olmuştur. Günümüzde Doppler sistemleri kardiyoloji,

nöroloji, radyoloji, doğum, pediatri ve cerrahi alanlarında da kullanılmaktadır. Görüntülenebilen çok ince damarlarda bile akış izlenebilmektedir. Ultrasonik Doppler ile kan akısının olması, olmaması, yönü ve karakteristiği belirlenebilmektedir. Doppler cihazlarından alınan sonuçların doğru bir şekilde yorumlanabilmesi için fiziksel mekanizmanın ve Doppler işaretlerinde kullanılan işaret işleme metotlarının tam olarak anlaşılması gereklidir⁽³¹⁻³³⁾.

2.1.2. Doppler Etkisi

Klinik uygulamaların geliştirilmesi ve anlaşılması açısından Doppler etkisini fiziksel olarak belirtmek gereklidir. Hareketten dolayı frekans veya dalga boyundaki değişme Doppler etkisidir. Buradaki hareket, kaynak veya gözlemcinin hareketi olabilir. Gözlemci kaynağa göre hareketli ise gönderilen frekans ile gözlenen frekans farklı olmaktadır. Kaynak ile gözlemci birbirlerine doğru hareket ediyor ise gözlenen frekans gönderilen frekanstan daha fazladır. Kaynak ile gözlemci birbirlerinden uzaklaşıyor ise gözlenen frekans gönderilen frekanstan daha düşüktür. Bu durum, 1843 yılında Christian Doppler tarafından gözlenmiştir. Christian Doppler o zamanda, şu fizik sorusuna çözüm bulmuştur: Neden bazı yıldızlar kırmızı ve bazıları mavi olarak görülmektedir⁽³⁴⁾. Yıldızların hareketli olmasından yola çıkarak, Doppler bu gözlemleri tanımlayabilecek bir denklem geliştirmiştir. Bu denklem, ışık kaynağı gözlemciden uzaklaşıyor ise renk kırmızıya doğru kayar ve kaynak gözlemciye doğru hareket ediyor ise renk maviye doğru kayar düşüncesine dayanmaktadır. Bir dalganın hareketten dolayı, gözlenen frekansındaki değişme Doppler etkisi olarak bilinmektedir. Kaynak ve gözlemcinin hareketli olması veya olmaması ile ilgili üç durum olabilir. İlk olarak, gözlemci hareketli olur ve kaynak

durağandır. İkinci olarak, gözlemci durağan kaynak hareketlidir. Üçüncü durumda ise her ikisi hareketlidir. Kaynak ve gözlemcinin hareketli olması halinde biri referans noktası olarak seçilebilir. Böyle bir durumda, kaynak hareketli gözlemci durağan olarak düşünülebilir. Gözlemci kaynağa doğru hareket ediyor ise, artmış olan gözlenen (alınan) frekans şu şekilde belirtilir:

$$f_r = f_t \frac{c+v}{c} \quad (2.1)$$

Burada f_t gönderilen frekans, v gözlemcinin hızıdır. Gözlemcinin hızı ile dalganın yayılma yönü arasında θ açısı var ise ifadede v yerine dalga yönündeki v 'nin bileşeni olan $v \cos \theta$ konur:

$$f_r = f_t \frac{c+v \cos \theta}{c} \quad (2.2)$$

Gözlemci durağan ve kaynak dalganın hareketi yönünde v hızı ile hareket ediyor ise dalga boyu kısalır. Sonuçta gözlenen frekans:

$$f_r = f_t \frac{c}{c-v} \quad (2.3)$$

Açı dikkate alındığında:

$$f_r = f_t \frac{c}{c-v \cos \theta} \quad (2.4)$$

Ultrasoniğin klinik uygulamalarında, ultrasonik dalga hareketli kan hücrelerinden saçılmaktadır. Yukarıda belirtilen etkiler birleştirilerek frekanstaki Doppler kayması elde edilir. Bu durumda gözlenen frekans şu şekilde verilir:

$$f_r = f_t \frac{c}{c-v \cos \theta} \cdot \frac{c+v \cos \theta}{c} = f_t \frac{c+v \cos \theta}{c-v \cos \theta} \quad (2.5)$$


Doppler kayması:

$$f_d = f_r - f_t = f_t \frac{c + v \cos \theta}{c - v \cos \theta} - f_t = \frac{f_t(c + v \cos \theta) - f_t(c - v \cos \theta)}{c - v \cos \theta}$$

$$f_d = \frac{f_t c + f_t v \cos \theta - f_t c + f_t v \cos \theta}{c - v \cos \theta}$$

$c \gg v$ olduğu için:

$$f_d = \frac{2f_t v \cos \theta}{c} \quad (2.6)$$



Şekil 2.1. Frekansın damara gönderilmesi ve yansıyan dalgalar.

Doppler cihazının klinik uygulamalarında Şekil 2.1’de görüldüğü gibi vücuda bir işaret gönderilir ve ulaştığı hedeflerden saçılması veya yansımaları durumunda frekanstaki değişimler gözlenir. Bu şartlar altında ultrasonik frekansta bir kayma belirlenir:

$$f_d = f_t - f_r = \frac{2f_t v \cos \theta}{c}$$

Burada, f_t ve f_r sırası ile gönderilen ve alınan ultrasonik frekanslardır, v hedefin hızı, c ultrasonun ortamdaki hızı, θ ultrasonik dalga ile hedefin hareket yönü arasındaki açıdır. Belirtilen herhangi bir durumda c hızı ve gönderilen frekans f_t bilinmektedir. Böylece, bir hedefin hızı yukarıdaki ifadeden şu şekilde bulunabilir:

$$v = \frac{Kf_t}{\cos \theta} \quad (2.7)$$

Burada, $K = \frac{c}{2f_t}$ olarak bilinen katsayıdır. θ açısı, tam olarak belirlenebilir ise hız hesaplaması doğru olarak yapılabilir.

Pratik uygulamalarda, Doppler kaymasını tek bir hedef değil aynı hızda hareket eden hedefler oluştururlar. Bundan dolayı, Doppler kayma işareti tek frekans bileşenli değil çok frekans bileşenli bir işarettir. Doppler kayma işareti kullanılacak ise bu işarete ait spektrum tam olarak yorumlanmalıdır⁽³⁵⁾.

2.2. Yapay Sinir Ağları

Beynin üstün özellikleri, bilim adamlarını üzerinde çalışmaya zorlamış ve beynin nörofiziksel yapısından esinlenerek matematiksel modeli çıkarılmaya çalışılmıştır. Beynin bütün davranışlarını tam olarak modelleyebilmek için fiziksel bileşenlerinin doğru olarak modellenmesi gerektiği düşüncesi ile çeşitli yapay hücre ve ağ modelleri geliştirilmiştir. Böylece Yapay Sinir Ağları (YSA) denen yeni ve günümüz bilgisayarlarının algoritmik hesaplama yönteminden farklı bir bilim alanı ortaya çıkmıştır. Yapay sinir ağları; yapısı, bilgi işleme yöntemindeki farklılık ve uygulama alanları nedeniyle çeşitli bilim dallarının da kapsam alanına girmektedir.

Genel anlamda YSA, beynin bir işlevi yerine getirme yöntemini modellemek için tasarlanan bir sistem olarak tanımlanabilir. YSA, yapay sinir hücrelerinin birbirleri ile çeşitli şekillerde bağlanmasından oluşur ve genellikle katmanlar şeklinde düzenlenir. Donanım olarak elektronik devrelerle ya da bilgisayarlarda yazılım olarak gerçekleştirilebilir. Beynin bilgi işleme yöntemine uygun olarak YSA, bir öğrenme sürecinden sonra bilgiyi toplama, hücreler arasındaki bağlantı ağırlıkları ile bu bilgiyi saklama ve genelleme yeteneğine sahip paralel dağılmış bir işlemcidir. Öğrenme süreci, arzu edilen amaca ulaşmak için YSA ağırlıklarının yenilenmesini sağlayan öğrenme algoritmalarını ihtiva eder.

2.2.1. Yapay Sinir Ağlarının Özellikleri

Yukarıda verilen açıklamalardan, YSA'nın hesaplama ve bilgi işleme gücünü, paralel dağılmış yapısından, öğrenebilme ve genelleme yeteneğinden aldığı söylenebilir. Genelleme, eğitim ya da öğrenme sürecinde karşılaşılmayan girişler için de YSA'nın uygun tepkileri üretmesi olarak tanımlanır. Bu üstün özellikleri, YSA'nın karmaşık problemleri çözebilme yeteneğini gösterir. Günümüzde birçok bilim alanında YSA, aşağıdaki özellikleri nedeniyle etkin olmuş ve uygulama yeri bulmuştur.

2.2.1.1. Doğrusal Olmama

YSA'nın temel işlem elemanı olan hücre doğrusal değildir. Dolayısıyla hücrelerin birleşmesinden meydana gelen YSA da doğrusal değildir ve bu özellik

bütün ağı yayılmış durumdadır. Bu özelliği ile YSA, doğrusal olmayan karmaşık problemlerin çözümünde en önemli araç olmuştur.

2.2.1.2. Öğrenme

YSA'nın arzu edilen davranışı gösterebilmesi için amaca uygun olarak ayarlanması gerekir. Bu, hücreler arasında doğru bağlantıların yapılması ve bağlantıların uygun ağırlıklara sahip olması gerektiğini ifade eder. YSA'nın karmaşık yapısı nedeniyle bağlantılar ve ağırlıklar önceden ayarlı olarak verilemez ya da tasarlanamaz. Bu nedenle YSA, istenen davranışı gösterecek şekilde ilgilendiği problemde aldığı eğitim örneklerini kullanarak problemi öğrenmelidir.

2.2.1.3. Genelleme

YSA, ilgilendiği problemi öğrendikten sonra eğitim sırasında karşılaşmadığı test örnekleri için de arzu edilen tepkiyi üretebilir. Örneğin, karakter tanıma amacıyla eğitilmiş bir YSA, bozuk karakter girişlerinde de doğru karakterleri verebilir ya da bir sistemin eğitilmiş YSA modeli, eğitim sürecinde verilmeyen giriş sinyalleri için de sistemle aynı davranışı gösterebilir.

2.2.1.4. Uyarlanabilirlik

YSA, ilgilendiği problemdeki değişikliklere göre ağırlıklarını ayarlar. Yani, belirli bir problemi çözmek amacıyla eğitilen YSA, problemdeki değişimlere göre tekrar eğitilebilir, değişimler devamlı ise gerçek zamanda da eğitime devam

edilebilir. Bu özelliği ile YSA, uyarlamalı örnek tanıma, sinyal işleme, sistem tanılama ve denetim gibi alanlarda etkin olarak kullanılır.

2.2.1.5. Hata Toleransı

YSA, çok sayıda hücrenin çeşitli şekillerde bağlanmasından oluştuğundan paralel dağılmış bir yapıya sahiptir ve ağına sahip olduğu bilgi, ağdaki bütün bağlantılar üzerine dağılmış durumdadır. Bu nedenle, eğitilmiş bir YSA'nın bazı bağlantılarının hatta bazı hücrelerinin etkisiz hale gelmesi, ağına doğru bilgi üretmesini önemli ölçüde etkilemez. Bu nedenle, geleneksel yöntemlere göre hatayı tolere etme yetenekleri son derece yüksektir.

2.2.1.6. Donanım ve Hız

YSA, paralel yapısı nedeniyle büyük ölçekli tümleşik devre teknolojisi ile gerçekleştirilebilir. Bu özellik, YSA'nın hızlı bilgi işleme yeteneğini artırır ve gerçek zamanlı uygulamalarda arzu edilir.

2.2.1.7. Analiz ve Tasarım Kolaylığı

YSA'nın temel işlem elemanı olan hücrenin yapısı ve modeli bütün YSA yapılarında yaklaşık aynıdır. Dolayısıyla, YSA'nın farklı uygulama alanlarındaki yapıları da standart yapıdaki bu hücrelerden oluşacaktır. Bu nedenle, farklı uygulama alanlarında kullanılan YSA'ları benzer öğrenme algoritmalarını ve teorilerini

paylaşabilirler. Bu özellik, problemlerin YSA ile çözümünde önemli bir kolaylık getirecektir.

2.2.2. YSA'nın Uygulama Alanları

Son yıllarda YSA'ları, özellikle günümüze kadar çözümü güç ve karmaşık olan ya da ekonomik olmayan çok farklı alanlardaki problemlerin çözümüne uygulanmış ve genellikle başarılı sonuçlar alınabilmiştir. YSA'ları çok farklı alanlara uygulanabildiğinden bütün uygulama alanlarını burada sıralamak zor olmakla birlikte genel bir sınıflandırma ile YSA'nın uygulama alanları 6 grup içerisinde toplanabilir. Tıp alanında, elektroensefalogram (EEG) ve elektrokardiyogram (EKG) gibi tıbbi sinyallerin analizi, kanserli hücrelerin analizi, protez tasarımı, transplantasyon zamanlarının optimizasyonu ve hastanelerde giderlerin optimizasyonu vb. gibi uygulama yeri bulmuştur.

2.2.3. İleri Beslemeli Sinir Ağları

Bu çalışmada kullanılan ileri beslemeli ağ mimarisinde nöronlar katmanlar halinde yerleştirilir⁽³⁶⁾. İleri beslemeli sinir ağları, geniş bir uygulama alanına sahiptir. Bu tip ağ yapısı biyomedikal dâhil birçok alana başarı ile uygulanmıştır^(27-40 41). Bu çalışmada da tıbbi işaretlerin değerlendirilmesinde kendisini kanıtlamış olan ileri beslemeli sinir ağları Karotid arterlere ait Doppler işaretlerinin sınıflandırılmasında kullanılacaktır⁽³⁷⁾.

İleri beslemeli sinir ağı en az üç katmandan oluşur. Bu katmanlı yapısından dolayı kullanılan mimari çok katmanlı algılayıcı (Multilayer perceptron) olarak da

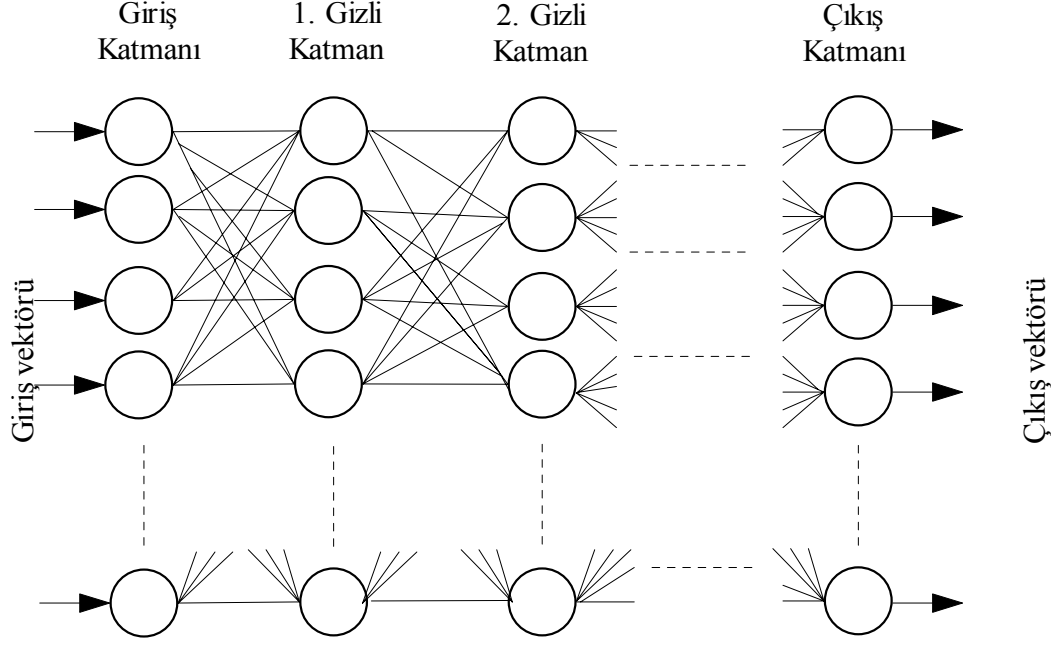
isimlendirilmektedir. İleri beslemeli yapay sinir ağı Şekil 2.8'de de izlendiği gibi giriş, gizli ve çıkış katmanlarındaki nöronlardan oluşmaktadır. Giriş katmanındaki işlem elemanları veya nöronlar sadece giriş işareti x_i 'nin gizli katmandaki nöronlara dağılmasını sağlayan tampon görevini yaparlar. Gizli katmanda bulunan her bir j indisli işlem elemanı; x_i giriş işaretini, giriş katmanında w_{ij} ağırlıkları ile çarptıktan sonra toplar. Bu toplam bir f eşik fonksiyonu olarak y_i çıkışını aşağıdaki gibi hesaplar.

$$y_i = f\left(\sum w_{ij}.x_i\right) \quad (2.9)$$

Eşik fonksiyonu sigmoid veya hiperbolik tanjant gibi bir fonksiyon olabilir. Karotid arterlere ait Doppler işaretlerinin sınıflandırılması için kullanılacak sinir ağlarında hiperbolik tanjant eşik fonksiyonu seçilmiştir. Çünkü sigmoid fonksiyonu (0,1) aralığında değer alabilmekte iken bu fonksiyona benzeyen hiperbolik tanjant fonksiyonu (-1,1) aralığında değer alabilmektedir.

Aynı şekilde çıkış katmanındaki her bir nöronun değeri de gizli katmanda bağlı olduğu nöronlardan çıkarılır. Bir öğrenme algoritması kullanılarak nöronlar arasındaki bağlantıların ağırlıkları düzenlenir.

İleri beslemeli sinir ağında bir gizli katman olabileceği gibi birden fazla gizli katman da olabilir. Önceki katmandaki her bir nöronun ağırlıkları toplamını alan her bir nöron bir sonraki katmandaki her bir nörona giriş olarak uygulanır. Her bir nöronun aktivasyonu eşik fonksiyonu ile kontrol edilir.



Şekil 2.2. İleri beslemeli giriş, gizli ve çıkış katmanlarından oluşan sinir ağı mimarisi

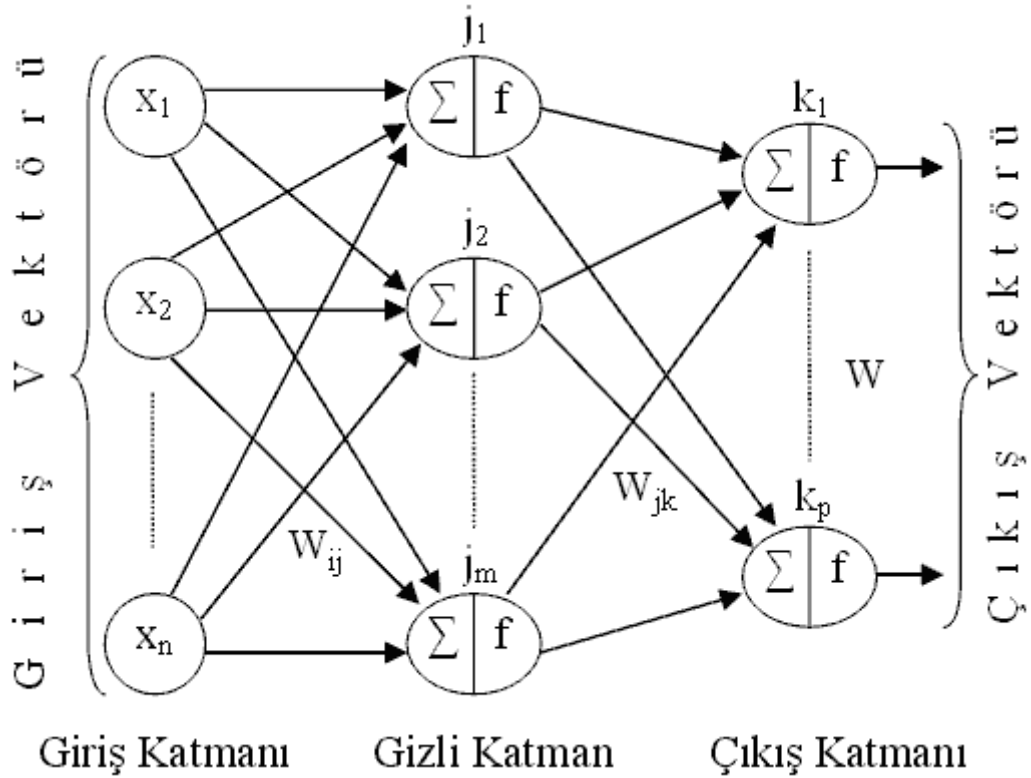
Bu çalışmada Karotid arterlere ait Doppler işaretlerini sınıflandıracak sinir ağının öğrenmesinde başarılı bir öğrenme algoritması olan geri yayılım (back propagation) algoritması kullanılır. Geri yayılım algoritması, ağın çıkışındaki hatayı hesaplayarak nöronların ağırlıklarını yeniden düzenler. Yeniden düzenleme katmanlara yayılarak, çıkıştaki hata azaltılmaya çalışılır.

2.2.4. Çok Katmanlı Algılayıcı

Çok Katmanlı Algılayıcılar (ÇKA); günümüzde birçok mühendislik probleminin çözümünde kullanılabilen ve sınıflandırma amacıyla etkin şekilde sonuçlar üretebilmektedir. Ryu ve arkadaşları⁽⁴²⁾, ÇKA'nın da içinde yer aldığı farklı türde sınıflandırıcılarla bir çerçeve oluşturmaya çalışmış ve farklı veri kümeleri üzerinde analizler yapmıştır. ÇKA'da Delta öğrenme kuralı denilen bir öğrenme

yöntemini kullanılmaktadır. Bu kuralın amacı; ağırlık istenen çıktı ile ürettiği çıktı arasındaki hatayı minimum yapmaktır.

ÇKA'lar; üç katmandan oluşmaktadır. Bunlar; girdi katmanı, gizli katmanlar ve çıktı katmanıdır. Bilgiler girdi katmanından ağırlık katmanına, gizli katmanlardan çıktı katmanına ulaşır ve çıktı katmanından dış dünyaya aktarılır.



Şekil 2.3. Çok katmanlı Algılayıcıların Yapısı

Şekil 2.3'de gösterildiği gibi burada giriş, gizli ve çıkış katmanlarındaki nöronlardan oluşmaktadır. Giriş, gizli ve çıkış katmanları arasındaki vektörel bağıntılarda ağırlık katsayıları olan W_i değeri mevcuttur. Giriş katmanı $(x_1, \dots, x_i, \dots, x_n)$, hastalardan alınan ölçümleri hiçbir değişikliğe uğratmadan gizli katmandaki $(j_1, \dots, j_i, \dots, j_m)$ hücrelere iletir ve daha sonra iletilen bu veriler, gizli ve çıkış katmanında işlenerek ağ çıkışına ait sonuçların (y_1, y_2) belirlenmesini sağlar⁽⁴³⁾.

Burada giriş değerlerine önce toplama fonksiyonları uygulanır ve her bir işlem elemanının çıkış (İEÇ) değeri

$$IEÇ = \sum_{i=1}^N X_i W_{ij} - \theta_i \quad (2.10)$$

olarak bulunur. X_i i'inci girişi, W_{ij} j'inci elemandan i'inci elemana bağlantı ağırlığını ve W_i eşik (threshold) değerini göstermektedir. Daha sonra bu çıkış değerleri sigmoidal aktivasyon fonksiyonuna yani öğrenme eğrisine uygulanır. Sonuçta çıkış değeri aşağıdaki şekilde bulunur.

$$ÇIKIŞ = \frac{1}{1 + e^{-IEÇ}} \quad (2.11)$$

Transfer fonksiyonları olarak çoğunlukla, hiperbolik tanjant veya sigmoid fonksiyonu kullanılmaktadır. Bu işlemci elemanın çıkış değeri diğer işlemci elemanlarına giriş veya ağırlık çıkış değeri olabilir^(15,44).

Bilgi akışı ileri doğru olup, geri besleme yoktur. Bunun için ileri beslemeli sinir ağı modeli olarak adlandırılır. Giriş katmanında herhangi bir bilgi işleme yapılmaz. Buradaki işlem elemanı sayısı uygulanan problemin giriş sayısına bağlıdır. Ara katman sayısı ve ara katmanlardaki işlem elemanı sayısı ise, deneme-yanılma yolu ile bulunur. Çıkış katmanındaki eleman sayısı ise yine uygulanan probleme dayanılarak belirlenir.

Çok katmanlı algılayıcı ağlarında, ağa bir örnek gösterilir ve örnek neticesinde nasıl bir sonuç üreteceği de bildirilir (danışmanlı öğrenme). Örnekler giriş katmanına uygulanır, ara katmanlarda işlenir ve çıkış katmanından da çıkışlar elde edilir. Kullanılan eğitme algoritmasına göre, ağırlık çıkışı ile arzu edilen çıkış

arasındaki hata tekrar geriye doğru yayılarak hata minimuma düşünceye kadar ağırlıkları değiştirilir.

İleri beslemeli ağlar, en genel anlamıyla giriş uzayıyla çıkış uzayı arasında statik haritalama yapar. Bir andaki çıkış, sadece o andaki girişin bir fonksiyonudur.

2.2.5. Geri Yayılım Algoritması

Karmaşık örüntülerin sınıflandırılmasında kullanılan etkin sinir ağı modellerinden birisi, ilk olarak Werbos tarafından düzenlenen, daha sonra Parker, Rummelhart ve McClelland tarafından geliştirilen geriye yayılım ağıdır^(27, 28, 45). Yayınma ve uyum gösterme olarak iki aşamada işlemleri gerçekleştiren geri yayılım, katmanlar arasında tam bir bağlantının bulunduğu çok katmanlı ileri beslemeli ve denetimli olarak eğitilen bir sinir ağı modelidir.

Katmanlarda yer alan nöronlar arası bağlantı ağırlıklarının başlangıç değerlerinin belirlenmesi, problemin çözümüne giden yolda ilk adımdır. Bu çalışmada ilk ağırlık ve eşik değerleri pozitif, 1'den küçük değerler olarak belirlenmektedir.

Eğitime işlemi ve eğitimden sonraki test işlemi bu akışa göre yapılır. Bu algoritma ile i ve j kat işlem elemanları arasındaki ağırlıklardaki $\Delta w_{ji}(t)$ değişikliği hesaplanır. Bu ifade,

$$\Delta w_{ji}(t) = \eta \delta_j x_i + \alpha \Delta w_{ji}(t-1) \quad (2.12)$$

olarak verilir. Eşitlik (2.16)'da η öğrenme katsayısı, α momentum katsayısı ve δ_j ara veya çıkış katındaki herhangi bir j nöronuna ait bir faktördür. Çıkış katı için bu faktör aşağıdaki şekilde verilir.

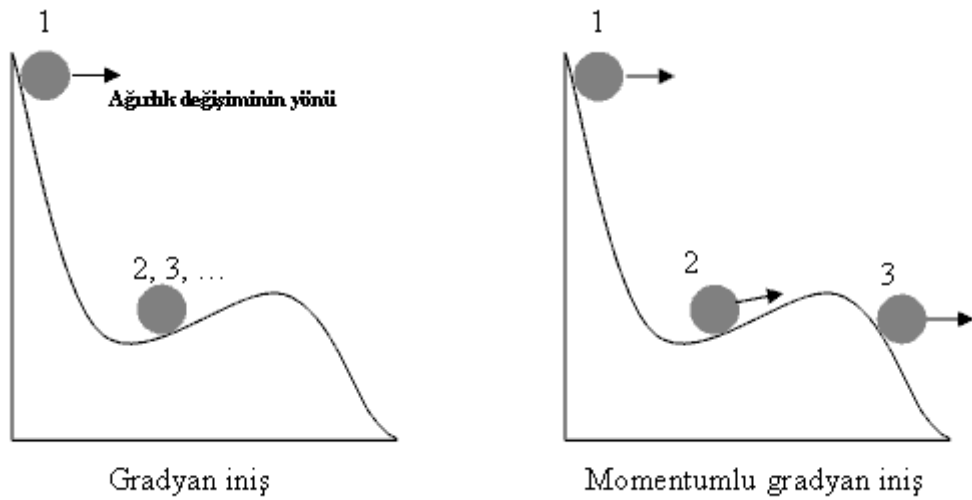
$$\delta_j = \frac{\partial f}{\partial net_j} = (y_j^{(t)} - y_j) \quad (2.13)$$

Burada, $\partial net_j = \sum x_j w_{ji}$ ve $y_j^{(t)}$ ise j işlemci elemanının hedef çıkışıdır. Ara katlardaki işlemci elemanları için ise bu faktör,

$$\delta_j = \left(\frac{\partial f}{\partial net_j} \right) \sum w_{qi} \delta_q \quad (2.14)$$

Olarak verilir. Ara katlardaki işlemci elemanları için herhangi bir hedef çıkış olmadığından eşitlik (2.17) yerine Eşitlik (2.18) kullanılır. Bu duruma bağlı olarak çıkış katından başlayarak δ_j faktörü, bütün katlardaki işlemci elemanları için hesaplanır. Daha sonra Eşitlik (2.16)'daki formüle bağlı olarak, bütün bağlantılar için ağırlıkların güncelleştirilmesi gerçekleştirilir ⁽⁴⁶⁾.

Öğrenme sürecinin süratini, minimum noktadan uzaklaşmayacak şekilde artırabilmek için diğer bir yol, momentum ismi verilen bir tekniğin kullanılmasıdır. Şekil 2.4 momentum algoritmasının avantajını özetlemektedir.




Şekil 2.4. Gradyan girişleri ve Momentum Etkisi

Yapay sinir ağlarında öğrenme esnasında yapılması gereken en önemli konulardan biri de öğrenme katsayısı ve momentum teriminin ayarlanmasıdır. Öğrenme katsayısı 0,01 ile 1 aralığında seçilebilen sabit bir sayıdır. Ağırlıkların çok yüksek tutulması yüzünden yapay sinir ağının öğrenme davranışı bozulabilir. Bunu önleyebilmek için öğrenme katsayısının küçük tutulması gerekir. Öte yandan küçük öğrenme oranı ise öğrenme işlemini yavaşlatmaktadır. Bu nedenle momentum öğrenme tekniği için adım büyüklüğünün ve momentum katsayısının ağın öğrenmesi için uygun olarak belirlenmesi gerekir. Bu parametrelerin dikkatlice ayarlanması ile başarılı sonuçlar elde edilebilir⁽⁴⁶⁾.

Bu çalışmada amaçlananlardan biri de, obezite parametrelerinin ileri beslemeli geri yayılım algoritmaları uygulayarak sınıflama performanslarını incelemek, aynı zamanda Jordan-Elman metodu ile karşılaştırmaktır.

2.2.6. Jordan-Elman Metodu

Jordan Elman Sinir Ağları basit yinelenen sinir ağlarıdır. Yinelenen Sinir ağlarının genel ilkesine göre; gizli ya da çıkış katmanındaki bazı nöronların çıktılarında Girdi katmanındaki nöronlara bir geri-besleme vardır. Bu geri besleme bağlantıları; Elman sinir ağlarında gizli katmanın çıktılarında ve Jordan sinir ağlarında çıkış katmanından giriş katmanının bağlam düğümleri denen düğümlerindedir. Giriş katmanının bağlam düğümlerini içeren bu bölümüne bağlam katmanı denir ve Elman ve Jordan Ağlarının iç durumlarını muhafaza eder⁽⁴⁷⁾.



Şekil 2.5. Yinelemeli Sinir Ağları modelinin yapısı a) Elman Ağları b) Jordan Ağları

Elman ve Jordan yinelenen sinir ağlarının yapıları Şekil 2.5’de gösterilmiştir. Burada \underline{X} , \underline{Y} , \underline{C} , \underline{Z} ve z^{-1} sırasıyla girdi katmanı, gizli katman, bağlam katmanı, çıkış katmanı vektörleri ve bekleme birimi elemanıdır. (W1), giriş ve gizli katman arasındaki ağırlık matrisi; (W2), gizli ve çıkış katman arasındaki ağırlık matrisi ve (W3) de bağlam katmanı için tanımlanan ağırlık matrisidir.

Jordan-Elman Sinir Ağlarında rastgele bir iterasyonda yani s. iterasyonda:

$$x_i^{(s)} \in \underline{X} \quad (i=1, \dots, n), \quad y_j^{(s)} \in \underline{Y} \quad (j=1, \dots, m), \quad z_k^{(s)} \in \underline{Z} \quad (k=1, \dots, l),$$

$$c_t^{(s)} \in \underline{C} \quad t = \begin{cases} j & \text{Elman Sinir ağında} \\ k & \text{Jordan Sinir Ağında} \end{cases} \quad (2.15)$$

Burada i, girdi düğüm sayısını; j, gizli düğüm sayısını; k çıkış düğüm sayısını ve t, bağlam tabakanın düğümlerini gösterir. Gizli katman düğümlerinin çıktılarını hesaplamak için $f(\cdot)$ aktivasyon fonksiyonunu önerilmiştir. s’inci iterasyonda j’inci

gizli düğüm çıkışı $y_j^{(s)} = f(a_j^{(s)})$ olarak tanımlanır. $a_j^{(s)}$, s 'inci iterasyonda j gizli düğümünün lineer çıkışıdır. s 'inci iterasyonda bağlam katmanının girişi; Elman ağları için $c_{t=j}^{(s)} = y_j^{(s-1)}$ ve Jordan ağları için $c_{t=k}^{(s)} = z_k^{(s-1)}$ 'dir.

Yinelenen sinir ağlarında ilk durumlar için Elman ağları için $y_j^{(0)} = 0$, ($j = 1, \dots, m$) ve Jordan ağları için $z_k^{(0)} = 0$, ($k = 1, \dots, l$) varsayılır.

Bağlam katmanı girişi $s=1$ 'de $c_j^{(1)} = 0$ ve $c_t^{(1)} = 0$ 'dır. Yinelemeli sinir ağ yapısında her ağırlık vektörü bu matrislerin bir elemanı olarak tanımlanabilir:

$$\begin{aligned} w1_{ji} &\in [W1]; & w2_{kj} &\in [W2] \\ w3_{ij} &\in [W3]', & t = j; & \bar{w}3_{ij} \in [W3]'', & t = k; \end{aligned} \quad (2.16)$$

Burada (W3)', Elman yinelenen sinir ağlarının bağlam katmanı için tanımlanan ağırlık matrisi ve (W3)'', Jordan yinelenen sinir ağlarının bağlam katmanı için tanımlanan ağırlık matrisidir.

Bundan dolayı, ağırlık matrislerini kullanarak s 'inci iterasyonda gizli katman ve çıkış katmanındaki çıkışlar:

$$\begin{aligned} y_j^{(s)} &= f\left(\sum_{i=1}^n w1_{ji} x_i^{(s)} + \sum_{j=1}^m w3_{ij} y_{jt}^{(s-1)}\right), t = j & \text{(Elman ağında)} \\ \bar{y}_j^{(s)} &= f\left(\sum_{i=1}^n w1_{ji} x_i^{(s)} + \sum_{j=1}^l \bar{w}3_{ij} \bar{z}_{jt}^{(s-1)}\right), t = k & \text{(Jordan ağında)} \end{aligned} \quad (2.17)$$

olarak hesaplanır. Çıkışlar da:

$$z_k^{(s)} = f\left(\sum_{i=1}^n w_{2_{kj}} y_i^{(s)}\right), \text{ (Elman ağı için)} \quad (2.18)$$

$$\bar{z}_k^{(j)} = f\left(\sum_{j=1}^m w_{2_{kj}} \bar{y}_j^{(s)}\right), \text{ (Jordan ağı için)}$$

olarak tanımlanır.

Çıkış katmanındaki E yaklaşık hatayı minimize etmek için güncellenen ağırlık faktörleri de $w^{new} = w^{old} + \eta \Delta w$ olarak verilir. Burada η öğrenme oranıdır.

E, bütün örüntü vektörleri ve çıkış düğümleri için tanımlayan eşitlik:

$$E(w) = \frac{1}{2} \sum_{s=1}^p \sum_{k=1}^l [Z_k^{(s)} - z_k^{(s)}]^2, \text{ Elman ağıları} \quad (2.19)$$

$$E(w) = \frac{1}{2} \sum_{s=1}^p \sum_{k=1}^l [\bar{Z}_k^{(s)} - \bar{z}_k^{(s)}]^2, \text{ Jordan ağıları}$$

Burada p eğitim dizisi ile $W1$ ve $W3$ ağırlık vektörlerinin uzunluğudur. Standart geri yayılım algoritmasını kullanarak düzeltilir. Giriş ve çıkış katmanları arasındaki ağırlık bu kısmı ileri beslemeli karakterdedir. Zincir kuralı türevini kullanarak $W3$ matris elemanlarını güncellenebilir. Her iki yinelenen sinir ağı topolojilerinin eğitim sonuçları için bağlam katmanı ve gizli/çıkış katmanı arasındaki ilişki:

$$\Delta w_{3_{ij}} = \frac{\partial E}{\partial y_j} \frac{\partial y_j}{\partial w_{3_{ij}}} = \sum_{k=1}^l [Z_k^{(s)} - z_k^{(s)}] w_{2_{kj}} f'(y_j^{(s)}) y_j^{(s-1)}, \text{ Elman ağıları} \quad (2.20.)$$

$$\bar{\Delta w}_{3_{ij}} = \frac{\partial \bar{E}}{\partial \bar{y}_j} \frac{\partial \bar{y}_j}{\partial \bar{w}_{3_{ij}}} = \sum_{k=1}^l [\bar{Z}_k^{(s)} - \bar{z}_k^{(s)}] w_{2_{kj}} f'(\bar{y}_j^{(s)}) \bar{z}_k^{(s-1)}, \text{ Jordan ağıları}$$

şeklinde olacaktır.

2.2.7. Karotid Arter Doppler Sinyallerinin Jordan Elman Sinir Ağı ile Sınıflandırılması

Bu çalışmada ele aldığımız Karotid arterlerin Doppler işaretlerine ait verilerin ÇKA ve Jordan-Elman sinir ağına uygulanmasından önce bazı konulara dikkat edilmesi gerekir. Sinir ağı mimarisinin, tıbbi parametrelere uygun hale getirilmesi sırasında öncelikle ağın girişlerine uygulanacak tıbbi verilerin yeterli sayıda ve uygun eğitim vektörlerine dönüştürülmesi gerekir. Yetersiz sayıda kişiden alınan tıbbi veriler kullanılarak eğitilen sinir ağına farklı bir kişiden alınan tıbbi veriler uygulandığında yanlış teşhis yapma riski artmaktadır. Bu nedenle yaş, ırk, cinsiyet, aile geçmişi vb. gibi toplumda farklılıklara neden olan özellikler de dikkate alınarak çalışılan hasta sayısının yüksek tutulması gerekir. Ayrıca gelecekte kliniklerde pratik olarak kullanılacak olan Doppler teşhis sistemlerinin devamlı öğrenmesi sağlanarak (sistemin yaptığı teşhislere ait sonuçlar sisteme geri besleme olarak girilir ise) çalışılan hasta sayısı giderek arttırılabilir.

Hastalardan alınan Doppler parametrelerinin bir kısmı eğitim amacıyla kullanılır iken kalan kısmı test amacıyla kullanılır. Böylece eğitim verilerini öğrenen sinir ağının daha önce karşılaşmadığı test vektörlerine olan tepkisi ölçülebilir. Eğitim sırasında bozuk veya eksik tıbbi verileri de içeren vektörlerin kullanılması, daima faydalı sonuçlar vermektedir. Eğitilen sinir ağının klinik ortamda kullanımı sırasında, bilinmeyen, bozuk veya eksik tıbbi verilerin ağ tarafından tanınabilmesi böylece sağlanacaktır.

Aynı sınıfa ait olan birçok farklı giriş vektörünün ağa uygulanması durumunda, sinir ağı bu vektörler arasındaki anlamlı benzerlikleri genelleme yaparak öğrenecektir. Ağın eğitimi için hastalıklı ve sağlıklı kişilerden birbirine yakın sayıda eğitim vektörü alınarak ağın dengeli eğitimi yapılmalıdır. Eğer hastalara ait veriler sağlıklılara oranla çok fazla ise sinir ağı hastalık teşhisini başarılı bir şekilde yaparken sağlıklı bireyleri de yanlışlıkla hasta olarak gösterebilir. Bu nedenle eğitim verileri, hastalık teşhisinin tüm sınıflarını kapsayacak şekilde düzenlenmiş olmalıdır.

Ağın eğitimi esnasında hastalıklı ve sağlıklı kişilere ait veriler belirli bir düzende değil rastgele olarak ağa uygulanmalıdır. Eğer verileri hastalıklı ve sağlıklı olarak gruplandırdıktan sonra önce hastalıklı sonra sağlıklı bireylere ait veriler ağa uygulanır ise hastalıklı veri grubundan sonra sağlıklı veri grubu uygulandığı için nöronlar arasındaki bağlantılar sağlıklı bireylere uygun olarak düzenlenir. Sinir ağındaki nöronlar arasındaki bağlantılar hastalıklı verilerin özelliklerini unutacaktır. Bu nedenle hastalıklı bireylere ait teşhiste başarı oranı azalacaktır. Eğitim verileri gruplandırılmadan tesadüfi olarak ağa uygulanmalıdır.

Çok katmanlı bir ağın kullanılması halinde üç katmanlı ağın yeterli olup olmadığı, her katmanda kaç nörona yer verilmesi gerektiği teşhisi yapılacak tıbbi parametrelerin özelliklerine bağlı olarak belirlenecektir. Ağa uygulanan tıbbi verilere çok fazla ve karmaşık değil ise genellikle üç katmanlı (giriş, gizli ve çıkış) ağ yapısı yeterli olmaktadır. Daha karmaşık tıbbi verilerde katman sayısı artırılabilir. Fakat bu durumda hem ağ yapısı karmaşıklaşacak hem de işlem yükü ve zamanı artacaktır.

Giriş katmanındaki nöron sayısı ağa uygulanacak tıbbi verilerin sayısına bağlıdır. Örneğin Karotid arterlere ait Doppler işaretlerinden elde edilen TA/Systol,

TA/Diastol, RCC, RCI parametreleri ađın giriřine uygulanırken 5 –10 arasında giriř nöronu yeterli olacaktır. Bu nedenle tek gizli katman yeterlidir ve gizli katmandaki nöron sayısı giriř katmandakinin %50'si civarından 4–8 aralıđında olması iyi bir sınıflama için yeterlidir. Tabi ki çıkıř katmanındaki nöron sayısı yani yapılacak olan teřhis çeřidinin sayısı da önemlidir. Bu alıřmada iki çıkıř nöronu alınmıřtır. Bunlar normal ve obezite olabilir. Giriř ve çıkıř katmanlarındaki nöron sayısı arttırıldıđça ađın bařarılı öđrenebilmesi için gizli katmandaki nöron sayısının da arttırılması gerekir. Yine bu tez alıřmasında obezite teřhisinde önemli yere sahip vücut kitle indeksi verileri ađın giriřine uygulandıđında gizli katman sayısı da arttırılmıřtır. Burada unutulmaması gereken diđer bir faktör de gizli katmanda yer alacak her gereksiz nöronun bilgisayar alıřmasını uzatacađı, buna karřılık olması gerekenden daha az nöronun bulunması halinde de ađın öđrenme sürecini gerekleřtirmeyeceđidir.

2.2.8. KA ve Jordan – Elman YSA Performanslarının Deđerlendirmesi

Ađın öđrenmedeki bařarısını deđerlendirmek için gerek ve tahmin edilen deđerler arasındaki sapmalar ölçülür. Bu alıřmada sinir ađının çıkıřındaki nöronların deđerleri (hesaplanan teřhis) ile daha önceden belirlenen gerek teřhis bilgisi karřılařtırılarak aradaki fark hata deđerleri olarak hesaplanır.

Ortalama Karesel Hata (OKH), deđerleri istenen ile hesaplanan ađ çıkıřının birbirine ne kadar iyi uyup uymadıđına karar vermek için kullanılır. Bu hata deđerleri dikkate alınarak çıkıř katmanından giriř katmanına dođru bađlantıların ađırlıkları yeniden düzenlenir. OKH deđerleri öđrenmenin bařlarında biraz büyük olabilir. Fakat öđrenmede adım sayısı arttıđça OKH azalacak ve sabitleřecektir. Geri yayılım

öğrenme tekniğinde OKH değeri kabul edilebilir değerin altına düşünceye kadar öğrenmeye devam edilir.

OKH, ağın istenen çıkış değerlerine ne kadar yaklaştığını belirlemek için kullanılır. Denetimli öğrenmede durma kriteri genellikle OKH üzerine kurulur. OKH bir eşik değerinin altına düştüğünde öğrenme durdurulur. Bir başka durma kriteri ise adımlar arasındaki hata değişiminin eşik değerinin altına düşmesi durumudur.

OKH değerinin belli bir değerin altına düşmesiyle sinir ağının verilen veri yapısını başarıyla öğrendiği kabul edilir. Böylece herhangi bir hastaya ait Doppler parametreleri ağa uygulandığında ağın çıkışında elde edilen sonuç önceden belirlenen sonuçlar ile uyumlu olmalıdır. Bu çalışmamızda Karotid arterlerindeki obeziteye bağlı olarak değişiminin tespit edilmesi için uygulanan veri hangi sonucu gösteriyor ise sinir ağının çıkış katmanındaki normal ya da obezite nöronunun çıkış değeri diğer nöronlardan daha yüksek olmalıdır. Önceden belirlenen sonuçlar ile sinir ağının çıkışında hesaplanan sonucun ne kadar uyumlu olduğu bir çizelge üzerinde gösterilebilir. Sınıflama tablosu (confusion matrix) olarak adlandırılan bu çizelge (Çizelge 2.1) incelenerek sinir ağının tahmin başarısı ölçülebilir. Çizelge 2.1’de bahsedilen Doğru Pozitif (DP), Doğru Negatif (DN), Yanlış Pozitif (YP) ve Yanlış Negatif (YN) değerleri Çizelge 2.2’de açıklanmaktadır.

Çizelge 2.1. Sınıflama tablosu

		Sinir ağı tahmin değeri	
		Normal	Anormal
Gerçek Değeri	Normal	DN	YN
	Anormal	YP	DP

Ayrıca sinir ağının sınıflama performansını belirleyebilmek için duyarlılık (sensitivity) ve belirlilik (specificity) analizi yapılır. Duyarlılık değeri önceden belirlenen sonuç ile aynı hastalık teşhis sayısının; önceden belirlenen toplam hastalık teşhis sayısına bölünmesi ile elde edilir. Doğru Pozitif oranı (DPO) olarak da adlandırılan duyarlılık;

$$\text{Duyarlılık} = DPO = \frac{DP}{DP + YN} \quad (2.21)$$

formülüyle hesaplanır. Böylece hastalıklı verilerin ne oranda başarı ile tahmin edilebildiği görülür. Diğer taraftan belirlilik değeri önceden belirlenmiş doğru teşhis ile aynı sağlıklı teşhis sayısının; önceden belirlenmiş olan toplam sağlıklı teşhis sayısına bölünmesi ile elde edilir. Doğru Negatif oranı (DNO) olarak da adlandırılan belirlilik;

$$\text{Belirlilik} = DNO = \frac{DN}{DN + YP} \quad (2.22)$$

formülüyle hesaplanır. Belirlilik sayesinde de sağlıklı verilerin hastalıklılardan ne oranda ayrılabilirdiği görülür. Burada geçen DP, DN, YP ve YN değerleri Çizelge 2.2’de açıklanmaktadır.

Çizelge 2.2. Sınıflama tablosu kullanılarak elde edilen parametreler

Doğru Pozitif (DP)	Hastalıklı verilerin doğru sınıflandırılması
Doğru Negatif (DN)	Sağlıklı verilerin doğru sınıflandırılması
Yanlış Pozitif (YP)	Hastalıklı verilerin yanlış sınıflandırılması
Yanlış Negatif (YN)	Sağlıklı verilerin yanlış sınıflandırılması

Sınıflandırma başarısı ölçümünün grafiksel olarak yapılabilmesi için test sonucu elde edilen çıkış verileri analiz edilerek ROC (Receiver Operating Characteristic) eğrisi hesaplanır. Doğru ve yanlış sınıflama bilgisine bakılarak belirlilik ve duyarlılık arasındaki ilişki bu grafikte görülebilir. Ayrıca ROC eğrisi altında kalan alan da hesaplanarak sinir ağının performansı ölçülebilir⁽⁴⁸⁾.

Korelasyon katsayısı olan r ise $(-1, 1)$ aralığında bir değer olarak ağın eğitimi hakkında bilgi vermektedir. Korelasyon katsayısının 1'e yakın değeri eğitimin ne kadar başarılı olduğunu göstermektedir.

3. ARAŞTIRMA BULGULARI

Kişilerden alınan Doppler işaretlerini yorumlanıp tanı konulabilmesi için önce hangi parametrelerin yapay sinir ağına uygulanacağı belirlenmelidir. Bu amaçla yapılan çalışmada toplam 71 kişiden alınan Karotid arterlere ait Doppler işaretlerinin analizi yapılan TA/Systol, TA/Diastol, RCCAMAX, RCCAMİN, RİCAMAX, RİCAMİN, LCİ, LCA, LCCAMAX, LCCAMİN, LİCAMAX, LİCAMİN, RİMT, LİMT, RCC ve RCI parametreleri ile kişilerin kilo, boy, yaş, cinsiyet, VKE değerleri obezitenin sınıflandırılması için yapay sinir ağına uygulanabilirliği açısından istatistiksel olarak araştırılmıştır. Bunun için SPSS 15.0 istatistik programı kullanılmıştır. Bu değerler içinde TA/Systol, TA/Diastol, RCC ve RCI Doppler parametreleri ile kilo ve VKE değerleri anlamlı derecede farklı bulunmuştur. Bunlar Çok Katmanlı Algılayıcılar ile Jordan-Elman Ağlarına uygulanmıştır. Yapay Sinir ağlarının uygulamaları için Neuro Dimentions Firmasının Neuro Solutions Programı kullanılmıştır.

3.1. Doppler parametrelerinin İstatistiksel Analizi

Toplam 71 kişiden alınan Doppler hız parametreleri ile oluşturulan bağımsız değişken veri seti Çizelge 3.1’de verilmektedir. Bu kişilerin VKE değerlerine göre ayırım yapılmıştır. Öğrenme ve test amacıyla kullanılan veri setlerinin dağılımı Çizelge 3.2’de verilmiştir.

Çizelge 3.1. Doppler hız parametrelerinin karakteristikleri

Giriş Değişkenleri	Ortalama	Standart Sapma	Minimum	Maksimum
YAS	40,58	8,093	25	58
CİNS	1,54	0,502	1	2
VKE	26,10	2,654	20,2	29,99
VKE2	1,66	0,476	1	2
TASİS	132,61	18,533	90	185
TDİAS	80,14	12,011	55	110
BOY	168,08	7,377	156	185
KG	75,56	11,557	55	125
RCİ	5,15	0,8570	3,8	7,4
RCC	7,19	0,8129	5,3	9,0
RCCAMAX	75,18	16,908	39	115
RCCAMİN	20,39	5,058	9	34
RİCAMAX	44,59	11,803	19	76
RİCAMİN	16,72	6,248	5	32
LCİ	5,25	1,0215	3,2	8,3
LCA	6,98	0,7181	5,9	9,0
LCCAMAX	76,69	16,279	40	119
LCCAMİN	20,55	5,084	10	41
LİCAMAX	44,97	13,697	18	79
LİCAMİN	17,32	6,182	6	35
RİMT	6,35	1,596	1	9
LİMT	6,63	1,667	4	14

Çizelge 3.2. Öğrenme ve test amacıyla kullanılan veri setlerinin dağılımı

Sınıf	Öğrenme Seti	Test Seti	Toplam
Normal (VKE<25)	12	12	24
Obezite (VKE≥25)	23	24	47
Toplam	35	36	71

Toplamda 71 kişiden 47 tanesinin obezite olduğu belirlenmiş. Normal olan 24 kişiye ait veriler de kontrol amacıyla sınıflandırmaya katılmıştır.

3.2. Karotid arterlerin iki farklı kategoride incelenmesi

71 kişiden seçilen rastgele 35 kişinin Karotid arterlerine ait Doppler işaretlerinden elde edilen TA/Systol, TA/Diastol, RCC ve RCI değerleri ile VKE ve kilo olmak üzere toplam 6 parametreleri uygulanabilecek şekilde Çok Katmanlı Algılayıcılar ve Jordan Elman Ağları geliştirilmiştir. Geriye kalan 36 kişinin verileri ise geliştirilen modellerin değerlendirilebilmesi için test amacıyla kullanılmıştır. Her iki modelde de aynı optimizasyon stratejisi kullanılmış, başlangıç değerleri rastgele seçilmiştir.

Obeziteyi normalden ayıran VKE değeri eşik değeri (threshold) kabul edilerek Doppler hız parametreleri iki sınıfa ayrılmış ve Çok Katmanlı Algılayıcılar ile Jordan-Elman sinir ağı modellerine uygulanmıştır.

Çizelge 3.3’de verilen t-testi sonuçları incelendiğinde giriş değişkenlerinden TA/Systol, TA/Diastol, RCC ve RCI Doppler parametreleri ile VKE ve kilo değerleri

p<0,05 değeri ile obezitede istatistiksel olarak anlamlı bulunmuştur. Bu değerler Yapay sinir ağlarına girdi olarak uygulanacaktır.

Çizelge 3.3. Normal ve Obezite veri setlerini tanımlayıcı istatistikler

Giriş Değişkeni	Normal	Obezite	p – değeri
	Ortalama ± SS	Ortalama ± SS	
VKE	23,1771 ± 1,53368	27,5985 ± 1,67119	,000
TASİS	126,6667 ± 17,17345	135,6383 ± 18,63893	,049
TDİAS	75,6250 ± 9,24456	82,4468 ± 12,67797	,022
BOY	168,7083 ± 7,51508	167,7660 ± 7,36683	,614
KG	66,1250 ± 6,54292	80,3830 ± 10,56564	,000
RİCA	5,2500 ± 0,83562	5,1064 ± 0,87263	,508
RCCA	6,9458 ± 0,82672	7,3106 ± 0,78608	,073
RCCAMAX	78,9167 ± 17,03683	73,2766 ± 16,70160	,186
RCCAMİN	21,5000 ± 5,67987	19,8298 ± 4,67332	,190
RİCAMAX	50,0000 ± 11,23659	41,8298 ± 11,21590	,005
RİCAMİN	19,8333 ± 6,20425	15,1277 ± 5,70132	,002
LİCA	5,5500 ± 1,13521	5,1021 ± 0,93495	,080
LCCA	6,9833 ± 0,74639	6,9851 ± 0,71139	,992
LCCAMAX	76,5833 ± 12,48622	76,7447 ± 18,03676	,969
LCCAMİN	20,4167 ± 5,14077	20,6170 ± 5,10989	,877
LİCAMAX	45,9167 ± 10,93823	44,4894 ± 14,99837	,681
LİCAMİN	18,1667 ± 5,53775	16,8936 ± 6,50162	,416
RİMT	6,0833 ± 1,63964	6,4894 ± 1,57249	,314
LİMT	6,3750 ± 1,40844	6,7660 ± 1,78414	,354

Doppler işaretlerinden elde edilen TA/Systol, TA/Diastol, RCC ve RCI değerleri ile VKE ve kilo olmak üzere toplam 6 parametre hem çok katmanlı algılayıcıların hem de Jordan – Elman Yapay Sinir Ağlarının giriş katmanındaki 6 giriş nöronuna uygulanmaktadır. Giriş katmanı uygulanan girişleri gizli katmandaki (j_1, j_2, \dots, j_m) nöronlarına iletir ve daha sonra iletilen bu veriler gizli ve çıkış katmanında işlenerek ağ çıkışına ait sonuçların belirlenmesi sağlanır.

Karotid arterinden alınan Doppler işaretlerinden elde edilen giriş vektörlerinin her biri için istenen çıkış değeri $y_1 = (1 \ 0)$ (Normal) ve $y_2 = (0 \ 1)$ (Obezite) vektörleri şeklinde önceden belirlenmiştir. Çıkış katmanında vücut kitle indeksine bağlı olarak normal ya da obezite seçimini yapılabilmesini sağlayan 2 adet nöron bulunmaktadır.

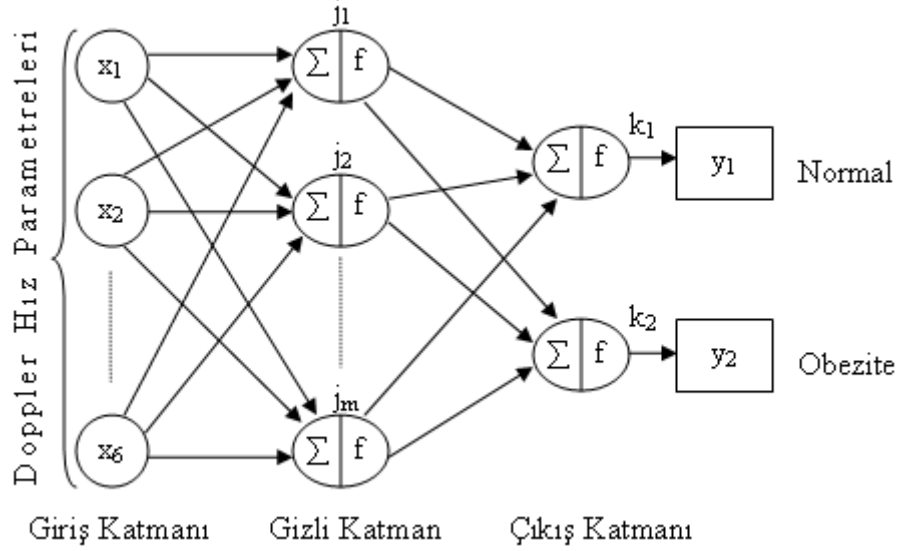
Ağın yeni verilere cevabını belirlemek için; test verisi kullanılmaktadır. Bu çalışmada; 71 örneğin 35 tanesi test, kalan 36 tanesi eğitim için kullanılmıştır. Oluşturulan Çok Katmanlı Algılayıcının; girişinde 6 işlem elemanı, saklı katmanda 4 işlem elemanı, çıkış katmanında 2 işlem elemanı kullanılmıştır.

Transfer fonksiyonu, tanjant hiperbolik (tanh) olup momentum değeri 0,7 seçilmiştir. Öğrenme oranı, giriş katmanı-gizli katman arasındaki ağırlıklar için 0,1, gizli katman-çıkış katmanı arasındaki ağırlıklar için 0,1 olarak alınmıştır.

3.2.1. Çok katmanlı algılayıcılar ağı analizine ait bulgular

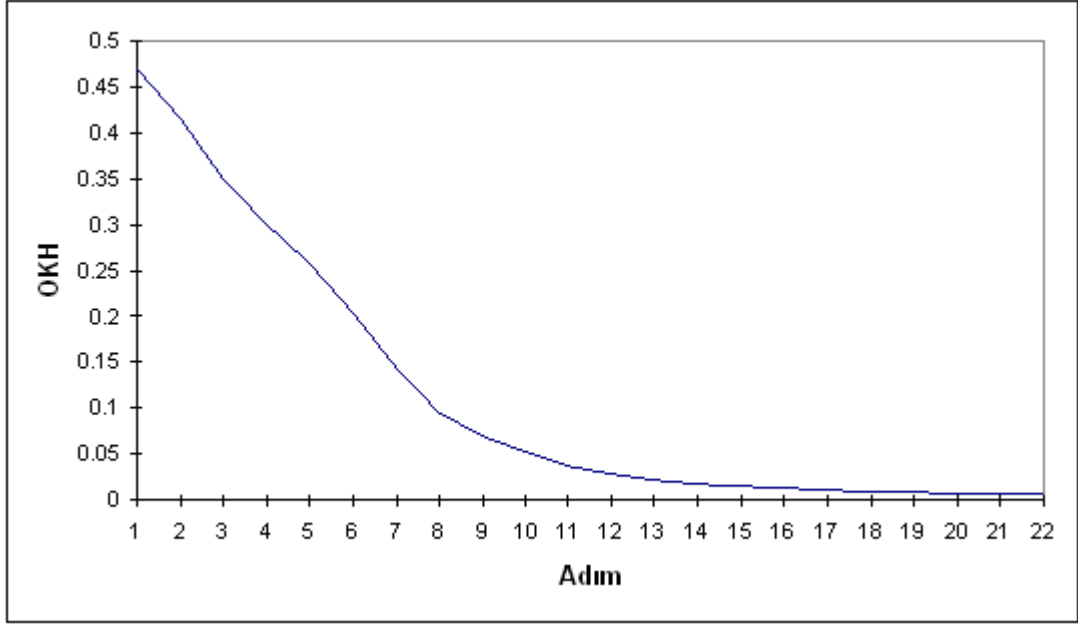
Şekil 3.1’de çıkış katmanı ve çıkış değerleri olan iki nöron olduğu gösterilmiştir. Böylece çıkış katmanındaki nöronların değerlerine bakılarak giriş katmanı uygulanan Doppler parametrelerinin obezite hastalığına işaret edip etmediği

anlaşılabilir. Her hastadan elde edilen Karotid arter Doppler parametreleri rastgele olarak giriş katmanındaki nöronlara uygulanarak sinir ağı aktive edilir.



Şekil 3.1. Doppler işaretlerinden ÇKA Ağına uygulanması

Sinir ağının Karotid arterlere ait Doppler parametrelerini sınıflandırması sonucu elde edilen sonuçlar diğer bir yapay sinir ağı olan Jordan Elman Ağları ile karşılaştırılarak sınıflama başarısı ölçülecektir.



Şekil 3.2. ÇKA Öğrenme Eğrisi

71 örnek üzerinde 100 eğitime adımı sonucunda, elde edilen öğrenme eğrisi Şekil 3.2’de görülmektedir. Bu grafiğe göre; eğitim kümesi için ortalama karesel hata (OKH) zamanla azalarak 0,00555 değerine ulaşmaktadır. Çizelge 3.4’deki sonuçlar da bu grafiği doğrulamaktadır.

Çizelge 3.4. Eğitim en iyi değerleri

En iyi Ağ	Eğitim
Adım Sayısı #	22
Minimum OKH	0.00555
Son OKH	0.00555

Çizelge 3.5’de görüldüğü gibi normal ve obezite sınıflanmasında, normali sınıflandırmada on tanesini doğru, iki tanesini yanlış ve obeziteyi sınıflandırmada 21 tanesini doğru, iki tanesini yanlış olarak sınıflandırılmıştır.

Çizelge 3.5. Test sonuçlarının sınıflama tablosu

Çıkış \ Beklenen	Normal	Obezite
Normal	10	2
Obezite	2	22

Çizelge 3.6'daki test performans sonuçları incelendiğinde, OKH ve r değerleri yaklaşık olarak birbirlerine eşit, r değerleri daha yüksek olduğundan sınıflandırmada bir fark görülmemektedir.


Çizelge 3.6. ÇKA Ağının Sınıflandırma Performansı sonuçları

Performans	Normal	Obezite
OKH	0.062622599	0.064133524
DOKH	0.281801695	0.288600856
OMH	0.127499051	0.130042773
Minimum Mutlak Hata	0.002241906	0.001424125
Maksimum Mutlak Hata	0.850829132	0.86155305
Korelasyon Katsayısı (r)	0.848943922	0.8453131

Çizelge 3.7. İstatistiksel analiz

İstatistik Tipi	Sınıflama
Belirlilik (DPO)	83.33
Duyarlılık (DNO)	91.67
Doğru Sınıflama	88.57


Çok katmanlı algılayıcının tahmin kabiliyetini göstermek için test sonucu çıkış verileri analiz edilerek ROC eğrisi ortaya çıkarılır. Ayrıca ROC eğrisi altında kalan alan da hesaplanarak sinir ağının performansı ölçülebilir. Bu değer 1'e ne kadar yakınsa, çalışma o oranda başarılı demektir. ROC eğrisi altında kalan alan 0,886'dır. Şekil 3.3'de gösterilen ROC eğrisi ÇKA ile yapılan çalışmanın başarısını göstermektedir.




Şekil 3.3. ÇKA ROC analizi

3.2.2. Jordan Elman ağı analizine ait bulgular

Şekil 3.4'te Jordan-Elman sinir ağında kullanılan giriş katmanı altı, çıkış katmanı iki düğümden oluşmaktadır. 71 örnek üzerinde 100 eğitime adımı sonucunda, elde edilen öğrenme eğrisi Şekil 3.5'te görülmektedir. Bu grafiğe göre; eğitim kümesi için ortalama karesel hata (OKH) zamanla azalarak 0,00933 değerine ulaşmaktadır. Çizelge 3.8'deki sonuçlar da bu grafiği doğrulamaktadır.



Şekil 3.4. Doppler işaretlerinin Jordan Elman ağına uygulanması



Şekil 3.5. Jordan-Elman Öğrenme Eğrisi

Çizelge 3.8. Eğitim en iyi değerleri

En iyi Ağ	Eğitim
Adım Sayısı #	64
Minimum OKH	0.00933
Son OKH	0.00933

Çizelge 3.9’da görüldüğü gibi normal ve obezite sınıflanmasında, normali sınıflandırmada on bir tanesini doğru, bir tanesi yanlış ve obeziteyi sınıflandırmada 22 tanesini doğru, bir tanesini yanlış olarak sınıflandırılmıştır.

Çizelge 3.9. Test sonuçlarının sınıflama tablosu

Çıkış \ Beklenen	Normal	Obezite
Normal	11	1
Obezite	1	23

Çizelge 3.10’deki test performans sonuçları incelendiğinde, OKH ve r değerleri yaklaşık olarak birbirlerine eşit, r değerleri daha yüksek olduğundan sınıflandırmada bir fark görülmemektedir.


Çizelge 3.10. ÇKA Ağının Sınıflandırma Performansı sonuçları

Performans	Normal	Obezite
OKH	0.04819991	0.051068521
DOKH	0.216899594	0.229808343
OMH	0.124508109	0.13032748
Minimum Mutlak Hata	0.006188291	0.007877218
Maksimum Mutlak Hata	0.693078235	0.731107338
Korelasyon Katsayısı (r)	0.885513448	0.878077916

Çizelge 3.11. İstatistiksel analiz

İstatistik Tipi	Sınıflama
Belirlilik (DPO)	91.67
Duyarlılık (DNO)	95.83
Doğru Sınıflama	94.28

Jordan Elman ağının tahmin kabiliyetini göstermek için test sonucu çıkış verileri analiz edilerek ROC eğrisi ortaya çıkarılır. Ayrıca ROC eğrisi altında kalan alan da hesaplanarak sinir ağının performansı ölçülmüştür. ROC eğrisi altında kalan alan 0,943'tür. Şekil 3.6'da gösterilen ROC eğrisi Jordan – Elman ile yapılan çalışmanın başarısını göstermektedir.



Şekil 3.6. Jordan Elman ROC analizi

4. TARTIŞMA VE SONUÇ

Bu çalışmada sağ ve sol AKA ve IKA sistol, diyastol, lümen çapları, intima media kalınlıkları, akış hızları ultrasonografik Doppler ile algılanmıştır. Doppler işaretleri öncelikle anlamlılık testine sokulmuştur. Anlamlı ölçüde farklı bulunan veriler altı tane olup bunlar Çok katmanlı algılayıcılar ve Jordan – Elman Yapay sinir ağları ile sınıflandırma çalışmalarında yüksek doğru sınıflama başarısı göstermiştir. Çok katmanlı Algılayıcılar Tıbbi verileri sınıflandırmada başarı oranı %90'ın altında kalmıştır. Jordan – Elman yöntemi ise gizli katmanın ve çıkışların girişe etki etmesi sayesinde verilerin az olmasına rağmen %95'e yakın bir sonuç elde edilmiştir.

Çok katmanlı Algılayıcılar tıbbi verileri sınıflandırmada en çok kullanılan yapay sinir ağı yöntemidir. Fakat giriş verilerinin az olması sebebiyle başarı oranı %88'de kalmıştır. Fakat sınıflamalarda en az %90 başarı beklenir ve %95'in üstüne çıkması yöntemine önemli bir avantaj getirir.

Jordan – Elman yöntemi ise gizli katmanın ve çıkışların bağlam katmanına dönmesi ve bağlam katmanının giriş katmanı ile birlikte etki etmesi sayesinde verilerin az olmasına rağmen %95'e yakın bir sonuç elde edilmiştir.

Jordan – Elman yöntemi ayrıca bir katmana sahip olduğu için diğer ağlara göre daha yavaş çalışmaktadır. Bu bir dezavantajdır. Fakat parametre sayısının azalması durumunda diğer yapay sinir ağları modellerine göre daha yüksek doğruluk oranı sağlamaktadır. Bu çalışmada Jordan-Elman yönteminin başarısı %94 olmuştur. MLP ile karşılaştırınca Jordan – Elman yönteminin başarısı önemlidir.

Yapay Sinir Ağları birçok çalışmada kullanılmaktadır. Henüz tıp alanında belirli bir yöntem sürekli kullanılmamakla beraber en çok kullanılan yöntem Çok

Katmanlı Algılayıcılarıdır. Sinir ağlarının performansını veri boyutu ve eğitimi için seçilen parametreler etkili olduğu için bu çalışmada Çok Katmanlı Algılayıcıların performansı düşük kalmıştır. Tersine Jordan-Elman yönteminin performansı yüksek çıkmıştır.

İleriki çalışmalarda Çok Katmanlı Algılayıcıların performansı düşük olduğu durumlarda Jordan – Elman yöntemi bir alternatif olabilir.

KAYNAKLAR

1. G. Gardner, B. Halweil, World Watch; **13**; 25 (2000).
2. S. Jelic, M. N. Bartels, J. H. Mateika, P. Ngai, R.E. DeMeersman, R. C. Basner, Sleep; **25**; 850 (2002).
3. J.E. Hall, Hypertension; **41**; 625 (2003).
4. M. Eliasziw, R.N. Rankin, A. J. Fox, R. B. Haynes, H. J. Barnett; Stroke; **26**; 1747 (1995).
5. R. J. Wityk, D. Lehman, M. Klag, J. Coresh, H. Ahn, B. Litt; Stroke; **27**; 1974 (1996).
6. S. Satomura, Journal of Acoustical Society of Japan; **15**; 151 (1959).
7. I. Edler, Ultrasound in Medicine and Biology, **17 (5)**: 425 (1991).
8. W.S. McCulloch and W.A. Pitts, Bulletin of Mathematical Biology, **5**, 115, (1943).
9. D. O. Hebb, The Organization of Behavior, New York: Holt, 1949.
10. T. Kohonen, IEEE Transaction on Computers, **C-21(4)**, 353 (1972).
11. P. J. Werbos, Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences. PhD thesis, Harvard University, (1974).
12. S. Grossberg, Cognitive Science, **11**, 23 (1987).
13. T Kohonen, Biological Cybernetics, **43**, 59, (1982).
14. J. .J. Hopfield, Proc. Natl Acad. Sci., **79**, 2554, (1982).
15. J. McLelland, D.E. Rumelhart, Parallel Distributed Processing, MIT Press, 1986.
16. D. H. Ackley, G.E. Hinton, T.J. Sejnowski, Cognitive Science, **9**, 147 (1985).
17. D. B. Parker, Center for Computational Res. in Economics and Management Sci., MIT Cambridge, TR-47 (1985).
18. DS Broomhead and D. Lowe, Complex Systems, **vol. 2**, 321(1988).

19. DF Specht, Neural Networks, 1988., IEEE International Conference on, **vol. 1**, 525 (1988).
20. DF Specht, IEEE Trans Neural Netw, **2(6)**, 568 (1991).
21. S. Haykin, "Neural Networks: A Comprehensive Foundation", Macmillan College Publishing Company, New York, 1 (1994).
22. W. G. Baxt, Lancet, **346**, 1135 (1995).
23. R.V. Freeman, K.A. Eagle, E.R. Bates, S.W. Werns, E. Kline, American Heart Journal, **140(3)**, 511 (2000).
24. MS Beksaç, F Başaran, S Eskiizmirliler, AM Erkmen, European Journal of Obstetrics and Gynecology, **64 (1)**, 37 (1996).
25. I.A. Wright, N.A. Gough, F. Rakebrandt, M. Wahab, J.P. Woodcock, Ultrasound Med Biol, **23(5)**, 683 (1997).
26. U. Ergün, F. Hardalaç, İ. Güler, Biyomedikal Mühendisliği Ulusal Toplantısı Biyomut 2002, İstanbul, 111 (2002).
27. N. Barışçı, U. Ergün, E. İlkay, S. Serhatlioğlu, F. Hardalaç, İ. Güler, Journal of Medical Systems, **28 (5)**: 423, 2004.
28. U. Ergün, S. Serhatlioglu, F. Hardalaç, İ. Güler, Computers in Biology and Medicine, **34**, 389 (2004).
29. H. Özdemir, H. Artaş, S. Serhatlioğlu, E. Oğur, Diagn Interv Radiol, **12**, 142 (2006).
30. İ. Güler, F. Hardalaç, S. Müldür, Computers in Biology and Medicine, **31**, 229 (2001).
31. D. L. Franklin, W. A. Schlegel, N. W. Watson, Biomedical Science Instrumentation, **1**, 301 (1963).
32. F.S. Schlindwein, M.J. Smith, D.H. Evans, Medical & Biological Engineering Computing, **26**, 228 (1988).
33. Y.L. Larry, S.C. Richard, IEEE Transactions On Ultrasonics Ferroelectrics and Frequency Control, **2**, 522 (1989).
34. I.A. Basheer, M. Hajmeer, Journal of Microbiological Methods, **43**, 3 (2000).

35. N. Barışçı, Kardiyak Doppler İşaretlerinin Yapay Sinir Ağı ve Nefclass İle Sınıflandırılması, Doktora tezi, Gazi Üniversitesi, Ankara (2005).
36. E., Tafeit, G., Reibnegger, Clinical Chemistry and Laboratory Medicine, **37 (9)**, 845 (1999).
37. C.P., Lim, R.F., Harrison, R.L., Kennedy, Artificial Intelligence in Medicine, **11**, 215 (1997).
38. W. G. Baxt, Neural Computation, **2**, 480 (1990).
39. J., Allen, A., Murray, Physiological Measurement, **14**, 13 (1993).
40. J., Allen, A., Murray, Physiological Measurement, **16**, 39 (1995).
41. R. Williams, Addison–Wesley, 1–212 (1989).
42. J. Ryu, S.B. Cho - International Joint Conference on Neural Networks (2002)
43. S. W. K Cheng, L. L. H. Wu, A. C. W. Ting, H. Lau, L. K. Lam, W. I. Wei, The American Journal of Surgery, **178**, 323 (1999).
44. Anderson, JA. Rosenfels, E. MIT Press, Cambridge, 147 (1998).
45. H. Akpınar, Yapay sinir ağları ve kredi taleplerinin değerlendirilmesinde bir uygulama önerisi, Doktora tezi, İstanbul Üniversitesi İşletme Fakültesi Sayısal Yöntemler Ana Bilim Dalı, İstanbul, 13 (1993).
46. U. Ergün, Transcranial Doppler İşaretlerinin Yapay Zeka Ortamında Sınıflandırılması, Doktora tezi, Gazi Üniversitesi, Ankara (2005).
47. E. Ayaz, S. Seker, B. Barut E. Turkcan, Progress in Nuclear Energy, **43(1–4)**, 381, (2003)
48. J.A. Hanley, B.J. McNeil, Radiology, **143**, 29 (1982).