

T.C
SELÇUK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DOPPLER İŞARETLERİNİN KAOTİK ÖLÇÜTLERLE
SINIFLANDIRILMASI

Ali ÖZTÜRK

DOKTORA TEZİ

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Konya, 2008

ÖZET

Doktora Tezi

DOPPLER İŞARETLERİNİN KAOTİK ÖLÇÜTLERLE SINIFLANDIRILMASI

Ali ÖZTÜRK

Selçuk Üniversitesi Fen Bilimleri Enstitüsü

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Ahmet ARSLAN

2008, 171 Sayfa

Bu tez çalışmasında, Transcranial Doppler (TCD) sinyallerini kaotik ölçütlerle otomatik olarak sınıflandırmak için kullanılabilecek yeni bir yaklaşım önerilmiştir. TCD sinyalleri 82 hasta ve 23 sağlıklı bireyin beyinlerinin temporal bölgesinden kaydedilmiştir. Tanının doğrulanması için TCD sinyallerine ait sonogramlar birbirleriyle ve manyetik rezosans görüntüleme kayıtlarıyla karşılaştırılmıştır. 82 hastanın, 20 tanesinde beyin damarında balonlaşma, 10 tanesinde beyin kanaması, 22 tanesinde beyinde su toplama ve geri kalan 30 tanesinde beyin tümörü tespit edilmiştir. Yapay veriler yöntemiyle yapılan doğrusalsızlık testleri TCD sinyallerinin doğrusal stokastik süreçle üretildiğine dair hükümsüz hipotezi reddetmektedir. Durağanlık analizleri, TCD sinyallerinin sinüs sinyali gibi tam deterministik sinyallerle rasgele sinyaller arasında bir dinamik durağanlığa sahip olduğunu göstermektedir. Sinyallere ait kaotik çekicilerin faz uzayında doğru biçimde yeniden oluşturulması için gerekli olan zaman gecikmesi ve en küçük gömülme boyutu değerleri elde edilmiştir. Bu verilerle, TCD sinyallerine ait kaotik çekiciler faz uzayında yeniden oluşturularak en büyük Lyapunov üsteli ve ilinti boyutu hesaplanmıştır. Kaosun en güçlü nicel göstergesi olan en büyük Lyapunov üsteli tüm TCD sinyalleri için pozitif bulunmuştur. İlinti boyutu da, yine tüm TCD sinyalleri için 2'den büyük ve kesirli olarak bulunmuştur. Burg autoregressive (AR) yönteminin TCD sinyallerine uygulanmasıyla elde edilen sonogramlar incelendiğinde, kaotik ölçütlerin TCD sinyallerinin tahmin edilemezlik ve karmaşıklık seviyesini gösterdiği tespit edilmiştir. Sonogram ne kadar periyodik ve düzenli ise, en büyük Lyapunov üstelinin değeri o kadar düşük olmaktadır. Benzer şekilde, sonogram karmaşıklıkla ilinti boyutunun değeri yükselmektedir.

Elde edilen kaotik ölçütler çeşitli sınıflandırma algoritmalarına uygulanarak performansları karşılaştırılmıştır. Bunun için, yapay sinir ağı bulanık sistemlerden ANFIS ve NEFCLASS yöntemleri ile Karar Ağacı, k-En Yakın Komşu ve Çok Katmanlı Algılayıcı Sinir Ağı algoritmaları incelenmiştir. Elde edilen sonuçlara göre, kaotik ölçütlerin özellik olarak çıkarıldığı önişleme algoritması ile Çok Katmanlı Algılayıcı Sinir Ağını birleştiren yöntem, incelenen beyin rahatsızlıklarını en yüksek doğruluk oranıyla sınıflandırmıştır.

Karşılaştırma amacıyla, sınıflandırma algoritmalarının performansları doğrusal bir yöntem olan güç spektrum yoğunluğu kestirimi yöntemi ile elde edilen spektral parametrelerle de test edilmiştir. Kaotik ölçütlerin, spektral özelliklere göre daha yüksek sınıflandırma doğruluğu sağladığı gözlenmiştir.

Anahtar Kelimeler: Transcranial Doppler, kaos teorisi, doğrusal olmayan analiz, kaotik ölçütler, sınıflandırma, ANFIS, NEFCLASS, Karar Ağacı, k-En Yakın Komşu, Çok Katmanlı Algılayıcı Sinir Ağı.

ABSTRACT

Ph.D. Thesis

CLASSIFICATION OF DOPPLER SIGNALS USING CHAOTIC MEASURES

Ali ÖZTÜRK

Selçuk University

Graduate School of Natural and Applied Sciences

Department of Electrical-Electronics Engineering

Supervisor: Prof. Dr. Ahmet ARSLAN

2008, 171 Pages

In this thesis study, a new approach to classify the Transcranial Doppler (TCD) signals with their chaotic invariant measures was proposed. The TCD signals were recorded from the temporal region of the brain on 82 patients and 23 healthy people. The sonograms of the TCD signals were compared with each other and also with the magnetic resonance imaging (MRI) records for verification of the diagnosis. Among 82 patients, 20 of them had cerebral aneurysm, 10 patients had brain hemorrhage, 22 patients had cerebral oedema and the remaining 30 patients had brain tumour. The result of the surrogate data test applied to each TCD signal rejected the null hypothesis that the signal was generated by a linear Gaussian stochastic process. According to the stationarity analysis, the dynamical stationarity of the TCD signals lies between the purely deterministic and the stochastic signals. The time delay and minimal embedding dimension which are crucial values to reconstruct the chaotic attractor in phase space were calculated for each signal. The maximum Lyapunov exponent which is the strongest quantitative indicator of chaos was found as positive for all the TCD signals. The correlation dimension was found as greater than 2 and fractional for all the TCD signals. The sonograms obtained by applying the Burg autoregressive (AR) method to the TCD signals showed that these two chaotic invariant measures represented the unpredictability and complexity levels of the TCD signals. The more periodic and uniform the sonogram the lower the maximum Lyapunov exponent, whereas the more complex the sonogram the higher the correlation dimension.

For comparison purposes, the classification performance of two different neuro-fuzzy methods, namely ANFIS and NEFCLASS as well as Decision Trees, k-Nearest Neighbour and Multilayer Perceptron Neural Network were

investigated. According to the results, the proposed method which combines the chaotic invariant feature extraction algorithm as the preprocessing step and the Multilayer Perceptron Neural Network as the classifier has the highest classification accuracy in detecting the blood flow velocity changes due to various brain diseases.

The spectral parameters obtained via power spectrum density estimation were also applied to the classifiers in order to observe their performance against the features extracted with linear methods, The results suggested that the chaotic measures provide better classification performance than the spectral features.

Keywords: Transcranial Doppler, chaos theory, nonlinear analysis, chaotic measures, classification, ANFIS, NEFCLASS, Decision Trees, k-Nearest Neighbour, Multilayer Perceptron Neural Network.

ÖNSÖZ

Çalışmalarım boyunca ilgi ve bilimsel katkılarıyla beni yönlendiren tez danışmanım Selçuk Üniversitesi Bilgisayar Mühendisliği Bölüm Başkanı sayın Prof. Dr. Ahmet ARSLAN'a, belirttiği görüşler ve önerilerle tezin yönlenmesinde yardımcı olan Gazi Üniversitesi Bilgisayar Mühendisliği Bölüm Başkanı sayın Doç. Dr. Şeref SAĞIROĞLU'na, tezin içeriğine yönelik önemli yapıcı eleştirilerinden dolayı Selçuk Üniversitesi Bilgisayar Mühendisliği Bölümü öğretim üyesi sayın Prof. Dr. Şirzat KAHRAMANLI'ya ve verdiği her türlü destekten dolayı Selçuk Üniversitesi Elektrik-Elektronik Mühendisliği Bölüm Başkanı sayın Prof. Dr. Mehmet BAYRAK'a teşekkürlerimi sunarım.

Ayrıca çalışmalarım sırasında maddi ve manevi desteğini hiçbir zaman esirgemeyen anne ve babama, tezimle ilgili yaptıklarımı büyük bir merak ve ilgiyle dinleyen, iyi dileklerle yanımda olan bütün arkadaşlarıma teşekkür ederim.

İÇİNDEKİLER

ÖZET	iii
ABSTRACT	v
ÖNSÖZ	vii
İÇİNDEKİLER	viii
SİMGELER	x
ŞEKİLLER	xiii
ÇİZELGELER	xviii
1. GİRİŞ	1
2. KAYNAK ARAŞTIRMASI	8
2.1. Kaos Teorisi Yöntemlerinin Kısa Süreli Tahminde Kullanımı	8
2.2. Kaotik Ölçütlerle Dinamik Sistemdeki Değişim Arasındaki İlişkinin Araştırılması	11
2.3. Biyomedikal Sinyallerin Otomatik Sınıflandırılması	17
3. MATERYAL VE METOT	21
3.1. TCD Sinyallerinin Elde Edilmesinde Kullanılan Sistemin Donanımı	21
3.1.1. Transcranial Doppler İnceleme Tekniği	21
3.2. Kaos Teorisi ve Yöntemleri	23
3.2.1. Kaos Teorisi	23
3.2.2. Doğrusalsızlık Analizi	25
3.2.3. Durağanlık Analizi	32
3.2.4. Çekicinin Yeniden Oluşturulması	36
3.2.5. Zaman Gecikmesinin Seçilmesi	37
3.2.6. En Düşük Gömülme Boyutunun (Embedding Dimension - D_E) Bulunması	40
3.2.7. İlinti Boyutu	43
3.2.8. Lyapunov Üstelleri	46
3.3. Sınıflandırmada Kullanılan Yöntemler	50
3.3.1. Bulanık Çıkarım Sistemleri	50
3.3.2. Yapay Sinir Ağılı Bulanık Sistemler	53
3.3.2. NEFCLASS Modeli	55
3.3.3. Adaptif Yapay Sinir Ağılı Bulanık Mantık Çıkarım Sistemi (Adaptive Neuro Fuzzy Inference System - ANFIS)	63
3.3.4. Karar Ağaçları	68

3.3.5. En Yakın Komşu (EYK) Algoritması.....	74
3.3.6. Çok Katmanlı Algılayıcı (ÇKA) Sinir Ağları	76
3.4. TCD Sonogramlarından Spektral Parametrelerin Elde Edilmesi	85
3.5. İstatistiksel Analiz Yöntemleri.....	88
3.5.1. Çoklu Doğrusal Regresyon.....	88
3.5.2. Bland-Altman Çizimleri	88
3.5.3. Alıcı Çalışma Karakteristiği (Receiver Operating Characteristic - ROC) Eğrileri	89
4. ARAŞTIRMA SONUÇLARI ve TARTIŞMA.....	91
4.1. TCD Sinyallerinin Doğrusal Olmadığının Tespit Edilmesi.....	95
4.2. TCD Sinyallerinin Durağanlık Analizi	100
4.3. Kaotik Çekicilerin Yeniden Oluşturulması	112
4.4. Zaman Gecikmesi ve En Düşük Gömülme Boyutu Değerlerinin Hesaplanması.....	114
4.3. İlinti Boyutunun Hesaplanması	119
4.4. En Büyük Lyapunov Üstelinin Hesaplanması.....	122
4.5. Sınıflandırma Sonuçları	127
4.5.1. NEFCLASS İle Bulunan Sonuçlar	129
4.5.2. ANFIS İle Bulunan Sonuçlar	135
4.5.3. Karar Ağacı İle Bulunan Sonuçlar	141
4.5.4. K En Yakın Komşu Algoritması ile Bulunan Sonuçlar	145
4.5.5. Çok Katmanlı Algılayıcı Sinir Ağı (ÇKASA) ile Bulunan Sonuçlar	149
4.6. Sınıflandırma Algoritmalarının ROC Eğrileri ile Karşılaştırılması.....	153
5. SONUÇ.....	155
6. KAYNAKLAR	164

SİMGELER

Simgeler	Açıklama
$\ \dots\ $	Öklid Uzaklığı
$\{a_i, b_i, c_i\}$	Öncül ANFIS parametreleri
$\{p_i, q_i, r_i\}$	Sonuç ANFIS parametreleri
a_R	R kural düğümünün aktivasyon değeri
a_c	c çıkış düğümünün aktivasyon değeri
C4.5	Gelişmiş ID3 Algoritması
C_ε	İlinti integrali
$C_L(\tau)$	Doğrusal öz ilinti fonksiyonu
$d(x_i, x_j)$	x_i ve x_j noktaları arasındaki uzaklık
D_2	İlinti Boyutu
D_A	Çekici Boyutu
D_E	Gömülme Boyutu
E	Ortalama kare hata değeri
ε	İlinti boyutunun hesaplanmasında kullanılan hacmin yarıçapı
Θ	Heaviside fonksiyonu
Hz	Hertz
ID3	Karar Ağacı Oluşturma Algoritması
$I(\tau)$	Karşılıklı Bilgi Değeri
$\lambda(i)$	i. Lyapunov üsteli
λ_1	En Büyük Lyapunov üsteli
$\mu_A(x)$	x girişinin bulanık üyelik fonksiyonu değeri
MHz	Megahertz
O_i	i. düğümün çıkış değeri
τ	Zaman gecikmesi
$\delta_{x(t)}$	Komşu yörüngeler arasındaki uzaklık
SF	Gerilme Faktörü
x	Giriş düğümü
y	Çıkış değeri
w	Bağlantı ağırlıkları

$W(x, R)$	x giriş düğümü ile R kural düğümü arasındaki bulanık ağırlık
$W(R, c)$	R kural düğümü ile c çıkış düğümü arasındaki ağırlık

Kısaltmalar Açıklama

ANFIS	Adaptive Neuro Fuzzy Inference System
ANOVA	Analysis of Variance
AR	Autoregressive
ARMA	Autoregressive Moving Average
ASABÇS	Adaptif Sinir Ağı Bulanık Çıkarım Sistemi
AV	Atrioventriküler
BIH	Beth Israel Hospital
CTM	Central Tendency Measure
ÇKASA	Çok Katmanlı Algılayıcı Sinir Ağı
DN	Doğru Negatif
DP	Doğru Pozitif
DSH	Diyastol Sonu Hız
ECG	Electrocardiogram
EEG	Electroencephalogram
EYK	En Yakın Komşu
FNN	False Nearest Neighbours
G-P	Grassberger-Procaccia
HFD	Hızlı Fourier Dönüşümü
IAAFT	Iterative Amplitude Adjusted Fourier Transform
ICA	Internal Carotid Arter
MIT	Massachusetts Institute of Technology
NEFCLASS	Neuro Fuzzy Classification
Pİ	Darbe (Pulsatilité) İndeksi
PSH	Pik Sistolik Hız
RDS	Respiratory Distress Syndrome
R-R	ECG sinyalindeki R tepeleri
Rİ	Direnç (Rezistans) İndeksi
ROC	Receiver Operating Characteristics

SA	Sinoatrial
SAH	Subarachnoid Hemorrhage
S/D	Sistol/Diyastol Oranı
TCD	Transcranial Doppler
YP	Yanlış Pozitif
YN	Yanlış Negatif

ŞEKİLLER

Şekil 1.1. Beyin loblarının genel görünümü	1
Şekil 3.1. Orijinal zaman dizisi ve bu dizinin ilk ve son nokta değerlerinin birbirinden çok farklı olması durumunda üretilen yapay zaman dizisi.....	28
Şekil 3.2. Orijinal zaman dizisi ve bu dizinin ilk ve son nokta değerlerinin birbirine yakın olması durumunda üretilen yapay zaman dizisi	29
Şekil 3.3. Yapay veri yöntemi.....	29
Şekil 3.4. N=40,000 veriden oluşan Baker haritası zaman dizisi için köşegensel çapraz tahmin hataları	34
Şekil 3.5. Baker haritası kaotik zaman dizisi için durağanlık resmi	35
Şekil 3.6. C_g değerinin hesaplanması	44
Şekil 3.7. Lyapunov üstelinin hesaplanması	48
Şekil 3.8. Bulanık Çıkarım Sistemi.....	51
Şekil 3.9. Bulanık EĞER-O HALDE kuralları ve bulanık akıl yürütme yöntemleri	52
Şekil 3.10. 2 giriş, 5 kural ve 2 çıkış düğümü olan bir NEFCLASS sistemi	56
Şekil 3.11. Kural Öğrenme Algoritması sonucunda oluşan sınıflandırma.....	59
Şekil 3.12. Bulanık kümelerin adaptasyonu.....	61
Şekil 3.13. Bulanık kümelerin adaptasyonu sonrasında oluşan sınıflandırma.....	62
Şekil 3.14. (a) Sugeno (Tür-3) bulanık mantık modeli (b) Buna karşılık gelen ANFIS yapısı	64
Şekil 3.15. (a) Tür-1 bulanık mantık modeli (b) Buna karşılık gelen ANFIS yapısı.	67
Şekil 3.16. (a) 2 Girişli 9 Kurallı Tür-3 ANFIS (b) İlgili Bulanık Alt Uzaylar	67
Şekil 3.17. Örnek bir karar ağacı	68
Şekil 3.18. Karar Ağaçlarında Aşırı Öğrenme (Overfitting) Durumu	73
Şekil 3.19. Karar Ağaçlarında Budama (Pruning) işlemi sonucu test verilerindeki doğruluğun artması	73
Şekil 3.20. Direnç (Rezistans) İndisi (RI) ve Darbe (Pulsatilité) İndisi (PI) değerlerinin hesaplanmasında kullanılan değişkenler.....	85
Şekil 4.1. Her bir hasta grubu ve sağlıklı birey grubu için elde edilen örnek Doppler sonogramları (a) Beyin damarında balonlaşma (b) Beyin kanaması (c) Beyinde su toplama (d) Beyin tümörü (e) Sağlıklı	92
Şekil 4.2. Beyin Damarında Balonlaşma Olan Bir Hastadan Alınan TCD Sinyali ...	95

Şekil 4.3. Beyin damarında balonlaşmalı bir hastanın TCD sinyalinin IAAFT yöntemi ile üretilmiş örnek yapay zaman dizileri	95
Şekil 4.4. Sinüs sinyali	97
Şekil 4.5. Sinüs sinyali için üretilen örnek yapay zaman dizileri	98
Şekil 4.6. Gauss dağılımına uyan rasgele sayılardan oluşan zaman dizisi.....	99
Şekil 4.7. Gauss dağılımına uyan rasgele zaman dizisi için üretilen örnek yapay zaman dizileri	99
Şekil 4.8. Beyin damarında balonlaşma olan bir hasta için durağanlık analizi.....	101
Şekil 4.9. Ikeda ve Henon haritaları ile beyin damarında balonlaşma olan bir hastanın TCD sinyalinin köşegensel çapraz tahmin hatalarının karşılaştırılması	102
Şekil 4.10. Ikeda ve Henon haritası verilerinin köşegensel çapraz tahmin hataları için Bland-Altman çizimi.....	102
Şekil 4.11. Beyin damarında balonlaşma olan hastaların köşegensel çapraz tahmin hataları.....	103
Şekil 4.12. Beyin kanamalı hastaların çapraz tahmin hataları	104
Şekil 4.13. Beyinde su toplamalı hastaların çapraz tahmin hataları	104
Şekil 4.14. Beyin tümörlü hastaların çapraz tahmin hataları	105
Şekil 4.15. Sağlıklı bireylerin çapraz tahmin hataları	105
Şekil 4.16. TCD, sinüs ve rasgele sinyallerinin çapraz tahmin hata değerlerinin karşılaştırılması	106
Şekil 4.17. Beyin damarında balonlaşma olan bir hastanın TCD sinyaline ait yineleme çizimi (REC=0.236886, DET=0.400897, ENT=1.0595, TREND=2.50995)	107
Şekil 4.18. Beyin kanamalı bir hastanın TCD sinyaline ait yineleme çizimi (REC=0.175948, DET=0.508334, ENT=0.955506, TREND=2.68942)	107
Şekil 4.19. Sağlıklı bireyin TCD sinyaline ait yineleme çizimi (REC=0.14899, DET=0.330671, ENT=0.650027, TREND=2.40626).....	108
Şekil 4.20. Beyinde su toplama olan bir hastanın TCD sinyaline ait yineleme çizimi (REC=0.23728, DET=0.496309, ENT=1.49789, TREND=3.18693)	108
Şekil 4.21. Beyin tümörlü bir hastanın TCD sinyaline ait yineleme çizimi (REC=0.268756, DET=0.798428, ENT=1.66949, TREND=4.1864)	109

Şekil 4.22. Beyin damarında balonlaşma olan bir hastanın TCD sinyaline ait uzay-zaman ayrımı çizimi (w=25)	109
Şekil 4.23. Beyin kanamalı bir hastanın TCD sinyaline ait uzay-zaman ayrımı çizimi (w=35)	110
Şekil 4.24. Sağlıklı bir bireyin TCD sinyaline ait uzay-zaman ayrımı çizimi (w=20)	110
Şekil 4.25. Beyinde su toplamalı bir hastanın TCD sinyaline ait uzay-zaman ayrımı çizimi (w=50)	111
Şekil 4.26. Beyin tümörlü bir hastanın TCD sinyaline ait uzay-zaman ayrımı çizimi (w=40)	111
Şekil 4.27. Beyin damarında balonlaşma olan bir hasta için elde edilen kaotik çekiciler (a) 2 boyutlu faz uzayında 1 adımlık zaman gecikmesi ile (b) 3 boyutlu faz uzayında 1 adımlık zaman gecikmesi ile	112
Şekil 4.28. Beyin kanamalı bir hasta için elde edilen kaotik çekiciler (a) 2 boyutlu faz uzayında 1 adımlık zaman gecikmesi ile (b) 3 boyutlu faz uzayında 1 adımlık zaman gecikmesi ile	112
Şekil 4.29. Sağlıklı bir birey için elde edilen kaotik çekiciler (a) 2 boyutlu faz uzayında 1 adımlık zaman gecikmesi ile (b) 3 boyutlu faz uzayında 1 adımlık zaman gecikmesi ile	113
Şekil 4.30. Beyinde su toplamalı bir hasta için elde edilen kaotik çekiciler (a) 2 boyutlu faz uzayında 1 adımlık zaman gecikmesi ile (b) 3 boyutlu faz uzayında 1 adımlık zaman gecikmesi ile	113
Şekil 4.31. Beyin tümörlü bir hasta için elde edilen kaotik çekiciler (a) 2 boyutlu faz uzayında 1 adımlık zaman gecikmesi ile (b) 3 boyutlu faz uzayında 1 adımlık zaman gecikmesi ile	113
Şekil 4.32. Beyin damarında balonlaşma olan bazı hastalar için bulunan zaman gecikmesi değerleri	114
Şekil 4.33. Beyin damarında balonlaşma olan bazı hastalar için bulunan en düşük gömülme boyutu değerleri	115
Şekil 4.34. Beyin kanamalı bazı hastalar için bulunan zaman gecikmesi değerleri	115
Şekil 4.35. Beyin kanamalı bazı hastalar için bulunan en düşük gömülme boyutu değerleri	116

Şekil 4.36. Bazı sağlıklı bireyler için bulunan zaman gecikmesi değerleri	116
Şekil 4.37. Bazı sağlıklı bireyler için bulunan en düşük gömülme boyutu değerleri	117
Şekil 4.38. Beyinde su toplamalı bazı hastalar için bulunan zaman gecikmesi değerleri	117
Şekil 4.39. Beyinde su toplamalı bazı hastalar için bulunan en düşük gömülme boyutu değerleri	118
Şekil 4.40. Beyin tümörlü bazı hastalar için bulunan zaman gecikmesi değerleri ..	118
Şekil 4.41. Beyin tümörü olan bazı hastalar için bulunan en düşük gömülme boyutu değerleri	119
Şekil 4.42. Farklı hastalık grupları için Cao yöntemiyle en düşük gömülme boyutlarının hesaplanması.....	119
Şekil 4.43. Beyin damarında balonlaşma olan bir hasta için ilinti boyutunun hesaplanması	120
Şekil 4.44. Beyin kanaması olan bir hasta için ilinti boyutunun hesaplanması	120
Şekil 4.45. Beyinde su toplama olan bir hasta için ilinti boyutunun hesaplanması ..	121
Şekil 4.46. Beyinde tümörü bir hasta için ilinti boyutunun hesaplanması.....	121
Şekil 4.47. Sağlıklı bir birey için ilinti boyutunun hesaplanması	121
Şekil 4.48. Farklı hastalık gruplarından ve sağlıklı gruptan örnek birer birey için bulunan ilinti toplamı $C(m,\epsilon)$ ve ϵ grafikleri a) Balonlaşma b) Kanama c) Su Toplama d) Tümör e) Sağlıklı.....	122
Şekil 4.49. Beyin damarında balonlaşma olan bir hasta için en büyük Lyapunov üstelinin hesaplanması	123
Şekil 4.50. Beyin kanaması olan bir hasta için en büyük Lyapunov üstelinin hesaplanması	124
Şekil 4.51. Beyinde su toplama olan bir hasta için en büyük Lyapunov üstelinin hesaplanması	124
Şekil 4.52. Beyin tümörlü bir hasta için en büyük Lyapunov üstelinin hesaplanması	125
Şekil 4.53. Sağlıklı bir birey için en büyük Lyapunov üstelinin hesaplanması	125
Şekil 4.54. TCD Sinyallerinin Sınıflandırılması Adımları	126

Şekil 4.55. Her hasta grubuna ve sağlıklı birey grubuna ait örnek bir TCD sinyaline ait güç spektrum yoğunluğu kestirimi (a) Beyin damarında balonlaşma (b) Beyin kanaması (c) Beyinde su toplama (d) Beyin tümörü (e) Sağlıklı.....	128
Şekil 4.56. NEFCLASS sistemin 2 girişi için başlangıçtaki bulanık kümeler (a) İlinti boyutu (b) Lyapunov üsteli	131
Şekil 4.57. NEFCLASS sistemin 2 girişi için 1000 adımlık eğitim sonucu oluşan bulanık kümeler (a) İlinti boyutu (b) Lyapunov üsteli.....	132
Şekil 4.58. Eğitim adımlarına karşılık ağ yakınsama hata değerinin gösterimi.....	136
Şekil 4.59. 250 adımlık eğitim işlemi sonucunda 3. kümedeki adet eğitim verisinin ANFIS çıktıları ile eşleştirilmesi.....	136
Şekil 4.60. İlinti boyutuna karşılık gelen giriş değeri için iki-taraflı Gauss eğrisi üyelik fonksiyonunun (a) eğitimden önce (b) eğitimden sonra görünümü.....	137
Şekil 4.61. Lyapunov üsteline karşılık gelen giriş değeri için iki-taraflı Gauss eğrisi üyelik fonksiyonunun (a) eğitimden önce (b) eğitimden sonra görünümü.....	138
Şekil 4.62. ANFIS'in 3. kümedeki test alt kümesi ile değerlendirilmesi.....	138
Şekil 4.63. C4.5 algoritmasının 1. kümedeki eğitim alt kümesini oluşturan kaotik ölçüt verileriyle oluşturduğu Karar Ağacı.....	142
Şekil 4.64. Kullanılan ÇKASA mimarisi.....	149
Şekil 4.65. Sınıflandırma yöntemlerinin performansını gösteren ROC eğrileri (a) ANFIS (b) NEFCLASS (c) Karar Ağacı (d) K-En Yakın Komşu (e) Çok Katmanlı Algılayıcı.....	154
Şekil 5.1. Zaman asimetrisi ölçütü ile yapılan yapay veriler testi sonuçları (a) Balonlaşma (b) Kanama (c) Su Toplama (d) Tümör (e) Sağlıklı.....	157
Şekil 5.2. Üçüncü seviye moment ile yapılan yapay veriler testi sonuçları (a) Kanama (b) Su Toplama.....	158
Şekil 5.3. TCD sinyallerini kaotik ölçütler ile sınıflandıran sistem.....	162

ÇİZELGELER

Çizelge 3.1. Yapay Sinir Ağları ile Bulanık Sistemlerin Avantaj ve Dezavantajları	54
Çizelge 4.1. Tez çalışmasında yararlanılan grubu oluşturan bireylerin genel profili	91
Çizelge 4.2. Farklı birey grupları için kaotik ölçütlerin istatistiği	93
Çizelge 4.3. Beyinde balonlaşma olan bir hasta için doğrusalsızlık analizi	97
Çizelge 4.4. Sinüs sinyali için doğrusalsızlık analizi	98
Çizelge 4.5. Rasgele sayılar zaman dizisi için doğrusalsızlık analizi	100
Çizelge 4.6. Sınıflandırıcıların eğitim ve test işlemlerinde kullanılan veri kümeleri	127
Çizelge 4.7. NEFCLASS için birinci sınıflandırma sonuçları (K.Ö. = Kaotik Ölçütler ve S.P. = Spektral Parametreler)	130
Çizelge 4.8. Kaotik ölçütlerin NEFCLASS ile birinci sınıflandırmada oluşan hata değerleri	130
Çizelge 4.9. Spektral parametrelerin NEFCLASS ile birinci sınıflandırmada oluşan hata değerleri	130
Çizelge 4.10. NEFCLASS sisteminde otomatik budama sonucu oluşan kural tabanı	131
Çizelge 4.11. NEFCLASS için ikinci sınıflandırma sonuçları (K.Ö. = Kaotik Ölçütler ve S.P. = Spektral Parametreler)	132
Çizelge 4.12. Kaotik ölçütlerin NEFCLASS ile ikinci sınıflandırmasında oluşan hata değerleri	133
Çizelge 4.13. Spektral parametrelerin NEFCLASS ile ikinci sınıflandırmasında oluşan hata değerleri	133
Çizelge 4.14. NEFCLASS için üçüncü sınıflandırma sonuçları (K.Ö. = Kaotik Ölçütler ve S.P. = Spektral Parametreler)	133
Çizelge 4.15. Kaotik ölçütlerin NEFCLASS ile üçüncü sınıflandırmasında oluşan hata değerleri	134
Çizelge 4.16. Spektral parametrelerin NEFCLASS ile üçüncü sınıflandırmasında oluşan hata değerleri	134
Çizelge 4.17. NEFCLASS için genel sınıflandırma sonuçları	134
Çizelge 4.18. Kaotik ölçütlerin NEFCLASS ile sınıflandırma hata değerleri	134


Çizelge 4.19. Spektral parametrelerin NEFCLASS ile sınıflandırma hata değerleri	135
Çizelge 4.20. ANFIS için birinci sınıflandırma sonuçları (K.Ö. = Kaotik Ölçütler ve S.P. = Spektral Parametreler)	135
Çizelge 4.21. Kaotik ölçütlerin ANFIS ile birinci sınıflandırmasında oluşan hata değerleri	135
Çizelge 4.22. Spektral parametrelerin ANFIS ile birinci sınıflandırmasında oluşan hata değerleri	136
Çizelge 4.23. ANFIS için ikinci sınıflandırma sonuçları (K.Ö. = Kaotik Ölçütler ve S.P. = Spektral Parametreler)	138
Çizelge 4.24. Kaotik ölçütlerin ANFIS ile ikinci sınıflandırmasında oluşan hata değerleri	139
Çizelge 4.25. Spektral parametrelerin ANFIS ile ikinci sınıflandırmasında oluşan hata değerleri	139
Çizelge 4.26. ANFIS için üçüncü sınıflandırma sonuçları (K.Ö. = Kaotik Ölçütler ve S.P. = Spektral Parametreler)	139
Çizelge 4.27. Kaotik ölçütlerin ANFIS ile üçüncü sınıflandırmasında oluşan hata değerleri	140
Çizelge 4.28. Spektral parametrelerin ANFIS ile üçüncü sınıflandırmasında oluşan hata değerleri	140
Çizelge 4.29. ANFIS için genel sınıflandırma sonuçları	140
Çizelge 4.30. Kaotik ölçütlerin ANFIS ile sınıflandırma hata değerleri	140
Çizelge 4.31. Spektral parametrelerin ANFIS ile sınıflandırma hata değerleri	141
Çizelge 4.32. Karar Ağacı için birinci sınıflandırma sonuçları (K.Ö. = Kaotik Ölçütler ve S.P. = Spektral Parametreler)	141
Çizelge 4.33. Kaotik ölçütlerin Karar Ağacı ile birinci sınıflandırmasında oluşan hata değerleri	141
Çizelge 4.34. Spektral parametrelerin Karar Ağacı ile birinci sınıflandırmasında oluşan hata değerleri	142
Çizelge 4.35. Karar Ağacı için ikinci sınıflandırma sonuçları (K.Ö. = Kaotik Ölçütler ve S.P. = Spektral Parametreler)	142

Çizelge 4.36. Kaotik ölçütlerin Karar Ağacı ile ikinci sınıflandırılmasında oluşan hata değerleri.....	143
Çizelge 4.37. Spektral parametrelerin Karar Ağacı ile ikinci sınıflandırmasında oluşan hata değerleri	143
Çizelge 4.38. Karar Ağacı için üçüncü sınıflandırma sonuçları (K.Ö. = Kaotik Ölçütler ve S.P. = Spektral Parametreler)	143
Çizelge 4.39. Kaotik ölçütlerin Karar Ağacı ile üçüncü sınıflandırmasında oluşan hata değerleri.....	144
Çizelge 4.40. Spektral parametrelerin Karar Ağacı ile üçüncü sınıflandırmasında oluşan hata değerleri	144
Çizelge 4.41. Karar Ağacı için genel sınıflandırma sonuçları	144
Çizelge 4.42. Kaotik ölçütlerin Karar Ağacı ile sınıflandırma hata değerleri	144
Çizelge 4.43. Spektral parametrelerin Karar Ağacı ile sınıflandırma hata değerleri.....	145
Çizelge 4.44. K En Yakın Komşu algoritması için birinci sınıflandırma sonuçları (K.Ö. = Kaotik Ölçütler ve S.P. = Spektral Parametreler).....	145
Çizelge 4.45. Kaotik ölçütlerin K En Yakın Komşu algoritması ile birinci sınıflandırmasında oluşan hata değerleri.....	145
Çizelge 4.46. Spektral parametrelerin K En Yakın Komşu algoritması ile birinci sınıflandırmasında oluşan hata değerleri.....	146
Çizelge 4.47. K En Yakın Komşu algoritması için ikinci sınıflandırma sonuçları (K.Ö. = Kaotik Ölçütler ve S.P. = Spektral Parametreler).....	146
Çizelge 4.48. Kaotik ölçütlerin K En Yakın Komşu algoritması ile ikinci sınıflandırmasında oluşan hata değerleri.....	146
Çizelge 4.49. Spektral parametrelerin K En Yakın Komşu algoritması ile ikinci sınıflandırmasında oluşan hata değerleri.....	147
Çizelge 4.50. K En Yakın Komşu algoritması için üçüncü sınıflandırma sonuçları (K.Ö. = Kaotik Ölçütler ve S.P. = Spektral Parametreler).....	147
Çizelge 4.51. Kaotik ölçütlerin K En Yakın Komşu algoritması ile üçüncü sınıflandırmasında oluşan hata değerleri.....	147
Çizelge 4.52. Spektral parametrelerin K En Yakın Komşu algoritması ile üçüncü sınıflandırmasında oluşan hata değerleri.....	148
Çizelge 4.53. K En Yakın Komşu algoritması için genel sınıflandırma sonuçları ..	148

Çizelge 4.54. Kaotik ölçütlerin K En Yakın Komşu algoritması ile sınıflandırma hata değerleri	148
Çizelge 4.55. Spektral parametrelerin K En Yakın Komşu algoritması ile sınıflandırma hata değerleri	148
Çizelge 4.56. ÇKASA için birinci sınıflandırma sonuçları (K.Ö. = Kaotik Ölçütler ve S.P. = Spektral Parametreler)	149
Çizelge 4.57. Kaotik ölçütlerin ÇKASA ile birinci sınıflandırmasında oluşan hata değerleri	150
Çizelge 4.58. Spektral parametrelerin ÇKASA ile birinci sınıflandırmasında oluşan hata değerleri	150
Çizelge 4.59. ÇKASA için ikinci sınıflandırma sonuçları (K.Ö. = Kaotik Ölçütler ve S.P. = Spektral Parametreler)	150
Çizelge 4.60. Kaotik ölçütlerin ÇKASA ile ikinci sınıflandırmasında oluşan hata değerleri	151
Çizelge 4.61. Spektral parametrelerin ÇKASA ile ikinci sınıflandırmasında oluşan hata değerleri	151
Çizelge 4.62. ÇKASA için üçüncü sınıflandırma sonuçları (K.Ö. = Kaotik Ölçütler ve S.P. = Spektral Parametreler)	151
Çizelge 4.63. Kaotik ölçütlerin ÇKASA ile üçüncü sınıflandırmasında oluşan hata değerleri	152
Çizelge 4.64. Spektral parametrelerin ÇKASA ile üçüncü sınıflandırmasında oluşan hata değerleri	152
Çizelge 4.65. ÇKASA için genel sınıflandırma sonuçları	152
Çizelge 4.66. Kaotik ölçütlerin ÇKASA ile sınıflandırma hata değerleri	152
Çizelge 4.67. Spektral parametrelerin ÇKASA ile sınıflandırma hata değerleri	153
Çizelge 5.1. Sınıflandırma algoritmalarının performansları (K.Ö. = Kaotik Ölçütler ve S.P. = Spektral Parametreler)	160
Çizelge 5.2. Kaotik ölçütler için sınıflandırma algoritmalarında oluşan hata değerleri	160

1. GİRİŞ

İnsan beyni zarlar ve kafatası dediğimiz kemik yapı ile örtülüdür. Kafatası boşluğu içinde beyin dokusu yer alır ve beyin dokusu kafa kemikleri haricinde içte beyin zarları tarafından örtülüdür. Bunlar dıştan içe doğru dura mater (sert zar), araknoid (örümceksi) ve pia mater (ince zar) olarak adlandırılır. Araknoid zarın iç kısmı, ince uzantılarla ve örümcek ağı yapısında bağlantılarla doludur. Araknoid zar, bu uzantıları aracılığıyla pia mater'e bağlanarak, arada bir boşluk oluşmasına neden olur. Subarachnoid denen bu boşlukta beyin omurilik sıvısı bulunur. Bu sıvı beyin dokusunun beslenmesi ve atıklarının temizlenmesi ile görevlidir. Beynin tamamını saran zar yapısı ve içindeki sıvı dolu bölmeler sayesinde, beyin sıvı içinde yüzer durumda darbelere karşı emici bir tamponla korunmuş olur. Ayrıca beynin yumuşak dokusunun kendi ağırlığıyla hasar görmesini engelleyecek bir yastık görevi de görmektedir. Dura mater, kafatası boşluğunu içte yaptığı oluşumla üst ve alt olmak üzere iki kısma ayırır. Üst kısımda beyin hemisferleri ve diencephalon vardır. Her iki hemisfer 4 loba ayrılır. Bu loblar kendilerini örten yassı kemiklerin adını alır. Frontal lob ön kısımda bulunur. Motor hareket, motor konuşma ve kişilik gibi işlevleri yerine getirir. Temporal lob işitme ve anlama gibi işlevlerden sorumludur. Oksipital lob görme işlevinden sorumludur. Bütün loblar ayrıca birbirleriyle ilişkilidir.



Şekil 1.1. Beyin loblarının genel görünümü

Beyin dokusu içinde beyin omurilik sıvısı ile dolu ventrikül adı verilen boşluklar vardır ve bunlar toplam 4 adettir. Her bir beyin hemisferinde iç kısımda önden arkaya uzanan yan ventriküller, ortada diencephalon'da yer alan üç ventriküle, oradan beyin sapı ve beyincik arasında oluşturulan dördüncü ventriküle ve oradan da beyine ve omuriliğe araknoid dediğimiz zar altına yayılmaktadır. Beyin omurilik

sıvısı yaklaşık 21 ml/sa hızla ventriküllerde üretilir ve yaklaşık olarak toplam 150 ml'dir. Günlük üretim 450-500 ml'dir.

Beyin vücut sistemindeki en fazla kan ihtiyacı olan organdır. Dolaşımdaki toplam kan miktarının yaklaşık %18'ini beyin almaktadır. Ortalama 50 cl/100 gr/dk kanlanan beyin dokusu, akciğerlerden emilen oksijenin yaklaşık %20'sini kullanır. Kanlanma durduğunda 1 dakika sonra bilinç kaybı ve 5 dakika sonra da geriye dönüşsüz beyin hasarı ortaya çıkar (Morgan ve Mikhail, 1996).

Beynin kanlanması; ön ve arka sistem denilen ve birbiri ile ilişkili iki sistem tarafından sağlanır. Ön sistem aortadan çıkan sağ ve sol taraflı birleşik karotid arterinin iç karotid arter dalı, boynun sağ ve sol tarafından ilerleyip beyine yanlardan girer. Beynin sağ ve sol hemisferlerine dallar verir. Ayrıca beynin ön, üst, iç ve yan kısımlarını besler. Arka sistem her iki subklavian arterin vertebral dallarından beslenir. Bu damarlar boynun arka kısmında omur kemiğinin her iki yan tarafından ilerleyip beyine foramen magnumdan girer. Daha sonra birleşerek tek bir damar olarak ilerler, beynin arka kısmına, beyin sapına ve beyinciğe dallar verir. Daha sonra da ön ve arka sistemi birbirine bağlayan yapıya katılır. Bu yapı, Willis poligonudur ve büyük damarlardan birinin tıkanması durumunda çok etkili kollateral dolaşım sağlar.

Yetişkin bireylerin beyin damarlarındaki kan akışının TCD analizi, genel olarak damarlarda tıkanma, doğuştan gelen bozukluk, daralma ve akış dinamiğini değerlendirmek için kullanılır (Evans ve ark., 1989). TCD ile yapılan tanımlar, artan veya azalan kan akış hızının, kan akışının tamamen kesilmesinin veya damar direncindeki değişimlerin tespit edilmesi şeklindedir. Beyin damarlarındaki kan akış hızının ölçülerek tıkanma ve daralmanın teşhis edilmesinde kullanılan TCD inceleme tekniği, anjiyografi ve manyetik rezonans yöntemlerine alternatif olarak kullanılabilecek invazif olmayan bir tanı yöntemidir. Uzman tıp personelinin TCD sinyallerini uygun biçimde yorumlayabilecek şekilde eğitilmesinin gerekliliği, kliniklerde daha etkin ve yaygın biçimde kullanımlarını engellemektedir. TCD sinyallerinin doğrusal olmayan dinamiğinin analizi tıbbi teşhisin daha sağlıklı yapılmasını sağlayabileceği gibi, beyin fizyolojisinin anlaşılmasında ve hastalık durumlarında kan akışının nasıl değiştiğinin gözlenmesinde yardımcı olabilecektir. TCD spektrum analizinden elde edilen veriler yanında, kaos teorisinin sunduğu

yöntemlerin zaman dizilerine uygulanması ile elde edilen nicel değerler teşhisin daha güvenilir olmasını sağlayabilir. Bazı beyin rahatsızlıklarında, TCD sinyallerinin spektrum analizi tıbbi teşhisin doğru olarak yapılmasını sağlayacak bilgiyi vermeyebilmektedir.

TCD sinyallerinin, zaman içinde değişen bir dizi ayırık değerden oluştuğu düşünülebilir. Bu tür dizilere zaman dizileri denir. Doğrusal olmayan bir sistemin ürettiği zaman dizisinin güç analizi, doğrusal dikey dönüşümler veya parametrik doğrusal modelleme gibi standart doğrusal yöntemlerle ele alınması, bu zaman dizisinin kritik özelliklerinin tespit edilememesine ve yanlış bir şekilde dizinin çoğunun rasgele gürültü olarak değerlendirilmesine yol açabilir (Tong 90). Kaotik sinyaller ve gürültü sinyalleri sürekli (geniş bant) spektrumuna sahiptir. Harici gürültü ile bozulan doğrusal bir sistem ile düşük serbestlik dereceli bir doğrusal olmayan sistem birbirine yakın geniş bant spektrumuna sahip olabilir. Ayrıca farklı doğrusal olmayan sistemler de birbirine yakın geniş bant spektrumuna sahip olabilir. Bu yüzden, doğrusal olmayan bir sistemin karakteristik özellikleri frekans içeriği ile belirlenemez.

Bir sinyal doğrusal denklemle üretilmişse, üssel olarak artar (azalır) veya periyodik olarak salınım yapar. Sinyaldeki düzensizlikler, sisteme dışardan gelen rasgele girdilerden (gürültü) kaynaklanır. Kaos teorisine göre ise rasgele girdi sistemin çıktısındaki düzensizliğin tek kaynağı olmayabilir. Doğrusal olmayan, kaotik sistemler tamamen deterministik denklemlerle çok düzensiz sinyaller üretebilir. Rasgele gürültü, çok küçük genliğe sahiptir. Düzensiz yapıdaki doğal sinyallerin genliği ise genellikle gürültünün neden olduğu genlik değişiminden büyüktür. Canlılardan elde edilen sinyaller genellikle bu tür görünüme sahiptir.

Zaman dizileri üzerinde doğrusal tahmin modelleri iyi sonuç vermeyebilir. Doğrusal olmayan tahmin modelleri ise kısa dönemli tahminde oldukça başarılı olmaktadır. Kaotik çekici üzerindeki geometrik yapılar tahmin edilebilir bölgeleri ortaya çıkarır. Doğrusal yöntemler bir zaman dizisindeki düzenli yapıyı (örneğin; baskın frekansı) doğrusal ilintiler şeklinde (zaman veya frekans kümesinde) ortaya çıkarır.

Kaos teorisi (Doğrusal olmayan zaman dizisi analizi), zaman dizilerinin nicel olarak analiz edilebilmesi için gerekli bazı araçlar sağlamaktadır. Örneğin; rasgele

görünümlü bir sinyalin faz uzayında gömülmesi ile elde edilen kaotik çekici gizli deterministik yapıyı ortaya çıkarabilir. Gömülme boyutu 3'ten büyük ise çekicinin grafik olarak gösterimi mümkün değildir. Fakat bu durum, kaos analizini ve kaotik ölçütlerin hesaplanmasını engellemez. En büyük Lyapunov üsteli ve ilinti boyutu gibi değerler, nicel kaos ölçütleridir. Lyapunov üstelleri, sistemin dinamik davranışını belirler ve çekici üzerindeki komşu yörüngeler boyunca ilerlerken bu farklı yörüngeler üzerindeki komşu noktaların birbirlerinden uzaklaşmalarının veya yaklaşmalarının ölçütünü verir. Şayet komşu noktalar birbirinden uzaklaşıyorlarsa, Lyapunov üsteli pozitif olacaktır. Aksi halde, negatif bir üstel söz konusudur. D_E boyutlu bir faz uzayına gömülü olan çekici için D_E adet Lyapunov üsteli vardır. Bu üstellerden en az birinin pozitif olması, incelenen doğrusal olmayan dinamik sistemin kaotik olduğunu gösterir. Kaotik çekicilerde, sistemin faz uzayında ziyaret ettiği noktalardan oluşan kümeler düzensiz geometrik yapılar meydana getirir. Bu fraktal geometri, sınırlı bir faz uzayı içindeki uzama, katlanma ve hacim küçülmesi sonucu küçük boyutlarda istatistiksel olarak kendine benzer yapılar şeklinde ortaya çıkar. Kaotik çekicilerdeki bu çok küçük boyutlardaki kendine benzerliğin nicel ölçütü ilinti boyutu ile ifade edilir.

Kaos, teorik olarak, sadece doğrusal olmayan deterministik sistemlerde ortaya çıktığı için, kaos teorisi yöntemlerinin uygulanacağı TCD zaman dizilerinin doğrusal olmadığının gösterilmesi gerekir. Doğrusal olmama tek başına, bir sinyalin kaotik olduğunu göstermemekle birlikte, kaotik yöntemleri uygulamak için aranan şartlardan biridir. Ayrıca, kaos teorisinin kullandığı yöntemler, faz uzayındaki noktaların uzaklığına bağlı olduğu için, elde edilen sonuçların güvenilir ve sağlıklı olması için veri kümelerinin durağan olmasını da gerektirir.

Bu çalışmada, tüm TCD sinyallerinin hem doğrusal olmadığı hem de tam deterministik sinyal olan sinüs sinyali ile rasgele sinyal arasında bir durağanlığa sahip olduğu gösterilmiştir. En güçlü kaotik göstergeler olan en büyük Lyapunov üsteli ve ilinti boyutu her bir sinyal için hesaplanmıştır. Sonuçlar, TCD sinyallerinin kaotik olduğunu göstermektedir. TCD sinyallerine Burg algoritmasını kullanan AR yönteminin uygulanması ile sonogramlar elde edilmiştir. Bu sonogramlarda gözlenen sinyal karmaşıklığı ile kaotik ölçütler arasında ilişki olduğu gözlenmiştir. Sonogram periyodik bir görüntüye sahip ise kaotik ölçütler küçük, rasgele görünümlü ise kaotik

ölçütler büyük olmaktadır. Kaotik ölçütlerle hastalık grupları ve sağlıklı birey grubu arasındaki ayrımı nicel olarak ortaya çıkarmak için, çoklu doğrusal regresyon yöntemi kullanılmıştır. Bu istatistiksel analizin sonucu, kaotik değişkenler ile çıkış değerleri arasında bir bağımlılık olduğunu göstermiştir. Bu gözleme dayanarak, bahsedilen beyin rahatsızlıklarının otomatik olarak tanınması için kaotik ölçütlerin uygun bir sınıflandırma algoritmasının eğitilmesinde giriş özellikleri olarak kullanılabileceği sonucuna varılmıştır. Veri kümesi farklı sayıda bireyden oluşan eğitim ve test alt kümelerine bölünmüştür. Yapay Sinir Ağılı Bulanık Çıkarım Sistemleri olan ANFIS ve NEFCLASS yanında Karar Ağacı, K En Yakın Komşu ve Çok Katmanlı Algılayıcı Sinir Ağı yöntemlerinin sınıflandırma performansları değerlendirilmiştir. Deney sonuçları göstermektedir ki, TCD sinyallerinden çıkarılan kaotik ölçütler kullanılarak değişik beyin rahatsızlıklarının otomatik olarak sınıflandırılmasını sağlayan başarılı bir sistem elde etmek mümkündür.

Bu tez çalışmasında aşağıdakiler amaçlanmıştır:

- 1-Doppler sinyallerinin kaotik ölçütlerinin hesaplanması
- 2-Kaotik ölçütler ile çeşitli beyin rahatsızlıklarına bağlı olarak meydana gelen kan akış dinamiğindeki değişim arasındaki ilişkinin ortaya çıkarılması.
- 3-Farklı sınıflandırma algoritmalarının kaos ölçütlerini sınıflandırma performanslarının incelenmesi.
- 4-Kaotik ölçütler ve doğrusal yöntemlerle elde edilen ölçütlerin sınıflandırma performanslarına etkilerinin karşılaştırılması.

Bu amaçla, beyin damarında balonlaşma, beyinde su toplama ve beyin kanaması bulunan hastalar ile beyinde tümör olan hastaların beyin içi damarlarında kan akışı incelenmiştir. Sağlıklı bireylerden alınan TCD sinyalleri de karşılaştırma amacıyla kullanılmıştır. İncelenen rahatsızlıklar beyin damarlarındaki kan akış dinamiğinin değişmesine neden olurlar. Beyin damarlarında daha çok dallanma noktalarında damarsal yapı bozukluğu ya da başka nedenlerle balonlaşma oluşur. Genellikle doğuştan gelen kimi genetik anatomik bozukluklara bağlı oluşan kan dolaşımındaki düzensizlikler balonlaşmaya neden olabilir. Diğer nedenleri arasında kafa travması, yüksek tansiyon, enfeksiyon, tümörler, damar duvarlarında yağ birikimi, sigara ve uyuşturucu sayılmaktadır. Beyin damarlarının duvarlarının zayıflamasıyla balonlaşan kısmın yırtılması sonucu beyin kanaması oluşabilir. Her

yaşıta insanda bu görülebilir. Önceden tespit edilmeleri mümkün değildir. Ani bir zorlanma, heyecanlanma ile balonlaşan damar yırtılabilir. Balonlaşma olan damarın yırtılması kanamaya bağlı şoka, felce veya ölüme neden olabilir. Kanama sonucu hasta ani ve çok şiddetli baş ağrısı, çift görme, mide bulantısı, kusma ve/veya bilinç kaybı yaşamaktadır. Beyin tümörleri, kafatası içinde büyüyerek beyin üzerine baskı yaparlar. Bulundukları bölgeye ve baskı altında tuttıkları beyin alanına göre belirtiler verirler. İyi ya da kötü huylu olabilen beyin tümörleri özellikle kafa içi basıncın artmasına bağlı belirtiler gösterirler. Bu belirtiler arasında, uzun süreli olmak kaydıyla, genellikle sabahları şiddetli baş ağrısı, öksürük, halsizlik ve mide bulantısı sayılmaktadır. Ayrıca görme bozuklukları, dikkat dağınıklığı, bayılmalar da görülebilir. Tümörün beyindeki konumuna göre de, vücut dengesinin kaybı, zeka kaybı, kişilik değişimi, duyu bozuklukları, konuşma, yazma ve çizmede problemler görülebilir. Beyin kanamaları, beyni besleyen damarlardan dışarı kan sızması sonucu kanla beslenen bölgenin çalışamaz duruma gelmesidir. Beyin içine doğru olan kanamalarda, kan beyin içine doğru sızarak beyin dokusunu tahrip edebilir. Beyin damarları yaş ilerledikçe yıpranarak elastiki özelliklerini yitirirler. Bu nedenle özellikle tansiyon yüksekliği olan yaşlı insanlarda yırtılarak beyin kanamaları oluştururlar. Beyin dışına kanamalar ise genellikle travma sonucu oluşurlar. Beyin üzerinde bulunan zardaki damarlar travma sonucu kırılan veya çatlayan kafatası kemiklerinin zedelenmesiyle kanama yapabilirler. Oluşan kanama beyin zarı ile kafatası kemikleri arasında birikir ve beynin sıkışmasına neden olur. Cerrahi müdahale olmazsa beyin ölümü olabilir. Bu kanamalara epidural hematoma adı verilir. Şiddetli travmalarda beyin üzerindeki damarlar da zedelenir. Bu damarlardan sızan kan beyin zarı altında birikerek beynin sıkışmasına neden olur. Bu tür kanamalara subdural hematoma denir. Ayrıca beynin üzerini örten çok ince zar olan araknoid zarın altına doğru da kanama olabilir. Bu tür kanamalara da subaraknoid kanama denir. Beyin boşluklarında beyin omurilik sıvısının fazla basınçla birikmesine beyinde su toplanması denir. Kafa içi basıncın artmasına neden olan bu rahatsızlığın sebepleri arasında travmatik yaralanmalar, iltihaplı hastalıklar, beyin tümörleri ve hipertansiyona bağlı beyin rahatsızlıkları sayılmaktadır.

Literatürde, spektral analiz yöntemleriyle Doppler sinyallerinden elde edilen özellikler (Örneğin; sistolik hız, diyastolik hız, direnç indeksi, darbe indeksi gibi)

otomatik tıbbi teşhiste yaygın olarak kullanılmıştır (Ergün ve ark., 2004, Übeyli ve Güler, 2005, Güler ve ark., 2002, Serhatlıoğlu ve ark., 2003). Örneğin; Übeyli ve Güler'in (2005) yaptığı çalışmada, sonogramlardan çıkarılan iki özellik (direnç indeksi ve darbe indeksi) karotid arter Doppler sinyallerinin analizi için adaptif bulanık sinir sistemine uygulanmıştır. Serhatlıoğlu ve ark. (2003), spektral eğriden elde edilen sistol, diyastol ve direnç endeksi gibi parametreleri kullanarak TCD sinyallerin sınıflandırılmasında 2 farklı yapay sinir ağının performansını karşılaştırmışlardır. Öte yandan, Doppler sinyallerinin kaos teorisi yöntemleri ile analizini açıklayan yayınlar da literatürde yer almaktadır (Vliegen ve ark., 1996, Keunen ve ark., 1996, Visee ve ark., 1995, Keunen ve ark., 1994). Keunen ve ark. (1996) sağlıklı bireylere ait TCD sinyallerin temelinde doğrusal olmayan dinamiğin bulunduğunu bulmuşlardır. Visee ve ark. (1995), damar tıkanıklığı rahatsızlığı olan hastalarda, normal kan akışı olan bölgelere göre iskemik bölgelerden elde edilen sinyallerin doğrusal ve periyodik olduğunu tespit etmişlerdir. Bunlardan başka, Übeyli ve Güler (2005) yerel Jacobi matrislerinden Lyapunov üstellerinin spektrumunu hesaplamışlar ve Doppler sinyallerindeki değişimi tespit etmek için Çok Katmanlı Algılayıcı'ya uygulamışlardır.

Bu çalışmada, farklı beyin rahatsızlıklarından kaynaklanan beyin arterlerindeki kan akışı değişimlerinin kaotik ölçütlerle otomatik sınıflandırma yaparak tespit edilmesini sağlayabilecek yeni bir yaklaşım önerilmiştir. Bunun için, TCD sinyallerinden çıkarılan iki adet kaotik ölçütü (en büyük Lyapunov üsteli ve ilinti boyutu) değişik sınıflandırma yöntemlerine giriş özellikleri olarak uygulanarak performansları karşılaştırılmıştır. Kullanılan sınıflandırma yöntemleri NEFCLASS, ANFIS, Karar Ağacı, K En Yakın Komşu ve Çok Katmanlı Algılayıcı Sinir Ağı'dır. TCD sinyallerinden spektral analiz yöntemiyle elde edilen direnç indeksi (RI) ve atım indeksi (PI) değerleri de aynı sınıflandırma yöntemlerine uygulanmıştır. Kaotik ölçütlerle elde edilen sınıflandırma doğruluğu tüm yöntemler için belirgin biçimde daha yüksek bulunmuştur. Yukarıda verilen beyin rahatsızlıklarından herhangi biriyle karşılaşıldığında, bu çalışmada önerilen yöntemin sınıflandırma sonucu, sonogramlar ve spektral dalga analizi parametrelerine ek bir destekleyici bilgi olarak kullanılarak tıbbi teşhisin doğruluğunu genel olarak artırmada yararlanılabilir.

2. KAYNAK ARAŞTIRMASI

Kaos teorisinin sunduğu doğrusal olmayan analiz yöntemleri dinamik sistemlerin incelenmesinde kullanılmaktadır. Literatürde yer alan çalışmalarda, zaman içinde değişen herhangi bir büyüklüğün belirli aralıklarla ya da sürekli olarak ölçülmesi ile elde edilen zaman dizileri üzerinde kaos teorisi yöntemleri, genel olarak kısa süreli tahminde veya kaotik ölçütleri ile sistem dinamiğinin farklı koşullardaki değişimleri arasındaki ilişkinin tespit edilmesinde kullanılmıştır. Kısa süreli tahmin, borsadaki hisse senetleri değişiminden sismik verilere, elektrik fiyatlarından otomobil motorlarındaki en uygun hava/yakıt oranının hesaplanmasına kadar pek çok alanda uygulanmıştır. Bölüm 2.1’de zaman dizileri üzerinde kısa süreli tahminlerin yapıldığı çalışmalar özetlenmiştir. Lyapunov üsteli, ilinti boyutu gibi kaotik ölçütler ile zaman serisini üreten dinamik sistemdeki değişim arasındaki ilişki genellikle biyomedikal sinyallerle ilgili çalışmalarda göze çarpmaktadır. Bölüm 2.2’de bu alanda yapılan çalışmaların özeti verilmiştir. Bölüm 3.3’te biyomedikal sinyallerin spektral analizi sonucu veya kaotik analiz sonucu elde edilen parametrelerle farklı rahatsızlıkların otomatik olarak teşhis edilmesini ele alan çalışmalar özetlenmiştir.

2.1. Kaos Teorisi Yöntemlerinin Kısa Süreli Tahminde Kullanımı

Yang ve Duan (2003)’ın yaptığı çalışmada, öncelikle elektrik fiyatlarının pek çok faktör tarafından etkilendiği ve çok karmaşık ve düzensiz iniş çıkışlar gösterdiği vurgulanmıştır. Elektrik fiyatı zaman dizisi kullanılarak faz uzayında bir çekici oluşturulmuştur. Oluşturulan çekici üzerinde ilinti boyutu ve Lyapunov üstelleri hesaplanmıştır. Bulunan bu değerlerin doğruluğundan emin olmak için yapay veriler testi (surrogate data test) yöntemi kullanılmıştır. Analiz sonuçlarına göre, elektrik fiyatlarının kaotik olduğu ve kısa dönemli tahmininin kaos teorisi yardımıyla gerçekleştirilebileceği anlaşılmıştır.

Recurrent Yapay Sinir Ağı kullanılarak genel ve yerel fiyat tahmin modeli önerilmiş ve başarıyla uygulanmıştır. Elektrik fiyatlarındaki değişimin belirsiz oluşu, zaman dizisini üreten sistemin düzensiz olduğunu ve elektrik fiyatlarının da düzensiz bir değişkene bağlı olduğunu göstermektedir.

Veri kümesindeki toplam değer sayısı 4368'dir. Zaman gecikmesinin bulunması için, öz ilinti (autocorrelation) fonksiyonu ve karşılıklı bilgi yöntemleri kullanılmış ve zaman gecikmesi (τ) 8 olarak bulunmuştur.

Gömülme (embedding) boyutunun bulunması için, Sözde Yakın Komşular (False Nearest Neighbours) yöntemi kullanılmıştır ve gömülme boyutu D_E 9 olarak bulunmuştur. İlinti boyutu 5,3 olarak bulunmuştur. Bu değer 2'den büyük ve kesirli olmasının zaman dizisini üreten sistemin kaotik olduğunu gösterdiği vurgulanmıştır. Lyapunov üsteli çok küçük pozitif bir sayı olarak bulunmuştur. Lyapunov üstelinin pozitif olması uzun süreli tahmin yapmanın imkansız olduğunu, çok küçük olması ise fiyatların çok yavaş değiştiğini ve kısa süreli tahmin yapmanın mümkün olduğunu göstermektedir.

Iokibe ve Fujimoto (2001), daha az yakıtla, ideal yanma koşullarında çalışacak motor geliştirmek üzerine bir çalışma yapmışlardır. Amaç düşük emisyonlu ve yüksek mesafe gidebilen otomobil üretmektir. Otomobilin daha fazla mesafe yapması için hava/yakıt oranı azaltılmaktadır. Fakat bu durum, yanma koşulunun dengesizleşmesine yol açabilmektedir. Tutuşturma zamanlaması ve hava/yakıt oranının hassas biçimde kontrol edilmesi, motor performansının yitirilmemesi için gereklidir. Yanma işlemi, doğrusal olmayan karmaşık bir işlemdir. Sonraki yanmaların tepe basıncı, sadece motor içindeki silindirlerin yanma basınçlarına ait zaman dizileri kullanılarak tahmin edilebilir. Tutuşturma zamanlamasının kontrolü bilgisayar yardımıyla yapılırsa bunun dinamik olarak kontrolü mümkündür. Geçmişteki yanma basıncı bir sonraki yanma basıncını etkilemektedir.

Kaos teorisine göre, sistem çok boyutlu olsa bile gözlenen tek-boyutlu bir zaman dizisi kullanılarak sistemin davranışı tahmin edilebilecek şekilde modelleme yapmak mümkündür. Ayrıca bir sistemi analiz etmek için giriş-çıkış ilişkisi ve matematik modelinin ne olduğu önemli değildir. Bu çalışmada, silindir içindeki yanma basıncı gözlenmiş ve zaman dizisi olarak kaydedilmiştir. Doğrusal olmayan kısa süreli tahmin yapmak için, yerel doğrusal olmayan tahmin yöntemlerinden biri olan yerel bulanık (local fuzzy) oluşturma yöntemi uygulanmıştır.

Sabit dönme hızında, hava/yakıt oranını değiştiren sonraki yanmanın tepe basıncı tahmin edilmiştir. Eğer y_t zaman dizisi kaotik ise, $\{X_{mi}\}$ değerinden $\{X_{mi+S}\}$ değerine geçişin deterministik olduğu kabul edilerek bulanık koşullar

oluşturulmuştur. İki farklı durum için iki zaman dizisi elde edilmiştir. Birinci zaman dizisi, ideal hava/yakıt oranı, diğer zaman dizisi düşük hava/yakıt oranı için elde edilmiştir. 4 silindirin tamamından elde edilen zaman dizileri tek bir zaman dizisi oluşturacak şekilde birleştirilmiştir. Bir sonra ateşleme yapılacak silindirdeki tepe yanma basıncı tahmin edilmiştir.

Ekonomik verilerin pek çoğu kaotik davranışlar göstermektedir. Wang ve ark. (2004), yaptıkları çalışmada hisse senetlerinin günlük değişimlerdeki karmaşık dinamik davranışları incelemişlerdir. Diziler için en büyük Lyapunov üsteli, ilinti boyutu ve frekans spektrumu hesaplanmıştır. Bazı günlük zaman dizilerinin düşük-boyutlu kaos gösterdiği, bir kısmının ise kaotik olmadığı tespit edilmiştir. Kısa süreli tahmin için ağırlıklı tek dereceli yerel bölge yaklaşımı kullanılmıştır. Bu yayında, elde sınırlı sayıda veri olması durumunda ekonomik zaman dizilerinin kaotik davranışının nasıl gösterilebileceği üzerinde durulmuştur. Gömülme boyutunun hesaplanmasında Grassberger-Procaccia yaklaşımı kullanılmıştır. Bu yaklaşım aynı zamanda ilinti boyutunu da hesaplamaktadır. Zaman gecikmesi için ise öz ilinti (autocorrelation) fonksiyonunun, başlangıç değerinden itibaren $1/e$ değerine ilk düştüğü andaki değeri seçilmiştir. En büyük Lyapunov üstelinin hesaplanmasında Rosenstein yöntemi kullanılmıştır. Bu yöntemdeki gömülme boyutu ve zaman gecikmesi hesaplama adımları G-P yöntemindeki ilgili adımlarla değiştirilmiştir. Bu yayında, Shenzen (Çin) borsasından 31.12.1996 ile 14.03.2002 tarihleri arasında alınan 900 farklı hisse senedi ve Shangay (Çin) borsasından 07.04.1998 ile 14.03.2002 tarihleri arasında 1000 farklı hisse senedi verisi toplanmıştır. Her bir borsa verisinden sadece birer tanesi üzerinde yapılan kaos analizi yayında gösterilmiştir. Doğru tahmin edilebilirlik süresi, en büyük Lyapunov üsteline (λ_1) bağlı olarak $T_m=1/\lambda_1$ şeklinde en fazla 156 gün olarak bulunmuştur. $T_m \leq 156$ için, tahmin hataları $< \%5$ ve $T_m \geq 220$ için tahmin hataları $> \%30$ şeklinde tespit edilmiştir.

Depremlerin dinamiği enerji kayıplı (dissipative) sistemlere uymaktadır ve kaotik davranış sergilemektedir. Kaotik davranış gösteren enerji kayıplı (dissipative) dinamik sistemlerin genellikle faz uzayında bir garip çekicisi bulunur.

Plagianakos ve Tzanaki (2001)'nin yaptıkları çalışmada, kaos analizinin ardından evrensel fonksiyon yakınlaştırmacıları olan yapay sinir ağları zaman dizisinin kısa-süreli tahmini için kullanılmıştır. Yapay sinir ağının mimarisi, zaman dizisinin

kendisine ait karakteristik özelliklerinin hesaplanması ile ortaya çıkmıştır. Doğrusal olmayan veri analizi genel olarak 2 adımdan oluşmaktadır:

Veriler sistem dinamiğinin yeniden oluşturulması için kullanılmaktadır. Buna faz uzayında gömülme denir. İnşa edilen dinamiğe ait karakteristik ölçütler hesaplanır. Bu ölçütler ilinti boyutu, en büyük Lyapunov üsteli gibi değerlerdir.

Takens (1981) teoremine göre, yeniden oluşturulan dinamik orijinal zaman dizisine geometrik olarak benzerdir. Kaos analizini kullanmadaki amaç, gömülme boyutu için en uygun değeri bulmak ve bunu yapay sinir ağı mimarisini oluşturmada kullanmaktır. Sismik aktivite periyodik değildir. Yani eşit zaman aralıklarından ölçülmez. Çoğu durumlarda analiz için interpolasyon gerekebilir. 20 yıllık deprem verileri üzerinde yapılan kaos analizi sonucunda, en büyük Lyapunov üsteli 0.3717 olarak bulunmuştur. Bu sonuç, kısa dönemli tahminin mümkün olduğunu göstermektedir. Çekicinin oluşturulması için gerekli gömülme boyutu 5 olarak bulunmuştur. Bu değer yapay sinir ağının giriş katmanındaki düğüm sayısıdır. Gizli katmanda 30 ve çıkış katmanında 1 düğüm bulunmaktadır. Çekicinin ilinti boyutu 2 ile 3 arasında bir değer bulunmuştur. Bu durum, deprem verilerinin düşük seviyeli garip çekici içerdiğini, yani kaotik olduğunu, göstermektedir.

2.2. Kaotik Ölçütlerle Dinamik Sistemdeki Değişim Arasındaki İlişkinin Araştırılması

Mitchell ve ark. (1995), erken doğan çocuklar ile solunum sıkıntısı sendromu (respiratory distress syndrome - RDS) çeken çocuklara ait kalp hızı değişkenliğini incelemiştir. Kalp Hızı Değişkenliği verileri, ardışık R-R aralıklarına ait zaman dizilerinden oluşmaktadır. Kullanılan yöntem, çok büyük miktarda veri gerektirmeden kaos teorisinin araçlarını kullanmaktadır. 20 normal erken doğmuş çocuk verileri ile 17 RDS'li yeni doğmuş çocuk verileri toplanmıştır. Toplanan veriler filtreleme gerektirmemektedir ve hesaplama zamanı çok düşüktür. Zaman dizilerini kaos analizine sokmadan önce, fark dizisi oluşturularak dizi verileri arasındaki ilinti giderilmiştir. Klinik sendromlar, vurular arası aralık dinamiğinin normal kaotik karmaşıklığının kaybolması ile ilişkilendirilmektedir. Normal çocuklarda ilinti boyutu (D_2) 2 olarak, RDS'li çocuklarda 1.85 olarak bulunmuştur. Normal ve RDS'li çocukların 2 boyutlu uzaydaki garip çekicileri incelenerek

aralarındaki fark tespit edilmiştir. Çekici oluşturulmasında kullanılan zaman gecikmesi, 1 vuru aralığı olarak belirlenmiştir. Çekicilerinin ilinti boyutu 2.0'den küçük olan çocuklar RDS'li olarak belirlenmiştir. Normal ve hasta çocuklara ait Poincare kesit grafikleri çıkarılmıştır. Fakat görsel analiz her zaman öznel yoruma açıktır. Bu yüzden daha nicel bir kaotik ölçüt olan ilinti boyutu normal çocuklar ile hasta çocukları birbirinden ayırmak için kullanılmıştır.

Hudson ve ark. (1998)'nin yaptığı çalışmada, kaotik ve klinik parametreler doğru tıbbi teşhise yardımcı olmak üzere birleştirilmiştir. Bu parametrelerin birleştirilmesi ile yanlış bir şekilde hasta kabul edilen normal kişiler (false positive) ile yanlışlıkla normal kabul edilen hastaların (false negative) sayısının azaltılacağı öngörülmüştür. Hypernet yapay sinir ağı, kaotik ve klinik değişkenlerin birleştirilmesi için kullanılmıştır. Damar tıkanıklığına bağlı kalp hastalıklarının teşhisi amaçlanmıştır. ECG sinyallerinin kaos teorisi yöntemleri ile analizi yapılarak hastalığın tespiti yapılmaya çalışılmıştır.

Normal kişilere ait ve değişik kalp rahatsızlıkları olan kişilere ait Holter cihazı zaman dizileri üzerinde ikinci-derece fark grafiği oluşturulmuştur. Normal kişilere ait ikinci-derece fark grafiği kalp rahatsızlığı olan kişilerden farklı çıkmıştır. İkinci-derece fark grafiğinin özeti niteliğindeki sayısal ölçütler Central Tendency Measure (CTM) yöntemi ile elde edilmiştir. Bu sayısal ölçütler, klinik parametreler ile birleştirilerek yapay sinir ağına teşhis için verilmiştir. CTM yöntemi, belirli bir yarıçapa sahip daire içinde bulunan noktaların sayısını hesaplar. Holter cihazı 24 saatlik bir süre boyunca çalıştırılır ve 100,000 veri içeren bir zaman dizisi oluşur. Holter kaydında şu bilgiler bulunmaktadır :

- a. Her kalp vurusunun zamanı
- b. Kayıt durumu gösteren kod
- c. Muhtemel aritmileri gösteren 2 kod
- d. Kalp vuruları arasında kalan zaman (R-R aralıkları)

Bu yayında sadece kalp vuruları arasında kalan zaman süresi (R-R aralığı) analiz için kullanılmıştır. 25 damar tıkanıklığı olan kalp hastasının ve 27 normal kişinin Holter kayıtları analiz için kullanılmıştır. Yapay sinir ağına eğitim ve test için 4 farklı değişken girilmiştir:

X1: CTM (yarıçap=0.05)

X2: CTM (yarıçap=0.10)

X3: 24 saat içindeki toplam R-R aralığı sayısı

X4: CTM>0.99 için en düşük yarıçap değeri

Yapay sinir ağının sınıflandırma sonuçları şu şekilde bulunmuştur: 27 sağlıklı bireyden 3'ü yanlışlıkla damar tıkanıklığı olan hasta şeklinde sınıflandırılmıştır. Damar tıkanıklığı olan 25 hastanın 5'i yanlış şekilde sağlıklı olarak sınıflandırılmıştır.

Casaleggio ve Corana (1996)'nın yaptıkları çalışmada, kaos teorisi ile değişik kalp hastalıklarının sınıflandırılması ve kalp dinamiğinin nasıl çalıştığının izlenmesi amaçlanmıştır. Bunun için ECG sinyallerinden elde edilen zaman dizilerinin ilinti boyutu hesaplanmıştır. MIT-BIH Aritmi Veritabanından alınan çok sayıda ECG verisi analiz edilmiştir.

İncelenen sinyallerdeki gürültü miktarı çok ise, hesaplanan ilinti boyutunun güvenilirliği azalmaktadır. MIT-BIH veritabanında her sinyalde bulunan gürültü miktarı verildiği için, böyle bir karşılaştırma yapmak mümkün olmuştur.

Kardiyak aritmilerin sebebi, SA düğümündeki anlık ritim üretimindeki anormallikler, bu aktivitelerin anormal iletilmesi veya uygun olmayan konumlarda gelişen anlık ritmik aktivitelerdir. AV düğüm bölgesindeki anormallikler, atriya ve ventriküller arasındaki senkronizasyonu bozmaktadır. Faheem ve ark. (1997) yaptıkları çalışmada, 2 boyutlu faz uzayında çekiciler oluşturmuşlardır. Gerekli zaman gecikmesi öz ilinti (autocorrelation) fonksiyonunun ilk defa sıfıra ulaştığı nokta olarak hesaplanmıştır. Kalp dokusunun normal ve ilaçlı durumları için en büyük Lyapunov üsteli (λ_1) hesaplanmıştır. Her ilaç konsantrasyon seviyesi için kaotik dinamiğin varlığını göstermek üzere λ_1 pozitif olarak bulunmuştur. İlaç konsantrasyon seviyesi arttıkça λ_1 değeri azalmaktadır.

Beynin değişik bölgelerinde bulunan sinirsel kütlelerin kolektif dinamik davranışının EEG zaman dizileri kullanılarak tayin edilebileceği öne sürülmektedir. Blanco ve ark. (1997)'nin yaptıkları çalışmanın amacı, kaos teorisinin sağladığı doğrusal olmayan dinamik ölçüm araçları ile EEG verilerini kullanarak global beyin dinamiğini karakterize etmektir. Ayrıca kaos teorisi ölçütlerinin beynin değişik bölgelerinde aldığı değerler incelenmiştir. EEG sinyallerine deterministik kaos uygulanması ile elde edilen bulgular, göreceli olarak basit bir kaç kural ile

oluşturulabilecek ve görünürde düzensiz bir işlem sonucu üretildiğini göstermektedir. Bu yayında kullanılan EEG verileri, cerrahi müdahale yapılacak olan bir epilepsi hastasına aittir. Elektrotlar, epileptojenik bölgelere ve beyindeki yayılma alanlarına yerleştirilmiştir. Örnek hızı 204.8 Hz olarak sabitlenmiş ve 20 farklı kanaldan aynı anda kayıt yapılmıştır. Ortalama kayıt süresi 5 ila 15 dakika arasındadır. Klinik raporu hazırlamak için kayıtlar hastanın değişik aktiviteleri (gözleri kapalı dinlenirken, gözleri açık dinlenirken, uykuda ve dikkatini topladığında) esnasında alınmıştır. Kaos teorisi araçları veri noktaları arasındaki uzaklığa göre hesaplama yaptığından, EEG verilerinin durağanlık analizi yapılmış ve sadece durağan bölgelerdeki zaman dizisi verileri kaos analizine alınmıştır. Durağanlık analizi sonucu her biri 1024 veriden oluşan ardışık 6 bölgenin toplamı olan 6144 değer içeren veri kümesi üzerinde kaos analizi uygulanmıştır. 20 farklı EEG zaman dizisinin çekicilerinin oluşturulması için zaman gecikme ve gömülme boyutu değerleri hesaplanmıştır. Zaman gecikmesinin hesaplanması için Rosenstein ve arkadaşlarının önerdiği yöntem uygulanmıştır. Gömülme boyutunun hesabında ise sözde yakın komşular (false nearest neighbours) yöntemi kullanılmıştır. Çekicilerin ilinti boyutunun hesaplanmasında Grassberger-Procaccia algoritması uygulanmıştır. İlinti boyutu ile ölçekleme değerinin logaritmik koordinat sisteminde işaretlenmesi sonucu elde edilen eğride yatay bir bölge içerdiği için bu durumun bir çekicinin varlığını gösterdiğine karar verilmiştir. Çekicinin boyutu kesirli ve 2'den büyük olduğundan çekicinin kaotik harekete sahip ve garip olduğu anlaşılmıştır. Çekicilerin kaotik olduğunu gösteren bir başka ve daha geçerli ölçüt en büyük Lyapunov üstelinin pozitif olmasıdır. En büyük Lyapunov üstelinin hesaplanmasında Rosenstein ve arkadaşlarının önerdiği algoritma kullanılmıştır. Beynin farklı bölgelerinden elde edilen EEG zaman dizilerinde en büyük Lyapunov üsteli pozitif ve farklı olarak bulunmuştur. Beynin iki yarım küresindeki benzer beyin yapılarının ilinti boyutu ile en büyük Lyapunov üsteli birbirinde farklı çıkmıştır. Beynin sağ tarafı için bu değerler biraz daha küçük bulunmuştur. Bu durumun hastanın beyninin sağ tarafındaki epileptojenik bölgenin varlığıyla ilişkili olduğu sonucuna varılmıştır.

Epilepsi genel nüfusun yaklaşık %0.6'sında ve her yaşta görülmektedir. Epilepsi, muhtemelen genetiğe bağlı olarak, beyinde herhangi bir organik fonksiyon bozukluğu olmadan ortaya çıkabildiği gibi kolaylıkla tespit edilebilen yapısal beyin

lezyonu sonucu da oluşabilir. Epilepsi nöbetleri kısa süreli dikkat kaybı şekline olabileceği gibi uzun süreli şuur kaybına da neden olabilir. Hornero ve ark. (1999) yaptıkları yayında, *grand mal* ve *petit mal* olmak üzere iki farklı epilepsi türü incelemişlerdir. Doğrusal olmayan dinamik sistem teorisi yöntemleri kullanılarak 5 epilepsi hastası ile 5 normal kişinin EEG zaman dizileri incelenmiştir. EEG zaman dizileri, kaos teorisi yöntemlerini uygulayabilmek için durağanlık koşulunu sağlayan kesimleri bulmak üzere pencerelere bölünmüştür. Daha sonra, EEG verilerinin durağan kesimlerindeki veriler ile faz uzayında kaotik dinamik çekiciler oluşturularak ilinti boyutları hesaplanmıştır. Ayrıca, bir *petit mal* epilepsi nöbeti sırasında alınan EEG'ye ait çekicinin 3 boyutlu grafiği çizilerek, ilinti boyutu hesaplanmıştır. Normal kişilerin ilinti boyutu, epilepsi hastalarinkine göre daha büyük bulunmuştur. Bu durum normal kişilerin EEG karmaşıklığının daha fazla olduğunu göstermektedir. ANOVA (Analysis of Variance) test uygulanarak, her iki grup arasında belirgin bir fark olduğu doğrulanmıştır. Bir hastadan *petit mal* epilepsi nöbeti sırasında alınan EEG sinyalinin ilinti boyutu ise 2.89 olarak bulunmuştur. Bu değer, normal kişilerin ve aktif nöbet geçirmeyen epilepsi hastalarının EEG kayıtlarına göre çok düşük bir değerdir.

Vliegen ve ark. (1996)'nın yaptıkları çalışmada, ölçülen veri kümesinin bilgisayar tarafından üretilen yapay veri kümesi ile karşılaştırıldığı bir yöntem önerilmiştir. Yapay veri kümesindeki veriler, doğrusal ilintileri orijinal veri kümesi ile aynı olacak şekilde üretilmiştir. Buradaki temel fikir, orijinal veri kümesi ile yapay veri kümelerinin her birisi için doğrusal olmayan bir istatistik hesaplama şeklindedir. Bu çalışmada, zaman dizilerinin karmaşıklığını gösteren ilinti boyutu kullanılmıştır. Yapay veriler yöntemi TCD sinyallerindeki değişimlerin doğrusal olmamakla ilgili olup olmadığını belirlemek için uygulanmıştır. Sağlıklı bireylerin sol orta beyin arterlerindeki kan akış hızları TCD inceleme tekniğiyle ölçülmüştür. Her TCD sinyali için, Gaussian ölçekli faz rasgeleliğini kullanan Fourier dönüşümü ile 50 adet yapay veri kümesi üretilmiştir. Orijinal ve yapay veri kümeleri için ilinti boyutu hesaplanmıştır. Orijinal TCD sinyallerinin ilinti boyutları, yapay veri kümelerinin ortalama ilinti boyutlarından belirgin biçimde farklı bulunmuştur. Bu yüzden, orijinal TCD zaman dizilerinin filtrelenmiş gürültüden kaynaklandığı

şeklindeki hipotez reddedilmiş ve TCD sinyallerinin doğrusal olmadığı kabul edilmiştir.

Keunen ve ark. (1996), en yüksek hız dalga biçimlerini inceleyerek beyin damarlarındaki kan akışı karmaşıklığındaki yaş ve cinsiyete bağlı değişimleri incelemişlerdir. TCD sinyalleri, orta beyin arterinden 2-Mhz TCD sistem kullanılarak alınmıştır. Doğrusal olmayan dinamik sistemler veya kaos teorisi yöntemleri kullanılarak, karmaşıklık derecesi en iyi biçimde ilinti boyutu ve en büyük Lyapunov üsteli hesaplanarak bulunmuştur. Yaş ortalaması 48.6, yaş aralığı 19 ila 86 arasında olacak şekilde sağlıklı 20 adet erkek ve 20 adet kadından alınan TCD sinyalleri incelenmiştir. Cinsiyete bağlı bir değişiklik tespit edilmemiştir. Yaşlı hastalarda ise Lyapunov üsteli azalırken, ilinti boyutu artmıştır. Lyapunov üstelinin azalması sinyaldeki belirgin periyodik yapıyı ve R-R aralıklarındaki iniş-çıkışların azalmasını göstermektedir. Ayrıca bu durum, baroreseptör refleks kazanımının değiştiğini gösterir. İlinti boyutunun yüksek olmasının, ileri yaşlarda damar duvarının sertliğinin artmasına bağlı olarak damar duvarındaki daha belirgin salınımlarla ilişkili olabileceği öne sürülmüştür.

Visee ve ark. (1995), beyin damarlarındaki kan akışının hemodinamiğinin doğrusal olmayan analiz sonuçlarını karşılaştırmak için, iç karotid arterlerinde unilateral ve bilateral tıkanıklığı olan 14 hastanın TCD sinyallerini incelemişlerdir. Bilinen TCD verileri ile doğrusal olmayan analiz verileri karşılaştırılmıştır. TCD zaman dizisinin doğrusal olmayan analizi, TCD eğrisinin fraktal boyutuna bağlı olarak dinamik kaosu var olduğunu göstermektedir. Orta beyin arterinin uzlaşmış ve uzlaşmamış bölgelerine karşılık gelen pozitif Lyapunov üsteli bulunmuştur. Uzlaşmış dolaşımın bulunduğu bölgelerde pozitif Lyapunov üsteli, uzlaşmamış bölgelerle karşılaştırıldığında daha küçüktür. Bazı durumlarda beyinsel vasomotor aktivitesi negatif ve Lyapunov üsteli sıfıra çok yakındır. Lyapunov üstelinin sıfıra yakın olması bozuk kan dolaşımındaki periyodik davranışı göstermektedir. Dinamik kaos ise sağlıklı durumlarda ortaya çıkmaktadır. Beyinsel vasomotor aktivitesini tespit etmede geleneksel ve doğrusal olmayan TCD sinyal analizinin birlikte kullanılabileceği öne sürülmektedir.

Keunen ve ark. (1994) tarafından, TCD zaman dizilerindeki deęişiklięin rasgele veya deterministik bir iřlemin sonucu olup olmadıęı incelenmiřtir. 8 adet normal bireyin orta beyin arterlerindeki kan akıř hızları 50 saniye boyunca ölçölmöř ve en yüksek kan akıř hızları incelenmiřtir. Elde edilen zaman dizileri kullanarak çekiciler oluřturulmuř ve iki boyutlu faz uzayında çizilmiřtir. TCD zaman dizilerinin çekicileri, kardiyovasköler sistemin sergileyebileceęi tüm durum aralıklarını göstermektedir. Çekicilerin geometrik yapısı, ilinti boyutunun hesaplanması ile ortaya çıkarılabilmektedir. İlinti boyutu, TCD zaman dizilerinin zamansal evriminin temel olarak periyodik olduęunu ve düřük boyutlu kaos ile karakterize edilebileceęini göstermektedir. Hypocapnia boyunca ortaya çıkan ilinti boyutu deęeri, normocapnia boyunca ortaya çıkan ilini boyutuna göre belirgin olarak yüksek bulunmuřtur.

2.3. Biyomedikal Sinyallerin Otomatik Sınıflandırılması

Göler ve ark. (2002), beyin damarlarından kaydedilen TCD sinyalleri üzerinde hızlı Fourier dönuřümü ve adaptif ARMA yöntemlerini karřılařtırmıřlardır. Bu çalıřmada, 35 bireyin beyin temporal bölgesindeki orta beyin arterinden kaydedilen TCD Sinyalleri bir kiřisel bilgisayara 16-bit ses kartı kullanılarak aktarılmıřtır. Hızlı Fourier Dönuřümü ve Adaptif Autoregressive Moving Average (A-ARMA) yöntemleri TCD frekanslarına uygulanmıřtır. Tıbbi teřhisi geliřtirmek adına her iki yöntemi karřılařtırmak için spektral analizleri elde edilmiřtir. A-ARMA yöntemi ile elde edilen sonogramlar HFD yöntemiyle elde edilenlerden daha iyi spektral çözünürlük saęlamıřtır. A-ARMA yöntemiyle elde edilen sonogramlar net zarf ve daha iyi görüntöleme sunmuř, böylece kan akıřını ve beyin içi basıncı belirlemede daha doęru sonuçlar saęlamıřtır. Hastalıklı bireylerin damarları saęlıklara göre kan akıřına daha fazla direnç göstermektedir. Yařın ölçömlere bir etkisinin olmadıęı görölmöřtür. İncelenen beyin rahatsızlıkları beyin damarında balonlařma, beyin kanaması, beyin iltihabı, beyinde su toplama, beyin travması ve beyin tümöruüdür. Her hasta için beyin içi basıncını gösteren direnç indeksi hesaplanmış ve listelenmiřtir. Hastalık sınıfları arasındaki direnç deęerleri birbirinden farklı olmakla birlikte, aynı hastalık grubuna ait bireylerin direnç deęerleri yakın bulunmuřtur.

Ergun ve ark. (2004), diyabetli hastaların karotid arter tıkanıklığını sinir ağları ve lojistik regresyon ile sınıflandırmışlardır. 168 adet diyabetli hastanın karotid arterlerinden kan akış hemodinamiği 7.5 Mhz ultrason Doppler M-unit cihazı ile elde edilmiştir. Hızlı Fourier Dönüşümü (HFD) yöntemleri, zaman-frekans kümesinde Doppler sinyallerinden özellik çıkarımı için kullanılmıştır. Doppler sonogramlarından elde edilen parametreler matematiksel modellere uygulanarak, diyabetin internal karotid arter (ICA) tıkanıklığına (stenosis) etkisi incelenmiştir. Doppler parametrelerini sınıflandırmak için kullanılan iki matematiksel modelden biri lojistik regresyon diğeri Çok Katmanlı Algılayıcı Sinir Ağıdır. Veriler matematik modellere uygulanmadan önce, uzman bir radyolog tarafından anjiyografi kullanılarak sınıflandırılmıştır. Matematiksel modellerde sınıflandırılacak veriler öncelikle karotid arter tıkanıklığın olup olmasına göre iki sınıfa ayrılmıştır. Her iki model için de %92.8 olmak üzere aynı sınıflandırma doğruluğu elde edilmiştir. Tıkanıklık dereceleri %0-39, %40-59, %60-79 ve %80-99 olmak üzere 4 farklı sınıf olarak düşünülmüştür. Tıkanıklık derecesi arttıkça sinir ağı %73.9 ile %67.7 performanslı lojistik regresyon analizden daha iyi performans göstermiştir. Bu sonuçlara göre, karotid arterlerden alınan Doppler sinyallerinin sinir ağları ile başarılı biçimde sınıflandırılabilceği sonucuna varılmıştır.

Serhatlıoğlu ve ark. (2003), TCD sinyallerini yapay sinir ağı ile sınıflandırmışlardır. 90 tanesi normal ve 20 tanesi hasta olmak üzere 110 bireyin beyinlerinin temporal bölgesinden kaydedilen TCD sinyalleri 16-bit ses kartı ile kişisel bilgisayara aktarılmıştır. TCD sinyallerine Hızlı Fourier Dönüşümü (HFD) uygulanmıştır. HFD yöntemi yüksek hızlı burgaç akımlarında iyi bir spektral çözünürlük sunmadığı için, bazen TCD sinyallerinin yanlış yorumlanmasına neden olabilmektedir. Doğru ve hızlı teşhis yapabilmek için, TCD sinyalleri istatistiksel olarak düzenlenerek yapay sinir ağına sınıflandırılmıştır. Geri yayımlı sinir ağı ve Kendini Düzenleyen Harita yapay sinir ağı, momentum ve delta-bar-delta algoritmaları kullanılarak eğitilmiştir. Bu algoritmaların sonuçları sınıflandırma ve öğrenmede karşılaştırılmıştır. Momentum algoritması ile eğitilen Geri Yayılmalı Sinir Ağı normal bireyler için %96.66 doğruluk oranı, hastalar için %92.30 doğruluk oranı göstermiştir. Geri Yayılmalı Sinir Ağı, delta-bar-delta algoritması ile eğitildiğinde normal bireyler için %96.66 doğruluk oranı, hastalar için %84.61

doğruluk oranı göstermiştir. Kendini Düzenleyen Harita, momentum algoritması ile eğitildiğinde normal bireyler için %90 doğruluk oranı ve hastalar için %84.61 doğruluk oranı vermiştir. Kendini Düzenleyen Harita, delta-bar-delta ile eğitildiğinde normal bireyler için %86.66 doğruluk oranı ve hastalar için %69.23 doğruluk oranı vermiştir.

Übeyli ve Güler (2005) yaptıkları çalışmada, iç karotid arter tıkanıklığı (stenosis) ve kapanması (occlusion) tespiti için Adaptif Sinir Ağı Bulanık Çıkarım Sistemine (ASABÇS) dayalı yeni bir yaklaşım sunmuşlardır. Bu amaçla, 130 bireyin iç karotid arter Doppler sinyali kaydedilmiştir. 130 bireyin, 45 tanesinde iç karotid arter tıkanıklığı, 44 tanesinde iç karotid arter kapanması bulunmaktadır. Geri kalan 41 birey sağlıklıdır. Üç farklı iç karotid arter durumunun (normal, tıkanıklık ve kapanma) tespiti için, 3 farklı ASABÇS sınıflandırıcısı kullanılmıştır. Sınıflandırıcılara, iç karotid arter Doppler dalga biçimlerindeki değişimleri tanımlayan direnç (resistivity) ve atım (pulsatility) indisleri giriş değerleri olarak uygulanmıştır. Teşhis doğruluğunu artırmak için, dördüncü bir ASABÇS sınıflandırıcı (birleştirici ASABÇS), önceki 3 ASABÇS sınıflandırıcısının çıkışları giriş olarak kullanılarak eğitilmiştir. Önerilen modelin seçiciliği %96.43, tıkanıklık için duyarlılığı %96.77, kapanma için duyarlılığı %96.55 ve toplam sınıflandırma doğruluğu %96.59 olarak bulunmuştur.

Güler ve ark. (2002), hızlı Fourier dönüşümü analizi yapılan kardiyak Doppler sinyallerini bulanık algoritmaya uygulamışlardır. Bu çalışmada, 60 bireyin tricuspid, mitral ve aorta kapakçıklarının çıkışından kaydedilen Doppler sinyalleri 16-bit ses kartı ile kişisel bilgisayara aktarılmıştır. Hastalara ait kardiyak sinyaller öncelikle kardiyoloji uzmanlarınca sınıflandırılmıştır. 60 bireyin 10 tanesi sağlıklı, 15 tanesi hipertansiyon, 8 tanesi tricuspid yetmezlik, 5 tanesi aorta yetmezliği, 5 tanesi mitral yetmezliği, 10 tanesi mitral tıkanıklığı ve 7 tanesi aorta yetmezliği hastasıdır. Hastalardan kaydedilen sinyallere HFD yöntemi uygulanmıştır. Doğası gereği HFD yöntemi, yüksek türbülanslı kan akışlarında iyi bir spektral çözünürlük sunamadığı için, bazen kardiyak Doppler sinyalinin yanlış biçimde yorumlanmasına neden olmaktadır. Bu sorunu aşmak için, öncelikle bilinen sınıflara ait kalp sinyalleri (hipertansiyon, mitral tıkanıklık, mitral bozukluk, tricuspid yetmezlik, aorta tıkanıklığı, aorta yetmezliği ve sağlıklı) bulanık algoritmaya uygulanmıştır. Daha

sonra, rahatsızlığı bilinmeyen 15 hastanın sinyali rahatsızlığın türünü tespit etmek için aynı bulanık algoritmaya uygulanmıştır. Kardiyak sinyallerine ait sistol ve diyastol değerleri kullanılarak bulanık kurallar oluşturulmuştur. Eğitim verileri için doğru sınıflandırma oranı %98.33 olarak ve test verileri için doğru sınıflandırma oranı %100 olarak bulunmuştur.

Übeyli ve Güler (2005)'in, oftalmik arter Doppler sinyallerindeki değişimin Lyapunov üstelleri ile belirlenmesi üzerine yaptıkları çalışmada geliştirilen yöntem, oftalmik arter Doppler sinyallerinin kaotik olduğu düşüncesine dayandırılmıştır. Bu düşünce, Lyapunov üstellerinin hesaplanması gibi doğrusal olmayan dinamik araçları kullanılarak başarılı biçimde test edilmiştir. Sinyallere ait 128 adet Lyapunov üsteli yerel Jacobi matrisleri kullanılarak hesaplanmıştır. Lyapunov üstelleri Çok Katmanlı Algılayıcı Sinir Ağı (ÇKASA)'na oftalmik arter Doppler sinyallerinin fiziksel durumundaki tıkanıklık, Behçet hastalığı ve göz iltihabı gibi değişimleri belirlemek için uygulanmıştır. Oftalmik arter Doppler sinyallerinden hesaplanan Lyapunov üstelleri ÇKASA'ya girdi olarak uygulanmıştır. 214 adet bireyin 80 tanesi eğitim için, geri kalan 134 tanesi test için kullanılmıştır. Eğitim işlemi 500 adımda, ortalama kare hata 0.000533 olacak şekilde yapılmıştır. Alıcı Çalışma Karakteristiği (ROC) eğrisi, doğru tespit etme işleminin performansını tayin etmek için kullanılmıştır. Oftalmik arter Doppler sinyalleri, %93.75 ila %97.06 arasında değişen doğrulukla sınıflandırılmıştır. Elde edilen sonuçlara göre, Levenberg-Marquart algoritması ile eğitilen ÇKASA mimarisinin oftalmik arterlerdeki tıkanıklık, Behçet hastalığı ve göz iltihabı rahatsızlıklarını tespit etmede önemli bir potansiyele sahip olduğu görülmüştür. Test verilerinin eğitilmiş olan ÇKASA'ya uygulanması sonucu seçicilik %95.35, oftalmik arter tıkanıklığı için duyarlık %93.75, Behçet hastalığı için duyarlık %97.06, göz iltihabı için duyarlık %96 ve toplam sınıflandırma doğruluğu %95.52 olarak bulunmuştur.

3. MATERYAL VE METOT

TCD sinyallerinin hastalardan alınması için kullanılan sistemin donanımı ve TCD inceleme tekniği aşağıdaki bölümde açıklanmıştır. Bölüm 3.2’de kaos teorisi açıklanarak, kullandığı yöntemler verilmiştir. TCD sinyallerinden kaos teorisi yöntemleri ile elde edilen ölçütlerin sınıflandırılması için kullanılan yapay zeka yöntemleri Bölüm 3.3’te anlatılmıştır. Elde edilen sonuçların değerlendirilmesi için kullanılan istatistiksel yöntemler Bölüm 3.4’te açıklanmıştır.

3.1. TCD Sinyallerinin Elde Edilmesinde Kullanılan Sistemin Donanımı

TCD sinyallerinin elde edilmesi için kullanılan sistem 4 bloktan oluşmaktadır. Bunlar; 2 Mhz’lik ultrasonik dönüştürücü, analog Doppler ünitesi (Multi Doppler Transducer XX, DWL Gmb, Uberlingen, Germany), analog/sayısal arabirim kartı (Sound Blaster Pro-16), Sony kaydedici, Pentium III 600 Mhz işlemcili bir kişisel bilgisayar ve yazıcıdır.

Analog Doppler ünitesi hem sürekli hem de darbeli olarak çalışabilmekte ve örnek uzunluğunun beyin damarları üzerinde istenen bir yerine yerleştirebilmesini mümkün kılan bir ultrasonik görüntüleme ünitesi de içermektedir. Bu çalışmada, analog Doppler ünitesi darbeli ve sürekli moda kullanılmış ve beyin içi kan akışı incelenmiştir.

Analog Doppler cihazı çıkışındaki Doppler işareti teybe kaydedilip, bir ses kartı yardımıyla örneklenerek sayısal bilgiye dönüştürölüp kişisel bilgisayara aktarılmıştır.

3.1.1. Transcranial Doppler İnceleme Tekniği

Beyin içi kan akış ölçümlerinin yapılması gelişmiş görüntüleme yöntemleri gerektirir. Tıpta kullanılan Doppler tekniği klasik Doppler yönteminden farklıdır. İnsan vücudundaki hedefler ışınım yapmadığı için, vücut içine bir sinyal gönderdikten sonra gönderilen ve hedeflerden yansımaları sonucu algılanan sinyallerdeki frekans değişimlerinin gözlenmesi gereklidir. Bu koşullarda, ultrason frekansında aşağıdaki gibi bir kayma olur.

$$f_d = f_t - f_r = 2f_t v \cos \theta / c \quad (3.1)$$

Yukarıdaki formülde f_t ve f_r gönderilen ve alınan ultrason frekansları, v hedefin hızı, c sesin ortamdaki hızı ve θ ultrason sinyali ile hedefin hareket yönü arasındaki açıdır. Sesin ortamdaki hızı c hemen her yumuşak doku için sabit olup 1540 m/sn'dir. Formülün başındaki 2 sayısı ultrason dalgasının hareketli hedefe gidip dönüştürücüye geri gelmesi gerektiğini belirtir. Doppler eşitliğinde θ açısının önemi büyüktür. Eğer θ açısı 0° ise $\cos \theta = 1$ olduğundan maksimum Doppler fark frekansı elde edilir. θ açısı büyüdükçe ölçülen Doppler fark frekansı azalır. Eğer θ , 90° ise $\cos \theta = 0$ olacağı için kan akışı ile ilgili hiçbir bilgi alınamayacaktır. Doppler fark frekansı sabit bir açıda kan akış hızına doğrudan orantılıdır. Sabit bir akış hızı, c ve dönüştürücü frekansında θ açısının değişmesi Doppler fark frekansının değişmesindeki tek parametredir. Hız ölçümü sırasında akış yönü ile ultrasonik ses demeti arasındaki açının artması, ölçüm doğruluğunu olumsuz yönde etkiler. Ultrasonik dalga ile damar arasındaki açı 90° 'ye yaklaştıkça kan akış hızı ölçümündeki hata artar (Burns 1995).

Ultrasonografik Doppler yöntemi kan akış bilgileri ile bir organ veya sistemin fonksiyonel yönden incelenmesini sağlar. Ultrason doku derinliğinden geri yansırken görüntü alanına ait iki boyutlu görüntüyü ve damarlarda seyreden kırmızı kan hücrelerinden yansırken de akış bilgisini spektral olarak oluşturur. Böylece morfolojik ve fonksiyonel değerlendirmeler yapılabilir (Taylor ve Holland, 1990, Weds 1995, Zwiebel 1995)

Bir ses dalgası kaynağı dinleyiciye veya alıcıya yaklaştığında sıkışır ve frekansı artar, uzaklaşırken de frekansı azalır. Aynı olay hareket eden bir kan hücresine ultrason dalgası gönderildiğinde de gözlenebilir. Ultrasonik dönüştürücü, hareketli kan hücresine doğru ses ulaştıran sabit bir verici istasyon ve oradan yayılan dalgaları toplayan sabit bir alıcı istasyon görevini yapar.

TCD, beyin içi damarlarındaki kan akışını incelemek ve beyin performansını görüntülemek amacıyla Nöroşirürjide kullanılmaktadır. Basit algılama cihazları kullanılarak büyük damarlarda faydalı ölçümler yapılabilir. Fakat beyin içi çalışmalar için genellikle ayrıntılı görüntüleme yöntemleri gerekir.

Kafa içi arterlerin incelenebilmesi için dört farklı TCD yaklaşımı tanımlanmıştır. Bunlar: transtemporal, transorbital, suboksipital ve submandibular yaklaşımdır. Bu projede incelenecek rahatsızlıklar orta beyin arterinin incelenmesi

ile ele alınacağı için sadece transtemporal yaklaşımın kullanılması yeterlidir. Transtemporal yaklaşımda prob, başın şakak kemiği kısmına, elmacık kemiği yayı üzerine yerleştirilir. Burası genellikle en çok önerilen inceleme bölgesidir. Ön ya da arkaya doğru açı verilebilir. Atımın ön tarafa yönlendirilmesi, orta beyin arterinin ve ön beyin arterinin incelenmesine olanak sağlar.

Doppler spektrum analizleri ile incelenen damar yapısına ait PSH (Pik Sistolik Hız), DSH (Diyastol Sonu Hız), V_{ort} S/D (sistol/diyastol) oranı, RI (Rezistans (Direnç) İndeksi) ve PI (Pulsatilité (Darbe) İndeksi) gibi değerler hesaplanabilmektedir (Lupetin ve ark., 1995, Otis ve Ringelstein, 1992). Hız ölçümlerinin doğruluğu için elektronik açı düzeltme işlemi yapılması gereklidir. Bunun için incelenen damar mümkün olduğunca düz ve uzun bir parça olarak ortaya konmalıdır. Bu yapıldığında düzeltme açısı da kabul edilir en küçük düzeyde olacak ve kaydedilen hız ölçümleri ve spektral analiz değerleri doğru çıkacaktır. İncelemelerde düzeltme açısı hiç bir zaman 45° 'yi geçmemelidir (Martin ve ark., 1994).

3.2. Kaos Teorisi ve Yöntemleri

3.2.1. Kaos Teorisi

Kaos teorisi, insan beyni gibi pek çok parametreye bağlı olan karmaşık sistemlerin dinamiğinin anlaşılmasında çok güçlü yöntemler sağlamaktadır. Bu yöntemler özellikle tek boyutlu zaman dizisi verilerinin analizinde çok değerlidir. Takens (1981) teorisine göre, doğrusal olmayan dinamik bir sistem çok boyutlu olsa bile sadece bir değişkeninin ürettiği zaman dizisi kullanılarak sistemin davranışı modellenebilir. Böyle bir sisteme ait faz uzayının geometrik ve topolojik yapısını gösteren kaotik çekici, tek bir değişkenin zaman dizisinin belli bir zaman gecikmesi ile örneklenmesi ile oluşturulabilir.

Kaotik sistemler, tam olarak deterministik sistemler ile tamamen düzensiz ve rasgele sistemlerin arasında yer alır. Kaotik sistemlerin en önemli özelliği başlangıç koşullarına hassas biçimde bağlı olmalarıdır. Deterministik bir sistemin başlangıç durumu ve denklemleri biliniyorsa, sistemin sonraki davranışı belirlenebilir. Kaotik sistemlerde, sistemin zaman içindeki gelişimini tam olarak belirleyebilmek için başlangıç değerlerini sonsuz hassasiyetle bilmek gerekmektedir. Teorik olarak

sonsuz hassasiyete sahip ölçümler imkansız olduğundan, deterministik olmalarına rağmen kaotik sistemlerde uzun dönemli tahmin yapılamaz. Öte yandan, kaotik sistemlerde kısa süreli yerel tahminler oldukça başarılı biçimde yapılabilir (Yang ve Duan, 2003, Iokibe ve Fujimoto, 2001, Baker 1990, Williams 1997).

Doğrusal analiz teknikleriyle incelendiğinde kaotik zaman dizileri gürültü olarak algılanır. Fakat, faz uzayında global olarak bakıldığında kaotik zaman dizisinin belli bir yapıya sahip olduğu görülür. Bu yapıya kaotik çekici denir. Kaotik çekicilerin, sistem dinamiği hakkında değerli bilgiler sağlayan ölçütleri vardır. Bu ölçütler arasında çapraz tahmin hataları, karşılıklı bilgi, öz ilinti değeri, Shannon entropisi, Lyapunov üstelleri ve ilinti boyutu sayılabilir. Kaotik çekicinin dinamiği ve geometrisi hakkında bilgi veren değişmez ölçütler, sırasıyla en büyük Lyapunov üsteli ve ilinti boyutudur. Çekicilerin oluşturulacağı sözde faz uzayının içereceği eksen sayısını belirleyen gömülme boyutu ile τ zaman gecikmesi değerleri çok kritiktir. Bunlar doğru olarak belirlenemezse çekicini oluşturulması mümkün olmaz. Bu durumda, ilinti boyutu ve Lyapunov üstelleri gibi kaotik ölçütlerin hesaplanması da yapılamaz. Takens (1981) teoremine göre, eğer çekicinin gerçek boyutu D_A ise, D_E gömülme boyutunun $D_E > 2D_A$ olacak şekilde seçilmesi yörüngelerin kesişmesini önleyerek periyodik olmayan bir akışa neden olur.

Bir veri kümesinde tespit edilen yapıların tamamı doğrusal olmayan dinamik tarafından üretilmiş olmayabilir. Doğrusal stokastik süreçler de çok karmaşık görünümlü sinyaller üretebilir. Dolayısıyla, sinyalde görülen yapının doğrusal olmayan süreçle mi ortaya çıktığı yoksa doğrusal ilintilerle açıklanabilir olup olmadığı belirlenmelidir. Sinyalde görülen düzensizlik doğrusal olmayan determinizmle ortaya çıkmış olabilir, ya da sisteme dışardan verilen rasgele girdiler ya da sistem parametrelerindeki değişimlerin sonucu olabilir. Kaos, teorik olarak, doğrusal olmayan deterministik sistemlerde ortaya çıktığı için, TCD sinyallerinden elde edilen zaman dizisinin doğrusal olmadığını gösterilmesi gereklidir. Bu amaçla kullanılan yöntemler arasında en yaygını yapay veriler testidir. Bu yöntemde, gözlenen veri kümesi ile aynı uzunlukta ve aynı ortalama, varyans veya güç spektrumu değerlerine sahip yapay veri kümeleri üretilir. Doğrusalsızlığa duyarlı bir ayırıcı istatistiksel değer yapay veriler ve orijinal zaman dizisi için hesaplanır. Kriter olarak seçilen ayırıcı istatistik değerinin, orijinal zaman dizisi ile yapay diziler

arasında farklı olması durumunda orijinal zaman dizisinin doğrusal olduğuna dair hükümsüz hipotez reddedilir.

Kaos teorisi yöntemleri zaman dizisinin faz uzayında gömülmesiyle elde edilen veri kümelerinin durağan olmasını (stationarity) gerektirir. Bir sinyalin hangi seviyede durağan kabul edileceği uygulamadan uygulamaya değişir. Öncelikli olarak, elde edilen zaman dizisinin incelenen sistemin karakteristik dinamiğini gösterecek zaman aralığı kadar uzun olması gereklidir. Örneğin; kan şekeri yiyecek tüketimi ile ilgilidir ve 24 saatlik bir periyotta izlenmelidir. Eğer ölçüm 24 saatten az bir zamanda yapılırsa, eldeki veri sayısı ne olursa olsun sürecin durağan olmadığı kabul edilir. Durağan veri kümelerinde ortalama ve varyans gibi ikinci seviye moment değerleri zaman içinde değişim göstermez. Buna zayıf durağanlık denir. Doğrusal analiz yöntemleri sinyallerde bu seviyede durağanlık olmasını gerektirirken, kaotik bir sistemin analizinde zayıf durağanlık genellikle yeterli olmaz (Sprott, 2002). Sentetik kaotik sistemlerde, denklem parametrelerindeki değişimler ortalama veya olasılık dağılımında herhangi bir değişime neden olmayabilmekte, sinyaldeki doğrusal ilintiler veya spektrum dağılımı da bundan etkilenmeyebilmektedir. Sadece, doğrusal olmayan dinamik ilişkiler ve geçiş olasılıkları belirgin biçimde değişmektedir. Bu değişim, zaman dizisinin değişik kesimlerindeki doğrusal olmayan tahmin hataları ile tespit edilebilmektedir (Kantz ve Schreiber, 2005). Kaos teorisi yöntemleri zaman dizilerinin gömüldükleri faz uzayında durağan olmasını gerektirir. Faz uzayındaki noktalar arasındaki uzaklıklar ilinti boyutu, Lyapunov üstelleri gibi nicel kaotik ölçütlerinin hesaplanmasında kullanılır. İlinti boyutu hesabı, zaman dizisinin durağan olmamasından önemli ölçüde etkilenmektedir. Zaman dizisinin durağan olmaması veya az sayıda veri içermesi ilinti boyutu değerinin olması gerekenden düşük çıkmasına neden olmaktadır.

3.2.2. Doğrusalsızlık Analizi

TCD sinyallerine kaos teorisi tekniklerini uygulamadan önce, sinyallerin doğrusal olmadığı gösterilmelidir. Bir sistemin doğrusal olmayan bileşenler içermesi, bu sistemden ölçülen belirli bir sinyalin de doğrusal olmamasını gerektirmez. Doğrusal stokastik süreçler de çok karmaşık görünümlü sinyaller üretebilir ve bir zaman dizisinde bulunan tüm yapılar doğrusal olmayan dinamiğe bağlı olmayabilir.

Ayrıca, doğadaki pek çok süreç doğrusal olmamasına rağmen, dinamiklerinin belirli özelliklerinde doğrusallık olabilir. Bir zaman dizisinde görülen karmaşık yapılar doğrusal olmayan sürece bağlı olabileceği gibi doğrusal ilintilerle de açıklanabilir. Zaman dizisinde görülen düzensizlik (periyodik olmama) doğrusal olmayan determinizm sonucu değil, sisteme dışardan verilen rasgele girdiler veya sistem parametrelerindeki değişimler sonucu oluşmuş olabilir (Kantz ve Schreiber, 2005). Zaman dizilerinin doğrusal olup olmadığını tespit etmek için çeşitli yöntemler geliştirilmiştir (Theiler ve ark., 1992, Takens 1993, Kaplan ve Glass 1992, Shreiber ve Schmitz, 1996, Yu ve ark., 1999). Bunlar içinde literatürde en çok kullanılan Theiler ve ark. (1992) tarafından önerilen yapay veri (surrogate data) yöntemidir.

Bu tez çalışmasında, TCD zaman dizilerinin doğrusal olup olmadığını tespit etmek için istatistiksel bir yaklaşım olan yapay veri yöntemi uygulanmıştır. Yapay veriler orijinal veriyi belli değerler ve parametrelere göre kıyaslayacak bir referans oluşturur. Orijinal zaman dizisinin doğrusal olmayan dinamiğini ortaya çıkarmak yerine, orijinal zaman dizisinin doğrusal bir model tarafından üretilmediğini göstermek yeterlidir. Bunun için genel olarak, ‘orijinal zaman dizisi doğrusal bir model tarafından üretilmiştir’ şeklinde bir hükümsüz hipotez belirlenir. Kriter olarak seçilen ayırıcı istatistik değerinin, orijinal zaman dizisi ile doğrusal Gaussian stokastik işlemle üretilmiş yapay diziler arasında belirgin biçimde farklı olması durumunda bu hükümsüz hipotez reddedilir. Bu durumda orijinal zaman dizisinin doğrusal olmadığı sonucuna varılır. Ayırıcı istatistik olarak, Lyapunov üstelleri, ilinti boyutu, tahmin hataları, kararsız periyodik yörüngeler (Pierson ve Moss, 1995, So ve ark., 1996) gibi faz uzayından elde edilen ölçütler yanında zaman asimetrisi (Diks ve ark., 1995) veya yüksek seviyeli momentler (Rao ve Gabr, 1984) gibi *zayıf* doğrusalsızlık ölçütleri de kullanılabilir. Eğer ayırıcı istatistik değeri, veri kümesi ile yapay veri kümesi arasında belirgin biçimde değişiyor ise sistem doğrusal değildir. Schreiber ve Schmitz (1997), değişik ölçütlerin zaman dizilerindeki doğrusalsızlık testlerindeki ayırıcı güçlerini incelemişlerdir. İlgili yayında, tahmin hatası değeri ile zaman asimetrisi ölçütlerinin farklı zaman dizileri için en iyi sonucu verdiği belirtilmektedir. Yapay veriler yönteminden farklı olarak, zaman dizisinin sembolik gösteriminden elde edilen histogram analizi yöntemi (Hao, 1989) sinyallerdeki zaman asimetrisini tespit etmede kullanılmıştır.

Schreiber ve Schmitz (1996)'ın öne sürdüğü Tekrarlı Genlik Ayarlı Fourier Dönüşümü (Iterative Amplitude Adjusted Fourier Transform – IAAFT) yapay veri kümelerini üretmek için kullanılmıştır. Bu yöntem, orijinal zaman dizisi ile yapay veri kümesi arasındaki spektrum ve dağılım farklılıklarını tekrarlı olarak düzeltmektedir. Fourier tabanlı bu yöntemle yapay veri üretirken, zaman dizisini üreten model denklemleri değil zaman dizisinin ölçülebilir özellikleri göz önüne alınır. Doğrusal özellikler, aşağıdaki gibi ayrık Fourier dönüşümünün genlik kareleri ile belirlendiğinde

$$|S_k|^2 = \left| \frac{1}{\sqrt{N}} \sum_{n=0}^{N-1} s_n e^{i2\pi kn/N} \right|^2 \quad (3.2)$$

$\{\bar{s}_n\}$ yapay zaman dizileri, verilerin Fourier dönüşümünün rasgele fazlar ile çarpılmasından sonra tekrar zaman kümesine dönüştürülmesi ile elde edilir.

$$\bar{s}_n = \frac{1}{\sqrt{N}} \sum_{k=0}^{N-1} e^{i\alpha_k} |S_k| e^{-i2\pi kn/N} \quad (3.3)$$

Yukarıdaki denklemde α_k , 0 ile 2π arasında bağımsız rasgele sayılardır.

Genlik Ayarlı Fourier Dönüşümü (Amplitude Adjusted Fourier Transform – AAFT) yöntemi ilk olarak Theiler ve ark. (1992) tarafından önerilmiştir. Doğrusal olup olmama testi için gereken verilerin üretilebilmesi için N değerinin büyük olması, veri kümesindeki ilintinin çok güçlü olmaması ve $s(\cdot)$ 'nin özdeşliğe yakın olması gereklidir. Aksi halde, çok düz spektruma doğru belirli bir meyil vardır.

AAFT yöntemi ile yapay zaman dizileri üretirken, zaman dizisinin ilk ve son değerleri arasındaki farkın az olmasına dikkat edilmelidir. Aksi halde, aradaki bu atlama üretilen yapay zaman dizilerine gürültü olarak eklenecektir. Bu yüzden, öncelikle zaman dizisinin ilk ve son değerleri arasındaki farkın en az olduğu aralık bulunmalıdır (Theiler 1993). Yapay verileri üretmede Fourier genliklerinin kullanılabilmesi için zaman dizisinin kendini her N adımda tekrar eden bir periyotluk dizi olması gereklidir. Bu yüzden, doğrusalsızlık testlerinin yanlış sonuç vermemesi için, yapay verileri üretmeden önce zaman dizisinin uygun bir bölümünü seçmek gereklidir. Spektral hesaplamada, kenar etkilerinin meydana getirdiği problemleri gidermek için pencereleme veya sıfır ekleme gibi yöntemler kullanılır. Fakat bu yöntemler dönüşümün geriye dönülebilirliğini yok ettiği için, yapay verilerin

fazlarının rasgele değiştirilmesinde başarılı biçimde uygulanamazlar. Zaman dizisi sonunun uymazlık ölçütü aşağıdaki gibi,

$$\gamma_{atlama} = \frac{(s_1 - s_N)^2}{\sum_{n=1}^N (s_n - \langle s \rangle)^2} \quad (3.4)$$

ve ilk türevdeki uymazlık


$$\gamma_{kayma} = \frac{[(s_2 - s_1) - (s_N - s_{N-1})]^2}{\sum_{n=1}^N (s_n - \langle s \rangle)^2} \quad (3.5)$$

ile verilmiş olsun.

Bu durumda $0 < j < 1$ olmak üzere ağırlıklı uymazlık aşağıdaki gibi olacaktır.


$$j * \gamma_{atlama} + (1 - j) * \gamma_{kayma} \quad (3.6)$$

Zaman dizisi bölümünün uzunluğu, sadece 2, 3 ve 5'in katları olacak şekilde adım adım azaltılır. Ağırlıklı uymazlık değerinde bir artmanın olduğu zaman dizisi bölümü, yapay verileri üretmek için kullanılır.




Şekil 3.1. Orijinal zaman dizisi ve bu dizinin ilk ve son nokta değerlerinin birbirinden çok farklı olması durumunda üretilen yapay zaman dizisi

Yukarıdaki şekilde, üst kısımda $s_n = 1.9s_{n-1} - 0.9001s_{n-2} + \eta_n$ denklemi ile üretilen 1500 verilik zaman dizisinin ilk ve son noktaları arasında büyük bir fark görülmektedir. Bu zaman dizisinin periyodik olarak devam ettiği düşünülürse s_{1500} ve s_1 noktaları arasında bir atlama görülecektir. Yapay zaman dizilerinde orijinal zaman dizisindeki Fourier genliklerini korunacağı için, fazlar rasgele dağıtılmış olacaktır ve bu atlamaların spektral değeri zaman içinde dizi boyunca dağıtılacaktır. Yukarıdaki şeklin alt kısmında görülen yapay zaman dizisinde, atlamaların neden olduğu spektral güç yüksek frekans bileşeni olarak yansımıştır.



Şekil 3.2. Orijinal zaman dizisi ve bu dizinin ilk ve son nokta değerlerinin birbirine yakın olması durumunda üretilen yapay zaman dizisi

Yukarıdaki şekilde, $s_n = 1.9s_{n-1} - 0.9001s_{n-2} + \eta_n$ denklemi ile üretilen zaman dizisinin ilk ve son noktaları birbirine yakın olacak şekilde 1350 verilik kısmının kesilmesi sonrasında üretilen yapay zaman dizisinin sahte yüksek frekans yapısı içermediği görülmektedir.



Şekil 3.3. Yapay veri yöntemi

Yukarıdaki şekilde yapay veri yönteminin doğrusalsızlığın tespitinde nasıl kullanıldığı görülmektedir. Yapay veriler hükümsüz hipoteze uygun olarak üretilir. En genel hükümsüz hipotez orijinal zaman dizisinin Gauss dağılımlı gürültü ile bozulmuş doğrusal süreçle üretildiğidir. Bu tür süreçlere ARMA (autoregressive

moving average) süreçleri denir. Genel olarak ARMA süreçleri ortalama, varyans ve güç spektrumu ile belirlenebilir. Güç spektrumu ARMA katsayıları ile tam olarak ifade edilebilmektedir ve güç spektrumu sürecin tam bir istatistiksel tanımını verir.

$$X_n = a_0 + \sum_{i=1}^{M_{AR}} a_i x_{n-i} + \sum_{j=0}^{M_{MA}} b_j \eta_{n-j} \quad (3.7)$$

Örneğin; yukarıda verilen ARMA sürecine ait genel güç spektrum denklemi aşağıdaki gibi ifade edilebilir.

$$P(f) = (2\pi)^{-1} \frac{1}{\left| 1 + \sum_{i=1}^k a_i e^{jif} + \sum_{j=1}^l b_j e^{-jif} \right|^2} \quad (3.8)$$

Orijinal zaman dizisinin ARMA süreci ile üretildiğine dair hükümsüz hipoteze göre yapay veriler üretilirken, Ayırık Fourier dönüşümü ile orijinal zaman dizisinin Fourier genlikleri bulunmakta ve fazları Gauss dağılımına uyan bir rasgelelik ile karıştırılmaktadır. Böylece orijinal zaman dizisinin doğrusal özellikleri çıkarılarak doğrusal olmayan ilintiler yok edilmektedir. Fazların her defasında farklı biçimde karıştırılması ile ayrı bir yapay zaman dizisi üretilmektedir. Yapay verilerin ortalama, varyans ve güç spektrumu orijinal veri ile aynıdır. Bu yöntemle üretilen yapay veriler Gauss dağılımına uyarlar. Fakat orijinal zaman dizisi değerleri genellikle Gauss dağılımına uymazlar. Bu yüzden yapay verileri orijinal diziyle aynı dağılıma sahip hale getirmek gereklidir. Theiler ve ark. (1992) tarafından önerilen Genlik Ayarlı Fourier Dönüşümü yöntemi bunu sağlamaktadır. Bu yöntemde yapay verilerin üretiminde kullanılan hükümsüz hipotez şu şekildedir : “Orijinal zaman dizisi durağan bir ARMA süreci ile üretilmiştir. Fakat doğrusal olmayan statik bir ölçüm fonksiyonu zaman dizisini Gauss dağılımına uymayacak şekilde bozmaktadır.”. Buna göre yapay veriler aşağıdaki adımlar kullanılarak üretilir.

1. Gauss dağılımlı rasgele fonksiyon ile bir yapay zaman dizisi üretilir.
2. Orijinal zaman dizisine ait histogram küçükten büyüğe sıralanır.
3. Yapay zaman dizisinin histogramı orijinal zaman dizisi ile aynı olacak şekilde ölçeklendirilir (histogram dönüşümü).
4. Yapay zaman dizisinin güç spektrumu rasgele fazlarla karıştırılarak geçici bir yapay zaman dizisi üretilir.
5. Geçici yapay zaman dizisinin sıralı histogramı elde edilir.

6. Orijinal zaman dizisinin histogramı geçici yapay zaman dizisi ile aynı olacak şekilde ölçeklendirilir (histogram dönüşümü).

7. Bu şekilde değiştirilen orijinal zaman dizisine Genlik Ayarlı Fourier Dönüşümlü (GAFD) yapay zaman dizisi denir.

Bu yöntem orijinal zaman dizisi ile yapay veriler arasındaki genlik dağılımını korur. Fakat güç spektrumu bir miktar etkilenir. Schreiber ve Schmitz (1996)'ın önerdiği Tekrarlı Genlik Ayarlı Fourier Dönüşümü (Iterative Amplitude Adjusted Fourier Transform – IAAFT) yöntemi, orijinal veri ile yapay verilerin güç spektrumlarının birbirine daha yakın olmasını sağlar. Bu yöntemle ait adımlar aşağıda verilmiştir.

1. Orijinal zaman dizisinin Fourier katsayıları hesaplanır.
2. Orijinal zaman dizisinden GAFD yöntemi ile bir yapay veri üretilir.
3. Orijinal zaman dizisi ile yapay verinin Fourier katsayıları arasındaki fark belli bir seviyenin altına inene kadar aşağıdaki adımlar tekrarlanır.
 - 3.1. Yapay verinin Fourier katsayıları orijinal dizininkiyle değiştirilir.
 - 3.2. Yapay dizinin değişen Fourier katsayıları ve rasgele değiştirilen fazlarına ters HFD uygulanarak yeni yapay dizi elde edilir.
 - 3.3. Yeni yapay diziye ait histogram sıralanır.
 - 3.4. Orijinal zaman dizisinin histogramı yeni veri dizisiyle aynı olacak şekilde yapay veri dizisi üretilir (histogram dönüşümü).

Bu tez çalışmasında, üretilecek yapay veri kümelerinin sayısına karar vermek için, $\%(1-\alpha)$ 'lık bir istatistiksel belirginliğe karşılık gelecek şekilde, bir α yanlış karar verme olasılığı seçilmiştir (Schreiber ve Schmitz, 1996). Bu durumda, tek yönlü bir test için orijinal zaman dizisi de dahil olmak üzere $1/\alpha$ adet yapay veri kümesine ihtiyaç vardır. Yani, %95'lik bir istatistiksel belirginlik için en az 19 yapay veri kümesi üretilmelidir. Tek yönlü test, karşılaştıracağımız değer dağılımdan büyük veya küçük olup olmadığına bakar. Çift yönlü test ise, karşılaştırılacak değer dağılımdan farklı olup olmadığını bulur. Şayet, ayırıcı istatistik (λ) değerinin Gauss dağılımına uyduğunu bilseydik $\bar{\lambda} = \frac{1}{K} \sum_{i=1}^K \lambda_i$ ve $\sigma_{\lambda}^2 = \frac{1}{K-1} \sum_{i=1}^K (\lambda_i - \bar{\lambda})^2$ olmak üzere çift yönlü test için $|\lambda_0 - \bar{\lambda}| < 2\sigma$ şartı arayacaktık.

3.2.3. Durağanlık Analizi

Doğrusal ya da doğrusal olmayan, tüm zaman dizisi analiz yöntemleri, zaman dizisinin belli seviyede durağan olduğunu kabul eder. Böylece, ölçüm periyodu boyunca dinamikteki değişim genellikle analiz yönteminin istenmeyen bir komplikasyonu gibi düşünülür. Fakat bazı durumlarda, dinamikteki bu değişimler yapılan ölçümün en ilgi çekici yapıları olabilir. Örneğin; EEG (electroencephalographic) ölçümlerinin temel amacı, beynin dinamik durumundaki değişimleri tespit etmektir. Bu tür değişimler, farklı uyku evreleri arasında veya epileptik nöbetler ile normal beyin aktivitesi arasında meydana gelmektedir.

Doğrusal zaman dizisi uygulamalarının çoğunda, durağanlık sadece ikinci momentlere (ortalama, varyans veya güç spektrumu) kadar geçerlidir. Bu duruma zayıf durağanlık denir (Shreiber 1997). Doğrusal olmayan istatistik daha yüksek ilintiler, boyutlar, Lyapunov üstelleri ve olasılık dağılımları içerir (Islıker ve Kurths, 1993). Bu tez çalışmasında TCD zaman dizilerinin durağanlığını analiz ve tespit etmede kullanılan doğrusal olmayan çapraz-tahmin hatası yöntemi (Shreiber 1997), zaman dizisini oluşturan parçalar arasındaki benzerliği esas almaktadır. Diğer yöntemler, zaman dizilerinden yerel ortalamalarla elde edilen benzerlik parametrelerini kullanmaktadırlar. Bu çalışmadaki yöntem ise, bir zaman dizisini eşit parçalara ayırdıktan sonra, bu parçaların birbirlerine göre karşılıklı tahmin hatalarını hesaplayarak durağanlığı analiz etmektedir. Tahmin hatası hesaplama yöntemi zaman dizisinin faz uzayında gömülmesini yani çekicinin oluşturulmasını gerektirir. Böylece durağan olmama ölçütü, aynı zamanda dinamik değişmez ölçütleri (ilinti boyutu, Lyapunov üsteli vb.) sabit olan çekicinin faz uzayındaki değişimlerini ifade etmektedir. Bu yaklaşımda, zaman dizisini oluşturan kesimler istatistiksel parametreleriyle değil içerdikleri veriyle karşılaştırılmaktadır. Bu yaklaşım, zaman dizilerinin durağanlık seviyesinin incelenmesini ve ölçüm periyodu boyunca benzer dinamiğe sahip bölgelerle ilgili detaylı bilgi elde edilmesini sağlar. Böylece, dinamikte bulunan fiziksel olarak ilişkili değişimler izlenebilir.

Zaman dizisindeki nokta sayısı N ve parça uzunluğu l olmak üzere, hesaplanan parametre sayısı N/l 'den $(N/l)^2$ 'ye çıkmaktadır. Fakat bu yöntem, zaman dizisinin sadece durağan olup olmadığını söylemek yerine, dizinin değişik kesimlerinin durağanlığı hakkında da bilgi vermektedir. Kesimlerin durağanlığını

belirlemede kullanılacak γ parametresi, S_i kesiminin dinamiğinin S_j kesimine göreceli olarak değişimlerine duyarlı herhangi bir nicelik olabilir. Örneğin; Lyapunov üsteli kullanılmış olsaydı, S_i ve S_j kesimlerinden alınan iki farklı yörüngenin birbirinden uzaklaşması hesaplanacaktı. Fakat kullanılacak yöntemin kısa kesimler üzerinde tutarlı hesaplama yapabilmesi ve sağlam olması önemlidir. Doğrusal olmayan tahmin algoritmasından elde edilen hata değeri bu kriterleri sağlayan bir istatistiksel değerdir. Birkaç yüz veya daha az noktadan oluşan diziler bile için tutarlı sonuçlar vermektedir.

Bir X dizisi verildiğinde, Y dizisinin ortalama hatalar karesinin karekökü $\gamma(X, Y)$ aşağıdaki gibi belirlenir.

$$\gamma(X, Y) = \sqrt{\frac{1}{N_Y - m} \sum_{n=m}^{N_Y-1} (\hat{y}_{n+1}^X - y_{n+1})^2} \quad (3.9)$$

$\gamma(X, Y)$, X dizisinin dinamiğine yerel olarak sabit yaklaşıklığın Y dizisini tahmin etmek için ne kadar uygun olduğunu gösterir. Durağan bir zaman dizisi için, eğer işlemin tutarlılık zamanı l 'den küçük ise $\gamma(S_i^l, S_j^l)$ değerinin i ve j 'den bağımsız olması beklenir. Aksi halde, $\gamma(S_i^l, S_i^l)$ köşegensel terimleri $i \neq j$ durumlarındaki değerlerden daha küçük olacaktır.

Doğrusal olmayan çapraz tahmin yöntemi ile durağanlık analizinin nasıl yapıldığını, Baker haritası ile üretilen kaotik zaman dizisi üzerinde gösterelim.

$v_n \in [0,1]$, $\alpha, \beta \in]0,1[$ için aşağıdaki gibi tanımlanan bir Baker haritası için

$$v_n \leq \alpha \text{ için : } \begin{cases} u_{n+1} = \beta u_n \\ v_{n+1} = v_n / \alpha \end{cases} \quad (3.10)$$

$$v_n > \alpha \text{ için : } \begin{cases} u_{n+1} = 0.5 + \beta u_n \\ v_{n+1} = (v_n - \alpha) / (1 - \alpha) \end{cases} \quad (3.11)$$

2 adet Lyapunov üsteli aşağıdaki gibi hesaplanır:


$$\lambda_1 = \alpha \log \frac{1}{\alpha} + (1 - \alpha) \log \frac{1}{1 - \alpha} \quad (3.12)$$

$$\lambda_2 = \log \beta \quad (3.13)$$

Sadece β değiştirilerek, farklı dinamiklere fakat aynı en büyük Lyapunov üsteline sahip zaman dizileri üretmek mümkündür. Buradaki örnek için, $\alpha=0.4$ ile sabitlenip β değiştirilerek $u + v$ kaydedilmek suretiyle $N=40,000$ noktadan oluşan bir zaman dizisi aşağıdaki denklemle üretilmiştir.


$$x_n = \frac{w_n - \langle w \rangle_k}{\sqrt{\langle (w - \langle w \rangle_k)^2 \rangle_k}}, \quad w_n = u_n + v_n \quad (3.14)$$

Yukarıdaki denklemde $\langle \cdot \rangle_k$, $k=50$ olmak üzere $n'=n-k, \dots, n+k$ indislerindeki ortalamayı göstermektedir. Aşağıdaki şekilde her biri 1000 noktadan oluşan 40 kesime bölünmüş $N=40,000$ noktalık Baker haritası zaman dizisinin köşegensel çapraz tahmin hataları görülmektedir.



Şekil 3.4. $N=40,000$ veriden oluşan Baker haritası zaman dizisi için köşegensel çapraz tahmin hataları

Baker haritası zaman dizisi üzerinde çapraz tahmin hataları bulmak için kullanılan doğrusal olmayan tahmin algoritmasında gömülme boyutu $m=2$ ve komşuluk yarıçapı $\epsilon=0.25$ olarak kullanılmıştır. Köşegensel çapraz tahmin hatalarına bakınca sadece sonlara doğru durağanlığın kaybolduğu kararına varılabilmektedir. Aşağıdaki şekilde olduğu gibi tüm kesimlerin birbirlerine göre çapraz tahmin hataları, siyah kareler $\gamma_{ij} \leq 0.3$, beyaz kareler $\gamma_{ij} \geq 0.8$ ve gri seviye kareler bu ikisi arasındaki tahmin hatalarını gösterecek şekilde gösterildiğinde, zaman dizisi kesimleri birbirlerinden uzaklaştıkça tahmin hatasının arttığı görülmektedir.



Şekil 3.5. Baker haritası kaotik zaman dizisi için durağanlık resmi

Gömülme boyutu m ve komşuluk yarıçapı ε değerleri, doğrusal olmayan çapraz tahmin algoritması iyi tahmin değerleri üretecek şekilde seçilmelidir. Bu tez çalışmasında bu değerler $m=3$ ve $\varepsilon=0.25$ seçilmiştir. Kullanılacak kesim sayısını belirleyen iki farklı kriter vardır. Şayet istatistiksel olarak güvenilir değerler elde etmek istiyorsak kesim boyu büyük olmalı, yani daha çok nokta içermelidir. Şayet daha ayrıntılı durağanlık görüntüsü elde etmek istiyorsak kesim boyu küçük seçilmeli, yani daha çok kesim kullanılmalıdır.

Durağanlık analizinde literatürde en çok kullanılan diğer yöntemler arasında yineleme çizimleri (Eckmann ve ark., 1987, Casdagli, 1997), uzay-zaman ayrımı çizimleri (Provenzale ve ark., 1992) sayılabilir. Yineleme çizimleri (recurrence plots) çok karmaşık olduğundan yorumlanması zordur (Webber ve Zbilut, 1994). Durağan bir sürece ait zaman dizisinden elde edilen noktalar, çizim yüzeyine eşit biçimde dağılırken, durağan olmayan süreçlerin ürettiği zaman dizileri köşegene yakın biçimde kümelenirler (Sprott, 2002). Şayet çizim yüzeyinde birbirinden kopuk çok fazla nokta varsa, bu durum rastlantısal yakınlığı gösterir. Verilerde çok fazla gürültü olduğunda veya gömülme boyutunun yetersiz olduğu durumlarda ortaya çıkar. Noktalar, çizim yüzeyine gelişigüzel dağılmış ise zaman dizisinde determinizm olmadığı ya da çok zayıf olduğu sonucu çıkarılır (Kantz ve Schreiber, 2005). Zbilut ve ark. (1998), yineleme çizimlerinden istatistiksel nicel değerler elde etmişlerdir.

Elde edilen nicel değerlerden bazıları, çizimin noktalar tarafından kapsanma oranı (REC), köşegene paralel olarak bulunan noktaların oranı (DET), zaman dizisindeki deterministik yapıların oranını vermek üzere düz çizgi oluşturan noktaların uzunluk dağılımı (ENT) ve köşegenden uzaklık ile yineleme sayısı arasındaki ilişkiyi gösteren regresyon katsayısı (TREND)'dir. Büyük boyutlu zaman dizileri için bu değerlerin hesaplanması uzun sürmektedir. Bu yüzden zaman dizilerinin sınıflandırılması gibi pratik uygulamalarda kullanışlı değildirler. Yineleme çizimlerinde belli bir ϵ uzaklık değerinden daha yakın olan noktaların grafiği mutlak zamana göre elde edilirken, uzay-zaman ayrımı çizimleri (space-time separation plots) göreceli zaman kullanılarak oluşturulur. Bu çizim oluşturulurken, inşa edilen çekici üzerindeki geçerli bir vektör için belli bir δt aralığı ve Δd uzaklığında en az bir komşusu varsa $\delta t - \Delta d$ noktası olarak işaretlenir. Bu çizimden, zaman dizisi içindeki geçici ilintileri belirlemek ve Theiler algoritmasındaki (Theiler, 1990) ilinti boyutu ile Kantz algoritmasıyla (Kantz, 1994) yapılacak Lyapunov üsteli hesabında kullanılacak w Theiler penceresi boyutunu bulmak mümkündür. Faz uzayında geçici ilintilere sahip noktalar ilinti boyutu ve Lyapunov üsteli hesabının doğruluğunu etkilediği için, yapılacak hesaplamalarda bu noktaların atlanması gereklidir. Uzay-zaman ayrımı çizimindeki genel yüksekliğe yakın ilk tepe noktası genellikle en ideal w Theiler pencere boyutunu verir.

3.2.4. Çekicinin Yeniden Oluşturulması

Doğrusal olmayan sistemlerden elde edilen deneysel zaman dizilerinin analizindeki adımlardan ilki, sistem dinamiğinin izlenmesini sağlamak üzere sözde faz uzayının zaman gecikmeli olarak yeniden oluşturulmasıdır (Williams 1997).

Bunun için, gözlenen deneysel değişkenin zaman gecikmeli vektör gösterimleri faz uzayının koordinatlarını oluşturacak şekilde $x(t_0 + n\Delta t) \equiv x(n)$ değerleri kullanılır. Buradaki Δt , zaman dizisi değerlerinin alındığı örnek zamanıdır. Gözlem değerlerinden elde edilen ve D_E boyutlu uzayda oluşturulan çok değişkenli $Y(n)$ vektörleri dinamik sistemin yörüngesini izlemek için kullanılır.

$$Y(n) = (x(n), x(n + \tau), \dots, x(n + (D_E - 1)\tau)) \quad (3.15)$$

Vektörlerin zaman içindeki değişimi $Y(n) \rightarrow Y(n+1)$ şeklinde gösterilebilir. Çekicinin yeniden oluşturulmasında kullanılacak olan τ zaman gecikmesi (time-

delay) ve D_E gömülme boyutu (embedding dimension) değerlerinin uygun olarak seçilmesi çok önemlidir. Bunlar doğru olarak belirlenemezse çekicinin oluşturulması mümkün olmaz. Bu durumda, ilinti boyutu ve Lyapunov üstelleri gibi kaotik ölçütlerin hesaplanması da yapılamaz. $D_E > 3$ boyutlu çekicilerin grafik olarak gösterimi mümkün değildir. Fakat bu durum, sistemin kaotik olup olmadığını belirleyen ilinti boyutu ve Lyapunov üstellerinin hesaplanabilirliğini etkilemez.

Bir çekicinin kaotik olduğunu belirleyen özellikler şunlardır:

- 1-Yörüngeler hiçbir zaman kesişmez veya üst üste binmez (periyodik olmayan hareket). Yörüngelerin toplandığı bir veya daha fazla çekim merkezleri vardır.
- 2-Başlangıçta birbirine yakın olan iki komşu yörünge zaman içinde birbirinden uzaklaşır. Yörüngelerin birbirinden uzaklaşmasının ölçütünü veren Lyapunov üstellerinden en az bir tanesi sıfırdan büyüktür.
- 3-Sistemdeki enerji kaybından (dissipation) dolayı yörüngeler daima sınırlı bir bölge içinde hareket ederler. Sistemin enerji kaybetmesinin göstergesi Lyapunov üstellerinin toplamının sıfırdan küçük olmasıdır. Doğadaki tüm dinamik sistemler zaman içinde enerji kayıplı (dissipative) sistemlerdir.
- 4-Öklid geometrisine ait bir nesne değildirler. Değişik ölçeklerde birbirini tekrarlayan ince yapılara (fraktal) sahiptirler. Böyle yapılardan oluşan nesneler kesirli (fraktal) boyuta sahiptirler. Kaotik çekiciler, fraktal boyutla yakından ilişkili olan ilinti boyutu ile karakterize edilirler.

Takens (1981) teoremine göre, eğer çekicinin gerçek boyutu D_A ise, gömülme boyutu $D_E > 2D_A$ olacak şekilde seçilerek yörüngelerin kesişmesi önlenir. Gömülme sonucu elde edilen zaman gecikmeli vektörler, orijinal zaman dizisine topolojik olarak eşdeğerdir. Vektör değişkenleri faz uzayına yayılarak sistemin portresinin çizilmesini sağlar. Bu portre aslında sistemin faz uzayının tamamından daha düşük boyutlu alt uzaya yapılmış izdüşümüdür. Eğer sistem dinamiği deterministik kurallara indirgenabiliyorsa, vektör değişkenlerinin oluşturduğu yörüngeler faz uzayının belirli bir bölgesine doğru yakınsarlar. Faz uzayındaki bu değişmez yapıya kaotik çekici denmektedir.

3.2.5. Zaman Gecikmesinin Seçilmesi

Şayet elimizde sınırsız sayıda ve gürültüsüz veri olsaydı, çekicinin oluşturulması için gereken zaman gecikmesi için herhangi bir değeri seçmek

mümkündü. Pratikte deneysel veriler sınırlı ve gürültülü olduğundan en uygun zaman gecikmesinin bulunması gereklidir.

Zaman gecikmesi değeri;

1-Örnek zamanının katlarından biri olmalıdır. Çünkü elimizdeki veriler sadece örnek zamanlarında yer almaktadır.

2-Eğer çok küçük seçilirse, oluşturulacak çekiciye ait noktalara karşılık gelen $y(n)$ vektörlerinde yer alan $x(n)$ ve $x(n+\tau)$ koordinatları birbirine çok yakın olacak ve bağımsız koordinatlar olarak davranmayacaklardır. Bu durumda, gecikme koordinatları arasındaki bilgi kazancı çok az olacak ve veri artıklığına yol açacaktır. İnşa edilen çekiciye ait yörüngeler faz uzayındaki ana köşegen üzerinde sıkışıp kalacaktır.

3- Eğer çok büyük seçilirse, $x(n)$ ve $x(n+\tau)$ değerleri birbirinden tamamen ilgisiz olacak ve oluşturulan çekici faz uzayının tamamına dağılacaktır. Bu durumdaki çekici sistemin gerçek dinamiğini yansıtmayacaktır.

Zaman gecikmesinin hesaplanmasında kullanılabilecek yöntemlerin olumlu ve olumsuz tarafları aşağıda açıklanmıştır. Bu tez çalışmasında, Fraser ve Swinney (1986)'in önerdiği Karşılıklı Bilgi (Mutual Information) yöntemi kullanılmıştır.

Tepeler Arasındaki Ortalama Uzaklık (Average Peak to Peak Distance)

Zaman gecikmesi (τ)'nin hesaplanmasında kullanılabilecek en kolay ve hızlı yöntem bir zaman dizisindeki tepelerin arasındaki ortalama uzaklığın bir üst sınır olarak seçilmesidir. Aralarında tepeler arasındaki ortalama uzaklık kadar uzaklık bulunan noktaların artık veri oluşturmayacak kadar yakın olmayacakları, fakat birbiriyle ilgisiz olacak kadar da uzak olmayacakları varsayımına dayanmaktadır. Basit ve hızlı bir yöntem olmakla birlikte, her zaman doğru τ değerini veremeyebilmektedir (Taşkın, 1997).

Doğrusal Öz İlinti (Linear Autocorrelation)

Zaman gecikmesinin hesaplanmasında kullanılabilecek bir başka hızlı ve kolay yöntem de zaman dizisine ait $x(n)$ noktalarının bilinmeyen bir dağılımdan seçildiğini düşünerek $C_L(\tau)$ doğrusal öz ilinti fonksiyonunun hesaplanmasıdır.

$$C_L(\tau) = \frac{\frac{1}{N} \sum_{m=1}^N [x(m+\tau) - \bar{x}] \cdot [x(m) - \bar{x}]}{\frac{1}{N} \sum_{m=1}^N [x(m) - \bar{x}]^2} \quad (3.16)$$

Yukarıdaki denklemde, $\bar{x} = \frac{1}{N} \sum_{m=1}^N x(m)$ 'dir. Değişik τ 'ler içinde $C_L(\tau)$ 'nin

ilk olarak 0 değerini aldığı τ değeri zaman gecikme değeri olarak seçilir. Bu durumda $x(n)$ ve $x(n+\tau)$ noktaları doğrusal olarak bağımsız olacaktır. Fakat bu yaklaşım noktaların doğrusal olmayan şekilde bağımlı olup olmadıkları veya doğrusal olmayan bir sistemin koordinatları olup olmadıkları hakkında bir fikir vermemektedir (Williams 1997).

Karşılıklı Bilgi (Mutual Information - MI)

Fraser ve Swinney (1986)'nin önerdiği karşılıklı bilgi (mutual information) adlı yöntem doğrusal olmayan ilintileri de dikkate almaktadır. Bu yöntemde, optimum gecikmeyi bulmak için, S karşılıklı bilgi değeri aşağıdaki gibi farklı τ gecikme değerleri için hesaplanır,

$$S = - \sum_{ij} p_{ij}(\tau) \ln \frac{p_{ij}(\tau)}{p_i p_j} \quad (3.17)$$

Yukarıdaki denklemde, p_i değeri, bir zaman dizisi değerini i . aralıkta bulma olasılığına, $p_{ij}(\tau)$ bir gözlemin i . aralığa düşme ve τ zaman sonraki gözlemin j . aralığa düşme birleşik olasılığına karşılık gelmektedir. S karşılıklı bilgi değerinin ilk minimum değerini aldığı τ gecikme değeri, optimum zaman gecikmesi olarak seçilir.

Doğrusal öz ilintiden farklı olarak, karşılıklı bilgi $I(\tau)$ çekici üzerindeki noktalar arasında genel bir bağımlılık ölçütü verir. Doğrusal olmayan bir sistemde, artık veriden (redundance) ilgisiz (irrelevance) veriye doğru kayma hakkında daha iyi bir ölçüt sağlar. Karşılıklı bilgi $I(\tau)$, $x(n)$ verisinin gözlenmesi durumunda $x(n+\tau)$ değerinin ne kadar doğru biçimde tahmin edilebileceğinin ölçüsünü verir. Eğer $x(n+\tau)$ değeri $x(n)$ ile güçlü biçime ilişkili ise, karşılıklı bilgi göreceli olarak yüksektir. Karşılıklı bilgi küçük ise, ardışık gecikme koordinatlarının göreceli olarak bağımsız olduğu şeklinde yorumlanır. Zaman gecikmesi azaldıkça $I(\tau)$ değeri de azalır. $I(\tau)$ değeri ne kadar düşükse veri artıklığı o kadar azdır ve çekici en iyi şekilde

oluşturulmuş demektir. Bu yüzden, ilk en düşük $I(\tau)$ değerini veren τ zaman gecikmesi çekici oluşturmak için seçilir.

3.2.6. En Düşük Gömülme Boyutunun (Embedding Dimension - D_E) Bulunması

Çekicinin oluşturulacağı faz uzayının eksen sayısına karşılık gelen gömülme boyutu, çekici üzerindeki yörüngelerin birbirleriyle kesişmeyeceği veya üst üste gelmeyeceği şekilde seçilmelidir. Takens (1981) teoremine göre, gerçek boyutu D_A olan bir çekici için gömülme boyutu $D_E > 2D_A$ olacak şekilde seçilirse yörüngelerin kesişmesi önlenabilir. En düşük gömülme boyutunu belirlemede temel olarak aşağıdaki yöntemlerden biri kullanılır (Cao, 1997):

1-Çekici üzerinde belli bir değişmez kaotik ölçüt farklı gömülme boyutları için hesaplanır (Grassberger ve Procaccia, 1983). Ölçütün değişmez hale geldiği gömülme boyutu seçilir. Bu yöntem, veri kümesinin büyük olmasını ve yoğun hesaplama gerektirmektedir. Ayrıca genellikle gömülme boyutu ve ölçüt grafiğine bakılarak verilen karar öznel olmaktadır.

2-Tekil değer ayrımı yönteminde (Broomhead ve King, 1986), gömülme uzayındaki dikey yönler belirlenir. Bu dikey yönler, yörüngenin üzerindeki izdüşümünün varyans büyüklüğüne bağlı olarak sıralanırlar. Sıralama, gömülmenin tekil değerleri kullanılarak yapılır. Yeniden oluşturulan yörünge tarafından ziyaret edilen ve büyük tekil değerler ile gösterilen bu yönlerin sayısı, yörüngeyi içeren en küçük uzayın boyutu olarak bulunur. Bu yöntemin sonucunda verilen karar da öznel olmaktadır. Ayrıca, veri az ve gürültülü ise doğru sonuç vermeyebilir.

3-Sözde Yakın Komşular (False Nearest Neighbours) yöntemi. Bu yöntemde göre X_a ve X_b faz uzayında birbirine yakın iki nokta ise bu durumun iki nedeni olabilir:

1-Bu noktaların bulunduğu yörüngeler dinamik olarak değişerek bu noktalar birbirlerine yakınlaşmışlardır.

2-Çekici, olması gereken boyuttan daha düşük bir boyutta oluşturulduğu için izdüşüm sonucu, gerçekte birbirinden uzak olması gereken noktalar üst üste gelmişlerdir.

Bu yakınlığın sebebini anlamak için D_E ve D_{E+1} gömülme boyutları için $\|X^a - X^b\|$ uzaklığı karşılaştırılır. Eğer D_{E+1} için bu uzaklık artar ise X_a ve X_b

noktalarının sözde yakın komşular (false nearest neighbours) olduklarına karar verilir.

Sözde Yakın Komşular (False Nearest Neighbours - FNN) Yöntemi

Çekicinin oluşturulacağı faz uzayının en düşük gömülme boyutunu belirlemek üzere en yaygın kullanılan, gürültülü ve kısa zaman dizileri için de doğru olarak çalışan yöntemdir (Liebert ve ark., 1991, Kennel ve ark., 1992). Bu yöntemle göre m gömülme boyutu ve τ zaman gecikmesi olmak üzere a ve b noktaları arasındaki uzaklığın karesi R_d^2 şu şekilde hesaplanır:

$$R_d^2 = \sum_{m=0}^{d-1} [s^a(t + m\tau) - s^b(t + m\tau)]^2 \quad (3.18)$$

Buna göre m boyutundan $m+1$ boyutuna geçmek demek her gecikme vektörüne $s(t+m\tau)$ şeklinde yeni bir koordinat eklemek anlamına gelir. Bu durumda $m+1$ boyutu için a ve b noktaları arasındaki uzaklık aşağıdaki gibi olacaktır:

$$R_{d+1}^2 = R_d^2 + [s^a(t + d\tau) - s^b(t + d\tau)]^2 \quad (3.19)$$

Buna göre m ve $m+1$ boyutları için a ve b noktaları arasındaki göreceli uzaklık aşağıdaki gibi olur:

$$\sqrt{\frac{R_{d+1}^2 - R_d^2}{R_d^2}} = \frac{\|s^a(t + d\tau) - s^b(t + d\tau)\|}{R_d} \quad (3.20)$$

Yukarıda verilen oran, önceden tanımlı bir s değerinden büyükse a ve b noktaları birbirine sözde yakın komşudur. Eşik değeri s , deterministik kaos sonucu oluşacak olan noktalar arası üssel uzaklaşmayı ele alabilecek kadar büyük olmalıdır.

Kennel ve arkadaşları (Kennel ve ark., 1992), a ve b noktalarının sözde yakın komşu olması koşulunun $R_{d+1} > \sigma/s$ olduğunu öne sürmüşlerdir. Buradaki σ , verilerin ortalama etrafındaki standart sapma değeri ve s , önceden belirlenmiş bir değerdir. Kennel ve arkadaşlarına göre, $R_{d+1} > \sigma/s$ koşulunu içermeyen bir FNN algoritması yüksek-boyutlu düzensiz sistemler için bile hatalı bir düşük gömülme boyutu üretecektir.

FNN algoritması daha yüksek boyutlar için tüm nokta çiftleri için tekrarlanır. Algoritmanın sonlanma koşulu, tüm çekici için, sözde yakın komşuların sayısının sıfır olmasıdır. Bu durumda çekici, son halini almış ve ortaya çıkmış demektir.

Abarbanel ve Lall (1996)'a göre, doğrusal olmayan sistemlerin çoğu için $s \cong 15$ olmalıdır.

FNN aynı zamanda verideki gürültü miktarının bir göstergesidir. Gürültü, sonsuz serbestlik derecesine sahiptir ve hiçbir bir boyuta doğru açılım göstermez.

Hegger ve Kantz (1999), gürültüden kaynaklanabilecek yanlış sonuçları önlemek için yukarıda verilen algoritmaya küçük bir takım değişiklikler önermişlerdir. Zaman dizisinin standart sapması σ , sözde yakın komşu eşik değeri r olmak üzere ve faz uzayındaki vektörler arası uzaklık maksimum farka göre bulunmak üzere, sözde yakın komşular istatistiğini aşağıdaki gibi hesaplamışlardır;

$$X_{SYK}(r) = \frac{\sum_{n=1}^{N-m-1} \Theta\left(\frac{|S_n^{(m+1)} - S_{k(n)}^{(m+1)}|}{|S_n^{(m)} - S_{k(n)}^{(m)}|} - r\right) \Theta\left(\frac{\sigma}{r} - |S_n^{(m)} - S_{k(n)}^{(m)}|\right)}{\sum_{n=1}^{N-m-1} \Theta\left(\frac{\sigma}{r} - |S_n^{(m)} - S_{k(n)}^{(m)}|\right)} \quad (3.21)$$

Yukarıdaki denklemde $S_{k(n)}^{(m)}$, S_n 'in m gömülme boyutundaki en yakın komşusudur. Buradaki $k(n)$, zaman dizisindeki n 'den farklı olan ve $|S_n - S_k|$ en küçük olma şartını sağlayan k indisidir. Paydaki ikinci Heaviside fonksiyonu, başlangıçtaki uzaklıkları σ/r değerinden büyük olan vektörleri hesaba katmamak için kullanılmaktadır. Çünkü σ değerinden daha fazla uzaklaşmak mümkün olmadığından, uzaklıkları σ/r değerinden büyük olan vektörler sözde yakın komşu olamazlar. Bu tür vektörleri cezalandırmak için payda teriminde de aynı ifade yer almaktadır. Sözde yakın komşular analizinin sonucu seçilen zaman gecikmesi değerine göre değişir.

Cao (1997) tarafından önerilen yönteme göre, s eşik değerini belirlemede faz uzayındaki her vektör ayrı ayrı dikkate alınmaktadır. Farklı gömülme boyutları için komşular arasındaki uzaklık oranı $a(i, m)$ prensip olarak farklı vektörler için farklı olmalıdır. Ayrıca, farklı zaman dizileri için eşik değeri farklı olabilir. Bu yüzden, sadece m boyutuna ve τ zaman gecikmesine bağlı olan ve tüm $a(i, m)$ değerlerinin ortalamasının alındığı aşağıdaki denklem kullanılmıştır.

$$E(m) = \frac{1}{N - m\tau} \sum_{i=1}^{N-m\tau} a(i, m) \quad (3.22)$$

Yukarıdaki değerin, m ve $m+1$ boyutlarındaki değişimini incelemek için aşağıdaki ifade tanımlanmıştır.

$$E_1(m) = E(m+1) / E(m) \quad (3.23)$$

Eğer zaman dizisi için uygun gömülme boyutu bulunmuşsa, d değeri bir d_0 değerinden büyük olduğunda $E_1(m)$ değeri değişmez olacaktır. Bu durumda d_0+1 , aranan en küçük gömülme boyutu olacaktır.

3.2.7. İlinti Boyutu

Enerji kayıplı kaotik sistemlere ait çekiciler genellikle çok karmaşık geometriye sahiptirler. Bu yüzden garip çekiciler olarak adlandırılmışlardır. Kaotik çekicilerde periyodik olmayan hareketin gerekliliği olan yörüngelerin kesişmemesi şartının sağlanması için, hem faz uzayının hem de çekicinin boyutunu 2'den büyük olması gereklidir (Kantz ve Schreiber, 2005). Öklid geometrisine ait nesnelerin boyutları tam sayılarla gösterilirken, tüm ölçüm seviyelerinde aynı kendine benzer yapıyı gösteren geometrik nesnelerin (fraktal yapılar) boyutları kesirlidir.


Dinamik sistemlerin karmaşıklığını göstermek için değişik boyut tanımları verilmiştir. Bunların içinde literatürde en yaygın kullanılan ilinti boyutudur (Williams, 1997, Kantz ve Schreiber, 2005, Sprott 2002). İlinti boyutunun tercih edilmesinde iki faktör önemlidir. Birincisi, diğer boyutlara (Benzerlik boyutu, Bilgi boyutu, Hausdorff boyutu vs.) göre çekiciyi daha ince ayrıntıda ölçeklerde araştırır (Theiler 1990). İkincisi, diğer boyutlara göre daha kolay ve hızlı biçimde hesaplanabilmektedir. Sınırlı zaman dizilerinden ilinti boyutu hesaplanmasında karşılaşılan problemler literatürde geniş biçimde tartışılmıştır (Schreiber 1999).

Bir çekici kaotik ise, başlangıçta birbirine yakın olan komşu yörüngeler zaman içinde üssel olarak birbirinden uzaklaşacak ve bu yörüngeler üzerindeki noktalar dinamik olarak ilintisiz hale gelecektir. Bu noktalar rasgele görünseler bile, hepsi aynı çekici üzerinde yer aldığı için faz uzayında ilintili olarak bulunacaklardır. İlinti boyutu hesabında, çekici üzerindeki noktaların uzaysal ilişkisi göz önüne alınır, zaman bilgisi dikkate alınmaz (Williams 1997). Faz uzayında birbirine yakın olan noktalar için, yüksek seviyede ilinti söz konusudur.

İlinti boyutunun hesaplanmasında Grassberger-Procaccia (Grassberger ve Procaccia, 1983) algoritması literatürde yaygın biçimde uygulanmıştır. İlinti boyutu,

ε yarıçapına sahip alan veya hacim içinde kalan noktaların sayılması ile elde edilen ilinti integralinin C_ε 'nin değişik ε yarıçapları için hesaplanması ve log-log koordinat sistemine işaretlenmesi sonucu elde edilen noktaların oluşturduğu doğrunun eğiminin hesaplanması ile bulunur.

C_ε değeri, ε yarıçapı içinde kalan toplam nokta sayısının $N(N-1)$ değerine bölünmesi ile elde edilir. C_ε değerine, ilinti integrali veya ilinti toplamı denir. N ise veri kümesindeki toplam nokta sayısıdır.



Şekil 3.6. C_ε değerinin hesaplanması

$$\Theta \text{ (Heaviside fonksiyonu)} = \begin{cases} x_i - x_j < 0, & \text{ise } 0 \\ x_i - x_j > 0, & \text{ise } 1 \end{cases} \text{ şeklinde tanımlanmak}$$

üzere ilinti integrali C_ε 'nin formülü aşağıdaki gibidir.

$$C(\varepsilon) = \frac{2}{N(N-1)} \sum_{i=1}^N \sum_{j=i+1}^N \Theta(\varepsilon - |x_i - x_j|) \quad (3.24)$$

Bir döngü içinde ε değeri artırılarak, yeni C_ε değeri bulunur. Elde edilen C_ε değerlerine karşılık, ε değerlerinin log-log koordinat sisteminde işaretlenmesi ile elde edilen noktaların oluşturduğu doğrunun eğimi ilinti boyutunu verir.

En dıştaki döngüde, gömülme boyutu artırılarak yeni C_ε ve ε değerleri elde edilir. Genellikle 10 gömülme boyutuna kadar bu döngü çalıştırılır. Gömülme boyutu büyüdükçe C_ε küçülür fakat ilinti boyutu büyür. Belli bir aşamadan sonra, gömülme boyutunun artırılması ilinti boyutunu etkilemez duruma gelir. Gömülme boyutu, çekici boyutundan büyük olduğu sürece oluşturulan çekicinin ilinti boyutu gerçek çekicinin ilinti boyutuna sahip olacaktır. Yüksek derecede deterministik veya kaotik veriler için gömülme boyutu arttıkça ilinti boyutu da artar. Fakat belli bir noktadan

sonra sabit hale gelir. Aksi halde eldeki veri kümesi rasgele ve düzensizdir. Verinin sınırsız olması ($N \rightarrow \infty$) ve ε küçük olması durumunda, ilinti integrali C_ε 'nin

$$C(\varepsilon) \propto \varepsilon^D \text{ şeklinde bir üs kuralına uyacaktır. Bu durumda, } d(N, \varepsilon) = \frac{\partial \ln C(\varepsilon, N)}{\partial \ln \varepsilon}$$

olmak üzere D ilinti boyutu aşağıdaki gibi tanımlanır.

$$D = \lim_{\varepsilon \rightarrow 0} \lim_{N \rightarrow \infty} d(N, \varepsilon) \quad (3.25)$$

Yukarıdaki ifadede bulunan $N \rightarrow \infty$ ve $\varepsilon \rightarrow 0$ limitleri, zaman dizileri için hiçbir zaman gerçekleşmez. Şayet oluşturulan çekicide kendine-benzerliğin bulunduğu kesin olarak biliniyorsa ilinti boyutu değeri bunu nicel olarak belirler. Düşük seviye determinizme sahip olduğu bilinmeyen zaman dizilerinde bu ölçüt kullanılırken yanlış sonuçlara karşı dikkatli olunmalıdır. İlinti boyutu hesaplanırken, faz uzayındaki gömülme vektörleri arasındaki ilintinin zamansal mı yoksa geometrik mi olduğu göz önünde bulundurulmalıdır (Theiler, 1990). Kaotik çekici üzerinde birbirine zamansal olarak yakın vektörler uzaysal olarak da yakındırlar. Bu durum geçici ilinti olarak adlandırılır. Geçici ilintiye neden olan vektörler ilinti integrali hesabından çıkarılmazsa, ilinti boyutu değerinin yanlış biçimde olması gerekenden daha düşük çıkmasına neden olur. Geçici ilintili noktaları ilinti integrali hesabından çıkarmak için aşağıdaki gibi düzenlenmesi gereklidir.

$$C(\varepsilon) = \frac{2}{(N-w)(N-w-1)} \sum_{i=1}^N \sum_{j=i+1+w}^N \Theta(\varepsilon - \|s_i - s_j\|) \quad (3.26)$$

Yukarıdaki ifadede bulunan w değeri Theiler penceresi olarak adlandırılır ve geçici ilintili noktaların hesaplamaya dahil edilmemesini sağlar.

İlinti boyutunun elde edilmesinde kullanılan yöntemlerden birisi $C(\varepsilon)$ ilinti integraline karşılık ε değerinin farklı gömülme boyutları için x-y koordinat ekseninde çizdirilmesidir. Kaotik sistemlerde, elde edilen eğrilerin eğimi belli bir gömülme boyutu değerinden sonra rağmen değişmez hale gelir. Bu değişmeyen eğim değeri ilinti boyutu olarak tespit edilir.

Yukarıda anlatılan işlemin doğrudan kullanıldığı diğer yöntemde, farklı gömülme boyutları ve ε değerleri için elde edilen ilinti integrali değerlerinin yerel eğimlerine $D_2(\varepsilon, m)$ karşılık ε değerleri x-y koordinat ekseninde işaretlenir. Eğrilerin yaklaşık olarak düz bir plato oluşturduğu y değeri ilinti boyutu olarak seçilir.

Alternatif olarak, Takens (1985) ve Theiler (1988) tarafından önerilen en büyük olabilirlik kestirimi (maximum likelihood estimator) az sayıda, gürültülü ve yüksek boyutlu veri içeren gerçek zaman dizilerinde ilinti boyutu değerini daha belirgin olarak verebilmektedir (Sprott, 2002, Schreiber, 1999). Takens-Theiler kestirimi aşağıdaki gibi tanımlıdır.

$$D_{TT}(\varepsilon) = \frac{C(\varepsilon)}{\int_0^\varepsilon \frac{C(\varepsilon')}{\varepsilon'} d\varepsilon'} \quad (3.27)$$

Yukarıdaki kestirim değerleri, ilinti integralinden hesaplanan yerel eğim değerlerinden yararlanılarak hesaplanır. Paydadaki integral $i=1, \dots, k$ adet ε değeri için toplamlar şeklinde ifade edilecek olursa aşağıdaki denklem elde edilir.

$$\int_0^\varepsilon \frac{C(\varepsilon')}{\varepsilon'} d\varepsilon' = \sum_{i=1}^k \varepsilon^{b_i} \int_{\varepsilon_{i-1}}^{\varepsilon_i} (\varepsilon')^{a_{i-1}} d\varepsilon' = \sum_{i=1}^k \frac{\varepsilon^{b_i}}{a_i} (\varepsilon_i^{a_i} - \varepsilon_{i-1}^{a_i}) \quad (3.28)$$

Elde edilen $D_{TT}(\varepsilon)$ değerlerine karşılık ε değerlerinin log-log koordinat ekseninde çizdirilmesiyle elde edilen eğrilerin oluşturduğu yaklaşık düz platonun karşılık geldiği y değeri ilinti boyutu olarak seçilir.

3.2.8. Lyapunov Üstelleri

Kaotik sistemlerin periyodik olmayan dinamikler göstermesinin nedeni faz uzayı eğrilerinin neredeyse aynı başlangıç şartlarında farklı üstel artış oranlarına sahip olmalarıdır. Bu duruma başlangıç koşullarına hassas duyarlılık denir. En büyük Lyapunov üsteli λ_1 , başlangıç şartlarına duyarlılığı ölçüsünü verir ve faz uzayı içindeki komşu eğrilerin yerel ayrılma derecelerinin ortalaması olarak tanımlanır (Eckmann ve Ruelle, 1985). Biri referans olmak üzere iki yakın eğri üzerinde yer alan birbirine en yakın iki nokta (x_1 ve x_2) arasında başlangıçta $\delta_{x(0)}$ gibi çok küçük bir fark vardır. Bir t zamanı sonunda bu noktalar arasındaki fark $\delta_{x(t)}$ olur. Lyapunov üsteli, $\|\dots\|$ ifadesi Öklid uzaklığını göstermek üzere, aşağıdaki gibi bulunur;

$$\|\delta x_{(t)}\| = \|\delta x_{(0)}\| e^{\lambda t} \quad (3.29)$$

$$\lambda(i) = \lim_{t \rightarrow \infty} \frac{1}{t} \log \frac{\|\delta x_i(t)\|}{\|\delta x_i(0)\|} \quad (3.30)$$

Faz uzayında her bir boyuttaki ıraksama ve yakınsamayı bir λ temsil ettiğinden, d boyutlu dinamik bir sisteme ait Lyapunov üsteli spektrumu, λ_1 en büyük

olmak üzere $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_d$ şeklinde elde edilir. Herhangi bir sistemde en büyük Lyapunov üsteli $\lambda_1 > 0$ ise davranış kaotik, $\lambda_1 < 0$ ise davranış kararlı sabit nokta, $\lambda_1 = 0$ ise davranış kararlı limit döngüdür. Gürültü için $\lambda_1 = \infty$ kabul edilir. Kaotik sistemler en az bir pozitif Lyapunov üsteline sahiptir.

En büyük Lyapunov üstelinin özellikleri şunlardır:


- 1- N boyutlu bir sistemde, en hızlı büyüyen boyutun ortalama büyüme oranını verir.
- 2- Çekici üzerindeki ortalama tahmin edilebilirlik göstergesidir.
- 3- Sistemin küçük değişiklikler karşısındaki hassasiyetinin ortalama ölçütüdür.
- 4- Çekicinin tümü ele alınarak ölçüldüğü için hesaplamaya nereden başladığımız önemli değildir.
- 5- Verinin ya da koordinat sisteminin dönüşümünden etkilenmeyen değişmez bir ölçüttür.

Çekicinin yer aldığı faz uzayındaki boyutlara karşılık gelen temel eksenlerin her birine karşılık gelen bir Lyapunov üsteli söz konusudur. Başka bir deyişle Lyapunov üstellerinin sayısı, faz uzayının boyut sayısı kadardır.

En büyük Lyapunov üstelinin hesaplanmasında kullanılan Wolf (Wolf 1985) yöntemi aşağıdaki adımlardan oluşur:

1. Zaman gecikmesi ile gömülme yöntemi ile çekici oluşturulur.
2. Bir referans yörünge seçilir. Genellikle faz uzayındaki ilk noktadır.
3. Komşu yörünge üzerinden en yakın nokta seçilir. Başka bir deyişle, yakın nokta veri kümesinin farklı bir bölgesinden seçilmelidir.
4. İki yörünge arasındaki mesafenin zaman içindeki değişimi izlenir. Ne kadar süre izleneceği, mesafe uzunluğunun ne olduğuna bağlıdır. Mesafe uzunluğu önceden belirlenmiş bir ϵ değeridir.
5. Eğer mesafe aralığı $> \epsilon$ olmuş ise, yerel eğim (son mesafe – ilk mesafe) / adım sayısı şeklinde hesaplanır ve komşu yörünge izlenmesi bu noktada bırakılır.
6. Son referans noktası kullanılarak, en yakın noktanın yer aldığı yeni komşu yörünge bulunur.
7. Referans yörüngedeki son veri noktasına varıncaya kadar, 4-6 adımları tekrar edilir.

8. Yerel eğimlerin mutlak değerlerinin logaritması alındıktan sonra toplanarak ortalamalarının alınması ile en büyük Lyapunov üsteli (λ_1) elde edilir.



Şekil 3.7. Lyapunov üstelinin hesaplanması

Yukarıda açıklanan işlem N defa tekrar edilir ve en büyük Lyapunov üsteli aşağıdaki gibi hesaplanır;

$$\lambda = \frac{1}{t_N - t_0} \sum_{i=1}^N \log \frac{f'(t_i)}{f(t_{i-1})} \quad (3.31)$$

Bu algoritma gürültü bozulması olmayan geniş bilgi kümeleriyle iyi çalışır fakat kısa ve/veya gürültülü bilgi kümelerinin bulunduğu durumlarda başarılı olmayabilmektedir. Ayrıca, vektörler arasındaki uzaklığın çekici üzerinde her yerde artmayabileceği hatta bazı yerel bölgelerde azalacağını göz önüne almamaktadır. Lyapunov üsteli, çekici üzerindeki vektörlerin yerel uzaklaşma oranlarının ortalaması alınarak bulunmalıdır. Rosenstein ve arkadaşları (1993) ile Kantz (1994) birbirlerinden bağımsız olarak en büyük Lyapunov üsteli hesabı için hemen hemen aynı yöntemi geliştirmişlerdir.

Rosenstein ve arkadaşlarının (Rosenstein ve ark., 1993) yöntemi eldeki tüm veriyi kullanmakla birlikte, hem hızlı hem de gerçekleştirmesi kolaydır. Ayrıca gömülme boyutunda, veri kümesi boyunda, zaman gecikmesinde ve gürültü seviyesindeki değişimlere karşı da sağlamdır. Bu tez çalışmasında, TCD zaman dizileri için en büyük Lyapunov üstelinin hesaplanmasında bu yöntem kullanılmıştır.

Bu yöntemi oluşturan adımlar aşağıda verilmiştir:

1-Çekici üzerine bir X_0 noktası seçilir ve bu noktaya r uzaklığından daha yakın olan X_n noktalarının ortalama uzaklığı hesaplanır.

2-Yukarıdaki işlem, yörünge üzerindeki N nokta için tekrarlanır ve toplamaları bulunur.

3 - Toplamların ortalaması olan S gerilme faktörü aşağıdaki gibi hesaplanır.

$$S = \frac{1}{N} \sum_{n_0=1}^N \ln \left(\frac{1}{|\mathcal{G}_{X_{n_0}}|} \sum |X_{n_0} - X_n| \right) \quad (3.32)$$

Yukarıdaki denklemde $\mathcal{G}_{X_{n_0}}$ ifadesi X_{n_0} etrafındaki komşu noktaların sayısını göstermektedir.

Değişik N değerleri için bulunacak olan S değerlerinin x-y koordinat sisteminde işaretlenmesi ile aşağıdaki gibi bir eğri elde edilecektir. Bu eğrinin başlangıçtaki doğrusal kısmının eğimi en büyük Lyapunov üstelini verir.

Kantz (1994) tarafından geliştirilen algoritmanın yukarıda verilen algorithmadan en önemli farkı, hesaplama işlemi sırasında faz uzayında gömülü çekici üzerinde geometrik olarak değil zamansal olarak yakın olan noktaları dikkate almamasıdır. Ayrıca, m en düşük gömülme boyutunun ve en uygun ε uzaklığının bilinmediği durumlar için, S gerilme faktörü bu iki değerin değişik varyasyonları için hesaplanır. Farklı Δn yineleme adımları için bulunan S değerlerinin x-y koordinat sisteminde işaretlenmesiyle oluşan eğriler belirgin bir doğrusal artış gösteriyorsa, bu eğrilere uydurulan doğrunun eğimi en büyük Lyapunov üstelini verir. Komşuluk uzaklığı ε mümkün olduğunca küçük, fakat her referans noktasının en az birkaç komşusunun olmasını sağlayacak kadar da büyük olmalıdır. Aksi takdirde, hesaplamada çekicinin bazı bölgeleri kullanılmayacağı için yanlış sonuç elde edilir.

3.3. Sınıflandırmada Kullanılan Yöntemler

Bu bölümde TCD sinyallerinden elde edilen kaotik ölçütlerin sınıflandırmasında kullanılan yöntemler açıklanmıştır. Aynı sınıflandırma yöntemleri kullanılarak, doğrusal bir yöntem olan güç spektrum yoğunluğu kestirimi ile TCD sinyallerinden elde edilen spektral parametreler de sınıflandırılmış ve kaotik ölçütler ile yapılan sınıflandırmalarla karşılaştırılmıştır. Sınıflandırmada kullanılan yöntemlerden ilk ikisi olan NEFCLASS ve ANFIS, yapay sinir ağı bulanık çıkarım sistemleridir. Karar Ağaçları, k-En Yakın Komşu ve Çok Katmanlı Algılayıcı Sinir Ağı algoritmaları da aynı veriler üzerinde uygulanarak performansları karşılaştırılmıştır.

3.3.1. Bulanık Çıkarım Sistemleri

Diferansiyel denklemler gibi klasik matematik araçlara dayanan sistem modelleme eksik tanımlanmış ve belirsiz sistemler için uygun değildir. Öte yandan, bulanık EĞER-O HALDE kurallarını kullanan bir bulanık çıkarım sistemi, kesin nicel analiz olmadan insan bilgisinin ve akıl yürütme işleminin nitel özelliklerini modelleyebilir. Sistematsel biçimde ilk olarak Takagi ve Sugeno (1985) tarafından keşfedilen bu bulanık modelleme yöntemi kontrolde (Pedrycz 1989), tahmin ve çıkarımda (Kandel 1992) pek çok pratik uygulama bulmuştur.

Bulanık EĞER-O HALDE kuralları veya bulanık koşul ifadeleri EĞER A ise O HALDE B'dir şeklindeki ifadelerdir. A ve B, uygun üyelik fonksiyonları ile karakterize edilen bulanık kümelerin (Zadeh 1965) etiketleridir. Özlü biçimlerinden dolayı, bulanık EĞER-O HALDE kuralları genellikle akıl yürütmenin kesin olmayan durumlarını aynen almak için kullanılır. Belirsizlik içeren durumlarda insanın karar verme yeteneğine benzetilmektedir. Örneğin;

EĞER BASINÇ *yüksek* ise, O HALDE HACİM *küçük*.

şeklinde bulanık bir kural için BASINÇ ve HACİM dilsel değişkenler (Zadeh, 1973), *yüksek* ve *küçük* üyelik fonksiyonları ile karakterize edilen dilsel değerler veya etiketlerdir.


Takagi ve Sugeno (1983) tarafından önerilen bulanık EĞER-O HALDE kuralının başka biçimi sadece öncül kısımda yer alan bulanık kümelere sahiptir.

Takagi ve Sugeno'nun bulanık EĞER-O HALDE kuralını kullanarak, hareket halindeki bir nesne üzerindeki sürtünme kuvvetini aşağıdaki gibi tanımlayabiliriz:

$$\text{EĞER HIZ } y\ddot{u}ksek \text{ İSE, O HALDE } kuvvet = k * (HIZ)^2$$

Yukarıdaki bulanık kuralda, öncül kısımdaki *yüksek*, uygun bir üyelik fonksiyonu ile karakterize edilen dilsel bir değişkendir. Fakat sonuç kısım giriş değişkeni olan HIZ'ın bulanık olmayan eşitliği ile tanımlanmıştır.

Her iki tür bulanık EĞER-O HALDE kuralı da modelleme ve kontrolde yaygın olarak kullanılmıştır. Bulanık EĞER-O HALDE kuralları, bulanık çıkarım sistemlerinin temelini oluşturur.




Şekil 3.8. Bulanık Çıkarım Sistemi

Bulanık çıkarım sistemleri, bulanık kural tabanlı sistemler, bulanık modeller, bulanık birleşik bellekler veya kontrolde kullanıldığında bulanık kontrolcüler olarak da adlandırılırlar. Temel olarak, bir bulanık çıkarım sistemi 5 fonksiyonel bloktan oluşur.

- Bulanık EĞER-O HALDE kurallarını içeren bir kural tabanı
- Bulanık kurallarda yer alan bulanık kümelerin üyelik fonksiyonlarının tanımlandığı veritabanı
- Kurallar üzerinde çıkarım işlemlerinin yapıldığı karar verme ünitesi
- Net giriş değerlerini, dilsel değerlerle uygunluk derecelerine dönüştüren bulanıklaştırma arayüzü
- Çıkarım işleminin bulanık kurallarını net çıkış değerlerine dönüştüren berraklaştırma arayüzü

Genel olarak, kural tabanı ve veritabanı birlikte bilgi tabanı olarak anılır. Bulanık çıkarım sistemlerinin yaptığı bulanık akıl yürütme (bulanık EĞER-O HALDE kuralları üzerinde yapılan çıkarım işlemleri) adımları aşağıdaki gibidir:

1. Öncül kısımdaki üyelik fonksiyonları ile giriş değerlerini karşılaştırarak her dilsel etiket için üyelik değerleri (veya uyumluluk ölçütleri) bulunur (Bulanıklaştırma adımı).
2. Öncül kısımdaki üyelik değerleri birleştirilerek (çarpma veya minimum şeklinde belirli bir T-norm işleci ile), her kuralın ateşleme şiddeti (ağırlığı) bulunur.
3. Ateşleme şiddetine bağlı olarak her kuralın sonuç değeri (bulanık veya net) üretilir.
4. Net bir çıkış üretmek için sonuç değerleri toplanır (Berraklaştırma adımı).



Şekil 3.9. Bulanık EĞER-O HALDE kuralları ve bulanık akıl yürütme yöntemleri

Literatürde pek çok bulanık akıl yürütme yöntemi önerilmiştir (Lee 1990). Kullanılan bulanık akıl yürütme ve bulanık EĞER-O HALDE kurallarına bağlı olarak, 3 farklı bulanık akıl yürütme sistemi vardır:

Tür-1: Çıkış değeri, kuralın ateşleme şiddeti (öncül kısım ile en düşük uyumluk derecesi veya çarpımı) ile çıkış üyelik fonksiyonları ile elde edilen her kuralın net çıkışının ağırlıklı ortalamasıdır. Bu yapıda, çıkış üyelik fonksiyonları monotonik olarak artan biçimde olmalıdır (Tsukamoto 1979).

Tür-2: Genel bulanık çıkış değeri, elde edilen bulanık çıktıları “max” işleci uygulanarak elde edilir. Genel bulanık çıkış değerinden rakamsal net sonuç elde etmek için alanın merkezi, en büyüğün ortalaması vb. çeşitli yöntemler önerilmiştir (Lee 1990).

Tür-3: Takagi ve Sugeno EĞER-O HALDE kuralları kullanılır (Takagi ve Sugeno, 1983). Her kuralın çıktısı giriş değişkenleri ile sabit bir terimin doğrusal birleşimidir ve sonuç çıktı değeri her kuralın çıktısının ağırlıklı ortalamasıdır.

Şekil 3.8’de farklı bulanık kuralları ve yukarıda bahsedilen bulanık akıl yürütme yöntemlerini gösteren iki kurallı ve iki girişli bulanık çıkarım sistemi gösterilmiştir. Bulanık çıkarım sistemlerini birbirinden ayıran noktalar, sonuç kısmının kullandığı fonksiyon türü (monotonik olarak artan fonksiyonlar, çan eğrisi şeklinde üyelik fonksiyonları veya net rakamsal fonksiyonlar) ile berraklaştırma (ağırlıklı ortalama, alanın merkezi, vb.) yöntemidir.

3.3.2. Yapay Sinir Ağılı Bulanık Sistemler

Yapay Sinir Ağılı Bulanık Sistemler, sinir ağlarının öğrenme yeteneğiyle bulanık sistemlerin dilsel kuralları kullanma yeteneğini birleştirirler. Böyle sistemlerde dilsel kurallar şeklinde ön bilgi kullanılabilir ve nihai sistem yorumlanabilir bir yapıya sahiptir. Yapay Sinir Ağları ve Bulanık Sistemler tek başlarına kullanıldığı sınıflandırma problemlerinde başarılı sonuçlar vermişlerdir. Fakat her ikisinin de aşağıdaki tabloda belirtilen avantaj ve dezavantajları bulunmaktadır. Yapay Sinir Ağılı Bulanık Sistemler, her iki modelin dezavantajlarını aşarken avantajlarını da kaybetmemeyi hedeflemektedirler. Bu terim, genellikle sinir ağları ile bulanık sistemlerin her türlü birleşimini tanımlamada kullanılır. Bir yaklaşıma göre, bu birleşim bulanık bir sistemin parametrelerini belirlemede öğrenme algoritmalarını kullanma şeklindedir. Buna göre, bulanık bir sistem sinir ağı yöntemleri kullanılarak oluşturulur veya iyileştirilir. Daha da önemlisi, nihai sistem bulanık EĞER O HALDE kuralları şeklinde yorumlanabilir.

Öte yandan bir bulanık yapay sinir ağı, daha hızlı öğrenmek ve daha iyi performans göstermek için bulanık yöntemleri kullanan sinir ağıdır. Buradaki amaç, sinir ağının performansını iyileştirmektir. Böyle bir sistemin bulanık kurallar şeklinde yorumlanması hem önemli değildir hem de mümkün değildir.

Yapay Sinir Ağı	Bulanık Sistem
Avantajlar	
- o Matematiksel bir model gerektirmez - o Kural tabanlı bilgi gerektirmez - o Değişik öğrenme algoritmaları vardır	- o Matematiksel bir model gerektirmez - o Kural tabanlı ön bilgi kullanılabilir - o Kolay yorumlama ve gerçekleştirim
Dezavantajlar	
- o Kara kutudur - o Kurallar belirlenemez - o Akıl yürütme parametreleri gerekir - o Değişen şartlara adaptasyon zor olur ve yeniden eğitim gerekebilir - o Ön bilgi kullanılamaz (Her defasında baştan öğrenme yapılır) - o Öğrenmenin başarılacağı garantisi yoktur	- o Kurallar belirli olmalıdır - o Öğrenme yoktur - o Ayar için geçerli bir yöntem yoktur - o Ayarlanmış sistemi yorumlamada semantik problemler vardır - o Değişen şartlara adaptasyon zordur - o Ayarlama başarılı olmayabilir

Çizelge 3.1. Yapay Sinir Ağları ile Bulanık Sistemlerin Avantaj ve Dezavantajları
Yapay Sinir Ağları ve Bulanık Sistemler aşağıdaki şekillerde birleştirilebilirler:

1- Bulanık Sinir Ağları

Bir yapay sinir ağının öğrenme yeteneğini ve performansını artırmak için bulanık yöntemler kullanılır.

2- Sinir Ağı ve Bulanık Sistemin Aynı Görevde Bağımsız Kullanımı

Bir yapay sinir ağı ile bulanık sistem, aynı görev için fakat birbirlerinin parametrelerini etkilemeden çalışırlar. Böyle bir yapıda, yapay sinir ağı bulanık sistemin kullanacağı verileri oluşturabilir ya da bulanık sistemin ürettiği verileri işler.

3- Sinir Ağı ve Bulanık Sistemin Birlikte Kullanımı

Bir yapay sinir ağı, bir bulanık sistemin parametrelerini (kurallarını, kural ağırlıklarını ve/veya bulanık kümelerini) belirlemek için kullanılır. Öğrenme aşamasından sonra bulanık sistem yapay sinir ağı olmadan çalışır. ANFIS (Adaptive

Neuro-Fuzzy Inference System) bu tür bir yapıdır. Bulanık kurallara ait parametreler en küçük kareler yöntemi ile geri yayılma algoritmasının birleştirildiği melez bir yöntemle belirlenmektedir.

4- Melez Yapay Sinir Ağı Bulanık Sistemler

Bir yapay sinir ağı ile bir bulanık sistem tek bir homojen yapıda birleştirilir. Böyle bir yapı, bulanık parametrelere sahip özel bir sinir ağı olarak ya da paralel dağıtık biçimde gerçekleştirilmiş bulanık bir sistem olarak tanımlanabilir. Nauck ve ark. (1997) bu yapıya sahip pek çok model açıklamışlardır. Bu modellerden bir kısmı, özellikle kontrol uygulamalarında etkili olan takviyeli (reinforcement) öğrenme türünde iken diğerleri NEFCLASS gibi verileri sınıflandırmada kullanılan ve öğreticili (supervised) öğrenmeye dayalı çok amaçlı modellerdir.

3.3.2. NEFCLASS Modeli

Bir NEFCLASS sistemi bir genel bulanık algılayıcıdan türetilmiş 3-katmanlı ileri beslemeli mimariye sahiptir (Nauck ve Kruse, 1996). İlk katman olan U_1 örüntü özelliklerini temsil eden giriş düğümlerini içerir. Bir $x \in U_1$ düğümünün a_x aktivasyonu çıkışına eşittir. Gizli katman olan U_2 bulanık kuralları temsil eden kural düğümlerinden oluşurken, üçüncü katman olan U_3 her sınıf için bir tane olmak üzere çıkış düğümlerini içerir. Bir p örüntüsü uygulandığında, bir $R \in U_2$ kural düğümü aktivasyonu ve bir $c \in U_3$ çıkış biriminin aktivasyonu aşağıdaki gibi hesaplanır.


$$a_R^{(p)} = \min_{x \in U_1} \{W(x, R)(a_x^{(p)})\}, \quad (3.33)$$

$$a_c^{(p)} = \sum_{R \in U_2} \frac{W(R, c) \cdot a_R^{(p)}}{W(R, c)} \quad \text{veya} \quad a_c^{(p)} = \max_{R \in U_2} \{a_R^{(p)}\} \quad (3.34)$$

Yukarıdaki denklemde $W(x, R)$, x giriş düğümünden R kural düğümüne bağlantı üzerindeki bulanık ağırlıktır. $W(R, c)$, R kural düğümünden c çıkış düğümüne bağlantı üzerindeki ağırlıktır. Anlamsal nedenlerle bu ağırlıkların değeri 1'dir (Nauck ve Kruse, 1996).

Aşağıdaki şekilde 2 giriş, 5 kural ve 2 çıkış düğümü olan bir NEFCLASS sistemi görülmektedir. Bu sistemin temel özelliği bazı bağlantılarda görülen paylaşılmış ağırlıklardır. Bir ağırlığı paylaşan bağlantılar daima aynı giriş biriminden gelir. Öğrenme işlemine başlamadan önce, her giriş özelliğine ait kümeleri

bölümleyen başlangıç bulanık kümelerin sayısı tanımlanmalıdır. Seçenek olarak, yaratılacak en fazla bulanık kural sayısı, yani gizli katmandaki düğüm sayısı, kullanıcı tarafından belirtilebilir. Alternatif olarak, yaratılacak bulanık kural sayısı hakkındaki karar NEFCLASS algoritmasına bırakılabilir.



Şekil 3.10. 2 giriş, 5 kural ve 2 çıkış düğümü olan bir NEFCLASS sistemi

Yakınsamayı yapacak ve NEFCLASS sistemini belirleyecek olan bulanık kümeler ve dilsel kurallar, eğitim kümesinden öğrenme ile elde edilir. NEFCLASS sisteminde öğrenme işlemi iki aşamadan oluşur. İlk aşamada, eğitim örnekleriyle olabilecek en uyumlu kural tabanı elde edilerek ağ yapısı (başka bir bakış açısıyla bulanık sistem) oluşturulur. Oluşan ağ yapısında kuralların ve bulanık kümelerin sayısı kullanıcının belirlediği değer kadar olmalıdır. İkinci aşamada ise bulanık küme fonksiyonlarına ait parametreler değiştirilerek ağ yapısı eğitilir. Nihai sınıflandırıcının elde edileceği şekilde sistemin parametrelerinin yinelemeli biçimde değiştirildiği bu aşamada ağın yorumlanabilirliği kaybedilmeden doğruluğu artırılır. NEFCLASS sınıflandırıcısının oluşturulduğu iki aşama aşağıda anlatılmıştır.

Kural Tabanı Oluşturma Aşaması

Başlangıçta bir NEFCLASS sistemin hiç gizli düğümü yoktur. Öğrenme işlemi sırasında algoritmanın ilk geçişinde yaratılırlar. Verilen bir p giriş örüntüsü için bulanık kuralların kombinasyonu bulunarak bir kural yaratılır. Her kombinasyon, ilgili giriş özelliği için en yüksek üyeliği verir. Eğer bir kombinasyon daha önce var

olan bir kuralın ilk kısmıyla aynı değilse ve en fazla gizli düğüm sayısına ulaşılmadıysa yeni bir kural düğümü yaratılır. Başka bir yol olarak da puanlama sistemi kullanılabilir. Başlangıçta kural sayısı sınırlanmaz ve daha sonraki adımlarda en yüksek puana sahip kurallar seçilir.

Aşağıdaki gibi üç parametrelili üçgensel üyelik fonksiyonlarının kullanıldığı bir NEFCLASS sistemi olsun.

$$\mu: IR^n \rightarrow \mu(x) = \begin{cases} \frac{x-a}{b-a}, x \in [a,b), \\ \frac{c-x}{c-b}, x \in [b,c] \\ 0 \text{ diger} \end{cases} \quad (3.35)$$

NEFCLASS sisteminde;

- $x_1, \dots, x_n$ olmak üzere n adet giriş birimi
- $k \leq k_{\max}$ olmak üzere $R_1, \dots, R_k$ başlangıç kural birimleri
- $c_1, \dots, c_m$ olmak üzere m adet çıkış birimi olsun.

Her bir eğitim örneği için $p \in IR^n$ ve $t \in \{0,1\}^m$ olmak üzere eğitim örnekleri kümesi $L = \{(p_1, t_1), \dots, (p_s, t_s)\}$ olacak şekilde s adet örnek içeriyor olsun.

NEFCLASS sistemi başlangıçta $k \leq k_{\max}$ bulanık kural içersin. NEFCLASS kural tabanı, her p örneği için her p_i değerine en yüksek üyelik derecesi sağlayacak bulanık kümelerin birleşimi bulunarak oluşturulur. Bulanık kuralların birleşimi muhtemel bir kuralın öncül kısmıdır. Böyle bir öncül kısım daha önce bulunmuyorsa, bir listede saklanır. Her öncül için uygun bir sonuç, her bir sınıf için ayrı ayrı ait tüm örneklerin uygunluk dereceleri toplanarak bulunur. Sonuç, en büyük toplamı veren sınıf etiketi olacaktır. Her bir eğitim örneği en az bir kez kullanıldıktan sonra, k' kuraldan oluşan bir kural tabanı elde edilmiş olur. Eğer $k' > k_{\max}$ ise, algoritmanın başında belirtilen kural öğrenme seçeneğine göre;

- En iyi $k_{\max}$ kural seçilir ('en iyi' kural öğrenmesi)
- Her sınıf için en iyi $k_{\max}/m$ kural seçilir ('her sınıf için en iyi' kural öğrenmesi)

Geriye kalan tüm kurallar kural tabanından silinir. En iyi kurallar, her kural için performans değerleri hesaplanarak belirlenir. Eğer bir kural bir örneği doğru

biçimde sınıflandırır, uygunluk derecesi performans değerine eklenir. Aksi halde uygunluk derecesi performans değerinden çıkarılır.

Eğer örnekler her sınıfa eşit olarak dağıtılmak istenirse ‘Her sınıf için en iyi’ kural öğrenmesi kullanılmalıdır. Bazı sınıflara ait örnek sayısının diğer sınıflardan daha az olduğu durumlarda, her sınıf örneklerin dağılımından bağımsız olarak belli kurallarla kapsanması böylece garantilenmiş olur. ‘En iyi’ kural öğrenmesi, bazı sınıfların diğerlerinden daha fazla sayıda kural ile kapsanması istendiğinde daha uygundur (Nauck ve Kruse, 1998).

Kural tabanı öğrenme algoritmasının akış şeması aşağıdaki gibidir.

L örnekleri kümesindeki her **(p, t)** örneği için

Her giriş özelliği için

$$\mu_{ji}^{(i)}(p_i) = \max_{j \in \{1, \dots, q\}} \{\mu_j^{(i)}(p_i)\} \text{ olacak şekilde } \mu_{ji}^{(i)} \text{ bul;}$$

$$A = (\mu_{ji}^{(1)}, \dots, \mu_{jn}^{(n)}) \text{ şeklinde öncül kısmı oluştur;}$$

Eğer A , öncül listesinde yoksa

A ’yı öncül listesine ekle;

L örnekleri kümesindeki her **(p, t)** örneği için

Her A_j öncül kısmı için

c = **t** verildiğinde **p**’nin sınıf indisi;

$$C_j(c) = C_j(c) + A_j(p); \quad // \text{uygunluk derecesi ekle}$$

Her A_j öncül kısım için

$$c = \arg \max_{i \in \{1, \dots, m\}} \{C_j(i)\};$$

Öncül kısım A_j ve sonuç kısım **c** olacak şekilde R_j kuralı oluştur;

R_j kuralını kural tabanı aday kuralları listesine ekle;

$$performans_j = C_j(c) - \sum_{i \in \{1, \dots, m\}, i \neq c} C_j(i);$$

Eğer ‘En iyi Kural Öğrenmesi’ seçilmişse

$i=1$ ’den $k_{\max}$ ’a kadar

$$R = \arg \max_{R_j} \{performans\};$$

R ’yi kural tabanına ekle;

R ’yi aday kurallar listesinden sil;

Eğer ‘Her Sınıf İçin En İyi Kural Öğrenmesi’ seçilmişse

Her c sınıfı için


$i=1$ 'den $\frac{k_{\max}}{m}$ 'e kadar

$$R = \arg \max_{R_j, \text{consequent}_j=c} \{performans\};$$

R'yi kural tabanına ekle;

R'yi aday kurallar listesinden sil;

Kural öğrenme algoritması bir ızgara yapısında aşağıdaki şekilde olduğu gibi görselleştirilmiştir. Şekilde, özellik uzayındaki ızgara yapısında kuralların nasıl seçildiği görülmektedir. Özellik uzayı bağımsız değişkenlerin bulanık kümeleri olarak belirlenmiştir. Sistemin üç kural oluşturmaya izin verildiği için, sınıflandırılmamış örnekler söz konusudur.



Şekil 3.11. Kural Öğrenme Algoritması sonucunda oluşan sınıflandırma

Yukarıdaki şekle göre, Örnek 1 ve Örnek 2 yanlış sınıflandırılmış ve 3 örnek hiç sınıflandırılmamıştır. Bulanık kümelerin, aşağıdaki şekilde, tabanlarını kaydırma ve biçimlerini değiştirme sınıflandırma performansını artıracaktır:

- Örnek 1'in doğru sınıflandırılması için
 - o Bulanık küme **b** tepesi kısaltılmalı
 - o Bulanık küme **d** tabanı genişletilmeli
 - o Bulanık küme **c'** sola doğru biraz genişletilmeli

- Örnek 2'nin doğru sınıflandırılması için
 - o Bulanık küme c' sağdan biraz kısaltılmalı
 - o Bulanık küme e' sola doğru biraz genişletilmeli
- Sınıflandırılmamış 3 örneğin doğru sınıflandırılması için
 - o Bulanık küme b' sağa doğru genişletilmeli

Bulanık Kümelerin Adaptasyon Aşaması

Kural tabanı yaratıldıktan sonra, bulanık kuralların ilk kısımlarına ait üyelik fonksiyonlarının uyarlanması gereklidir. Bulanık kümeler için öğrenme işlemi basit bir akıl yürütmeye dayanır. Üyelik fonksiyonlarını kaydırma ve fonksiyon tabanlarını büyütme veya küçültme şeklinde sonuçlanır.

Bir örnek ağa verildikten sonra, her çıkış birimi için hata değeri belirlenir. Bu hataya bağlı olarak, her aktif kural birimi için uygunluk derecesinin küçük veya büyük olacağı kararlaştırılır. Uygunluk derecesinden sorumlu olan üyelik fonksiyonu belirlenir ve sadece ilgili bulanık küme gereken biçimde adapte edilir. Bir bulanık kümenin adapte edilebilmesi için kullanıcı tarafından belirlenen kısıtlamaların ihlal edilmemesi gereklidir. Kullanıcı aşağıdaki kısıtlamaları tanımlayabilir:

- Bulanık kümeler belirli bir dereceye kadar üst üste binebilir.
- Bulanık kümeler tamamen yer değiştirmemelidir.
- Bulanık kümeler simetrik olmalıdır.
- Üyelik dereceleri toplamı 1.0 olmalıdır.

Yukarıdaki kısıtlamalar yorumlanabilir bir kural tabanı elde edilmesine yardımcı olurken, sınıflandırma performansının düşmesine neden olabilir. Aşağıda üçgensel üyelik fonksiyonları için bulanık kümelerin eğitimi algoritması verilmiştir.

Tekrarla

Sonraki (p,t) örneğini uygula;

Her c_i çıkış ünitesi için

$$e_{ci} = t_i - \text{aktivasyon}(c_i);$$

Aktivasyon(R)>0 olan her R kural birimi için

$$e_R = \text{aktivasyon}(R) \cdot (1 - \text{aktivasyon}(R)) \cdot \sum_{c_i} (W(R, c) \cdot e_{ci})$$

$$j = \arg \min_{i \in \{1, \dots, n\}} \{W(x_i, R)(p_i)\}$$

$$\mu = W(x_j, R)$$

(* a_μ , b_μ ve c_μ , μ bulanık kümesinin parametreleri *)


$$\delta_b = \sigma \cdot e_R \cdot (c_\mu - a_\mu) \cdot \text{sgn}(p_i - b_\mu);$$

$$\delta_a = -\sigma \cdot e_R \cdot (c_\mu - a_\mu) + \delta_b;$$

$$\delta_c = \sigma \cdot e_R \cdot (c_\mu - a_\mu) + \delta_b;$$

μ bulanık kümesini δ_a , δ_b ve δ_c ile değiştir;


Sonlanma kriterini kontrol et;



Şekil 3.12. Bulanık kümelerin adaptasyonu

Bulanık kümelerin adaptasyonu, üyelik fonksiyonunun parametrelerinin değiştirilmesi ile sağlanır. Bu işlem, yukarıdaki şekilde gösterildiği gibi, ilgili özellik değerinin üyelik derecesini artırılması veya azaltılması şeklinde yapılır.

Aşağıdaki şekilde, sınıflandırma sonucunu iyileştirmek için bulanık kümelerin adaptasyonu sonucu oluşan durum görülmektedir. Burada öğrenme işlemini kısıtlayan hiçbir şart tanımlanmamıştır. Sonuçta ortaya çıkan bulanık bölümler iyi biçimde yorumlanabilir değildir. Böyle bir durumda, öğrenme işlemi başka parametrelerle tekrar edilebilir. Örneğin; sistemin dört kural oluşturması ve üyelik fonksiyonlarını değiştirmede kullanılan kısıtlamaların tanımlanması daha yorumlanabilir bir sonucun oluşmasını sağlayabilir.



Şekil 3.13. Bulanık kümelerin adaptasyonu sonrasında oluşan sınıflandırma

Bu tez çalışmasında, her giriş düğümü için 4 bulanık kümeden (çok küçük, küçük, büyük ve çok büyük) oluşan üçgensel üyelik fonksiyonu tanımlanmıştır. Üyelik fonksiyonunun değişimi aşaması için bulanık kümelerin birbirlerine göre göreceli durumlarını koruması fakat bulanık kümelerin üst üste binebilmesi şartları tanımlanmıştır. En fazla oluşacak kural sayısı 10 olarak seçilmiştir. Kural öğrenme yöntemi olarak ‘Her Sınıf İçin En İyi’ seçeneği kullanılmıştır. Ayrıca kural düğümlerinin aktivasyonunun belirlemek için *t-norm* işlemi olarak *min* fonksiyonu kullanılmıştır.

Kural Tabanının Budanması



NEFCLASS gerçekleştiriminde kullanılan otomatik budama teknikleri, sonuç modelin anlaşılabilirliğini artırmak için kural sayısını ve değişken sayısını azaltmaya çalışır. Bir bulanık kural tabanının boyutu, tüm eğitim örüntüleri en az bir kural ile kapsanana kadar kuralların sürekli seçilmesi ile otomatik olarak belirlenir. Kural tabanının performansını artırmak üzere üyelik fonksiyonlarının eğitilmesinden sonra, bir budama mekanizması sınıflandırıcının anlaşılabilirliğini artırmak üzere kuralları ve değişkenleri yok eder. Budama işlemi, aşağıda verilen 4 akıl yürütme stratejisini kullanan basit bir obur algoritmaya dayanır (Nauck ve ark., 1999):

- (i) İlinti ile Budama: Sınıflandırma üzerinde en az etkisi olan değişken silinir.
- (ii) Sınıflandırma Frekansı ile Budama: En az sayıda durumda en çok geçerlilik derecesi olan kural silinir.
- (iii) Artıklık ile Budama: En az sayıda durumdaki aktif bir kuralda en küçük üyelik derecesine sahip dilsel terim silinir.
- (iv) Bulanıklık ile Budama: En büyük tabana sahip bulanık küme belirlenir ve bu bulanık kümeyi kullanan tüm terimler tüm kurallardan silinir.

Her budama adımının sonunda, üyelik fonksiyonları yeniden eğitilir. Tüm bu 4 budama stratejisi bir budama adımı başarısız olana kadar tekrarlanır. Daha sonra sıradaki budama stratejisi seçilir. Değişken budama esnasında kural tabanı tutarsız hale gelirse, kural tabanı tekrar tutarlı hale gelene kadar tutarsızlıklar otomatik olarak çözülür. Üyelik fonksiyonlarının eğitilmesinden sonra hata artmışsa veya kural tabanı tutarlı duruma yeniden getirilemiyorsa, budama adımı başarısız olmuştur. Bu durumda budama işlemi geri alınır.

3.3.3. Adaptif Yapay Sinir Ağı Bulanık Mantık Çıkarım Sistemi (Adaptive Neuro Fuzzy Inference System - ANFIS)

ANFIS, eğimli azalma (gradient descent) ve en küçük kareler yöntemlerini birleştiren etkin ve hibrid bir öğrenme yöntemi kullanmaktadır. En küçük kareler yöntemi, hızlı öğrenmeyi sağlarken, eğimli azalma en küçük kareleri yönteminin temel fonksiyonlarını üreten üyelik fonksiyonlarını yavaşça değiştirir (Jang 1993).



Şekil 3.14. (a) Sugeno (Tür-3) bulanık mantık modeli (b) Buna karşılık gelen ANFIS yapısı

Sugeno türü (Tür-3) bulanık mantık modelinde, her kuralın çıktısı giriş değişkenlerinin ve sabit bir terimin doğrusal birleşimi şeklindedir. Sonuç değer, her kuralın çıktısının ağırlıklı ortalamasıdır.

Yukarıdaki şekilde, verilen bir $[x,y]$ giriş vektörü için f çıktısını üreten bulanık mantık sistemi görülmektedir. Ateşleme değerleri w_1 ve w_2 , giriş değişkenlerine ait üyelik değerlerinin çarpımı şeklinde elde edilir. Sonuç f değeri, her kuralın çıktısının ağırlıklı ortalamasıdır.

Şekil 3.14 (b)'de verilen ANFIS yapısı 5 katmandan oluşmaktadır (Jang ve ark., 1997). Bu yapıda, kareler parametreleri olan adaptif düğümleri, daireler ise sabit düğümleri göstermektedir. Aynı katmandaki düğümlerin hepsi aynı işleve sahiptir.

1. Katman : Bu katmandaki düğümler, girişlerin üyelik değerlerini üretirler. Bir i . düğüm, en büyük 1 ve en küçük 0 değerleri alacak şekilde, genelleştirilmiş çan eğrisi şeklinde bulanık üyelik fonksiyonuna sahip olsun. Bu düğümün çıkış değeri aşağıdaki gibi tanımlanır:

$$O_i^1 = \mu_{A_i}(x) = \frac{1}{1 + \left(\frac{x - c_i}{a_i} \right)^{2b_i}} \quad (3.36)$$

Bu denklemde x , i . düğümün girişi, A_i bu düğümle ilişkilendirilmiş dilsel etiket ve $\{a_i, b_i, c_i\}$ öncül parametreler kümesidir. Öncül parametre kümesi, ağın öğrenme ve adaptasyonu boyunca üyelik fonksiyonunun şeklini değiştirmede kullanılır.

2. Katman: Bu katmandaki düğümler T-norm işleci olarak *çarpım* kullanarak kuralların ateşleme şiddetini hesaplar.

$$O_i^2 = w_i = \mu_{A_i}(x) \times \mu_{B_i}(y), i = 1, 2 \quad (3.37)$$

3. Katman: Bu katmandaki i . düğüm i . kuralın ateşleme şiddetini normalize eder. Bunun için, i . kuralın ateşleme şiddetinin tüm kuralların ateşleme şiddetlerinin toplamına oranını kullanır.

$$O_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2}, i = 1, 2. \quad (3.38)$$

4. Katman : Bu katmandaki düğümler kendileri ile ilişkili kuralların tüm çıktıya yaptıkları katkıyı hesaplarlar.

$$O_i^4 = O_i^3 f_i = O_i^3 (p_i x + q_i y + r_i) \quad (3.39)$$

Yukarıdaki denklemde yer alan $\{p_i, q_i, r_i\}$ değerlerine sonuç parametreleri denir.

5. Katman : Bu katmanda bulunan tek düğüm, bir önceki katmandan gelen sinyallerin toplamını genel çıkış değeri olarak hesaplar.



$$O_i^s = \frac{w_1 f_1 + w_2 f_2}{w_1 + w_2} \quad (3.40)$$

ANFIS yapısında, *öncül* parametrelerin değeri verildiğinde f genel çıktı değeri *sonuç* parametrelerin doğrusal birleşimi şeklinde ifade edilebilir.

$$\begin{aligned} f &= \bar{w}_1 f_1 + \bar{w}_2 f_2 \\ &= [(\bar{w}_1 x) p_1 + (\bar{w}_1 y) q_1 + (\bar{w}_1) r_1] + [(\bar{w}_2 x) p_2 + (\bar{w}_2 y) q_2 + (\bar{w}_2) r_2]. \end{aligned} \quad (3.41)$$


Bu gözleme dayanarak Jang ve ark. (1993), en uygun parametreleri etkin biçimde aramak için eğimli azalma ve en küçük kareler yöntemlerini birleştiren bir hibrid öğrenme algoritması önermiştir. Adaptif sinir ağı parametrelerini belirlemede eğimli azalma yöntemi tek başına kullanıldığında yavaş çalışmakta ve yerel minimum noktasına takılma ihtimali artmaktadır. Hibrid algoritmadaki ileri geçişlerde, en küçük kareler yöntemi öncül parametreler sabitlenerek en uygun sonuç parametrelerini bulur. En uygun sonuç parametreleri bulunduktan sonra, eğimli azalma yöntemini kullanan geriye geçişlerde öncül parametreler ayarlanır. Beklenen giriş-çıkış eşleşmesini sağlamak için, önceden girilen adım sayısına ulaşılan kadar, eğitim verilerine göre her adımda bu parametreler güncellenir. Bu hibrid algoritmanın ANFIS yapısını eğitmede çok etkin olduğu ispatlanmıştır (Jang 1992, Jang 1993). Bu tez çalışmasında yer alan ANFIS yapısının eğitilmesinde bu algoritma kullanılmıştır.

Şekil 3.13 (b)'de verilen adaptif ağ yapısı, fonksiyon olarak Tür-3 bulanık çıkarım sistemine eşdeğerdir. Tür-1 bulanık çıkarım sisteminde, çıkış üyelik fonksiyonu ve ateşleme şiddeti kullanılarak her kuralın çıktısı elde edilir. Tür-2 bulanık çıkarım sistemleri için, merkezi berraklaştırma işlecinin yerine yaklaşık alan merkezinin hesaplandığı kesikli biçimi kullanılırsa, Tür-3 ANFIS yapısı yine elde edilebilir. Fakat Tür-3 ve Tür-1 biçimlerine göre daha karmaşık olduğu için, etkin biçimde kullanımı zor olmaktadır. Şekil 3.14'te Tür-1 bulanık mantık modeli ve buna karşılık gelen ANFIS yapısı verilmiştir.



Şekil 3.15. (a) Tür-1 bulanık mantık modeli (b) Buna karşılık gelen ANFIS yapısı

Aşağıdaki şekilde, 2 girişli ve 9 kurallı bir Tür-3 ANFIS modeli gösterilmiştir. Her girişle 3 üyelik fonksiyonu ilişkilendirilmiş, böylece giriş uzayı her biri farklı bir bulanık EĞER-O HALDE kuralı ile yönetilen 9 bulanık alt uzaya bölünmüştür. Bir kuralın öncül kısmı bulanık alt uzayın sınırlarını belirlerken, sonuç kısmı ilgili alt uzay içindeki çıktı değerini belirler.




Şekil 3.16. (a) 2 Girişli 9 Kurallı Tür-3 ANFIS (b) İlgili Bulanık Alt Uzaylar

3.3.4. Karar Ağaçları

Tümevarımsal sonuç çıkarma için kullanılan en yaygın ve pratik yöntemlerden birisidir. Ayrık değerli fonksiyonları yakınsayan, gürültülü verilere karşı dayanıklı ve ayıran (disjunctive) ifadeleri öğrenme yeteneği olan bir yöntemdir. Tamamen ifade edilmiş hipotez uzayında arama yapar. Böylece kısıtlı hipotez uzayının zorluklarını aşmayı sağlar. Tümevarım varsayımı olarak, küçük ağaçlar büyüklere tercih edilir. Öğrenilen fonksiyon karar ağacı şeklinde gösterilir. Karar ağaçları aynı zamanda EĞER-O HALDE kuralları şeklinde gösterilebilir. Örneğin; Hava, Sıcaklık, Nem ve Rüzgar özelliklerine göre “Tenis” oynanacağına karar verme işlemi için Şekil 3.16’daki gibi oluşmuş bir karar ağacının kural gösterimi şu şekildedir:

- EĞER HAVA güneşli ve NEM normal ise O HALDE tenis oynanabilir.
- EĞER HAVA bulutlu ise O HALDE tenis oynanabilir.
- EĞER HAVA yağışlı ve RÜZGAR zayıf ise O HALDE tenis oynanabilir.



Şekil 3.17. Örnek bir karar ağacı

Her bir düğüm, eğitim örneğine ait bir özelliğin test edilmesini sağlar ve bu düğümünden çıkan her dal özelliğin bir değerine karşılık gelir. Bir örnek, ağacın kök düğümünden başlayarak sınıflandırılmaya başlanır ve her düğümde ilgili özellik için test edilir. Örnekte, özelliğe verilen değere göre ilgili dala yönelir. Aynı işlem bir sonraki düğümde tekrarlanır.

Karar ağaçları, kesişimlerin (conjunction) birleşimi (disjunction) olarak düşünülebilir. Ağacın kökünden bir yaprağa izlenen yol, özellik testlerinin kesişimi ve ağacın kendisi bu kesişimlerin birleşimidir. Karar ağacı algoritması, ağacı oluşturmak için eğitim verileri kümesini kullanır.

Karar Ağacı öğrenmesinin sınıflandırma işleminde kullanımı aşağıdaki durumlarda uygundur:

- Örnekler, özellik-değer ikilileri şeklinde ifade ediliyorsa. Algoritma gerçek değerli özellikler için de kullanılabilir.
- Hedef fonksiyon, discrete çıkış değerlere sahipse. Boolean çıkışlı olabildiği gibi, ikiden çok değerli çıkışları olan hedef fonksiyonlar da kullanılabilir.
- Birleşim şeklinde (disjunctive) tanımlar gerekliyse
- Eğitim verilerinin bir kısmının hata içerebilme ihtimali varsa. Eğitim örneklerinin sınıflandırılmasında veya özellik değerlerinde hatalar olabilir.
- Eğitim verileri, eksik özellik değerleri içeriyorsa.

Quinlan (1986) tarafından tasarlanan ID3 algoritması eğitim örneklerinin özellikleri üzerinden arama yaparak, verilen örnekleri en iyi ayıran özelliği belirler. Ağacın her bir düğümünde hangi özelliğin seçilmesi gerektiği kararının verilmesine dayanır. Örnekleri sınıflandırmada en yararlı olacak özelliğin seçilmesi için istatistiksel bir fonksiyon olan Bilgi Kazancı (Information Gain) kullanılır. Bilgi Kazancı bir özelliğin, hedef sınıflandırmaya göre eğitim örneklerini ne kadar iyi ayırdığıyla ölçülür ve aşağıdaki gibi tanımlanır;

$$Kazanç(S, A) = Entropi(S) - \sum_{v=Deger(A)} \frac{|S_v|}{|S|} Entropi(S_v) \quad (3.42)$$

Yukarıdaki denklemde A özellik, S örnekler kümesi, Deger(A) A'nın alabileceği tüm değerler, S_v A özelliğinin v değerini aldığı örneklerin sayısı ve $Kazanç(S,A)$, A özelliğinin değerinin bilinmesiyle *Entropi*'de beklenen azalmadır. *Entropi*, S kümesinden rasgele seçilen bir örneğin ait olduğu sınıfı kodlamak için gereken bit sayısıdır. *Entropi*, örneklerin homojenliğini ölçmede kullanılır ve aşağıdaki gibi tanımlanır;

$$Entropi(S) = -p_{\oplus} \log_2 p_{\oplus} - p_{\ominus} \log_2 p_{\ominus} \quad (3.43)$$

Yukarıdaki denklemde S eğitim örnekleri kümesini, $p_{\oplus}$ pozitif örneklerin oranını ve $p_{\ominus}$ negatif örneklerin oranını göstermektedir. Örneğin; S kümesi 9 pozitif ve 5 negatif olmak üzere 14 örnekten oluşsun. Bu durumda;

$$Entropi([9+,5-]) = -(9/14)\log_2(9/14) - (5/14)\log_2(5/14) = 0.940 \text{ olacaktır.}$$

Bütün örnekler aynı sınıfa ait ise, örneğin tüm örnekler pozitif ise, bu durumda Entropi(S)=0 olacaktır. Örneklerin yarısı pozitif, yarısı negatif ise Entropi(S)=1 olur. Pozitif ve negatif örnekler eşit değilse Entropi(S), 0 ile 1 arasındadır.

Pozitif-negatif gibi 2 değerli sınıflandırmadan daha çok sınıflandırma içeren öğrenme sistemlerinden Entropi(S) aşağıdaki gibi tanımlanır:

$$Entropi(S) = \sum_{i=1}^c -p_i \log_2 p_i \quad (3.44)$$

ID3 algoritması, ağaç büyürken her adımda hangi özelliğin düğüm olarak kullanılacağını Bilgi Kazancı ölçütünü kullanarak bulur. Algoritmanın akışı aşağıda verildiği gibidir:

ID3 (Örnekler, Hedef_Özellik, Özellikler)

Örnekler → Eğitim Örnekleri

Hedef_Özellik → Değeri ağaç tarafından belirlenecek özellik

Özellikler → Öğrenilen karar ağacı tarafından test edilecek diğer özellikler

- Ağaç için kök düğüm oluştur.
- Eğer tüm örnekler pozitif ise, + değeri tek kök düğümlü ağacı döndür.
- Eğer tüm örnekler negatif ise, - değeri tek kök düğümlü ağacı döndür.
- Eğer özellikler boş ise, hedef özelliğin örneklerde en çok bulunan değerini içeren tek kök düğümlü ağacı döndür.
- Aksi halde,
 - o $A \leftarrow$ Örnekleri en iyi sınıflandıran (bilgi kazancına göre) özellik
 - o Kök için karar özelliği $\leftarrow A$
 - o A'nın her v_i değeri için
 - Kök'ün altına $A=v_i$ şeklinde bir dal ekle
 - Örnekler_{v_i} , A için v_i değeri olan alt örnekler kümesi olsun
 - Eğer Örnekler_{v_i} boş ise
 - Bu dalın altına, hedef_özellik Örnekle içindeki en çok bulunan değerini içeren bir yaprak düğüm ekle
 - Aksi halde bu dalın altına aşağıdaki verilen alt ağacı ekle
 - o ID3(Örnekler_{v_i} , Hedef_Özellik, Özellikler-[A])

- Son
- Kökü döndür

ID3 algoritması tüm olası karar ağaçları içinden eğitim örneklerini sağlayan ilk karar ağacını seçer. Küçük ağaçlar büyüklere tercih edilir ve yüksek bilgi kazancı sağlayan özellikler kök düğüme akın olur. Her özellik ağaçta sadece bir kez kullanılır. ID3 algoritması tüm özellikler ağaçta kullanıldığında ya da son eklenen düğümlerle (özellikle) ilgili tüm eğitim örnekleri aynı çıktıyı veriyorsa (tümü pozitif veya tümü negatif ise) sonlanır. Her yeni düğümlerde, kullanılan özellikleri içeren örnekler kullanılarak Bilgi Kazancı(S,A) hesaplanır.

Karar ağaçlarında, eğitim örneklerine uyan bir hipotez bulmak için hipotez uzayı aranır. Hipotez uzayı, mümkün olan tüm karar ağaçlarıdır. Basitten karmaşığa doğru tepe tırmanma (hill climbing) araması yapılır. Boş ağaçtan başlanır ve eğitim verisini doğru biçimde sınıflandıracak karar ağacının bulunması için ağaç oluşturulur. Aramada fonksiyon olarak *Bilgi Kazancı* kullanılır. Hipotez uzayı, eldeki özelliklere bağlı olarak ayrık değerli fonksiyonların eksiksiz uzayıdır. Her fonksiyon, ayrı bir karar ağacı ile gösterildiği için, eksik hipotez uzayı kullanma riskinden kurtulmuş olunur. Hipotez uzayı hedef fonksiyonu kesin olarak içerir. ID3 algoritması arama yaparken geriye doğru gitmediği için ulaşılan karar ağacı başka bir karar ağacına göre daha az tercih edilir olabilir.

ID3 algoritmasının kullandığı bilgi kazancı ölçütünde, bazı özellikler eğitim örneklerini çok sayıda küçük alt kümelere bölebilir. Bu tür özellikleri cezalandırmak için C4.5 algoritmasında (Quinlan 1993) Kazanç Oranı (Gain Ratio) denilen ölçüt kullanılır.

$$KazancOrani(S, A) \equiv \frac{Kazanc(S, A)}{Bolumleme(S, A)} \quad (3.45)$$

$$Bolumleme(S, A) \equiv -\sum_{i=1}^c \frac{|S_i|}{S} \log_2 \frac{|S_i|}{S} \quad (3.46)$$


Örneklerin büyük çoğunluğu için aynı değere sahip özellikler için *Bolumleme* fonksiyonunun değeri sıfıra yakın veya sıfır olacaktır. Bu durumda *KazancOrani* değeri, sonsuz veya çok büyük olacaktır. Bunu önlemek için özelliklerin ortalama kazancı bulunur. Sonra kazanç oranı ölçütü, kazancı bu ortalamadan büyük olanlar için hesaplanır.

Bazı öğrenme problemlerinde özelliklerin maliyeti olabilir. Böyle durumlarda, düşük maliyetli özellikleri tercih eden karar ağaçları tercih edilmelidir. Yüksek maliyetli özelliklere sadece daha güvenilir sonuç elde etmek için başvurulmalıdır. C4.5 algoritmasında, özellik seçim ölçüsüne maliyet terimi eklenmiştir. Bunun için; $Kazanc(S,A)$ fonksiyonu maliyet değerine bölünerek kullanılır. Böylece, düşük maliyetli özellikler kök düğüme yakın olacaktır. Bu uygulama, en uygun maliyet tabanlı ağacı vermeyebilir, fakat karar ağacı düşük maliyetli özelliklere dayalı olarak oluşacaktır.

C4.5 algoritması karar ağacı oluştururken sürekli değere sahip özellikleri de ele alabilmektedir. Bunun için, sürekli özellik değeri dinamik olarak ayrık aralıklar kümesine bölünür. C4.5 algoritması ayrıca, bir özelliğin eksik değerlerini ilgili özelliğin bir değere sahip olduğu diğer örnekleri kullanarak çıkarabilir. Bir n düğümünde seçilmesi gereken özelliğin A olup olmadığına karar vermek için $Kazanc(S,A)$ fonksiyonunun değeri bulunacaksa ve $(x, c(x))$ örneğinde A 'nın değeri bilinmiyorsa aşağıdaki yöntemlerden biriyle yeni bir değer verilebilir:


1. n . düğümdeki tüm eğitim örnekleri içinde en yaygın A değeri verilebilir.
2. $c(x)$ sınıflandırmasını sağlayan, n . düğümdeki tüm eğitim örnekleri içinde en yaygın A değeri verilebilir. $A(x)$ için verilen bu değeri içeren eğitim örneği, karar ağacına o anda verilerek eğitime devam edilebilir.
3. $A(x)$ 'in tüm olası değerleri için bir olasılık değeri verilir. Daha sonra bu olasılıklar, n . düğümdeki örnekler arasında A 'nın değişik değerlerinin frekanslarına bağlı olarak yeniden hesaplanır.

Eğitim verilerinde gürültü varsa veya hedef fonksiyonu tam bir gösterimini üretmek için eldeki veri çok az ise, karar ağaçlarında eğitim verilerini aşırı öğrenme (overfitting) durumu ortaya çıkabilir. Bu sorunu önlemek için ağacın büyümesi daha önceden durdurulabilir, fakat buna doğru karar vermek çok zordur. Pratikte daha kullanışlı diğer bir yaklaşıma göre ise, aşırı öğrenme ortaya çıkacak şekilde ağacın büyümesine izin verip daha sonra budama (pruning) yapılır.



Şekil 3.18. Karar Ağaçlarında Aşırı Öğrenme (Overfitting) Durumu

Ağaçtan budama yapılacak düğümleri bulmak için, elimizde eğitim kümesinden ayrı bir veri kümesi olmalıdır. Budama, bir düğümün altındaki tüm ağacı ortadan kaldırma ve bunun yerine eğitim örneklerinin en uygun sonucunu yazma şeklinde yapılır. Budama sonucu oluşan ağaç, önceki ağaçtan daha kötü performans göstermemelidir. Eğitim sırasında, verilerdeki yanlışlık sonucu eklenmiş düğümler, budama işlemi sırasında doğrulama verileri (hatasız oldukları için) tarafından silinecektir. Hatalı biçimde eklenmiş düğümler silindikçe, ağacın doğruluğu artacaktır.



Şekil 3.19. Karar Ağaçlarında Budama (Pruning) işlemi sonucu test verilerindeki doğruluğun artması

3.3.5. En Yakın Komşu (EYK) Algoritması

EYK algoritması gibi örneğe dayalı öğrenme yöntemleri gerçek değerli ve ayrık değerli bir hedef fonksiyona yakınsama yapabilir. Bu yöntemlerde, eğitim verileri başlangıçta saklanır, yeni bir örnek geldiği zaman bu saklanmış eğitim verileri içinden bu örneğe en çok benzeyenler kullanılarak sınıflandırılır. Ayrıca;

- Her farklı örnek için, hedef fonksiyona farklı bir yakınsama oluşturulur.
- Tüm örnek uzayı için tek bir hedef fonksiyon değil, yeni örneğin komşuları için geçerli olan hedef fonksiyona yerel bir yakınsama yapılır.
- Hedef fonksiyon çok karmaşık ise, fakat daha basit yerel yaklaşımlarla gösterilebiliyorsa çok avantajlıdır.

Örneğe dayalı öğrenmede, yeni örneklerin sınıflandırılma maliyeti yüksektir. Çünkü hesaplamalar sınıflandırma sırasında yapılır. Eğitim verilerini etkin biçimde indeksleme hesaplama zamanını azaltmak için önemlidir. En yakın komşu yöntemi, benzer eğitim örneklerini bellekten alırken tüm özelliklerini kullanarak sınıflandırma yapar. Eğer, hedef kavram sadece birkaç özelliğe bağlı ise gerçekte en çok benzeyen eğitim örneğini sınıflandırırken hiç kullanmama durumu ortaya çıkabilir.

EYK yönteminde, tüm örnekler n boyutlu uzaydaki noktalara karşılık gelir. Bir örneğin yakın komşuları Öklid uzaklığı tanımı ile belirlenir. Örnekler, $\langle a_1(x), a_2(x), \dots, a_n(x) \rangle$ şeklinde özellik vektörleri şeklinde tanımlansın. Bu durumda $a_r(x)$, x örneğinin r . özelliği iken x_i ve x_j örnekleri arasındaki $d(x_i, x_j)$ uzaklığı aşağıdaki gibi tanımlanır.

$$d(x_i, x_j) \equiv \sqrt{\sum_{r=1}^n (a_r(x_i) - a_r(x_j))^2} \quad (3.47)$$

V sınırlı kümesi $\{V_1, \dots, V_S\}$ iken ayrık değerli hedef fonksiyon $f, R^n \rightarrow V$ şeklinde tanımlanır.

EYK algoritması için eğitim aşaması şu şekildedir:

- Tüm $\langle x, f(x) \rangle$ eğitim örnekleri *Eğitim Örnekleri* listesine eklenir.

EYK algoritması için sınıflandırma işlemi adımları ise

- x_q örneği için
 - o $x_1, \dots, x_k$ örnekleri *Eğitim Örnekleri* içinden x_q 'ye en yakın olanlar olsun.

- o k adet komşu içeren EYK komşu algoritması için

$$\hat{f}(x_q) \leftarrow \arg \max_{v \in V} \sum_{i=1}^k \delta(v, f(x_i)) \text{ sonucu döndürülür.}$$

Burada eğer $a=b$ ise $\delta(a,b)=1$ ve eğer $a \neq b$ ise $\delta(a,b)=0$ 'dır.

Yukarıdaki algoritma x_q 'ye en yakın k eğitim örneği arasında f 'nin en çok bulunan değerini döndürür.

Gerçek değerli hedef fonksiyonların yakınsamasında k adet komşu için EYK algoritmasının son satırı aşağıdaki gibi değiştirilmelidir.

$$f(x_q) \leftarrow \frac{\sum_{i=1}^k f(x_i)}{k} \quad (3.48)$$

EYK algoritmasında, x_q noktasına en yakın komşuların uzaklıklarını belli bir ağırlık değeriyle çarpmak mümkündür. Bu durumda, yakın komşular için daha büyük ağırlık verilir.

$$f(x_q) \leftarrow \arg \max_{v \in V} \sum_{i=1}^k w_i \delta(v, f(x_i)) \quad (3.49)$$

$$w_i \equiv \frac{1}{d(x_q, x_i)^2} \quad (3.50)$$

Şayet x_q, x_i eğitim örneğine tam olarak uyarırsa $d(x_q, x_i)^2 = 0$ olacaktır. Bu özel durum için $f(x_q) \leftarrow f(x_i)$ aktarımı yapılır. Eğer bu şekilde birden fazla x örneği varsa, bunlar içinde en fazla bulunan sınıflandırma sonucu $f(x_q)$ 'ye aktarılır.

Örnekleri uzaklık ağırlık yöntemine göre kullanmak için, gerçek değerli hedef fonksiyon aşağıdaki gibi olur.

$$f(x_q) \leftarrow \frac{\sum_{i=1}^k w_i f(x_i)}{\sum_{i=1}^k w_i} \quad (3.51)$$

Yukarıdaki $\sum_{i=1}^k w_i$ değeri, ağırlıkların katsayılarını normalize etmektedir. Eğer tüm eğitim örnekleri için $f(x_i)=c$ ise, $f(x_q)=c$ olacaktır.

Uzaklık ağırlık yönteminde, yeni bir örneği sınıflandırmada tüm eğitim örnekleri kullanılabilir. Çok uzak örneklerin etkisi az olacağı için sonucu değiştirmeyecektir. Fakat bu durumda sınıflandırıcı çok yavaş çalışacaktır.

EYK algoritmasında kullanılan yöntemlerden biri olan global yöntem (Shepard yöntemi) tüm eğitim örneklerini kullanırken, yerel yöntem sadece en yakın örnekleri kullanır. Uzaklık ağırlıklı EYK algoritması;

- Pratikte çokça kullanılmaktadır.
- Gürültülü eğitim verilerine karşı dayanıklıdır.
- Yeterince büyük eğitim verisi kümesi verildiğinde oldukça etkindir.

EYK algoritması için tümevarım varsayımına göre x_q örneğinin sınıflandırılması, Öklid uzayında en yakın örneklerle aynı olacaktır.

EYK algoritmasını pratikte kullanmak için uygulanacak yöntemlerden biri etkin bellek indekslemedir. Yeni örneği sınıflandırmada kullanılacak eğitim verilerine hızlı biçimde ulaşmak önemlidir. Bunun için kullanılacak indeksleme yöntemlerinden biri *kd ağacı* yöntemidir. Bu yöntemde, eğitim örnekleri yapraklarda saklanır. Yakın örnekler aynı veya yakın düğümlerde saklanır. Yapraklar haricindeki iç düğümler, x_q örneğinin ilgili özellikleri test ederek ilgili yaprağa göre x_q örneğinin dizilmesini gerçekleştirir.

EYK yöntemi basit olmasına karşın, pek çok pratik uygulamada başarılı biçimde kullanılmıştır (Mitchell 1997, Zhang 2002, Moore 1992).

3.3.6. Çok Katmanlı Algılayıcı (ÇKA) Sinir Ağları

Geri yayılmayla eğitilen çok katmanlı algılayıcı (Rumelhart ve McClelland, 1986), yapay sinir ağı sınıflandırıcıları içinde en ünlüsü ve en yaygın kullanılanıdır. Lineer olmayan aktivasyon fonksiyonlu ve tek gizli katmanlı ağların en çok kabul gören sınıflandırıcılar olduğu bilinmektedir. Doğru biçimde eğitildiklerinde, herhangi bir örüntüyü belirleyen özellik kümesini giriş vektörü olarak alıp, istenilen sınıflandırmayı yapabilecek güce sahiptirler. ÇKA Sinir Ağları çok çeşitli tanıma ve tahmin görevlerini yerine getirmek için kullanılan parametrik olmayan tekniklerdendir (Haykin 1994, Basheer ve Hajmeer, 2000, Chaudhuri ve Bhattacharya, 2000). Öğrenme ve genelleme yeteneği, düşük eğitim gereksinimleri, eğitimden sonra hızlı işlem yapabilme ve kolay gerçekleştirim gibi özelliklere

sahiptirler. Bir ÇKA Sinir Ağı, giriş değişkenlerini temsil eden düğümlere sahip giriş katmanı farklı sınıfları temsil eden çıkış katmanı ve verilerdeki doğrusal dışılığı yakalamak için düğümler içeren bir veya daha fazla gizli katmandan oluşur. Gizli katmandaki her j düğümü, kendilerine gelen her x_i sinyalini ilgili w_{ji} ağırlığıyla çarptıktan sonra toplayarak çıkış değerini aşağıdaki gibi bir toplam fonksiyonu ile hesaplar.

$$y_j = f\left(\sum w_{ji}x_i\right) \quad (3.52)$$

Yukarıdaki denklemde f , düğüme gelen tüm sinyallerin ağırlıklı toplamını bir çıkış değerine dönüştüren aktivasyon fonksiyonudur.

Aktivasyon fonksiyonu olarak kullanılabilecek birkaç seçenek vardır. Bu tez çalışmasında Sigmoid kullanılmıştır:

$$f(net_i) = \frac{1}{1 + e^{\frac{-net_i}{Q_0}}} \quad (3.53)$$

Q_0 terimi, sinir hücresinin sıcaklık değeridir. Sıcaklık ne kadar büyükse, Sigmoid fonksiyonu o kadar yavaş değişir. Çok düşük sıcaklıklarda ise bir adım fonksiyonuna dönüşür.

Giriş örüntülerinin uygun sınıflandırılması için gerekli bilgi, ağırlıklar tarafından tutulur. İlk başta, belirli bir problem için ağırlıklar bilinmez. Uygun ağırlıklar bulunamadığı sürece, ağ hiçbir sorunu çözemez. Uygun ağırlıkları bulma işlemine eğitime denir. Eğitime işlemi, bir grup giriş vektörüne karşılık gelen uygun sınıfların ağa verilmesiyle gerçekleşir. Bu şekilde, her giriş vektörüne karşılık beklenen çıkışların ağa verilmesi işlemine öğretici yardımıyla eğitime denir.

Ağın eğitilmesi işlemi, eğitime setindeki vektörlerin yanlış sınıflandırılması oranı belli bir sınır değerinin altına ininceye kadar devam eder. Ağ, gerçekte ona öğretildiğinden başka bir problemi çözemez. Eğer eğitime kümesi iyi seçilmişse ve eğitime algoritması etkinse, ağ eğitime seti dışındaki verileri de belli oranda doğru olarak sınıflandırabilir. Bu kavram ağın genelleme (generalization) yeteneği olarak bilinir.

Yapay sinir ağlarının tanıma işleminde kullanılması iki aşamada düşünülebilir. Eğitime aşamasında, ağ ağırlıkları problem kümesinin özelliklerini

yansıtacak şekilde adapte edilir. İkinci aşama test aşamasıdır ve ağırlıklar eğitme işleminin sonundaki değerlerini korur. Ağa eğitme setinden farklı test verileri yüklenir ve bir sınıflandırma yapması beklenir.

Bir ağı eğitme işlemi, önceden tespit edilmiş beklenen bir değere ulaşana kadar devam eder. Bu bizi ağı toplam hatası kavramına götürür. Öğretici yardımıyla eğitmede, elimizdeki eğitme seti için beklenen değeri bilmemiz gerekir. Bu yüzden eğitme setinin uygun seçimi, başarılı bir sınıflandırma işlemi için çok önemlidir. Eğitme seti uygun boyda olmalı ve problem uzayını tam olarak yansıtmalıdır.

Geri yayımlı eğitim algoritmasında, ortalama kare hatası (mean squared error) olarak bilinen hata kriteri kullanılabilir. (Rumelhart ve McClelland 1986) Aslında bu fonksiyon tek hata kriteri değildir. Sürekli ve diferansiyel başka bir hata fonksiyonu da kullanılabilir. Fakat başka fonksiyon seçerken dikkatli olunmalıdır, çünkü bu yeni fonksiyon işlemlere ek yük getirebilir. Ayrıca seçilen fonksiyon, beklenen ve gerçekte oluşan çıkış değerleri arasında anlamlı bir fark ölçümü sağlamalıdır. Ortalama kare hatası fonksiyonu aşağıdaki gibi tanımlıdır,

$$E_p = \frac{1}{2} \sum_{j=1}^N (t_{pj} - O_{pj})^2 \quad (3.54)$$

Burada E_p , p. vektör için hatayı, t_{pj} j. sinir hücresi için beklenen değeri (yani eğitme setindeki ilgili çıkış değerini) ve O_{pj} , j. Çıkış düğümünün gerçek değerini göstermektedir. Hataların karesini almakla, beklenen değerden uzakta olan çıkış değerlerinin toplam hatayı oluşturması sağlanmaktadır. Eğer üssü daha çok büyütürsek, bu etki daha da artacaktır.

Geri Yayılma (Backpropagation) Algoritması

Geri yayılma algoritması, genel olarak dereceli azalma (gradient descent) diye anılan eğitme algoritmaları ailesinin basit üyelerinden biridir. Bu algoritmaların genel amacı, ağırlıkları ayarlamak suretiyle ağ hatasını en aza indirmektir. Her ağırlık N boyutlu hata uzayının bir boyutu gibi düşünülür ve ilgili hata yüzeyinin şekli, eğitme seti ile birlikte hata fonksiyonu tarafından belirlenir.

Ağırlıklara bağlı olarak hata fonksiyonunun negatif gradienti, hata fonksiyonunu en hızlı azaltacak yönde ilerler. Eğer ağırlık uzayında bu yönde ilerlersek, gradientin sıfır olduğu bir minimum noktasına ulaşırız. Fakat bu nokta bazen yerel minimum olabilir. Eğitim aşamasında yerel minimum noktasına düşen bir ağırlık, problem uzayının özelliklerini tam olarak yansıtmadığı halde, eğitim işlemine olumlu yanıt vermez.

Yukarıda açıklananları matematiksel olarak aşağıdaki gibi ifade edebiliriz:

$$\Delta pW_{ji} \approx -\frac{\partial E_p}{\partial w_{ji}} \quad (3.55)$$

Burada ΔpW_{ji} , (L-1). katmandaki i. sinir hücresini, L. katmandaki j. hücreye bağlayan ağırlıktaki değişimdir. Bu değişim ağırlık uzayında daha küçük hata değerine doğru bir adımı temsil etmektedir. Yapılması gereken, ağırlığın beklenen çıktıları üretmesi (yakınsaması) için ağırlıkları doğru biçimde ayarlamaktır. Her W_{ij} ağırlığındaki değişim, hata yüzeyi boyunca negatif gradiente doğru olmalıdır.

Denklem 3.55'i sayısal bir bilgisayarda gerçekleştireceğimiz bir diferansiyel denkleme dönüştürmeliyiz. Bunu yapmak için, kısmi $\frac{\partial E_p}{\partial W_{ji}}$ türevini hesaplamalıyız.

Zincir kuralını uygularsak,

$$\frac{\partial E_p}{\partial W_{ji}} = \frac{\partial E_p}{\partial net_{pj}} \frac{\partial net_{pj}}{\partial W_{ji}} \quad (3.56)$$

Buradan

$$net_{pj} = \sum_l W_{jl} O_{pl} \quad (3.57)$$

Yukarıdaki denklemde toplam, O_{pl} çıkışında sonlanan (L-1). katmandaki tüm hücreler için hesaplanmaktadır.

Böylece denklem 3.56'daki ikinci terimi bulabiliriz,

$$\frac{\partial net_{pj}}{\partial w_{ji}} = \frac{\partial}{\partial w_{ji}} \sum_l w_{jl} O_{pl} \quad (3.58)$$

Yukarıdaki denklemi açarsak,

$$\frac{\partial net_{pj}}{\partial w_{ji}} = \frac{\partial}{\partial w_{ji}} \left[\sum_l w_{jl} O_{pl} + w_{ji} O_{pi} \right] = O_{pi} \quad (3.59)$$

Yukarıdaki denklemi, denklem 3.56'da yerine koyarsak,

$$\frac{\partial E_p}{\partial w_{ji}} = O_{pi} \frac{\partial E_p}{\partial net_{pj}} \quad (3.60)$$

Şimdi hata sinyali δ_{pj} 'yi tanımlayabiliriz,

$$\delta_{pj} = - \frac{\partial E_p}{\partial net_{pj}} \quad (3.61)$$

Denklem 3.57 ve 3.58'yi birleştirerek aşağıdaki sonucu elde ederiz

$$- \frac{\partial E_p}{\partial w_{ji}} = \delta_{pj} O_{pi} \quad (3.62)$$

Yukarıdaki denklemi yerine koyarak ve bir η orantı sabiti kullanarak denklem 3.55'i yeniden yazabiliriz,

$$\Delta p w_{ji} = \eta \delta_{pj} O_{pi} \quad (3.63)$$

Buradaki η sabiti öğrenme oranı (learning rate) olarak bilinir. İsminden de anlaşılacağı gibi, bu değer, ağırlık uzayında bir adım değişme olduğunda negatif yönde kat edilen mesafeyi temsil etmektedir.

Bilgisayar ortamında uygulanabilecek bir diferansiyel denklem elde etmek için, δ_{pj} 'yi hesaplamak gerekmektedir. Yeniden zincir kuralını uygulayarak,

$$\delta_{pj} = - \frac{\partial E_p}{\partial net_{pj}} = - \frac{\partial E_p}{\partial O_{pj}} \frac{\partial O_{pj}}{\partial net_{pj}} \quad (3.64)$$

O_{pj} , doğrudan net_{pj} 'nin bir fonksiyonuydu. O halde,

$$O_{pj} = f(net_{pj}) \quad (3.65)$$

$$\frac{\partial O_{pj}}{\partial net_{pj}} = f'(net_{pj}) \quad (3.66)$$

demektir.

Denklem 3.64'ün ilk terimi olan $\frac{\partial E_p}{\partial O_{pj}}$ 'yi hesaplamak için, iki durumu göz

önünde bulundurmamız:

- 1) J. hedef hücre bir çıkış katmanı hücresi olabilir.
- 2) J. hedef hücre bir gizli katman hücresi olabilir.

Çıkış katmanındaki bir j hedef hücresi için, E_p hatasına, O_{pj} 'nin bir fonksiyonu olarak doğrudan erişebiliriz. Bu yüzden,

$$\frac{\partial E_p}{\partial O_{pj}} = \frac{\partial}{\partial O_{pj}} \left[\frac{1}{2} \sum_j (t_{pj} - O_{pj})^2 \right] = -(t_{pj} - O_{pj}) \quad (3.67)$$

yazabiliriz.

Yukarıdaki denklemlerle, bilgisayar ortamında uygulayacağımız algoritmamızı hata fonksiyonumuza (ortalama kare hatası) uyarlamış olduk. Başka bir hata fonksiyonu kullansaydık, değişik bir diferansiyel denklem elde etmemiz gerekirdi. Denklem 3.65 ve 3.66'yı, denklem 3.63'te yerine koyarak, çıkış katmanındaki sinir hücreleri için δ_{pj} 'yi şu şekilde yazabiliriz,

$$\delta_{pj} = (t_{pj} - O_{pj}) f'(net_{pj}) \quad (3.68)$$

Gizli katmandaki sinir hücreleri için, hata fonksiyonunun diferansiyelini doğrudan kullanamayız. Bu yüzden, zincir kuralını yeniden uygulayarak,

$$\frac{\partial E_p}{\partial O_{pj}} = \sum_k \frac{\partial E_p}{\partial net_{pk}} \frac{\partial net_{pk}}{\partial O_{pj}} \quad (3.69)$$

yazabiliriz.

Yukarıdaki denklemlerde toplam işlemi (L+1). katmandaki tüm sinir hücreleri için yapılmaktadır. net_{pk} 'nın tanımından yararlanarak, bu denklemin ikinci faktörünü aşağıdaki gibi hesaplayabiliriz,

$$\frac{\partial net_{pk}}{\partial O_{pj}} = \frac{\partial}{\partial O_{pj}} \left[\sum_l w_{kl} O_{pl} \right] = \frac{\partial}{\partial O_{pj}} \left[\sum_{l \neq j} w_{kl} O_{pl} + w_{kj} O_{pj} \right] = w_{kj} \quad (3.70)$$

Bu denklemi, denklem 3.69'da yerine koyarsak,

$$\frac{\partial E_p}{\partial O_{pj}} = \sum_k \frac{\partial E_p}{\partial net_{pk}} w_{kj} \quad (3.71)$$

Aşağıdaki denklemden yararlanarak,

$$\delta_{pk} = p \frac{\partial E_p}{\partial net_{pk}} \quad (3.72)$$

denklem 3.71’de yerine koyarsak,

$$\frac{\partial E_p}{\partial O_{pj}} = \sum_k \delta_{pk} w_{kj} \quad (3.73)$$

elde ederiz. Son olarak denklem 3.64, denklem 3.66 ve yukarıdaki denklemi birleştirirsek, gizli katmanlar için δ_{pj} sinyalini

$$\delta_{pj} = f'(net_{pj}) \sum_k \delta_{pk} w_{kj} \quad (3.74)$$

şeklinde yazabiliriz.

Şimdiye kadar elde ettiğimiz sonuçları şöyle özetleyebiliriz. Denklem 3.62, δ_{pj} cinsinden diferansiyel denklemini vermektedir. Bu denklem, hem gizli katmandaki ve hem de çıkış katmanındaki sinir hücreleri için geçerlidir. Denklem 3.68 ve 3.71, sırasıyla çıkış katmanı ve gizli katman ağırlıkları için δ_{pj} ’yi belirlemektedir.

Denklem 3.67, ortalama kare hata (MSE) fonksiyonuna göre bir çözüm üretmemizi gerekli kılmaktadır. Bu bakımdan, başka bir hata fonksiyonu için bu denklem yeniden hesaplanmalıdır. Sayısal bir bilgisayara uygun bir diferansiyel denklem elde etmek için, şimdi sadece $f(net_{pj})$ ‘yi hesaplamamız gerekmektedir. Bunu yaparken ilk başta karar kıldığımız aktivasyon fonksiyonunu kullanmalıyız. Sigmoid fonksiyonunu bu amaçla seçtiğimiz için aşağıda tanımlanan denklemi kullanmalıyız,

$$O_{pj} = f(net_{pj}) = \frac{1}{1 + e^{-net_{pj} + \theta}} \quad (3.75)$$

Denklem 3.66 ve 3.75'ten yararlanarak, $f'(net_{pj})$ 'yi hesaplayabiliriz,

$$f'(net_{pj}) = \frac{\partial}{\partial net_{pj}} \left[\frac{1}{1 + e^{-net_{pj} + \theta}} \right] \quad (3.76)$$

$$= \left(\frac{1}{1 + e^{-net_{pj} + \theta}} \right) \left(1 - \frac{1}{1 + e^{-net_{pj} + \theta}} \right) \quad (3.77)$$

Denklem 3.75'teki O_{pj} 'nin tanımından yararlanarak, yukarıdaki denklemde yerine koyarsak,

$$f'(net_{pj}) = O_{pj}(1 - O_{pj}) \quad (3.78)$$

olarak bulunur.

Şimdi aktivasyon fonksiyonu olarak sigmoid ve hata fonksiyonu olarak ortalama kare hatasını kullanan geri yayımlı eğitim algoritmasını sayısal bir bilgisayarda gerçekleştirmek için tüm gerekli denklemleri elde etmiş olduk. Geri yayımlı eğitim için gerekli denklem,

$$\Delta w_{ji} = \eta \delta_{pj} O_{pi} \quad (3.79)$$

Burada η öğrenme oranı, δ_{pj} , L. katmandaki sinir hücresinin hata sinyali ve O_{pi} , (L-1). katmandaki sinir hücresinin çıkış değeridir. δ_{pj} hata sinyali,

1) Çıkış katmanındaki sinir hücreleri için

$$\delta_{pj} = (t_{pj} - O_{pj}) O_{pj}(1 - O_{pj}) \quad (3.80)$$

2) Gizli katmandaki sinir hücreleri için

$$\delta_{pj} = O_{pj}(1 - O_{pj}) \sum_k \delta_{pk} w_{kj} \quad (3.81)$$

Burada O_{pj} , L. katmandaki sinir hücreleri için, O_{pj} , (L-1). katmandaki sinir hücreleri ve δ_{pk} , (L+1). katmandaki sinir hücreleri için kullanılmaktadır.

Denklem 3.79'dan görüleceği gibi, gradient yönünde sonlu sayıda adımlarla ilerlenebilir. Buradaki η değeri adım büyüklüğünü belirleyen bir kazanç sabiti gibi düşünülebilir. Dikkat edilmesi gereken nokta, bu sabit değeri salınımaya yol açmayacak ve yakınsamayı kolaylaştıracak bir değer olarak seçmektir.

Pratikte, denklem 3.79'da bir α momentum katsayısı daha çabuk yakınsamayı sağlamak amacıyla eklenmektedir. Bu katsayı değeri, ağırlıklardaki önceki değişimlerin de ele alınmasını sağlamaktadır ve ağırlık uzayındaki hata yüzeyini, yüksek frekanstaki değişimleri süzerek düzleştirmeyi sağlamaktadır. Momentum sabitinin kullanılması durumunda, ağırlıklar aşağıdaki gibi ayarlanmaktadır:

$$\Delta W_{ji}(n+1) = \eta \delta_{pj} O_{pi} + \alpha \Delta W_{ji}(n) \quad (3.82)$$

Geri yayılma algoritmasını uygulayabilmek için ilk etapta ağırlıklara küçük değerler verilmelidir. Ağırlıklara ilk değer olarak büyük sayılar verilmesi durumunda eğitime işlemi başarısız olmaktadır. Daha sonra eğitime setindeki vektörler ağırlık giriş katmanındaki sinir hücrelerine uygulanır.

İleriye doğru hesaplama sonucunda yapay sinir ağı çıkış katmanındaki sinir hücrelerinde gerçek değerler oluşacaktır. Daha sonra geri yayılma algoritması uygulanarak ağırlıklar ayarlanır. Toplam ağ hatası bu şekilde pek çok iterasyondan sonra azalmalıdır. Eğer bu olmazsa, eğitime parametreleri olan η ve α değerleri değiştirilebilir. Eğitime seti içinde çelişkili veri bulunması durumunda (örneğin; aynı eğitime vektörü için iki farklı beklenen çıkış vektörü verilmesi) da eğitime parametrelerinin değerine bağlı olmaksızın, toplam ağ hatası azalmayabilir. Bu durumda eğitime seti kontrol edilmelidir.

Belli sayıda iterasyondan sonra genel ağ hatası önceden belirlenen sınır değer altına düşerse, ağ yakınsaması sağlandı demektir. Genel ağ hatasının lineer biçimde azalması gerekmez. Eğitimin ilk başlarında salınım olması normaldir.


Geri yayılma algoritmasıyla eğitim sırasında ağırlık yerel minimum noktasına yakalanması bazen karşılaşılan bir durumdur. Yerel minimum noktası, ağırlık problem uzayını tam olarak yansıtmadığı halde genel ağ hatasının belli bir sınır noktaya düştüğü, fakat hata uzayı düzleminde negatif gradient yönünde daha fazla ilerlenemediği noktalardan biridir. Bunun çok çeşitli nedenleri olabilir. Eğitime

parametrelerinin doğru seçilememesi bu nedenlerden biridir. Optimal parametre değerlerinin seçimi için genel bir kural yoktur (Pandya ve Macy, 1996).

Yavaş yakınsama veya hiç yakınsamama geri yayılmalı eğitimde karşılaşılan bir diğer sorundur. Yavaş yakınsamanın nedeni hata uzayı yüzeyinin büyük bir kısmının düz olmasından kaynaklanmaktadır. Ayrıca, hata yüzeyinin geniş bölümünün düz olmasından ötürü oluşan yuvarlama hataları negatif gradient algoritmasının tamamen değişik bir yönde ilerlemesine neden olur.

3.4. TCD Sonogramlarından Spektral Parametrelerin Elde Edilmesi

Doppler sonogramlarından elde edilen spektral değerler, inceleme açısı, prob frekansı gibi etkenler optimal düzeyde sağlanmadığından farklı olabilir. Ancak bu etkenler spektral dalganın tümüne yansıtacağı için dalganın tümüne yönelik oranlamalar etkilenmeyecektir. Bu nedenle uzak direnci belirlemede indekslere sıkça başvurulur. Uzak direnç ne kadar yüksekse kalp atımına bağlı dalga formu da o kadar fazla olur. β açısının damarla ilgili değerlendirmelerindeki etkisini ortadan kaldırmak için bazı indeksler belirlenmiştir. Doppler sonogramlarından spektral analiz sonucu elde edilen Pik Sistolik Hız (PSH), Diyastol Sonu Hız (DSH) ve Ortalama Hız (M) değerleri kullanılarak aşağıdaki indisler hesaplanır (Ergün 2005).



Şekil 3.20. Direnç (Rezistans) İndisi (RI) ve Darbe (Pulsatilité) İndisi (PI) değerlerinin hesaplanmasında kullanılan değişkenler

Direnç (Rezistans) İndisi (Rİ): Pourcelot (1974) tarafından hiç ters akışı olmayan arteriyel dalga formlarında kullanılmaya başlanmıştır. Açıdan bağımsız olarak ölçülür ve spektrumda iki belirgin noktanın ölçümü yeterlidir. Rİ değeri aşağıdaki gibi hesaplanır.

$$RI = \frac{PSH - DSH}{PSH} \quad (3.83)$$

Darbe (Pulsatilité) İndisi (PI): Gosling (1974) tarafından önerilen bu değer aşağıdaki gibi hesaplanır.

$$PI = \frac{PSH - DSH}{M} \quad (3.84)$$

Periyodik sayısal bir işaret, bir Fourier serisi ile temsil edilebilir ve bir dalga şekli kendisinin Fourier katsayılarından yeniden elde edilebilir. Fourier analizi tek frekans bileşenli bir işarete birçok fiziksel sistemin cevabı, diğer frekans bileşenlerinin genliğinden ve görüntüsünden bağımsızdır. Böyle sistemler, giriş işaretinin büyüklüğündeki bir değişim çıkış işaretinde de aynı oranda değişim verdiği için doğrusal sistemler olarak bilinir. Fourier analizi için ilk olarak basınç değişimindeki sinüzoidal (Fourier) katsayıları alınır. İkinci olarak her frekanstaki akış katsayıları (genlik ve faz) aynı frekanstaki basınç değişiminden hesaplanır. Üçüncü olarak hesaplanan akış katsayıları tüm akış dalga şeklini vermesi için birbirleriyle toplanır (Hardalaç 1997).

Ayrık zamanlı periyodik bir işaretin ayrık Fourier dönüşümü aşağıdaki gibi tanımlanır,

$$X_k = \sum_{n=0}^{N-1} x(n) \exp\left(-jkn \frac{2\pi}{N}\right) \quad (3.85)$$

Buradaki X_k katsayıları ayrık Fourier katsayıları olarak adlandırılır. N çerçeve boyu ve $x(n)$ zaman kümesi giriş işaretidir. Bu işaretin frekans sonogramını bulmak için ayrık Fourier dönüşüm katsayıları olan X_k sayılarının mutlak değerlerinin karelerinin logaritmaları alınır.

$$P(k) = 10 \log |X_k|^2 \quad (3.86)$$

İşaretin ayrık Fourier dönüşümü hesaplandıktan sonra güç spektrum yoğunlukları, Fourier dönüşümlerinin büyüklüklerinin kareleri alınarak hesaplanmaktadır. N işaretin uzunluğu ve $x(n)$ zaman kümesindeki giriş işareti olmak üzere ayrık bir işaretin güç spektrum yoğunluğu vektörü aşağıdaki gibi elde edilir.

$$P(f) = \frac{1}{N} \left[\sum_{n=1}^N x(n) \exp(-j2\pi fn) \right]^2 \quad (3.87)$$

Doppler işaretlerinin spektral analizinde zaman kümesindeki Doppler işaretleri uygun frekansta örneklenir. Örneklenecek işaretin en büyük frekansına bakılarak örnekleme frekansı belirlenir. TCD işaretlerinin alındığı damara bağlı olarak işaretin en büyük frekansı değişebildiği için sistemin değişik örnekleme frekanslarında çalışabilir olması gerekir. Bu çalışmada kullanılan sistemde örnekleme frekansı 2,56 kHz ile 20,48 kHz arasında değişebilmektedir. Bu örnekleme frekansları kullanıldığında 1,28 kHz ile 10,24 kHz arasındaki frekanslarda beyin ölçümleri yapılabilmektedir (Guler ve ark., 2001).

TCD işaretlerinden alınan zaman örnekleri, her bir çerçeve aynı sayıda örnek içerecek şekilde çerçevelenir. En çok kullanılan çerçeve uzunlukları çerçeve başına 64, 128 ve 256'dır. Özellikle gerçek zamanlı spektral eğri çalışmalarında çerçeve uzunluğunun 2'nin katları şeklinde seçilmesi önemlidir. Çünkü Hızlı Fourier Dönüşümü (HFD)'nde en iyi performans bu çerçeve boylarında elde edilir. Genelde Doppler işaretleri durağan değildir. Laminar akışta ve hızın yüksek olmadığı durumlarda 10 ms'lik zaman periyotlarında işaret durağan kabul edilir. Bununla birlikte bu kabul yüksek hızlı türbülans akışta geçerli değildir. Bu durumda çerçeve boyunun daha kısa seçilmesi gerekir. Diğer taraftan çerçeve boyunun kısaltılması istatistiksel olarak kötü bir spektral çözünürlüğe neden olacaktır. Bu nedenle çerçeve uzunluğu Doppler spektral analizinde önemli bir faktördür. Bu çalışmada TCD işaretlerinden Rİ ve Pİ spektral parametrelerinin elde edilmesi için uygulanan HFD yönteminde çerçeve boyu 256 olarak alınmıştır.

TCD işaretlerinin içerdiği spektral bilgiyi görsel olarak incelemek ve işaretin spektrumunun zamanla değişimini izlemek için Autoregressive Burg yöntemi (Stremmer 1977) kullanılmıştır. AR model parametrelerinin hesaplanması için ya doğrudan spektral analizi yapılacak olan bilgi alanı örnekleri kullanılır ya da bu bilgi alanına ait öz ilinti fonksiyonu örnekleri kullanılır.

Burg yönteminin işlevi zaman kümesindeki sinyali kullanarak AR model parametrelerini hesaplamaktır. Burg yönteminde AR parametrelerinin doğrudan bulunmayışı, bunu diğer yöntemlerden ayıran özelliğidir. Bu algoritma doğrudan bilgi alanı örnekleri kullanarak yansıma katsayılarını hesaplar ve bu katsayılardan da Levinson yöntemi (Gibbs ve Millard, 1969) yardımıyla AR parametreleri elde edilir. Parametre hesabı sırasında her aşamada ileri ve geri yöndeki hata alanları yeniden

hesaplanır. Bu sayede hata giderek azalır ve parametreler hesabında yakınsaklık elde edilir. Levinson yöntemi önce bilgi alanına birinci dereceden bir AR model uydurur. Daha sonra bu modelden yararlanarak ikinci dereceden bir AR modelin parametrelerini hesaplar. İşlem bu şekilde devam eder ve n. dereceden AR model parametreleri (n-1). dereceden AR model parametrelerinden yararlanılarak hesaplanır. İstenilen model derecesine ulaşıldığında işlem sonra erer (Hardalaç 1997).

3.5. İstatistiksel Analiz Yöntemleri

3.5.1. Çoklu Doğrusal Regresyon

Çoklu Doğrusal Regresyon, gözlenen veriye doğrusal bir denklem uydurarak iki veya daha çok açıklayıcı değişken ile bir yanıt değişkeni arasındaki ilişkiyi modellemeye çalışır. Bağımsız x değişkeninin her değeri, y bağlı değişkeninin bir değeriyle ilişkilendirilir. Açıklayıcı değişkenler p adet ve $x_1, x_2, \dots, x_p$ olmak üzere topluluk regresyon eğrisi $\mu_y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p$ şeklinde tanımlanır. Bu eğri, ortalama yanıt μ_y 'nin açıklayıcı değişkenlerle nasıl değiştiğini açıklar. Gözlemlenen y değerleri μ_y ortalamaları etrafında değişir ve aynı σ standart sapmaya sahip oldukları düşünülür. Bu yöntemde, regresyon düzlemi ile bağımsız değişkenin gözlemlenen değerleri arasındaki farkın karelerinin toplamı minimize edilir.

Bu çalışmada, çoklu doğrusal regresyon yöntemi, kaos ölçütleri ile hastalık sınıfları arasında doğrusal bir ilişki olup olmadığını tespit etmek amacıyla kullanılmıştır. Bu yöntem, bulunan regresyon denkleminin giriş çıkış verileri arasındaki ilişkinin modellenmesinde ne kadar uygun olduğunu da vermektedir. Ayrıca, kaotik ölçütlerin her birinin hastalık sınıflarını belirlemede istatistiksel olarak belirgin olup olmadığı da belirlenmiştir.

3.5.2. Bland-Altman Çizimleri

Yöntem karşılaştırma çalışmalarındaki temel amaç, doğrudan alternatif yöntemlerle elde edilen sonuçların karşılaştırılmasından ibarettir. Burada cevabı aranan soru “bir yöntem diğerine tercih edildiğinde ölçüm için beklenen doğruluk aynı şekilde ve yeterli biçimde sağlanabilir mi?” şeklindedir.

A ve B yöntemlerinin ürettiği veriler arasındaki $(A - B)$ farkı ile $(A + B) / 2$ ortalamasının işaretlenmesi ile uyumsuzluğun büyüklüğünün tayini, ortalamadan sapan değerlerin tespiti ve verilerde eğilimin belirlenmesi mümkündür. Verilerin bu şekilde işaretlenmesi yöntem karşılaştırma çalışmalarında sonuçların gösterimi için güçlü bir tekniktir (Bland ve Altman, 1986).

Bu tez çalışmasında, TCD zaman dizilerinin durağanlık analizinde kullanılan doğrusal olmayan çapraz tahmin yönteminin kaotik zaman dizileri olan Ikeda ve Henon haritaları verilerinin durağanlıklarını belirlemede ne kadar tutarlı olduğunu belirlemek üzere Bland-Altman çizimleri kullanılmıştır. Ayrıca, NEFCLASS modelinin budama işlemi öncesinde ve sonrasındaki sınıflandırma performansını karşılaştırmada yine Bland-Altman çizimlerinden yararlanılmıştır.

3.5.3. Alıcı Çalışma Karakteristiği (Receiver Operating Characteristic - ROC) Eğrileri

Bir çift duyarlılık (sensitivity) ve seçicilik (specificity) değeri kullanmanın getirdiği dezavantajları ortadan kaldıracak bir yöntem olarak Lusted tarafından geliştirilmiştir. Bir yöntemin kendi doğruluğunu tanımlaması ve yöntemler arasında en doğru karşılaştırma yapmaya olanak sağlaması açısından sıklıkla kullanılmaktadır.

ROC eğrisi değişik kesim noktalarında yöntemin duyarlılığının (y-ekseni), testin yanlış pozitif oranına (x-ekseni) karşı noktalanması ile elde edilir. Her kesim noktasındaki doğru pozitif ve yanlış pozitive karşılık gelen noktalar birleştirilerek ROC eğrisi çizilir.

1970'li yıllardan sonra ROC eğrileri yaygın olarak tanılayıcı tıpta kullanılmaya başlanmıştır. ROC eğrileri elektronik sinyal algılama teorisi içerisinde geliştirilmiş, ancak tıbbi, askeri ve diğer birçok alanda kullanım yeri bulmuştur. Tanı yönteminin yararlılığını ölçebilmek için o yöntemi yorumlayanların performansının da ölçülebilmesi gereklidir. ROC eğrileri yorumlayıcı performansını incelemek için iyi bir temel oluşturur. Bir hastalığın varlığı ya da yokluğuna karar vermek için yorumlayıcının kullandığı kriter ile hastalığı belirlemede yorumlayıcının yeteneği (yöntem sonucunu yorumlamada kullanılan duygusal veya bilişsel özellikler) arasında ayırımın yapılması gerekir. ROC eğrisi bu ayırımı yapmak için kullanılabilir (Lusted, 1971).

Metz (1978), Swets ve Picket (1982) sınıflandırma doğruluğunun bir ölçüsü olarak ROC eğrisi altında kalan alanı tanımlayarak bu amaca yönelik yazılımları hazırlamışlardır. Mc Neil (1982) ROC eğrisi altında kalan alanla ilgili çalışmalarda örnek genişliğini ve aynı hasta grubunun değişik gözlemciler tarafından değerlendirilmesi durumunda ortaya çıkan bağımlılık ve değerlendiriciler arası uyumu konu alan çalışmalar yayınlamıştır. ROC eğrisi altında kalan alan bir testin hastalarla sağlamları ayırt edebilme başarısının en iyi göstergesi olarak kabul edilir. İki sınıflandırma aynı ROC eğrisi altında kalan alan değerine sahip olabilir, ancak işleyişleri farklıdır. Eğri altında kalan alan değeri ne kadar büyükse, sınıflandırma o kadar başarılıdır. Alan değeri 0.5 ile 1.0 arasında değişir.

ROC eğrileri olası tüm kesim noktalarını gösterirler ve her kesim noktasında değişik sonuçların (DP, DN, YP ve YN) sıklığı hakkında kestirimler yapılmasına olanak sağlarlar. Verilen bir sınıflandırma için en iyi kesim noktasının saptanmasına yönelik, doğru ve yanlış kararların yarar ve maliyetlerinin hesaplanmasında kullanılırlar.

Bu tez çalışmasında ROC eğrileri, NEFCLASS ve ANFIS algoritmalarının hastalıkları sınıflandırma performanslarını karşılaştırmada kullanılmıştır. ROC eğrilerinin çiziminde algoritmaların sınıflandırma sonuçlarının ortaya çıkardığı duyarlılık ve seçicilik değerlerinden yararlanılmıştır.

4. ARAŞTIRMA SONUÇLARI ve TARTIŞMA


Bu tez çalışması için, 82 hasta ve 23 sağlıklı olmak üzere toplam 105 bireyden alınan TCD sinyalleri kaydedilmiştir. Bu sinyallerden elde edilen sonogramlar ve manyetik rezonans görüntüleme kayıtları kullanılarak yapılan analiz sonucu 82 hastanın 20'sine beyin damarında balonlaşma, 10'una beyin kanaması, 22'sine beyinde su toplama ve geri kalan 30'una da beyin tümörü teşhisi konulmuştur. Grubu oluşturan bireylerin genel profili aşağıdaki tabloda verilmiştir.

	<i>Erkek Sayısı</i>	<i>Kadın Sayısı</i>	<i>Yaş Aralığı</i>	<i>Ortalama Yaş</i>
<i>Beyin Damarında Balonlaşma</i>	12	8	55-65	59.5±0.5
<i>Beyin Kanaması</i>	4	6	21-36	27.0±0.5
<i>Beyinde Su Toplama</i>	11	11	3-40	25.0±0.5
<i>Beyin Tümörü</i>	12	18	12-41	29.5±0.5
<i>Sağlıklı</i>	15	8	23-65	31.5±0.5
<i>Genel</i>	54	52	3-65	35.0±0.5


Çizelge 4.1. Tez çalışmasında yararlanılan grubu oluşturan bireylerin genel profili

Beyin damarında balonlaşma olan hastaların, damar duvarında doğuştan gelen veya sonradan oluşan zayıflama sonucu beyin arterlerinde anormal genişleme görülmüştür. Beyin kanaması olan hastalarda, kafa içindeki bir beyin damarında yırtılmaya bağlı olarak kafa içi kanama veya subaraknoid kanama (subarachnoid hemorrhage- SAH) gözlenmiştir. Beyin tümürlü hastaların beyin damarlarında direnç değişikliği gözlenmiştir. Beyin damarlarındaki direnç ile kan akışı arasında negatif bir ilinti söz konusudur. Damarlardaki direnç arttıkça kan akış seviyesi azalmaktadır. Her hasta grubu için örnek birer sonogram Şekil 3'te verilmiştir. Sonogramlar Burg autoregressive (AR) yöntemiyle elde edilmiştir. Beyin damarında balonlaşma olan hastanın sonogramında, yükselmiş ortalama kan akış hızı görülebilmektedir. Beyinde su toplama olan hastanın sonogramındaki temel karakteristik ise diyastol sonu kan akışında azalmadır. Öte yandan, sonogramlarda görsel olarak algılanabilen karmaşıklığı kaotik ölçüt değerleri nicel olarak vermektedir. Bu değerlerin yüksek


olması sinyalin rasgele ve tahmin edilemez oluşunu, düşük olması ise sinyaldeki periyodikliği ve tek düzeliği gösterir.




(a)




(b)



(c)



(d)



(e)

Şekil 4.1. Her bir hasta grubu ve sağlıklı birey grubu için elde edilen örnek Doppler sonogramları (a) Beyin damarında balonlaşma (b) Beyin kanaması (c) Beyinde su toplama (d) Beyin tümörü (e) Sağlıklı

Örneğin; Şekil 3(e)'de sonogramı görülen sağlıklı bireye ait TCD sinyalinin ilinti boyutu 3,51 tüm örnekler içinde en yüksek değerdir. Benzer şekilde, Şekil 3(a)'da sonogramı görülen beyin damarında balonlaşma olan hastanın ilinti boyutu da 3,42'dir. Bu iki sonogramdaki belirgin rasgelelik görüntüsü, karmaşıklık ile ilinti boyutu arasındaki pozitif yöndeki ilişkinin varlığını doğrulamaktadır. Şekil 3(a) ve 3(e)'deki sonogramlar rasgele görünümlü olmalarına rağmen, Şekil 3(a)'daki sonogramda kendini tekrarlayan tepe ve çukurlar daha düşük D_2 değerine neden olmaktadır. Şekil 3(d)'de görülen beyin tümörlü hastaya ait sonogramda periyodiklik çok belirgindir. Bu hastanın TCD sinyali için bulunan D_2 değeri 2,15 ile tüm örnekler içinde en düşüktür. Şekil 3(b) ve 3(c)'deki sonogramlarda bir miktar rasgelelik ile birlikte periyodiklik görülmektedir. Bu iki hastanın D_2 değeri sırasıyla 2,92 ve 2,36'dır. Beyin tümörlü ve beyinde su toplamalı hastaların ortalama Lyapunov üsteli (λ_1) değerleri yaklaşık 1,58 ve 1,83 civarındadır. Lyapunov üsteli değerindeki bu azalma kaotik davranışın kayboluşunu ve periyodikliğin ortaya çıktığını göstermektedir. Bu durum belirgin olarak Şekil 3(c) ve Şekil 3(d)'de görülmektedir. Öte yandan, sağlıklı bireyin TCD sinyali için bulunan λ_1 değeri 3,63'tür. Yüksek λ_1 değeri uzun dönemde rasgelelik ve tahmin edilemezliği belirler. Şekil 3(e)'deki sonogramda bu ifadenin doğruluğu görülmektedir.

Yapılan kaos analizi sonucunda, tüm TCD sinyallerinin hem doğrusal olmadığı hem de kabul edilebilir seviyede durağan olduğu bulunmuştur. Bu durumda, TCD sinyalleri için ilinti boyutu (D_2) ve en büyük Lyapunov üsteli (λ_1) gibi kaotik ölçütlerin hesaplanması için kaos teorisi yöntemleri uygulanabilir demektir. Yapılan bu hesaplama sonucunda elde edilen değerlerle ilgili istatistiksel özet aşağıdaki tabloda verilmiştir.

Birey Grubu	Ort. D_2	Min. D_2	Maks. D_2	Ort. λ	Min. λ	Maks. λ
<i>Damarda Balonlaşma</i>	3.58	3.23	3.84	3.28	2.96	3.38
<i>Beyin Kanaması</i>	2.67	2.41	2.92	3.12	2.71	3.26
<i>Su Toplama</i>	2.46	2.23	2.62	1.84	1.74	1.98
<i>Beyin Tümörü</i>	2.12	2.08	2.32	1.47	1.42	1.58
<i>Sağlıklı</i>	3.71	3.42	3.92	3.68	3.60	3.83

Çizelge 4.2. Farklı birey grupları için kaotik ölçütlerin istatistiği

Elde edilen kaotik ölçütleri (λ_1 ve D_2) aynı hastalık grubundaki bireyler için yaklaşık olarak aynı bulunmuştur. Yani, kaotik ölçütler için bir sınıf içi benzerlik söz konusudur. Kaotik ölçütler ile birey sınıfları arasındaki bağımlılığı ortaya çıkarmak için nicel bir istatistiksel analiz yöntemi olarak çoklu doğrusal regresyon uygulanmıştır.


Çoklu doğrusal regresyon sonucu aşağıdaki sonuçlar elde edilmiştir:

- a. Belirleme katsayısı: Bu katsayı regresyon modelindeki bağılı değişkendeki değişim miktarını verir ve modelin ne kadar uygun olduğunun bir ölçütüdür. Bu katsayı değeri 0 ila 1 arasındadır.
- b. Regresyon denklemi: Değişken sayısı kadar b_i regresyon katsayısı içerir. Regresyon katsayıları için standart hata, t-değeri ve P-değeri elde edilir. P-değeri, katsayının 0 olması durumunda aynı sonucun bulunma olasılığıdır. Eğer P-değeri geleneksel 0.05 değerinden küçükse, bu katsayının istatistiksel olarak belirgin olduğu söylenebilir. Bu durumda, ilgili bağımsız değişkenin Y bağımlı değişkeni üzerinde bağımsız etkisi vardır.
- c. Varyans analizi: Y bağılı değişkenindeki toplam değişim, regresyon modeli ve kalan model olmak üzere iki şekilde düşünülür. F-testi için belirginlik seviyesi 0.05'ten küçük ise, doğrusal ilişkinin olmadığı şeklindeki hipotez reddedilir.


F-testi için belirginlik seviyesi 0.012 olarak bulunmuştur. Bu sonuca göre bağımsız değişkenler, yani kaotik ölçütler ile çıkış arasında doğrusal bir ilişki olduğu söylenebilir. Belirleme katsayısı 0.0829 olarak bulunmuştur. Bunun anlamı, elde edilen doğrusal regresyon denkleminin veriler için uygun olmadığıdır. Regresyon denklemi için, iki katsayının P-değerleri sırasıyla 0.003 ve 0.2676 şeklinde bulunmuştur. Bu değerlere bakılarak, ilinti boyutunun hem istatistiksel olarak belirgin hem de çıkış değerleri üzerinde Lyapunov üstelinden daha fazla etkili olduğu, fakat Lyapunov üstelini de oluşturulacak muhtemel bir doğrusal modelde tamamen göz ardı edemeyeceğimiz söylenebilir.

4.1. TCD Sinyallerinin Doğrusal Olmadığının Tespit Edilmesi

Bu çalışmada, TCD zaman dizilerinin doğrusal olup olmadığını tespit etmede yararlanılacak yapay zaman dizileri kümelerini üretmek için, Iterative Amplitude Adjusted Fourier Transform (IAAFT) yöntemini içeren algoritma (Hegger ve ark., 1999) kullanılmıştır.



Şekil 4.2. Beyin Damarında Balonlaşma Olan Bir Hastadan Alınan TCD Sinyali



Şekil 4.3. Beyin damarında balonlaşmalı bir hastanın TCD sinyalinden IAAFT yöntemi ile üretilmiş örnek yapay zaman dizileri

Orijinal zaman dizisi ve yapay zaman dizileri için ortalama kare tahmin hataları üretilmiş ve bu değerler azalan veya artan biçimde sıralanmıştır. Eğer orijinal zaman dizisine ait ortalama kare tahmin hatası artan sıralamada en son veya azalan sıralamada ilk satır ise, orijinal zaman dizisinin doğrusal olmadığı söylenir.

Üretilecek yapay zaman dizilerinin sayısına karar verebilmek için, $(1-\alpha) * \%100$ belirginlik seviyesine karşılık gelecek şekilde, yanlış reddetme için α artık olasılığı kullanılmıştır. Bu durumda tek taraflı test için, orijinal zaman dizisi de dahil olmak üzere, $1/\alpha$ adet yapay diziye ihtiyaç vardır. Böylece %95’lik bir belirginlik seviyesi için en az 19 yapay veri dizisi üretilmesi gerekir.

TCD sinyallerine uygulanan doğrusalsızlık testinin adımları aşağıdaki gibidir:

1. TCD sinyalinin uçlarındaki periyodik etkiyi azaltmak için, uygun bir sinyal aralığı bulunur.
2. Seçilen aralık için yapay zaman dizileri üretilir.
3. Orijinal zaman dizisi ve yapay zaman dizileri için tahmin hataları bulunur.
4. Orijinal zaman dizisinin tahmin hatası, yapay zaman dizilerinin tümünden farklı ise orijinal zaman dizisinin doğrusal olmadığı söylenir.


Aşağıda, beyinde balonlaşma olan bir hasta için, doğrusal olup olmama analizi sonucu verilmiştir. Orijinal zaman dizisi için bulunan tahmin hatası son satırda yer almaktadır. Yapay diziler için bulunan tahmin hatalarından daha düşük ve farklı olması zaman dizisinin doğrusal olmadığını göstermektedir.

```
predict -o -d1 -m3 -v0.1 selectbalon1.txt selectbalon1.txt_surr_??? | sort /R > sonuc.txt
```


```
err: 43.1228561 selectbalon1.txt_surr_003  
err: 43.0785637 selectbalon1.txt_surr_007  
err: 43.0734901 selectbalon1.txt_surr_013  
err: 43.0556221 selectbalon1.txt_surr_016  
err: 42.8910065 selectbalon1.txt_surr_005  
err: 42.8822098 selectbalon1.txt_surr_019  
err: 42.8198547 selectbalon1.txt_surr_015  
err: 42.7691078 selectbalon1.txt_surr_017  
err: 42.7403183 selectbalon1.txt_surr_001  
err: 42.7133789 selectbalon1.txt_surr_009  
err: 42.6586723 selectbalon1.txt_surr_012  
err: 42.6484489 selectbalon1.txt_surr_014  
err: 42.628231 selectbalon1.txt_surr_002  
err: 42.6240654 selectbalon1.txt_surr_004  
err: 42.447197 selectbalon1.txt_surr_010  
err: 42.3605232 selectbalon1.txt_surr_018  
err: 42.358387 selectbalon1.txt_surr_011  
err: 41.890377 selectbalon1.txt_surr_006  
err: 41.7776985 selectbalon1.txt_surr_008  
err: 40.897583 selectbalon1.txt
```

Çizelge 4.3. Beyinde balonlaşma olan bir hasta için doğrusalsızlık analizi

Karşılaştırma amacıyla sinüs sinyalinin doğrusal olup olmadığı aynı yöntemle araştırılmış ve aşağıdaki sonuçlar bulunmuştur.



Şekil 4.4. Sinüs sinyali



Şekil 4.5. Sinüs sinyali için üretilen örnek yapay zaman dizileri


```
predict -o -d1 -m3 -v0.1 sinus.txt sinus.txt_surr_??? | sort /R > sonuc_sinus.txt
```

```
err: 9.18575857E-14 sinus_10000.txt_surr_018
err: 9.18575857E-14 sinus_10000.txt_surr_009
err: 9.17736888E-14 sinus_10000.txt_surr_012
err: 9.17068748E-14 sinus_10000.txt_surr_013
err: 9.17068748E-14 sinus_10000.txt_surr_010
err: 9.17068748E-14 sinus_10000.txt_surr_004
err: 9.17068681E-14 sinus_10000.txt_surr_016
err: 9.17068681E-14 sinus_10000.txt_surr_014
err: 9.17068681E-14 sinus_10000.txt_surr_008
err: 9.17068681E-14 sinus_10000.txt_surr_007
err: 9.17067529E-14 sinus_10000.txt_surr_006
err: 9.17067529E-14 sinus_10000.txt_surr_003
err: 9.16872711E-14 sinus_10000.txt_surr_017
err: 9.16872711E-14 sinus_10000.txt_surr_011
err: 9.16872711E-14 sinus_10000.txt_surr_001
err: 9.16872576E-14 sinus_10000.txt_surr_019
err: 9.16872576E-14 sinus_10000.txt_surr_002
err: 9.15360994E-14 sinus_10000.txt_surr_015
err: 9.15360994E-14 sinus_10000.txt_surr_005
err: 1.07151863E-13 sinus_10000.txt
```


Çizelge 4.4. Sinüs sinyali için doğrusalsızlık analizi

Çizelge 4.4'e göre sinüs sinyalinin hükümsüz hipoteze göre üretilmiş yapay zaman dizilerinden farklı olduğu, dolayısıyla doğrusal olmadığı görülmektedir. Sinüs sinyali periyodik ve deterministiktir. Sinyali üreten denklem bilindiği için, herhangi bir t anındaki sinyal değeri kesin olarak belirlenebilir. Kaotik sistemler tam olarak deterministik sistemler ile stokastik sistemler arasında yer alırlar. Haykin ve Li (1995) stokastik bir süreci, her biri ayrı bir olasılık dağılımıyla ifade edilen rasgele dalga biçimlerinin birleşimi olarak tanımlamışlardır.

Doğrusalsızlık analizi Gauss dağılımına uyan rasgele sayılardan oluşan zaman dizisi için de yapılmış ve aşağıdaki sonuçlar bulunmuştur.



Şekil 4.6. Gauss dağılımına uyan rasgele sayılardan oluşan zaman dizisi



Şekil 4.7. Gauss dağılımına uyan rasgele zaman dizisi için üretilen örnek yapay zaman dizileri

```
predict -o -d1 -m3 -v0.1 rasgele.txt rasgele.txt_surr_??? | sort /R > sonuc_rasgele.txt
```


```
Err: 1.19340742 rasgele.txt_surr_002
err: 1.18465734 rasgele.txt_surr_011
err: 1.18347609 rasgele.txt_surr_001
err: 1.18332148 rasgele.txt_surr_008
err: 1.1828686 rasgele.txt_surr_004
err: 1.18155849 rasgele.txt_surr_017
err: 1.18088174 rasgele.txt_surr_016
err: 1.18062878 rasgele.txt_surr_019
err: 1.18047738 rasgele.txt_surr_007
err: 1.17837799 rasgele.txt_surr_005
err: 1.17576909 rasgele.txt
err: 1.17452538 rasgele.txt_surr_014
err: 1.17109025 rasgele.txt_surr_013
err: 1.17079914 rasgele.txt_surr_015
err: 1.16910708 rasgele.txt_surr_010
err: 1.16807675 rasgele.txt_surr_018
err: 1.16726315 rasgele.txt_surr_012
err: 1.16699004 rasgele.txt_surr_006
err: 1.16241825 rasgele.txt_surr_009
err: 1.16132498 rasgele.txt_surr_003
```

Çizelge 4.5. Rasgele sayılar zaman dizisi için doğrusalsızlık analizi

Ayrıca istatistik olarak tahmin hatasının kullanıldığı yapay veriler testi yöntemine göre, TCD zaman dizilerinin doğrusal bir sistem tarafından üretilmediği söylenebilir. Bir zaman dizisinin kaotik olması için mutlaka doğrusal olmaması gerekmektedir, fakat doğrusal olmayan zaman dizileri kaotik olmayan süreçler tarafından da üretilmektedir.

4.2. TCD Sinyallerinin Durağanlık Analizi

TCD sinyallerinin durağanlık analizi, doğrusal olmayan çapraz-tahmin yöntemi ile yapılmıştır. 10000 adetlik veri içeren zaman dizisinin tamamı, her biri 250 adet veri içeren 40 parçaya ayrılmıştır. Bu parçalar arasındaki, çapraz tahmin hataları bulunmuştur. Aşağıdaki şekilde, beyinde balonlaşma olan bir hastaya ait zaman dizisini oluşturan 40 farklı parça için çapraz tahmin hataları değerleri grafiksel olarak gösterilmiştir.




Şekil 4.8. Beyin damarında balonlaşma olan bir hasta için durağanlık analizi


Yukarıda durağanlık grafiği verilen hasta için, ortalama çapraz-tahmin hatası 0.69, standart sapma 0.072, en fazla çapraz-tahmin hatası 0.98 ve en az çapraz-tahmin hatası 0.50 olarak bulunmuştur.

Karşılaştırma olarak, 20000 adet Ikeda haritası verisi ve 20000 adet Henon haritası verisi için köşegen çapraz-tahmin hataları hesaplanmıştır. Bu zaman dizileri de 500 noktalık 40 parçaya ayrılmıştır. Ikeda ve Henon haritaları düşük boyutlu determinizm gösteren kaotik zaman dizileri olarak bilinir. Ikeda haritası zaman dizisi için, ortalama çapraz-tahmin hatası 0.69, standart sapma 0.031, en fazla çapraz-tahmin hatası 0.80 ve en az çapraz-tahmin hatası 0.62 olarak bulunmuştur. Henon haritası zaman dizisi için, ortalama çapraz-tahmin hatası 0.22, standart sapma 0.027, en fazla çapraz-tahmin hatası 0.28 ve en az çapraz-tahmin hatası 0.18 olarak bulunmuştur. Bu sonuçlara göre, bir zaman dizisinin kaotik olması için parçalar arası çapraz-tahmin hatalarının düşük olması gerekmemektedir. Öte yandan, Ikeda ve Henon haritası gibi yapay kaotik zaman dizileri için, tahmin hatalarının standart sapması TCD sinyalleri gibi gerçek zaman dizileri için bulunan tahmin hatalarının standart sapmasından daha düşüktür. Bu durumun doğruluğu aşağıdaki şekillerde de görülmektedir. Bland-Altman çizimi Ikeda ve Henon haritası verileri için çapraz-tahmin hataları arasındaki tutarlılığı göstermektedir. Bu çizime göre, çapraz-tahmin hataları arasındaki farkın 1.96'lık standart sapmasının %95'lik üst ve alt güven

sınırının sırasıyla %51.5 ve %42.3 olduğu görülmektedir. Bu çizime göre ayrıca, çapraz-tahmin hataları arasındaki farkın ortalaması %46.9'dur.




Şekil 4.9. İkedda ve Henon haritaları ile beyin damarında balonlaşma olan bir hastanın TCD sinyalinin köşegensel çapraz tahmin hatalarının karşılaştırılması




Şekil 4.10. İkedda ve Henon haritası verilerinin köşegensel çapraz tahmin hataları için Bland-Altman çizimi

Doğrusal olmayan çapraz tahmin hatası yöntemiyle yapılan durağanlık analizi sonucu elde edilen değerler, aynı zamanda hastalardan alınan TCD sinyallerinin deterministik sinyaller ile gürültü sinyalleri arasında kalan doğrusal olmayan


sinyaller olduğunu göstermektedir. Sinüs sinyali gibi deterministik bir sinyal için çapraz tahmin hata değerlerinin ortalaması sıfıra çok yakın çıkmaktadır. Gürültü sinyallerinin çapraz tahmin hatalarının ortalaması ise 1'e çok yakın veya 1'in üzerindedir. Hastalık sinyallerinin çapraz tahmin hata değerlerinin ortalamasının bu iki sınır değer arasında olduğu bulunmuştur. Ayrıca, sinyallerin karmaşıklığına bağlı olarak çapraz tahmin hataları yükselmektedir. Sağlıklı bireylerin, beyin damarında balonlaşma olan hastaların ve beyin kanamalı hastaların çapraz tahmin hata değerlerinin ortalaması 0.5'ten büyük iken, beyinde su toplamalı ve beyin tümörlü hastaların ortalaması 0.5'ten küçük bulunmuştur. Aşağıdaki şekillerde ilgili sonuçlar gösterilmiştir. Durağanlık analizinde çapraz tahmin hata değerlerinin istatistiksel doğruluğunun daha yüksek olması için kesim sayısı 20 olarak seçilmiştir. Elde edilen sonuçlara göre, TCD sinyalleri kaotiklik tanımlamasına uymaktadır. Kaotik sinyaller tam olarak deterministik sinyaller ile stokastik (rasgele) sinyaller arasındaki aralıkta yer alır (Abarbanel, 1996, Haykin ve Li,1995).




Şekil 4.11. Beyin damarında balonlaşma olan hastaların köşegensel çapraz tahmin hataları




Şekil 4.12. Beyin kanamalı hastaların çapraz tahmin hataları




Şekil 4.13. Beyinde su toplamalı hastaların çapraz tahmin hataları



Şekil 4.14. Beyin tümörlü hastaların çapraz tahmin hataları




Şekil 4.15. Sağlıklı bireylerin çapraz tahmin hataları




Şekil 4.16. TCD, sinüs ve rasgele sinyallerinin çapraz tahmin hata değerlerinin karşılaştırılması

Yukarıdaki grafiğin üst kısmındaki kırmızı noktalar Gauss dağılımına uyan rasgele sayılar zaman dizisi için elde edilen çapraz tahmin hata değerlerini, alt kısımdaki siyah noktalar ise sinüs sinyalinin çapraz tahmin hata değerlerini göstermektedir. Grafiğin ortasındaki noktalar, her bir hasta grubu ve sağlıklı bireylerden örnek bir TCD sinyalinin çapraz tahmin hata değerleridir.


Aşağıdaki şekillerde her hastalık grubundan ve sağlıklı gruptan örnek birer birey için yineleme çizimleri verilmiştir. Yineleme çizimlerinden elde edilen nicel ölçütler (REC, DET, ENT ve TREND) şekillerin altındaki açıklamalarda yer almaktadır. Çizimlerin karmaşıklığına göre bu değerler değişmektedir.




Şekil 4.17. Beyin damarında balonlaşma olan bir hastanın TCD sinyaline ait yineleme çizimi (REC=0.236886, DET=0.400897, ENT=1.0595, TREND=2.50995)




Şekil 4.18. Beyin kanamalı bir hastanın TCD sinyaline ait yineleme çizimi (REC=0.175948, DET=0.508334, ENT=0.955506, TREND=2.68942)



Şekil 4.19. Sağlıklı bireyin TCD sinyaline ait yineleme çizimi (REC=0.14899, DET=0.330671, ENT=0.650027, TREND=2.40626)




Şekil 4.20. Beyninde su toplama olan bir hastanın TCD sinyaline ait yineleme çizimi (REC=0.23728, DET=0.496309, ENT=1.49789, TREND=3.18693)




Şekil 4.21. Beyin tümörlü bir hastanın TCD sinyaline ait yineleme çizimi
(REC=0.268756, DET=0.798428, ENT=1.66949, TREND=4.1864)


Aşağıdaki şekillerde her hastalık grubundan ve sağlıklı gruptan örnek birer birey için uzay-zaman ayrımı çizimleri verilmiştir. Geçici ilinti durumundaki noktaları Theiler ilinti boyutu ve Kantz Lyapunov üsteli hesaplarında göz ardı etmek için kullanılacak w Theiler penceresi boyutu değeri şekillerin altındaki açıklamalarda verilmiştir.




Şekil 4.22. Beyin damarında balonlaşma olan bir hastanın TCD sinyaline ait uzay-zaman ayrımı çizimi ($w=25$)




Şekil 4.23. Beyin kanamalı bir hastanın TCD sinyaline ait uzay-zaman ayrımı çizimi (w=35)



Şekil 4.24. Sağlıklı bir bireyin TCD sinyaline ait uzay-zaman ayrımı çizimi (w=20)




Şekil 4.25. Beyinde su toplamalı bir hastanın TCD sinyaline ait uzay-zaman ayrımı çizimi ($w=50$)




Şekil 4.26. Beyin tümörlü bir hastanın TCD sinyaline ait uzay-zaman ayrımı çizimi ($w=40$)

4.3. Kaotik Çekicilerin Yeniden Oluşturulması


Gömülme boyutunun 3'ten büyük olması durumunda kaotik çekicilerin grafiksel olarak gösterimi mümkün değildir. Aşağıdaki şekillerde her bir hasta grubuna ve sağlıklı birey grubuna ait birer örnek TCD sinyali için 2 boyutlu ve 3 boyutlu faz uzaylarında zaman gecikmesi 1 olarak seçilmesi durumunda oluşacak kaotik çekicilerin nasıl oluşacağı gösterilmiştir. Her bir sinyal için gösterimin açık olması için ilk 300 nokta seçilmiştir.



Şekil 4.27. Beyin damarında balonlaşma olan bir hasta için elde edilen kaotik çekiciler (a) 2 boyutlu faz uzayında 1 adımlık zaman gecikmesi ile (b) 3 boyutlu faz uzayında 1 adımlık zaman gecikmesi ile




Şekil 4.28. Beyin kanamalı bir hasta için elde edilen kaotik çekiciler (a) 2 boyutlu faz uzayında 1 adımlık zaman gecikmesi ile (b) 3 boyutlu faz uzayında 1 adımlık zaman gecikmesi ile



(a)

(b)


Şekil 4.29. Sağlıklı bir birey için elde edilen kaotik çekiciler (a) 2 boyutlu faz uzayında 1 adımlık zaman gecikmesi ile (b) 3 boyutlu faz uzayında 1 adımlık zaman gecikmesi ile



(a)

(b)

Şekil 4.30. Beyinde su toplamalı bir hasta için elde edilen kaotik çekiciler (a) 2 boyutlu faz uzayında 1 adımlık zaman gecikmesi ile (b) 3 boyutlu faz uzayında 1 adımlık zaman gecikmesi ile




(a)

(b)



Şekil 4.31. Beyin tümörlü bir hasta için elde edilen kaotik çekiciler (a) 2 boyutlu faz uzayında 1 adımlık zaman gecikmesi ile (b) 3 boyutlu faz uzayında 1 adımlık zaman gecikmesi ile



4.4. Zaman Gecikmesi ve En Düşük Gömülme Boyutu Değerlerinin Hesaplanması



TCD sinyalleri için ilinti boyutu ve Lyapunov üstelinin hesaplanması için öncelikle kaotik çekicilerin faz uzayında yeniden oluşturulması gereklidir. Bunun için zaman gecikmesi ve en düşük gömülme boyutlarının doğru biçimde hesaplanması gereklidir. Zaman gecikmesi, sinyali oluşturan noktaların veri artıklığına neden olmayacak şekilde birbirinden ayrı olmasının ölçüsünü verir. Zaman gecikmesi gereğinden küçük seçilirse kaotik çekici yanlış biçimde faz uzayının bir bölümüne yığılıp kalacaktır. En düşük gömülme boyutunun gereğinden küçük seçilmesi durumunda kaotik çekicilerin karakteristik özelliği olan periyodik yörüngelerin faz uzayında kesişmemesi kuralı sağlanmamış olacaktır. Bu durumda bir sonraki boyutta aslında birbirinden uzak durumda olan kaotik çekici noktaları birbirine yakınmış gibi hesaplamalar yapılacağından ilinti boyutu ve Lyapunov üsteli hesapları yanlış olacaktır. Aşağıdaki grafiklerde farklı hastalık grupları ve sağlıklı bireyler için zaman gecikmesi ve en düşük gömülme boyutu değerlerinin nasıl bulunduğu gösterilmiştir.




Şekil 4.32. Beyin damarında balonlaşma olan bazı hastalar için bulunan zaman gecikmesi değerleri












Şekil 4.39. Beyinde su toplamalı bazı hastalar için bulunan en düşük gömülme boyutu değerleri



Şekil 4.40. Beyin tümörlü bazı hastalar için bulunan zaman gecikmesi değerleri



Şekil 4.41. Beyin tümörü olan bazı hastalar için bulunan en düşük gömülme boyutu değerleri




Şekil 4.42. Farklı hastalık grupları için Cao yöntemiyle en düşük gömülme boyutlarının hesaplanması


4.3. İlinti Boyutunun Hesaplanması

İlinti boyutunun hesaplanması için öncelikle, farklı gömülme boyutları için ilinti toplamalarının yerel eğimleri bulunarak bir dosyaya yazılmıştır. Daha sonra, dosyanın içeriği x-y koordinat düzlemine çizilerek aktarılmıştır. Bu çizimde, ε değerleri x koordinatına karşılık ve ilinti toplamalarının yerel eğimleri y koordinatına


karşılık gelmektedir. Farklı ε değerlerine için elde edilen eğrilerin üst üste binerek bir plato oluşturduğu y değeri kaotik çekicinin ilinti boyutunu verir. Aşağıdaki şekillerde, her hasta grubundan örnek bir TCD zaman dizisi için ilinti boyutunun nasıl hesaplandığı örnek olarak verilmiştir.




Şekil 4.43. Beyin damarında balonlaşma olan bir hasta için ilinti boyutunun hesaplanması




Şekil 4.44. Beyin kanaması olan bir hasta için ilinti boyutunun hesaplanması




Şekil 4.45. Beyinde su toplama olan bir hasta için ilinti boyutunun hesaplanması



Şekil 4.46. Beyinde tümörü bir hasta için ilinti boyutunun hesaplanması



Şekil 4.47. Sağlıklı bir birey için ilinti boyutunun hesaplanması




Şekil 4.48. Farklı hastalık gruplarından ve sağlıklı gruptan örnek birer birey için bulunan ilinti toplamı $C(m, \varepsilon)$ ve ε grafikleri a) Balonlaşma b) Kanama c) Su Toplama d) Tümör e) Sağlıklı


4.4. En Büyük Lyapunov Üstelinin Hesaplanması

TCD zaman dizileri için en büyük Lyapunov üstelini hesaplayan program, küçük ve gürültülü veri kümelerinde güvenilir sonuçlar veren Rosenstein ve ark. (1993)'nın yöntemini kullanmaktadır. Önceki adımlarda bulunan zaman gecikmesi


değeri ve en düşük gömülme boyutu değerlerini kullanan bu program, iki kolonlu bir dosya üretmektedir. İlk kolon adım sayısını, ikinci kolon ise gerilme faktörünün logaritmasını göstermektedir. En büyük Lyapunov üsteli, bu değerlerin her iki koordinat eksenini için de doğrusal ölçek kullanılarak işaretlenmesi ile elde edilir. İşaretleme sonucu elde edilen eğrinin ilk eğim değeri en büyük Lyapunov üstelini verir. Aşağıdaki şekillerde, her bir hasta grubuna ait örnek bir TCD zaman dizisi için en büyük Lyapunov üsteli hesabının nasıl yapıldığı gösterilmiştir.




Şekil 4.49. Beyin damarında balonlaşma olan bir hasta için en büyük Lyapunov üstelinin hesaplanması




Şekil 4.50. Beyin kanaması olan bir hasta için en büyük Lyapunov üstelinin hesaplanması



Şekil 4.51. Beyinde su toplama olan bir hasta için en büyük Lyapunov üstelinin hesaplanması




Şekil 4.52. Beyin tümürlü bir hasta için en büyük Lyapunov üstelinin hesaplanması



Şekil 4.53. Sağlıklı bir birey için en büyük Lyapunov üstelinin hesaplanması

Aşağıda çeşitli beyin rahatsızlıklarına ait TCD sinyalleri üzerinde yapılan sınıflandırma işlemlerine ait akış çizelgesi verilmiştir.



Şekil 4.54. TCD Sinyallerinin Sınıflandırılması Adımları


4.5. Sınıflandırma Sonuçları

Sınıflandırma yöntemlerini çapraz doğrulamaya (cross validation) tabi tutmak için, 105 bireye ait TCD sinyallerinden kaos teorisi yöntemleri ile elde edilen kaotik ölçütlerden oluşan veri kümesi, her biri 21 adet veri içeren 5 alt kümeye rasgele biçimde bölünmüştür. Her bir eğitim ve test aşaması için, eğitim alt kümesi 84 adet veri ve test alt kümesi 21 adet veri içerecek şekilde alt kümeler oluşturulmuştur. Böylece her bir parça hem eğitim kümesinde hem de test kümesinde birer defa yer almış ve eldeki verilerin tümü hem eğitim hem de test işleminde kullanılmıştır. Bu işlemler her sınıflandırıcı için 3 kez tekrarlanmış ve her adımda elde edilen performans değerlerinin ortalamaları alınarak sınıflandırma doğruluğuna göre sınıflandırıcıların performansları elde edilmiştir.


	<i>Eğitim Alt Kümeleri (84 adet veri)</i>	<i>Test Alt Kümeleri (21 adet veri)</i>
1.Küme	Alt Kümeler (1-2-3-4)	Alt Küme-5
2.Küme	Alt Kümeler (1-2-3-5)	Alt Küme-4
3.Küme	Alt Kümeler (1-2-4-5)	Alt Küme-3
4.Küme	Alt Kümeler (1-3-4-5)	Alt Küme-2
5.Küme	Alt Kümeler (2-3-4-5)	Alt Küme-1

Çizelge 4.6. Sınıflandırıcıların eğitim ve test işlemlerinde kullanılan veri kümeleri


Her bir sınıflandırma algoritması rasgele oluşturulan veri kümeleri ile eğitilmiş ve test edilmiştir. Eğitim ve test işlemleri sonucunda doğru sınıflandırma oranları ile ortalama mutlak hata, kök ortalama kare hata ve göreceli mutlak hata değerleri elde edilmiştir. Karşılaştırma amacıyla TCD sinyallerinden elde edilen spektral parametrelerden hesaplanan 105 adet Rİ (Rezistans İndis) ve Pİ(Pulsatilite İndis) değerleri kaotik ölçütlerle aynı sayıda eğitim ve test alt kümelerine ayrılarak sınıflandırma algoritmalarına uygulanmıştır. Hem spektral parametreler hem de kaotik ölçütler kullanılarak elde edilen eğitim ve test sonuçları ilgili sınıflandırma algoritmasına ait bölümlerde verilmiştir. Aşağıdaki şekillerde her gruba ait örnek bireylerin TCD sinyallerinden elde edilen güç spektrum yoğunluğu kestirimi grafikleri verilmiştir.




(a)




(b)



(c)



(d)



(e)

Şekil 4.55. Her hasta grubuna ve sağlıklı birey grubuna ait örnek bir TCD sinyaline ait güç spektrum yoğunluğu kestirimi (a) Beyin damarında balonlaşma (b) Beyin kanaması (c) Beyinde su toplama (d) Beyin tümörü (e) Sağlıklı

Sınıflandırma sonuçlarının performanslarını karşılaştırmada kullanılan hata değerleri aşağıdaki gibi hesaplanmıştır. Aşağıdaki denklemlerde, O_j oluşan j . çıkış değeri, T_j beklenen j . çıkış değeri ve $\bar{T}$ beklenen çıkış değerlerinin ortalamasıdır.

Ortalama Mutlak Hata

Sınıflandırma işlemi sonucu n adet örnek için beklenen ve oluşan çıktı değerleri kullanılarak ortalama mutlak hata değeri aşağıdaki gibi hesaplanmıştır.

$$E = \frac{1}{n} \sum_{j=1}^n |O_j - T_j| \quad (4.1)$$

Kök Ortalama Kare Hata

Sınıflandırma işlemi sonucu n adet örnek için beklenen ve oluşan çıktı değerleri ile ortalama kare hatanın karekökü aşağıdaki gibi hesaplanmıştır.

$$E = \sqrt{\frac{1}{n} \sum_{j=1}^n (O_j - T_j)^2} \quad (4.2)$$

Göreceli Mutlak Hata

Sınıflandırma işlemi sonucu n adet örnek için beklenen ve oluşan çıktı değerleri ile göreceli mutlak hata aşağıdaki gibi hesaplanmıştır.

$$E = \frac{\sum_{j=1}^n |O_j - T_j|}{\sum_{j=1}^n |T_j - \bar{T}|} \quad (4.3)$$

4.5.1. NEFCLASS İle Bulunan Sonuçlar

NEFCLASS modeli, otomatik budama uygulanarak 1000 adım ile eğitilmiştir. Öğrenme oranı 0.01 olarak seçilmiştir. Girişlere ait üyelik fonksiyonlarına ait bulanık kümeler üçgensel biçimde ÇOK KÜÇÜK, KÜÇÜK, BÜYÜK ve ÇOK BÜYÜK olmak üzere dört adet tanımlanmıştır. Elde edilen sınıflandırma sonuçları ve hata değerleri aşağıdaki tablolarda verilmiştir.

Veri Kümeleri	Eğitim				Test			
	Yanlış Sınıflandırma		Doğruluk		Yanlış Sınıflandırma		Doğruluk	
	K.Ö.	S.P.	K.Ö.	S.P.	K.Ö.	S.P.	K.Ö.	S.P.
1. Küme	11	25	%87	%70	1	7	%95	%67
2. Küme	13	21	%85	%75	2	6	%90	%71
3. Küme	9	25	%89	%70	4	9	%81	%57
4. Küme	14	22	%83	%74	7	9	%67	%57
5. Küme	11	31	%87	%63	6	10	%71	%52
Ortalama	12	25	%86	%70	4	8	%81	%61

Çizelge 4.7. NEFCLASS için birinci sınıflandırma sonuçları (K.Ö. = Kaotik Ölçütler ve S.P. = Spektral Parametreler)

Veri Kümeleri	Eğitim			Test		
	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata
1. Küme	0,07	0,14	0,21	0,06	0,12	0,19
2. Küme	0,07	0,14	0,22	0,06	0,11	0,17
3. Küme	0,07	0,14	0,21	0,11	0,21	0,35
4. Küme	0,07	0,14	0,22	0,06	0,12	0,18
5. Küme	0,07	0,14	0,22	0,08	0,18	0,26
Ortalama	0,07	0,14	0,22	0,07	0,15	0,23

Çizelge 4.8. Kaotik ölçütlerin NEFCLASS ile birinci sınıflandırmada oluşan hata değerleri


Veri Kümeleri	Eğitim			Test		
	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata
1. Küme	0,13	0,23	0,34	0,14	0,24	0,44
2. Küme	0,13	0,21	0,42	0,13	0,21	0,41
3. Küme	0,14	0,23	0,43	0,16	0,28	0,51
4. Küme	0,13	0,21	0,41	0,15	0,25	0,48
5. Küme	0,13	0,23	0,42	0,15	0,27	0,48
Ortalama	0,13	0,22	0,41	0,15	0,25	0,46

Çizelge 4.9. Spektral parametrelerin NEFCLASS ile birinci sınıflandırmada oluşan hata değerleri


3. kümedeki verilerle uygulanan eğitim işlemindeki otomatik budama işlemi sonunda oluşan NEFCLASS sisteminin kural kümesi aşağıdaki 6 kuralı içermektedir.

1. EĞER D_2 ÇOK_BÜYÜK ve λ_1 BÜYÜK ise Beyin_Damarında_Balonlaşma
2. EĞER D_2 ÇOK_BÜYÜK ve λ_1 ÇOK_BÜYÜK ise Sağlıklı
3. EĞER D_2 KÜÇÜK ve λ_1 ÇOK_BÜYÜK ise Beyin_Kanaması
4. EĞER D_2 ÇOK_KÜÇÜK ve λ_1 ÇOK_KÜÇÜK ise Beyinde_Su_Toplama
5. EĞER D_2 ÇOK_BÜYÜK ve λ_1 ÇOK_KÜÇÜK ise Beyin_Tümörü
6. EĞER D_2 BÜYÜK ve λ_1 ÇOK_KÜÇÜK ise Beyin_Tümörü

Çizelge 4.10. NEFCLASS sisteminde otomatik budama sonucu oluşan kural tabanı




(a)




(b)

Şekil 4.56. NEFCLASS sistemin 2 girişi için başlangıçtaki bulanık kümeler (a) İlinti boyutu (b) Lyapunov üsteli

1000 adımlık öğrenme işlemi sonucunda, bulanık kümeler aşağıdaki gibi değişmiştir.



(a)



(b)

Şekil 4.57. NEFCLASS sistemin 2 girişi için 1000 adımlık eğitim sonucu oluşan bulanık kümeler (a) İlinti boyutu (b) Lyapunov üsteli

Veri Kümeleri	Eğitim				Test			
	Yanlış Sınıflandırma		Doğruluk		Yanlış Sınıflandırma		Doğruluk	
	K.Ö.	S.P.	K.Ö.	S.P.	K.Ö.	S.P.	K.Ö.	S.P.
1. Küme	19	27	%77	%68	4	8	%81	%62
2. Küme	19	31	%77	%63	4	10	%81	%52
3. Küme	19	31	%77	%63	4	8	%81	%62
4. Küme	19	24	%77	%71	4	8	%81	%62
5. Küme	18	31	%79	%63	5	7	%76	%67
Ortalama	19	29	%77	%65	4	8	%81	%62

Çizelge 4.11. NEFCLASS için ikinci sınıflandırma sonuçları (K.Ö. = Kaotik Ölçütler ve S.P. = Spektral Parametreler)

Veri Kümeleri	Eğitim			Test		
	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata
1. Küme	0,1	0,19	0,30	0,1	0,2	0,31
2. Küme	0,1	0,19	0,31	0,1	0,18	0,30
3. Küme	0,1	0,19	0,31	0,1	0,19	0,31
4. Küme	0,1	0,19	0,31	0,1	0,19	0,31
5. Küme	0,1	0,19	0,31	0,1	0,2	0,34
Ortalama	0,1	0,19	0,31	0,1	0,19	0,31

Çizelge 4.12. Kaotik ölçütlerin NEFCLASS ile ikinci sınıflandırmasında oluşan hata değerleri

Veri Kümeleri	Eğitim			Test		
	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata
1. Küme	0,14	0,24	0,45	0,15	0,26	0,48
2. Küme	0,13	0,22	0,40	0,18	0,30	0,55
3. Küme	0,14	0,25	0,45	0,12	0,25	0,38
4. Küme	0,13	0,22	0,40	0,18	0,29	0,57
5. Küme	0,15	0,25	0,46	0,14	0,24	0,43
Ortalama	0,14	0,24	0,43	0,15	0,27	0,48

Çizelge 4.13. Spektral parametrelerin NEFCLASS ile ikinci sınıflandırmasında oluşan hata değerleri

Veri Kümeleri	Eğitim				Test			
	Yanlış Sınıflandırma		Doğruluk		Yanlış Sınıflandırma		Doğruluk	
	K.Ö.	S.P.	K.Ö.	S.P.	K.Ö.	S.P.	K.Ö.	S.P.
1. Küme	15	24	%82	%71	5	8	%76	%62
2. Küme	18	28	%79	%67	6	7	%71	%67
3. Küme	17	30	%80	%64	7	10	%67	%52
4. Küme	13	33	%85	%61	4	8	%81	%62
5. Küme	16	32	%81	%62	5	4	%76	%76
Ortalama	16	29	%81	%65	5	7	%76	%67

Çizelge 4.14. NEFCLASS için üçüncü sınıflandırma sonuçları (K.Ö. = Kaotik Ölçütler ve S.P. = Spektral Parametreler)

Veri Kümeleri	Eğitim			Test		
	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata
1. Küme	0,1	0,18	0,30	0,1	0,2	0,33
2. Küme	0,1	0,19	0,30	0,1	0,2	0,32
3. Küme	0,1	0,19	0,31	0,1	0,2	0,31
4. Küme	0,1	0,19	0,30	0,1	0,2	0,32
5. Küme	0,1	0,19	0,31	0,1	0,2	0,31
Ortalama	0,1	0,19	0,30	0,1	0,2	0,32

Çizelge 4.15. Kaotik ölçütlerin NEFCLASS ile üçüncü sınıflandırmasında oluşan hata değerleri

Veri Kümeleri	Eğitim			Test		
	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata
1. Küme	0,13	0,21	0,42	0,15	0,23	0,46
2. Küme	0,14	0,24	0,44	0,13	0,21	0,39
3. Küme	0,14	0,23	0,43	0,16	0,27	0,50
4. Küme	0,15	0,26	0,48	0,15	0,25	0,46
5. Küme	0,15	0,25	0,47	0,10	0,17	0,31
Ortalama	0,14	0,24	0,45	0,14	0,24	0,42

Çizelge 4.16. Spektral parametrelerin NEFCLASS ile üçüncü sınıflandırmasında oluşan hata değerleri

Veri Kümeleri	Eğitim				Test			
	Yanlış Sınıflandırma		Doğruluk		Yanlış Sınıflandırma		Doğruluk	
	K.Ö.	S.P.	K.Ö.	S.P.	K.Ö.	S.P.	K.Ö.	S.P.
1. Aşama	12	25	%86	%70	4	8	%81	%61
2. Aşama	19	29	%77	%65	4	8	%81	%62
3. Aşama	16	29	%81	%65	5	7	%76	%67
Ortalama	16	28	%81	%67	4	8	%79	%63

Çizelge 4.17. NEFCLASS için genel sınıflandırma sonuçları

Veri Kümeleri	Eğitim			Test		
	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata
1. Aşama	0,07	0,14	0,22	0,07	0,15	0,23
2. Aşama	0,10	0,19	0,31	0,10	0,19	0,31
3. Aşama	0,10	0,19	0,30	0,10	0,20	0,32
Ortalama	0,09	0,17	0,28	0,09	0,18	0,29

Çizelge 4.18. Kaotik ölçütlerin NEFCLASS ile sınıflandırma hata değerleri

Veri Kümeleri	Eğitim			Test		
	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata
1. Aşama	0,13	0,22	0,41	0,15	0,25	0,46
2. Aşama	0,14	0,24	0,43	0,15	0,27	0,48
3. Aşama	0,14	0,24	0,45	0,14	0,24	0,42
Ortalama	0,14	0,23	0,43	0,15	0,25	0,45

Çizelge 4.19. Spektral parametrelerin NEFCLASS ile sınıflandırma hata değerleri

4.5.2. ANFIS İle Bulunan Sonuçlar

ANFIS sınıflandırıcısı Tablo 4'te verilen biçimde alt kümelere bölünmüş kaotik ve spektral ölçüt eğitim verileriyle, parametre adaptasyon adım değeri olarak 0.01 verilerek 250'şer adımda eğitilmiştir. Kaotik ölçütler ve spektral parametrelerle yapılan eğitim ve test adımlarında elde edilen sınıflandırma sonuçları ve ilgili hata değerleri aşağıdaki tablolarda verilmiştir.

Veri Kümeleri	Eğitim				Test			
	Yanlış Sınıflandırma		Doğruluk		Yanlış Sınıflandırma		Doğruluk	
	K.Ö.	S.P.	K.Ö.	S.P.	K.Ö.	S.P.	K.Ö.	S.P.
1. Küme	5	14	%94	%83	0	8	%100	%62
2. Küme	3	18	%96	%79	1	5	%95	%76
3. Küme	0	15	%100	%82	3	9	%86	%57
4. Küme	5	17	%94	%80	0	4	%100	%81
5. Küme	2	19	%98	%77	2	4	%98	%81
Ortalama	3	17	%96	%80	1	6	%96	%71


Çizelge 4.20. ANFIS için birinci sınıflandırma sonuçları (K.Ö. = Kaotik Ölçütler ve S.P. = Spektral Parametreler)

Veri Kümeleri	Eğitim			Test		
	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata
1. Küme	0,08	0,28	0,07	0,02	0,05	0,02
2. Küme	0,11	0,28	0,09	0,11	0,29	0,09
3. Küme	0	0	0	0,43	1,13	0,35
4. Küme	0,10	0,29	0,08	0,02	0,04	0,02
5. Küme	0,05	0,24	0,04	0,12	0,28	0,10
Ortalama	0,07	0,22	0,06	0,14	0,35	0,12

Çizelge 4.21. Kaotik ölçütlerin ANFIS ile birinci sınıflandırmasında oluşan hata değerleri


Veri Kümeleri	Eğitim			Test		
	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata
1. Küme	0,26	0,38	0,22	0,47	0,76	0,44
2. Küme	0,32	0,45	0,27	0,47	0,84	0,39
3. Küme	0,31	0,45	0,26	0,48	0,73	0,39
4. Küme	0,30	0,44	0,25	0,29	0,37	0,24
5. Küme	0,31	0,41	0,26	0,43	0,85	0,35
Ortalama	0,30	0,43	0,25	0,43	0,71	0,36

Çizelge 4.22. Spektral parametrelerin ANFIS ile birinci sınıflandırmasında oluşan hata değerleri




Şekil 4.58. Eğitim adımlarına karşılık ağ yakınsama hata değerinin gösterimi

Aşağıdaki şekilde, ANFIS'in 3. kümedeki eğitim alt kümesini çok başarılı biçimde öğrendiği görülmektedir. Bu eğitim alt kümesindeki veriler %100 oranında doğru sınıflandırılmıştır.




Şekil 4.59. 250 adımlık eğitim işlemi sonucunda 3. kümedeki adet eğitim verisinin ANFIS çıktıları ile eşleştirilmesi

ANFIS yapısının eğitim verilerine göre adaptasyonunu sağlayacak şekilde giriş değişkenlerine karşılık gelen üyelik fonksiyonlarına ait öncül parametreler değiştirilmiştir. Bu değişim aşağıdaki şekillerde görülmektedir.



(a)




(b)

Şekil 4.60. İlinti boyutuna karşılık gelen giriş değeri için iki-tarafli Gauss eğrisi üyelik fonksiyonunun (a) eğitimden önce (b) eğitimden sonra görünümü




(a)



Şekil 4.61. Lyapunov üsteline karşılık gelen giriş değeri için iki-taraflı Gauss eğrisi üyelik fonksiyonunun (a) eğitimden önce (b) eğitimden sonra görünümü

Birinci sınıflandırmada 3. kümedeki eğitim alt kümesiyle eğitilen ANFIS, 21 veriden oluşan test alt kümesindeki bireylerden, beyin tümörü olan 3 hastayı yanlışlıkla beyin damarında balonlaşmalı hasta şeklinde sınıflandırmıştır.



Şekil 4.62. ANFIS'in 3. kümedeki test alt kümesi ile değerlendirilmesi

Veri Kümeleri	Eğitim				Test			
	Yanlış Sınıflandırma		Doğruluk		Yanlış Sınıflandırma		Doğruluk	
	K.Ö.	S.P.	K.Ö.	S.P.	K.Ö.	S.P.	K.Ö.	S.P.
1. Küme	2	18	%98	%79	1	6	%95	%71
2. Küme	3	15	%96	%82	0	5	%100	%76
3. Küme	2	18	%98	%79	1	7	%95	%67
4. Küme	3	15	%96	%82	1	8	%95	%62
5. Küme	4	20	%95	%76	1	6	%95	%62
Ortalama	3	17	%96	%80	1	6	%95	%68

Çizelge 4.23. ANFIS için ikinci sınıflandırma sonuçları (K.Ö. = Kaotik Ölçütler ve S.P. = Spektral Parametreler)

Veri Kümeleri	Eğitim			Test		
	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata
1. Küme	0,05	0,24	0,04	0,36	1,43	0,29
2. Küme	0,08	0,26	0,07	0,03	0,06	0,02
3. Küme	0,07	0,26	0,06	0,65	2,8	0,53
4. Küme	0,08	0,28	0,07	0,04	0,14	0,03
5. Küme	0,07	0,27	0,06	0,09	0,28	0,08
Ortalama	0,07	0,26	0,06	0,23	0,94	0,19

Çizelge 4.24. Kaotik ölçütlerin ANFIS ile ikinci sınıflandırmasında oluşan hata değerleri

Veri Kümeleri	Eğitim			Test		
	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata
1. Küme	0,30	0,41	0,25	0,46	0,86	0,37
2. Küme	0,30	0,42	0,25	0,32	0,45	0,26
3. Küme	0,39	0,55	0,33	0,36	0,47	0,29
4. Küme	0,28	0,40	0,23	0,42	0,57	0,34
5. Küme	0,36	0,50	0,29	0,31	0,41	0,29
Ortalama	0,33	0,46	0,27	0,37	0,55	0,31

Çizelge 4.25. Spektral parametrelerin ANFIS ile ikinci sınıflandırmasında oluşan hata değerleri

Veri Kümeleri	Eğitim				Test			
	Yanlış Sınıflandırma		Doğruluk		Yanlış Sınıflandırma		Doğruluk	
	K.Ö.	S.P.	K.Ö.	S.P.	K.Ö.	S.P.	K.Ö.	S.P.
1. Küme	1	16	%99	%81	1	1	%95	%95
2. Küme	2	21	%98	%75	2	5	%90	%76
3. Küme	3	15	%96	%82	2	7	%90	%67
4. Küme	1	21	%99	%75	3	2	%86	%90
5. Küme	2	20	%98	%76	2	6	%90	%71
Ortalama	2	19	%98	%77	2	4	%90	%81

Çizelge 4.26. ANFIS için üçüncü sınıflandırma sonuçları (K.Ö. = Kaotik Ölçütler ve S.P. = Spektral Parametreler)

Veri Kümeleri	Eğitim			Test		
	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata
1. Küme	0,02	0,07	0,02	0,14	0,60	0,12
2. Küme	0,06	0,26	0,05	0,23	0,70	0,19
3. Küme	0,05	0,26	0,04	0,86	3,62	0,70
4. Küme	0,07	0,21	0,06	0,74	2,24	0,61
5. Küme	0,08	0,25	0,06	0,19	0,62	0,18
Ortalama	0,06	0,21	0,05	0,43	1,56	0,36

Çizelge 4.27. Kaotik ölçütlerin ANFIS ile üçüncü sınıflandırmasında oluşan hata değerleri

Veri Kümeleri	Eğitim			Test		
	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata
1. Küme	0,27	0,39	0,23	0,38	0,80	0,31
2. Küme	0,35	0,50	0,30	0,30	0,40	0,24
3. Küme	0,29	0,44	0,24	0,51	0,77	0,42
4. Küme	0,34	0,47	0,29	0,24	0,41	0,20
5. Küme	0,36	0,51	0,30	0,27	0,36	0,25
Ortalama	0,32	0,46	0,27	0,34	0,55	0,28

Çizelge 4.28. Spektral parametrelerin ANFIS ile üçüncü sınıflandırmasında oluşan hata değerleri

Veri Kümeleri	Eğitim				Test			
	Yanlış Sınıflandırma		Doğruluk		Yanlış Sınıflandırma		Doğruluk	
	K.Ö.	S.P.	K.Ö.	S.P.	K.Ö.	S.P.	K.Ö.	S.P.
1. Aşama	3	17	%96	%80	1	6	%96	%71
2. Aşama	3	17	%96	%80	1	6	%95	%68
3. Aşama	2	19	%98	%77	2	4	%90	%81
Ortalama	3	18	%97	%79	1	5	%94	%73

Çizelge 4.29. ANFIS için genel sınıflandırma sonuçları

Veri Kümeleri	Eğitim			Test		
	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata
1. Aşama	0,07	0,22	0,06	0,14	0,35	0,12
2. Aşama	0,07	0,26	0,06	0,23	0,94	0,19
3. Aşama	0,06	0,21	0,05	0,43	1,56	0,36
Ortalama	0,07	0,23	0,06	0,27	0,95	0,22

Çizelge 4.30. Kaotik ölçütlerin ANFIS ile sınıflandırma hata değerleri

Veri Kümeleri	Eğitim			Test		
	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata
1. Aşama	0,30	0,43	0,25	0,43	0,71	0,36
2. Aşama	0,07	0,26	0,06	0,23	0,94	0,19
3. Aşama	0,32	0,46	0,27	0,34	0,55	0,28
Ortalama	0,23	0,38	0,19	0,33	0,73	0,28

Çizelge 4.31. Spektral parametrelerin ANFIS ile sınıflandırma hata değerleri

4.5.3. Karar Ağacı İle Bulunan Sonuçlar

C4.5 algoritması ile oluşturulan karar ağaçlarının, kaotik ölçütler ve spektral parametrelerin Elde edilen sınıflandırma sonuçları ve oluşan hata değerleri aşağıdaki tablolarda verilmiştir.

Veri Kümeleri	Eğitim				Test			
	Yanlış Sınıflandırma		Doğruluk		Yanlış Sınıflandırma		Doğruluk	
	K.Ö.	S.P.	K.Ö.	S.P.	K.Ö.	S.P.	K.Ö.	S.P.
1. Küme	2	10	%98	%88	0	5	%100	%76
2. Küme	1	8	%99	%90	1	6	%95	%71
3. Küme	0	6	%100	%93	4	9	%81	%57
4. Küme	2	9	%98	%89	0	3	%100	%86
5. Küme	2	10	%98	%88	1	3	%95	%86
Ortalama	1	9	%99	%90	1	5	%94	%75


Çizelge 4.32. Karar Ağacı için birinci sınıflandırma sonuçları (K.Ö. = Kaotik Ölçütler ve S.P. = Spektral Parametreler)

Veri Kümeleri	Eğitim			Test		
	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata
1. Küme	0,02	0,09	0,05	0,01	0,03	0,03
2. Küme	0,01	0,07	0,03	0,02	0,14	0,07
3. Küme	0	0	0	0,08	0,28	0,24
4. Küme	0,02	0,09	0,05	0,01	0,03	0,03
5. Küme	0,02	0,09	0,05	0,03	0,13	0,09
Ortalama	0,01	0,07	0,04	0,03	0,12	0,09

Çizelge 4.33. Kaotik ölçütlerin Karar Ağacı ile birinci sınıflandırmasında oluşan hata değerleri

Veri Kümeleri	Eğitim			Test		
	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata
1. Küme	0,07	0,19	0,23	0,11	0,27	0,35
2. Küme	0,05	0,16	0,16	0,13	0,32	0,41
3. Küme	0,05	0,15	0,15	0,18	0,39	0,58
4. Küme	0,07	0,18	0,21	0,09	0,21	0,28
5. Küme	0,07	0,18	0,21	0,08	0,24	0,25
Ortalama	0,06	0,17	0,19	0,12	0,29	0,37

Çizelge 4.34. Spektral parametrelerin Karar Ağacı ile birinci sınıflandırmasında oluşan hata değerleri



Şekil 4.63. C4.5 algoritmasının 1. kümedeki eğitim alt kümesini oluşturan kaotik ölçüt verileriyle oluşturduğu Karar Ağacı

Veri Kümeleri	Eğitim				Test			
	Yanlış Sınıflandırma		Doğruluk		Yanlış Sınıflandırma		Doğruluk	
	K.Ö.	S.P.	K.Ö.	S.P.	K.Ö.	S.P.	K.Ö.	S.P.
1. Küme	6	28	%93	%67	1	5	%95	%76
2. Küme	6	20	%93	%76	0	4	%100	%81
3. Küme	2	23	%98	%73	0	6	%100	%71
4. Küme	2	16	%98	%81	1	5	%95	%76
5. Küme	5	23	%94	%73	1	4	%95	%81
Ortalama	4	22	%95	%74	1	5	%97	%77

Çizelge 4.35. Karar Ağacı için ikinci sınıflandırma sonuçları (K.Ö. = Kaotik Ölçütler ve S.P. = Spektral Parametreler)

Veri Kümeleri	Eğitim			Test		
	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata
1. Küme	0,04	0,17	0,11	0,03	0,13	0,09
2. Küme	0,04	0,17	0,11	0,03	0,03	0,08
3. Küme	0,02	0,09	0,05	0,09	0,03	0,03
4. Küme	0,02	0,09	0,05	0,03	0,14	0,08
5. Küme	0,03	0,15	0,10	0,03	0,13	0,08
Ortalama	0,03	0,13	0,08	0,04	0,09	0,07

Çizelge 4.36. Kaotik ölçütlerin Karar Ağacı ile ikinci sınıflandırılmasında oluşan hata değerleri

Veri Kümeleri	Eğitim			Test		
	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata
1. Küme	0,14	0,3	0,44	0,1	0,3	0,35
2. Küme	0,11	0,3	0,36	0,09	0,23	0,29
3. Küme	0,13	0,3	0,41	0,13	0,27	0,40
4. Küme	0,09	0,26	0,31	0,11	0,26	0,35
5. Küme	0,12	0,28	0,40	0,10	0,24	0,33
Ortalama	0,12	0,29	0,38	0,11	0,26	0,34

Çizelge 4.37. Spektral parametrelerin Karar Ağacı ile ikinci sınıflandırmasında oluşan hata değerleri

Veri Kümeleri	Eğitim				Test			
	Yanlış Sınıflandırma		Doğruluk		Yanlış Sınıflandırma		Doğruluk	
	K.Ö.	S.P.	K.Ö.	S.P.	K.Ö.	S.P.	K.Ö.	S.P.
1. Küme	1	9	%99	%89	2	3	%90	%86
2. Küme	1	10	%99	%88	2	4	%90	%81
3. Küme	2	9	%98	%89	1	4	%95	%81
4. Küme	1	11	%99	%87	2	2	%90	%90
5. Küme	1	11	%99	%87	1	4	%95	%81
Ortalama	1	10	%99	%88	2	3	%92	%84

Çizelge 4.38. Karar Ağacı için üçüncü sınıflandırma sonuçları (K.Ö. = Kaotik Ölçütler ve S.P. = Spektral Parametreler)

Veri Kümeleri	Eğitim			Test		
	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata
1. Küme	0,01	0,07	0,03	0,04	0,19	0,13
2. Küme	0,01	0,07	0,03	0,04	0,20	0,13
3. Küme	0,02	0,09	0,05	0,03	0,13	0,08
4. Küme	0,01	0,07	0,03	0,04	0,19	0,13
5. Küme	0,01	0,07	0,03	0,02	0,14	0,07
Ortalama	0,01	0,07	0,03	0,03	0,17	0,11

Çizelge 4.39. Kaotik ölçütlerin Karar Ağacı ile üçüncü sınıflandırmasında oluşan hata değerleri

Veri Kümeleri	Eğitim			Test		
	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata
1. Küme	0,06	0,18	0,21	0,08	0,22	0,25
2. Küme	0,07	0,19	0,23	0,10	0,24	0,31
3. Küme	0,07	0,18	0,21	0,09	0,26	0,29
4. Küme	0,08	0,19	0,24	0,07	0,17	0,22
5. Küme	0,08	0,19	0,24	0,10	0,26	0,33
Ortalama	0,07	0,19	0,23	0,09	0,23	0,28

Çizelge 4.40. Spektral parametrelerin Karar Ağacı ile üçüncü sınıflandırmasında oluşan hata değerleri

Veri Kümeleri	Eğitim				Test			
	Yanlış Sınıflandırma		Doğruluk		Yanlış Sınıflandırma		Doğruluk	
	K.Ö.	S.P.	K.Ö.	S.P.	K.Ö.	S.P.	K.Ö.	S.P.
1. Aşama	1	9	%99	%90	1	5	%94	%75
2. Aşama	4	22	%95	%74	1	5	%97	%77
3. Aşama	1	10	%99	%88	2	3	%92	%84
Ortalama	2	14	%98	%84	1	4	%94	%79

Çizelge 4.41. Karar Ağacı için genel sınıflandırma sonuçları

Veri Kümeleri	Eğitim			Test		
	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata
1. Aşama	0,01	0,07	0,04	0,03	0,12	0,09
2. Aşama	0,03	0,13	0,08	0,04	0,09	0,07
3. Aşama	0,01	0,07	0,03	0,03	0,17	0,11
Ortalama	0,02	0,09	0,05	0,03	0,13	0,09

Çizelge 4.42. Kaotik ölçütlerin Karar Ağacı ile sınıflandırma hata değerleri

Veri Kümeleri	Eğitim			Test		
	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata
1. Aşama	0,06	0,17	0,19	0,12	0,29	0,37
2. Aşama	0,12	0,29	0,38	0,11	0,26	0,34
3. Aşama	0,07	0,19	0,23	0,09	0,23	0,28
Ortalama	0,08	0,22	0,27	0,11	0,26	0,33

Çizelge 4.43. Spektral parametrelerin Karar Ağacı ile sınıflandırma hata değerleri

4.5.4. K En Yakın Komşu Algoritması ile Bulunan Sonuçlar

Örnek-tabanlı algoritma olan K En Yakın Komşu Algoritması, bir merkez nokta etrafında 5 en yakın komşu kullanacak şekilde gerçekleştirilmiştir. Kaotik ölçütler ve spektral parametreler için elde edilen sınıflandırma sonuçları ve oluşan hata değerleri aşağıdaki tablolarda verilmiştir.

Veri Kümeleri	Eğitim				Test			
	Yanlış Sınıflandırma		Doğruluk		Yanlış Sınıflandırma		Doğruluk	
	K.Ö.	S.P.	K.Ö.	S.P.	K.Ö.	S.P.	K.Ö.	S.P.
1. Küme	2	7	%98	%92	0	3	%100	%86
2. Küme	0	11	%100	%87	1	3	%95	%86
3. Küme	0	9	%100	%89	3	7	%86	%67
4. Küme	2	15	%98	%82	0	3	%100	%86
5. Küme	1	9	%99	%89	0	3	%100	%86
Ortalama	1	10	%99	%88	1	4	%96	%82

Çizelge 4.44. K En Yakın Komşu algoritması için birinci sınıflandırma sonuçları (K.Ö. = Kaotik Ölçütler ve S.P. = Spektral Parametreler)

Veri Kümeleri	Eğitim			Test		
	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata
1. Küme	0,02	0,08	0,05	0,004	0,005	0,01
2. Küme	0,01	0,05	0,04	0,03	0,14	0,08
3. Küme	0,01	0,03	0,02	0,05	0,2	0,17
4. Küme	0,02	0,09	0,06	0,004	0,005	0,01
5. Küme	0,02	0,08	0,06	0,04	0,01	0,13
Ortalama	0,02	0,07	0,05	0,03	0,07	0,08

Çizelge 4.45. Kaotik ölçütlerin K En Yakın Komşu algoritması ile birinci sınıflandırmasında oluşan hata değerleri

Veri Kümeleri	Eğitim			Test		
	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata
1. Küme	0,07	0,18	0,23	0,11	0,26	0,35
2. Küme	0,07	0,18	0,23	0,11	0,23	0,35
3. Küme	0,08	0,18	0,24	0,14	0,31	0,43
4. Küme	0,1	0,21	0,31	0,09	0,20	0,30
5. Küme	0,08	0,19	0,25	0,11	0,24	0,35
Ortalama	0,08	0,19	0,25	0,11	0,25	0,36

Çizelge 4.46. Spektral parametrelerin K En Yakın Komşu algoritması ile birinci sınıflandırmasında oluşan hata değerleri

Veri Kümeleri	Eğitim				Test			
	Yanlış Sınıflandırma		Doğruluk		Yanlış Sınıflandırma		Doğruluk	
	K.Ö.	S.P.	K.Ö.	S.P.	K.Ö.	S.P.	K.Ö.	S.P.
1. Küme	2	8	%98	%90	0	2	%100	%90
2. Küme	3	13	%96	%85	0	5	%100	%76
3. Küme	2	9	%98	%89	0	1	%100	%95
4. Küme	2	12	%98	%86	0	5	%100	%76
5. Küme	3	11	%96	%87	0	1	%100	%95
Ortalama	2	11	%97	%87	0	3	%100	%86

Çizelge 4.47. K En Yakın Komşu algoritması için ikinci sınıflandırma sonuçları (K.Ö. = Kaotik Ölçütler ve S.P. = Spektral Parametreler)

Veri Kümeleri	Eğitim			Test		
	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata
1. Küme	0,02	0,08	0,06	0,02	0,05	0,05
2. Küme	0,03	0,10	0,09	0,08	0,03	0,02
3. Küme	0,02	0,08	0,06	0,01	0,04	0,04
4. Küme	0,02	0,08	0,06	0,01	0,06	0,04
5. Küme	0,02	0,09	0,06	0,01	0,06	0,04
Ortalama	0,02	0,09	0,07	0,03	0,05	0,04

Çizelge 4.48. Kaotik ölçütlerin K En Yakın Komşu algoritması ile ikinci sınıflandırmasında oluşan hata değerleri

Veri Kümeleri	Eğitim			Test		
	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata
1. Küme	0,08	0,19	0,28	0,10	0,20	0,34
2. Küme	0,09	0,21	0,28	0,13	0,27	0,41
3. Küme	0,09	0,20	0,29	0,09	0,18	0,28
4. Küme	0,09	0,21	0,29	0,13	0,30	0,42
5. Küme	0,10	0,21	0,31	0,06	0,15	0,20
Ortalama	0,09	0,20	0,29	0,10	0,22	0,33

Çizelge 4.49. Spektral parametrelerin K En Yakın Komşu algoritması ile ikinci sınıflandırmasında oluşan hata değerleri

Veri Kümeleri	Eğitim				Test			
	Yanlış Sınıflandırma		Doğruluk		Yanlış Sınıflandırma		Doğruluk	
	K.Ö.	S.P.	K.Ö.	S.P.	K.Ö.	S.P.	K.Ö.	S.P.
1. Küme	2	12	%98	%86	0	2	%100	%90
2. Küme	2	12	%98	%86	1	2	%95	%90
3. Küme	3	6	%96	%93	0	6	%100	%71
4. Küme	1	14	%99	%83	1	2	%95	%90
5. Küme	2	13	%98	%85	1	0	%95	%100
Ortalama	2	11	%98	%87	1	2	%95	%88

Çizelge 4.50. K En Yakın Komşu algoritması için üçüncü sınıflandırma sonuçları (K.Ö. = Kaotik Ölçütler ve S.P. = Spektral Parametreler)

Veri Kümeleri	Eğitim			Test		
	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata
1. Küme	0,02	0,07	0,06	0,02	0,06	0,05
2. Küme	0,02	0,07	0,05	0,02	0,09	0,07
3. Küme	0,02	0,09	0,06	0,02	0,07	0,06
4. Küme	0,01	0,06	0,04	0,03	0,10	0,08
5. Küme	0,02	0,08	0,05	0,03	0,10	0,08
Ortalama	0,02	0,07	0,05	0,02	0,08	0,07

Çizelge 4.51. Kaotik ölçütlerin K En Yakın Komşu algoritması ile üçüncü sınıflandırmasında oluşan hata değerleri

Veri Kümeleri	Eğitim			Test		
	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata
1. Küme	0,09	0,21	0,30	0,09	0,21	0,30
2. Küme	0,09	0,20	0,28	0,09	0,18	0,28
3. Küme	0,08	0,18	0,25	0,10	0,24	0,32
4. Küme	0,10	0,22	0,31	0,09	0,19	0,29
5. Küme	0,10	0,22	0,32	0,05	0,12	0,17
Ortalama	0,09	0,21	0,29	0,08	0,19	0,27

Çizelge 4.52. Spektral parametrelerin K En Yakın Komşu algoritması ile üçüncü sınıflandırmasında oluşan hata değerleri

Veri Kümeleri	Eğitim				Test			
	Yanlış Sınıflandırma		Doğruluk		Yanlış Sınıflandırma		Doğruluk	
	K.Ö.	S.P.	K.Ö.	S.P.	K.Ö.	S.P.	K.Ö.	S.P.
1. Aşama	1	10	%99	%88	1	4	%96	%82
2. Aşama	2	11	%97	%87	0	3	%100	%86
3. Aşama	2	11	%98	%87	1	2	%95	%88
Ortalama	2	11	%98	%87	1	3	%97	%85

Çizelge 4.53. K En Yakın Komşu algoritması için genel sınıflandırma sonuçları

Veri Kümeleri	Eğitim			Test		
	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata
1. Aşama	0,02	0,07	0,05	0,03	0,07	0,08
2. Aşama	0,02	0,09	0,07	0,03	0,05	0,04
3. Aşama	0,02	0,07	0,05	0,02	0,08	0,07
Ortalama	0,02	0,08	0,06	0,03	0,07	0,06


Çizelge 4.54. Kaotik ölçütlerin K En Yakın Komşu algoritması ile sınıflandırma hata değerleri

Veri Kümeleri	Eğitim			Test		
	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata
1. Aşama	0,08	0,19	0,25	0,11	0,25	0,36
2. Aşama	0,09	0,20	0,29	0,10	0,22	0,33
3. Aşama	0,09	0,21	0,29	0,08	0,19	0,27
Ortalama	0,09	0,20	0,28	0,10	0,22	0,32

Çizelge 4.55. Spektral parametrelerin K En Yakın Komşu algoritması ile sınıflandırma hata değerleri

4.5.5. Çok Katmanlı Algılayıcı Sinir Ağı (ÇKASA) ile Bulunan Sonuçlar

Bu tez çalışmasında kullanılan ÇKASA mimarisi 3 katmandan oluşmaktadır. Giriş katmanında kaotik ölçütler için 2 düğüm vardır. Çıkış katmanında her bir bireyin ait olacağı sınıflara karşılık gelecek şekilde 5 düğüm ve gizli katmanda 3 düğüm bulunmaktadır. ÇKASA, öğrenme oranı 0.3 ve momentum değeri 0.2 olacak şekilde 1000 adım sonucu eğitilmiştir. Ağırlıklara, başlangıçta küçük rasgele değerler atanmıştır.



Şekil 4.64. Kullanılan ÇKASA mimarisi

Çizelge 4.4'te belirtilen sayılarda veri içeren eğitim ve test kümelerine ayrılan kaotik ölçüt ve spektral parametre değerleri ÇKASA'ya uygulanmıştır. Elde edilen sınıflandırma sonuçları ve oluşan hata değerleri aşağıdaki tablolarda verilmiştir.

Veri Kümeleri	Eğitim				Test			
	Yanlış Sınıflandırma		Doğruluk		Yanlış Sınıflandırma		Doğruluk	
	K.Ö.	S.P.	K.Ö.	S.P.	K.Ö.	S.P.	K.Ö.	S.P.
1. Küme	1	20	%99	%76	0	4	%100	%81
2. Küme	0	19	%100	%77	1	7	%95	%67
3. Küme	0	21	%100	%75	3	7	%86	%67
4. Küme	1	21	%99	%75	0	6	%100	%71
5. Küme	1	20	%99	%76	0	7	%100	%67
Ortalama	1	20	%99	%76	1	6	%96	%71

Çizelge 4.56. ÇKASA için birinci sınıflandırma sonuçları (K.Ö. = Kaotik Ölçütler ve S.P. = Spektral Parametreler)

Veri Kümeleri	Eğitim			Test		
	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata
1. Küme	0,02	0,07	0,06	0,01	0,02	0,04
2. Küme	0,01	0,02	0,04	0,03	0,14	0,10
3. Küme	0,01	0,02	0,04	0,06	0,22	0,20
4. Küme	0,02	0,07	0,06	0,01	0,02	0,04
5. Küme	0,02	0,07	0,07	0,02	0,06	0,07
Ortalama	0,02	0,05	0,05	0,03	0,09	0,09

Çizelge 4.57. Kaotik ölçütlerin ÇKASA ile birinci sınıflandırmasında oluşan hata değerleri

Veri Kümeleri	Eğitim			Test		
	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata
1. Küme	0,15	0,25	0,48	0,14	0,24	0,45
2. Küme	0,14	0,25	0,46	0,16	0,28	0,52
3. Küme	0,16	0,26	0,50	0,17	0,28	0,55
4. Küme	0,14	0,25	0,46	0,16	0,27	0,52
5. Küme	0,15	0,25	0,46	0,18	0,29	0,56
Ortalama	0,15	0,25	0,47	0,16	0,27	0,52

Çizelge 4.58. Spektral parametrelerin ÇKASA ile birinci sınıflandırmasında oluşan hata değerleri

Veri Kümeleri	Eğitim				Test			
	Yanlış Sınıflandırma		Doğruluk		Yanlış Sınıflandırma		Doğruluk	
	K.Ö.	S.P.	K.Ö.	S.P.	K.Ö.	S.P.	K.Ö.	S.P.
1. Küme	1	21	%99	%75	0	6	%100	%71
2. Küme	1	21	%99	%75	0	5	%100	%76
3. Küme	1	14	%99	%83	0	5	%100	%76
4. Küme	1	21	%99	%75	0	5	%100	%76
5. Küme	1	15	%99	%82	0	4	%100	%81
Ortalama	1	18	%99	%79	0	5	%100	%76

Çizelge 4.59. ÇKASA için ikinci sınıflandırma sonuçları (K.Ö. = Kaotik Ölçütler ve S.P. = Spektral Parametreler)

Veri Kümeleri	Eğitim			Test		
	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata
1. Küme	0,02	0,07	0,07	0,02	0,06	0,07
2. Küme	0,02	0,07	0,07	0,01	0,02	0,04
3. Küme	0,02	0,07	0,07	0,02	0,06	0,07
4. Küme	0,02	0,07	0,06	0,01	0,02	0,04
5. Küme	0,02	0,07	0,07	0,02	0,03	0,05
Ortalama	0,02	0,07	0,07	0,02	0,04	0,05

Çizelge 4.60. Kaotik ölçütlerin ÇKASA ile ikinci sınıflandırmasında oluşan hata değerleri

Veri Kümeleri	Eğitim			Test		
	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata
1. Küme	0,15	0,25	0,48	0,17	0,29	0,56
2. Küme	0,14	0,25	0,45	0,16	0,27	0,50
3. Küme	0,13	0,24	0,43	0,16	0,28	0,51
4. Küme	0,14	0,25	0,45	0,15	0,25	0,48
5. Küme	0,15	0,25	0,47	0,15	0,26	0,48
Ortalama	0,14	0,25	0,46	0,16	0,27	0,51

Çizelge 4.61. Spektral parametrelerin ÇKASA ile ikinci sınıflandırmasında oluşan hata değerleri

Veri Kümeleri	Eğitim				Test			
	Yanlış Sınıflandırma		Doğruluk		Yanlış Sınıflandırma		Doğruluk	
	K.Ö.	S.P.	K.Ö.	S.P.	K.Ö.	S.P.	K.Ö.	S.P.
1. Küme	1	20	%99	%76	0	5	%100	%76
2. Küme	1	20	%99	%76	1	6	%95	%71
3. Küme	1	20	%99	%76	0	6	%100	%71
4. Küme	0	22	%100	%74	1	7	%95	%67
5. Küme	1	17	%99	%80	1	4	%95	%81
Ortalama	1	20	%99	%76	1	6	%97	%73

Çizelge 4.62. ÇKASA için üçüncü sınıflandırma sonuçları (K.Ö. = Kaotik Ölçütler ve S.P. = Spektral Parametreler)

Veri Kümeleri	Eğitim			Test		
	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata
1. Küme	0,02	0,07	0,07	0,02	0,07	0,08
2. Küme	0,02	0,06	0,07	0,03	0,13	0,10
3. Küme	0,02	0,07	0,07	0,02	0,06	0,08
4. Küme	0,01	0,02	0,04	0,03	0,14	0,10
5. Küme	0,02	0,05	0,06	0,03	0,13	0,11
Ortalama	0,02	0,05	0,06	0,03	0,11	0,09

Çizelge 4.63. Kaotik ölçütlerin ÇKASA ile üçüncü sınıflandırmasında oluşan hata değerleri

Veri Kümeleri	Eğitim			Test		
	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata
1. Küme	0,15	0,26	0,49	0,16	0,28	0,52
2. Küme	0,14	0,25	0,46	0,16	0,27	0,51
3. Küme	0,16	0,26	0,51	0,16	0,26	0,52
4. Küme	0,15	0,25	0,46	0,16	0,28	0,52
5. Küme	0,14	0,25	0,46	0,14	0,24	0,44
Ortalama	0,15	0,25	0,48	0,16	0,27	0,50

Çizelge 4.64. Spektral parametrelerin ÇKASA ile üçüncü sınıflandırmasında oluşan hata değerleri

Veri Kümeleri	Eğitim				Test			
	Yanlış Sınıflandırma		Doğruluk		Yanlış Sınıflandırma		Doğruluk	
	K.Ö.	S.P.	K.Ö.	S.P.	K.Ö.	S.P.	K.Ö.	S.P.
1. Aşama	1	20	%99	%76	1	6	%96	%71
2. Aşama	1	18	%99	%79	0	5	%100	%76
3. Aşama	1	20	%99	%76	1	6	%97	%73
Ortalama	1	0,19	%99	%77	1	6	%98	%73

Çizelge 4.65. ÇKASA için genel sınıflandırma sonuçları

Veri Kümeleri	Eğitim			Test		
	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata
1. Aşama	0,02	0,05	0,05	0,03	0,09	0,09
2. Aşama	0,02	0,07	0,07	0,02	0,04	0,05
3. Aşama	0,02	0,05	0,06	0,03	0,11	0,09
Ortalama	0,02	0,06	0,06	0,03	0,08	0,08



Çizelge 4.66. Kaotik ölçütlerin ÇKASA ile sınıflandırma hata değerleri


Veri Kümeleri	Eğitim			Test		
	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata	Ort. Mutlak Hata	Kök Ortalama Kare Hata	Gör. Mutlak Hata
1. Aşama	0,15	0,25	0,47	0,16	0,27	0,52
2. Aşama	0,14	0,25	0,46	0,16	0,27	0,51
3. Aşama	0,15	0,25	0,48	0,16	0,27	0,50
Ortalama	0,15	0,25	0,47	0,16	0,27	0,51

Çizelge 4.67. Spektral parametrelerin ÇKASA ile sınıflandırma hata değerleri

4.6. Sınıflandırma Algoritmalarının ROC Eğrileri ile Karşılaştırılması

Sınıflandırma algoritmalarının performanslarını gösteren ROC eğrileri elde edilmiştir. Bu ROC eğrileri, duyarlılık ve seçicilik değerlerinin tüm spektrumuna ait bir görünüm sunarlar, çünkü belirli bir yöntem için olabilecek tüm duyarlılık ve seçicilik ikilileri gösterilir. Aşağıdaki ROC eğrilerinde, ilk sınıflandırmada 4. kümedeki kaotik ölçüt verileriyle eğitilen sınıflandırma algoritmalarının 2. test alt kümesiyle testi sonrası elde edilen performanslar görülmektedir. ROC eğrileri altında kalan alan değerleri sırasıyla (a) 0.917 ve (b) 0.857 (c) 1.000 (d) 1.000 (e) 1.000 olarak bulunmuştur.





Şekil 4.65. Sınıflandırma yöntemlerinin performansını gösteren ROC eğrileri (a) ANFIS (b) NEFCLASS (c) Karar Ağacı (d) K-En Yakın Komşu (e) Çok Katmanlı Algılayıcı

5. SONUÇ


Bu tez çalışmasında, değişik beyin rahatsızlıkları bulunan hastalardan ve sağlıklı bireylerden alınan TCD sinyallerinin kaotik ölçütlerle otomatik olarak sınıflandırılmasını sağlayacak yeni bir yaklaşım önerilmiştir. Literatürdeki çalışmalar incelendiğinde, spektral analizle elde edilen TCD sonogramlarından çıkarılan Doppler hız parametrelerinin laboratuvar ve cihazın değişmesi ya da teknisyenin değişmesi durumunda eşik değerinin değiştiği ve tam bir fikir birliği sağlanamadığı görülmektedir. Dolayısıyla yapılan teşhisler hem öznel hem de hatalı olabilmektedir. Pratik kullanımda ultrasonik Doppler tek başına teşhis için yeterli görülmemekte ve şüphelenilen hastalar anjiyografiye tabi tutulmaktadır. Bu yüzden teşhis işleminin otomatik biçimde yapılarak objektif karar vermeyi sağlayacak güvenilir bir sınıflandırma sistemine gereksinim vardır. Literatürde önerilen ve TCD sinyallerinden doğrusal yöntemlerle elde edilen hız parametrelerinin kullanıldığı sınıflandırma sistemlerinin başarısı yeterli düzeyde değildir. Literatürde ayrıca, TCD sinyallerinin doğrusal olup olmadığı ve kaos teorisi yöntemleriyle elde edilen ölçütlerle kan akış dinamiğinde çeşitli nedenlerle meydana gelen değişim arasındaki ilişkiyi inceleyen yayınlar bulunmaktadır. Fakat bu ölçütlerle objektif karar vermeyi sağlayacak bir otomatik sınıflandırma yaklaşımı önerilmemiştir.

TCD sinyallerinin kaos analizine uygun olduğunu bulmak için öncelikle doğrusal olmadığının gösterilmesi gereklidir. Doğrusalsızlık testi için, yapay veriler yöntemi kullanılarak orijinal zaman dizisi ile aynı doğrusal özelliklere (aynı ortalama, varyans ve güç spektrumuna) sahip yapay veriler üretilmiştir. Doğrusal özellikler dışında yapay zaman dizilerinde orijinal diziye ait hiçbir ilinti bulunmamaktadır. Çünkü yapay veriler üretilirken frekans kümesinden zaman kümesine dönüştürülürken rasgele fazlarla çarpma işlemi yapılmaktadır. Hükümsüz hipotez, orijinal zaman dizisinin doğrusal stokastik süreçle üretilmiş olduğu şeklinde tanımlanırsa yapay veriler Gauss dağılımına uyarlar. Fakat TCD sinyalleri, çoğu doğal sinyallerde olduğu gibi, Gauss dağılımına uymamaktadır. Dolayısıyla, hükümsüz hipotez biraz daha geliştirilerek orijinal verinin doğrusal stokastik süreçle üretilmiş olduğu fakat doğrusal olmayan statik bir ölçüm fonksiyonu ile bozulduğu şeklinde tanımlanmıştır. Bu hipoteze uyan yapay verileri üretmek için histogram dönüşümü tekniği uygulanarak yapay verilerin orijinal veriyle aynı dağılıma sahip


olması sağlanmıştır. Şayet ayırıcı istatistiksel değer, orijinal zaman dizisi ile yapay veri kümeleri arasında belirgin biçimde farklı ise orijinal zaman dizisinin doğrusal süreçle üretildiği yönündeki hükümsüz hipotez reddedilir. Zaman dizilerindeki doğrusalsızlığa duyarlı birkaç ölçüt ayırıcı istatistiksel değer olarak seçilerek uygulanmıştır. Bu ölçütlerden ikisi faz uzayından diğer ikisi yüksek seviye istatistik yöntemleri ile elde edilmiştir. Faz uzayından elde edilen ölçütler verideki zayıf doğrusalsızlığa daha duyarlı olup orijinal veriyle yapay verileri ayırmada yüksek seviye istatistik ölçütlerine göre daha başarılı olmuştur. Kullanılan faz uzayı ölçütleri doğrusal olmayan tahmin hatası ve Lyapunov üstelidir. Bu değerler TCD sinyallerinin tümü için ve bunlardan hükümsüz hipoteze göre üretilen yapay veriler için hesaplanmıştır. Orijinal veri için elde edilen değerler yapay veriler için elde edilenlerden belirgin biçimde farklı bulunmuştur. Öte yandan, yüksek seviye istatistik yöntemleri ile elde edilen zaman asimetrisi ve üçüncü seviye ilinti değerleri orijinal veri ile yapay verileri ayırt etmede başarısız olmuştur.

Zaman asimetrisi veriye ait olasılık dağılımının asimetrikliğinin bir ölçütüdür ve aşağıdaki gibi tanımlanmıştır.


$$zaman \text{ asimetrisi} = \frac{\frac{1}{N-\tau} \sum (x_n - x_{n-\tau})^3}{\sqrt{\left(\frac{1}{N-\tau} \sum (x_n - x_{n-\tau})^2 \right)^3}} \quad (5.1)$$



(a)



(b)




Şekil 5.1. Zaman asimetrisi ölçütü ile yapılan yapay veriler testi sonuçları (a) Balonlaşma (b) Kanama (c) Su Toplama (d) Tümör (e) Sağlıklı

Şekil 5.1'deki grafiklerde zaman asimetrisi değeri orijinal zaman dizisi için kırmızı ile yapay zaman dizileri için mavi renkte gösterilmiştir. Grafiklerden görüldüğü gibi bu ölçüt orijinal zaman dizileri ve yapay zaman dizileri için belirgin biçimde farklı değildir. Dolayısıyla, doğrusalsızlığın tespitinde yetersiz kalmaktadır.

Momentler, sinyaldeki ilintileri karakterize eden istatistiksel ölçütlerdir. Bir sinyal Gauss dağılımına uyarsa ortalama ve varyans sinyalin olasılık dağılımını belirler. Aksi halde, yüksek seviye momentler dağılımı tam olarak ifade etmede gereklidir. Üçüncü seviye momentler, ikinci seviye ölçütlerin (öz ilinti fonksiyonu ve güç spektrumu gibi) bir üst seviyeye genişletilmiş halidir. Bir sinyal eğer Gauss olasılık yoğunluk fonksiyonuna sahipse ikinci seviye ölçütler sinyali ifade edebilir ve daha yüksek seviye istatistik değerleri sıfırdır. Fakat TCD sinyalleri, gerçek hayattaki diğer sinyaller gibi, Gauss dağılımına uymamaktadır. Bu tür sinyaller için üçüncü

seviye moment değeri sıfırdan farklıdır. Bu çalışmada, aşağıdaki gibi tanımlanan üçüncü seviye moment orijinal veri ile yapay verileri ayırt etmede yetersiz kalmıştır.

$$\text{üçüncü seviye moment} = \frac{\frac{1}{N-\tau} \sum (x_n x_{n-\tau} x_{n-2\tau})}{\sqrt{\left(\frac{1}{N-\tau} \sum (x_n x_{n-\tau}) \right)^3}} \quad (5.2)$$



Şekil 5.2. Üçüncü seviye moment ile yapılan yapay veriler testi sonuçları (a) Kanama (b) Su Toplama

Yukarıdaki grafiklerden görüldüğü gibi üçüncü seviye moment ölçütü bazı TCD sinyalleri için orijinal zaman dizilerindeki doğrusalsızlığın tespitinde yetersiz kalmıştır.

Kaos teorisi yöntemleri de, doğrusal yöntemler gibi zaman dizilerinde belli seviyede durağanlık olmasını gerektirmektedir. Bu çalışmada, zamana bağlı durağanlık görünümü sağlayan bir yöntem kullanılmıştır. TCD sinyallerinin çapraz tahmin hata değerleri, bağımsız rasgele sayıların çapraz tahmin hata değerleri ile tam olarak deterministik bir sinyal olan sinüs sinyalinin çapraz hata değerleri arasındaki aralıkta yer almaktadır. Rasgele sinyal sonsuz serbestlik derecesi gösterdiğinden ve faz uzayında hiçbir boyuta doğru açılım göstermediğinden kaos yöntemlerinin uygulanması için uygun değildir. TCD sinyallerinin tahmin hatalarının, rasgele sinyalden daha düşük olması kaos yöntemlerinin uygulanması için uygun olduklarını göstermektedir. Sinüs sinyali gibi tam deterministik bir sinyale de kaotik olmamasına rağmen, kaos teorisi yöntemleri uygulanarak ilinti boyutu ve Lyapunov üsteli hesaplanabilmektedir. Bu yüzden, kaos yöntemlerini uygulamadan önce rasgele sinyaller ile tam deterministik sinyalleri elemek için durağanlık testi gereklidir. Kaotik ölçütlerin hesaplanabilmesi için gerekli bir sonraki adım faz uzayında kaotik

çekicinin yeniden oluşturulmasıdır. Bunun için, en uygun zaman gecikmesi ve en düşük gömülme boyutu tespit edilir. Karşılıklı bilgi yöntemi ile zaman gecikmesi ve sözde en yakın komşular yöntemi ile de en düşük gömülme boyutu TCD sinyalleri için hesaplanmıştır. Bu iki değer ile faz uzayında yeniden oluşturulan kaotik çekiciler üzerinde en büyük Lyapunov üsteli (λ_1) ve ilinti boyutu (D_2) adıyla anılan kaotik ölçütler hesaplanmıştır. Bu ölçütlerin TCD sinyallerinin karmaşıklık ve tahmin edilemezlik seviyelerini gösterdiği tespit edilmiştir. Doppler sinyalleri geleneksel olarak spektral içeriklerinin analiziyle yorumlandığından, yukarıda bahsedilen bulguyu doğrulamak için Burg AR yöntemi ile elde edilen sonogramlar incelenmiştir. Eğer beyin damarlarındaki kan akışında oluşan değişim sonucu sonogram daha periyodik ve tek biçimli ise λ_1 değeri de daha küçük olmaktadır. Benzer şekilde sonogramları karmaşık olan bireylerin (sağlıklı bireylerde olduğu gibi) TCD sinyallerine ait D_2 değeri yüksek olmaktadır. Bu bulgular, TCD sinyallerin karmaşıklık ve tahmin edilemezlik seviyeleri ile kaotik ölçütler arasında pozitif ilinti bulunduğunu göstermektedir. Sağlıklı bireylerin beyin damarlarındaki kan akış hızının karmaşıklığı, rasgeleliği ve tahmin edilemezliği daha fazla iken, beyin damarlarındaki çeşitli rahatsızlıklara bağlı olarak kan akış hızı dalga biçimleri daha periyodik olabilmektedir.

Çoklu doğrusal regresyon analizinin sonucu, en büyük Lyapunov üsteli ve ilinti boyutu değerlerinin her ikisinin de istatistiksel olarak anlamlı olduğunu ve beyin hastalığının türünü belirlemek için çok değişkenli bir doğrusal regresyon modelinde kullanılabileceğini göstermektedir. Bu sonuç, kaos teorisi yöntemleri ile çıkarılan özelliklerin, bu çalışmada incelenen beyin damarı rahatsızlıklarını ayırt etmede başarılı olduğunu göstermektedir. Çoklu doğrusal regresyon analiz sonucuna göre her iki kaotik ölçütünün istatistiksel olarak belirgin olduğu ve regresyon denklemindeki bağlı değişken üzerinde doğrudan bir etkisi olduğu görülmüştür. Bu gözleme dayalı olarak, uygun bir sınıflandırma algoritması yardımıyla bu iki kaotik ölçütün çeşitli beyin rahatsızlıklarına bağlı olan kan akışındaki değişimlerin otomatik tanısında kullanılabileceği sonucuna varılmıştır. Çapraz doğrulama yöntemini uygulamak üzere veri kümesi, 3 aşamalı olarak aynı boyda 5 adet alt kümeye rasgele biçimde ayrılmıştır. Döngülü biçimde bunlardan her defasında 4 tanesi sınıflandırma algoritmalarının eğitimi için ve 1 tanesi testi için kullanılmıştır. Sınıflandırma

algoritmalarının performansları, her bir eğitim-test adımında elde edilen doğruluk oranlarının ortalaması hesaplanarak bulunmuştur. Karşılaştırma amacıyla, eğitim kümesi kullanılarak yapay sinir ağılı bulanık çıkarım sistemleri olan NEFCLASS ve ANFIS yöntemlerinin yanında Karar Ağacı, K-En Yakın Komşu Algoritması ve Çok Katmanlı Algılayıcı Sinir Ağı (ÇKASA) yöntemleri eğitilerek test edilmiştir. Elde edilen sonuç aşağıdaki tablolarda verilmiştir. Buna göre, test alt kümeleri üzerindeki ortalama sınıflandırma doğruluğu açısından ÇKASA yöntemi %98 ile en iyi performansı vermektedir. Çizelge 5.2’de verilen sınıflandırma hataları tablosundaki değerlere göre %94 ile aynı sınıflandırma doğruluğu göstermelerine rağmen Karar Ağacının ANFIS’ten daha başarılı olduğu görülmektedir. Kaotik ölçütlerin özellik olarak çıkarıldığı önişleme algoritması ile ÇKASA yönteminin birleştirilmesiyle oluşturulacak bir sistemin, farklı beyin rahatsızlıklarına bağlı olarak kan akış hızındaki değişimi tespit etmede önemli bir potansiyele sahip olduğu söylenebilir.

Sınıflandırma Yöntemi	Eğitim kümesi ortalama				Test kümesi ortalama			
	Yanlış Sınıflandırma		Doğruluk		Yanlış Sınıflandırma		Doğruluk	
	K.Ö.	S.P.	K.Ö.	S.P.	K.Ö.	S.P.	K.Ö.	S.P.
NEFCLASS	16	28	%81	%67	4	8	%79	%63
ANFIS	3	18	%97	%79	1	5	%94	%73
Karar Ağacı	2	14	%98	%84	1	4	%94	%79
K-En Yakın Komşu	2	11	%98	%87	1	3	%97	%85
ÇKASA	1	0,19	%99	%77	1	6	%98	%73

Çizelge 5.1. Sınıflandırma algoritmalarının performansları (K.Ö. = Kaotik Ölçütler ve S.P. = Spektral Parametreler)

Sınıflandırma Yöntemi	Eğitim Kümesi Ortalama			Test Kümesi Ortalama		
	Ort. Mutlak Hata	Ortalama Kare Hatanın Karekökü	Gör. Mutlak Hata	Ort. Mutlak Hata	Ortalama Kare Hatanın Karekökü	Gör. Mutlak Hata
NEFCLASS	0,09	0,17	0,28	0,09	0,18	0,29
ANFIS	0,07	0,23	0,06	0,27	0,95	0,22
Karar Ağacı	0,02	0,09	0,05	0,03	0,13	0,09
K-En Yakın Komşu	0,02	0,08	0,06	0,03	0,07	0,06
ÇKASA	0,02	0,06	0,06	0,03	0,08	0,08


Çizelge 5.2. Kaotik ölçütler için sınıflandırma algoritmalarında oluşan hata değerleri

Bu tez çalışmasının bilim ve teknolojiye katkısı 3 madde halinde özetlenebilir.

1- Kaos teorisi araçları ile elde edilen kaotik ölçütlerin, çeşitli beyin rahatsızlıklarının beyin damarlarında neden olduğu kan akış hızı değişimlerini yansıttığı gösterilmiştir. Bu sonuca göre, spektral analiz yöntemlerin TCD sinyallere uygulanmasıyla oluşturulan sonogramlardan elde edilen sistol, diyastol değerleri ve direnç indeksi gibi tanı koymada kullanılan değerlere destekleyici bilgiler olarak beyin damarlarındaki kan akışının değişmesine neden olan rahatsızlıkların tıbbi teşhisinde kaotik ölçütlerden yararlanılabileceği gösterilmiştir.

2- TCD sinyallerinden çıkarılan kaotik ölçütler, yani en büyük Lyapunov üsteli ve ilinti boyutu, otomatik bir tanı sistemi gerçekleştirimi için giriş özellikleri olarak kullanılmıştır. Bunun için ANFIS, NEFCLASS, C4.5 algoritması, K-En Yakın Komşu ve Çok Katmanlı Algılayıcı Sinir Ağı yöntemlerinin sınıflandırma performansları karşılaştırılmıştır. Elde edilen sonuçlara göre, kaotik ölçütlerin çıkarıldığı önişleme algoritması ile Çok Katmanlı Algılayıcı Sinir Ağı'nın birleştirilmesiyle oluşturulacak sistem çeşitli beyin damarı rahatsızlıklarına bağlı olarak beyin damarlarındaki kan akış hızındaki değişimleri başarılı biçimde tespit edebilir. Önerilen yöntem ile elde edilen sınıflandırma sonuçları, tıbbi tanının genel doğruluğunu artırmak için sonogramlar ve spektral dalga biçimi analiz parametrelerine ek olarak yardımcı bir klinik bulgu olarak kullanılabilir.

3- Doğrusal olmayan yöntemlerle çıkarılan kaotik ölçütlerin giriş olarak kullanıldığı sınıflandırma algoritmalarına, doğrusal bir yöntem olan güç spektrum yoğunluğu kestirimi ile TCD sinyallerinden elde edilen spektral parametreler uygulanmış ve karşılaştırma yapılmıştır. Kaotik özelliklerle yapılan sınıflandırmanın spektral parametrelerle yapılan sınıflandırmadan daha iyi sonuç verdiği görülmüştür. Buna göre, TCD sinyalleri gibi doğrusal olmayan doğal zaman dizilerinden kaos teorisi yöntemleriyle yapılan özellik çıkarımı doğrusal yöntemlere göre daha başarılı olmaktadır.



Şekil 5.3. TCD sinyallerini kaotik ölçütler ile sınıflandıran sistem

Bu çalışmada kullanılan kaotik ölçütler yerine yine faz uzayından elde edilebilecek başka ölçütler de TCD sinyallerini sınıflandırmada kullanılabilir. Örneğin, durağanlık analizi sırasında elde edilen doğrusal olmayan çapraz tahmin hataları, yineleme çizimlerinden elde edilen nicel ölçütler, uzay-zaman ayrımı çizimlerinden elde edilen w pencere boyutu, çapraz-ilinti integrali gibi değerler de özellik olarak kullanılabilir. Öte yandan, deterministik kaosun en önemli göstergesi gelecekteki durumların başlangıç koşullarına hassas biçimde bağlı olmasıdır. Kaotik bir sistemde, başlangıç değerlerindeki çok küçük bir sapmanın üssel olarak büyümesinin göstergesi pozitif Lyapunov üstelidir. Faz uzayında yeniden oluşturulan kaotik çekiciye ait yörüngelerin üssel uzaklaşmasını veren Lyapunov üsteli yanında, kaotik dinamik sistemlerin en önemli özelliği, sistemin zaman içinde faz uzayında ziyaret ettiği noktalardan oluşan kümelerin meydana getirdiği düzensiz geometrik yapılardır. Bu fraktal geometri, sınırlı bir faz uzayı içinde katlanan çekicinin birbirinden zaman içinde uzaklaşan yörüngelere sahip olmasının doğal sonucudur. Uzama, katlanma ve hacim küçülmesi, küçük boyutlarda istatistiksel olarak kendine-benzer yapıların ortaya çıkmasına neden olur. Kaotik çekicilerdeki bu çok küçük boyutlardaki kendine benzerliğin nicel ölçütü ilinti boyutu ile ifade edilir. Dolayısıyla bu tez çalışmasında bu iki kaotik ölçüt, TCD sinyallerinin faz uzayında gömülmesi sonucu yeniden oluşturulan kaotik çekicileri sınıflandırmada kullanılmıştır.

Bu tez çalışmasında önerilen sınıflandırma sistemi incelenen beyin rahatsızlıklarına ait daha çok sayıda TCD sinyali kullanılarak eğitilip geliştirilerek klinik çalışmalarda kullanılabilir. Böylece hem teşhis daha hızlı ve kolay olacaktır, hem de rahatsızlıkların objektif olarak değerlendirilmesi sağlanacaktır. İncelenen

beyin rahatsızlıklarından herhangi biriyle karşılaşıldığında, bu çalışmada önerilen yöntemin sınıflandırma sonucu, sonogramlar ve spektral dalga analizi parametrelerine ek bir destekleyici bilgi olarak kullanılarak tıp personelinin eğitiminde, tıbbi teşhisin doğruluğunu karşılaştırmada ve artırmada yararlanılabilir. Önerilen sistemin, beyin damarında balonlaşma, beyinde su toplama, beyin kanaması ve beyin tümörü dışındaki beyin rahatsızlıklarının teşhisini de güvenilir biçimde ve yüksek doğrulukta sağlaması için teşhisi istenilen hastalardan alınan TCD sinyallerinin kaotik ölçütleri çıkarılarak sınıflandırıcıların yeniden eğitilmesi gerekir.

6. KAYNAKLAR

- [1] Abarbanel, H.D.I. 1996. Analysis of Observed Chaotic Data, Springer-Verlag, New York.
- [2] Abarbanel, H. D. I., Lall, U. 1996. Nonlinear dynamics of the Great Salt Lake: system identification and prediction. *Climate Dynamics*. 12: 287-297.
- [3] Baker, G.L. 1990. Chaotic Dynamics an Introduction, Cambridge University Press, Cambridge.
- [4] Basheer, I.A., Hajmeer, M. 2000. Artificial Neural Networks: Fundamentals, computing, design and application. *Journal of Microbiology Methods*. 43:3-31.
- [5] Blanco, S., Figliola A., Kohen S., Rosso O.A. 1997. Using Nonlinear Dynamic Metric Tools for Characterizing Brain Structures. *IEEE Eng. in Medicine and Biology*. 16: 83-92.
- [6] Bland, J.M., Altman D.G. 1986. Statistical methods for assessing agreement between two methods of clinical measurement. *Lancet*. 1: 307-310.
- [7] Broomhead D.S., King, G.P. 1986. Extracting qualitative dynamics from experimental data. *Physica D*. 20(2): 217-236.
- [8] Burns, P.N., Taylor, K.W.J., Burns, P.N., Wells P.N.T. 1995. Doppler artifacts, Clinical Applications of Doppler Ultrasound, Raven Press, New York.
- [9] Cao, L. 1997. Practical method for determining the minimum embedding dimension of a scalar time series. *Physica D*. 110:43-50.
- [10] Casaleggio, A., Corana, A. 1996. On The Correlation Dimension Of ECG Signals. 18th Annual Int. Conf. of the IEEE Eng. in Med. and Bio. Society, 4: 1719-1720.
- [11] Casdagli, M. 1997. Recurrence plots revisited. *Physica D*. 108:12-44.
- [12] Chaudhuri, B.B., Bhattacharya, U. 2000. Efficient training and improved performance of multilayer perceptron in pattern classification. *Neurocomputing*. 34: 11-27.
- [13] Diks, C., Houwelingen, J.C., Takens, F., DeGoede, J. 1995. Reversibility as a criterion for discriminating time series. *Phys. Lett. A*. 201: 221.
- [14] Eckmann, J.P., Ruelle, D. 1985. Ergodic theory of chaos and strange attractors. *Rev. Mod. Phys*. 57: 617-656.
- [15] Eckmann, J.P., Oliffson, K.S., Ruelle, D. 1987. Recurrence plots of dynamical systems. *Europhys. Lett*. 4(9): 973-977.

- [16] Ergün U. 2005. Transcranial Doppler İşaretlerinin Yapay Zeka Ortamında Sınıflandırılması. Doktora Tezi. Gazi Üniversitesi Fen Bilimleri Enstitüsü. Ankara. 1-74.
- [17] Ergun, U., Serhatlioglu, S., Hardalac, F., Guler I. 2004. Classification of carotid artery stenosis of patients with diabetes by neural network and logistic regression. Computers in Biology and Medicine. 24: 389-405.
- [18] Evans, D.H., McDicken, W.N., Skidmore, R., Woodcock J.P. 1989. Doppler Ultrasound: Physics, Instrumentation and Clinical Applications. Wiley, Chichester.
- [19] Faheem, S.A., Bodruzzaman, M., Essawy, M. 1997. Chaos Analysis of a Drug Induced Cardiac Tissue. IEEE Proc. of 29th Southeastern Symp. On Systems Theory. 394-398.
- [20] Fraser, A. M., Swinney, H. L. 1986. Independent coordinates for strange attractors from mutual information. Physics Rev. A 33. 22: 1134-1140.
- [21] Gibbs, J.E., Millard, M.L. 1969. Walsh functions as solutions of a logical differential equation. National Physical Laboratory. Report No. 1.
- [22] Grassberger, P., Procaccia, I. Characterization of Strange Attractors, Physical Review Letters, 50 (1983) 346-349.
- [23] Gosling, R.G., King, D.H. 1974. Arterial assessment by Doppler shift ultrasound. Proceeding of the Royal Society of Medicine. 67: 447-449.
- [24] Guler, I., Hardalac, F., Muldur, S. 2001. Determination of aorta failure with the application of FFT, AR and wavelet methods to Doppler technique. Computers in Biology and Medicine. 31:229-238.
- [25] Guler, I., Hardalac, F., Barisci, N. 2002. Application of FFT analyzed cardiac Doppler signals to fuzzy algorithm. Computers in Biology and Medicine. 32: 435-444.
- [26] Guler, I., Hardalac, F., Kaymaz, M. 2002. Comparison of FFT and adaptive ARMA methods in transcranial Doppler signals recorded from the cerebral vessels. Computers in Biology and Medicine. 32: 445-453.
- [27] Guler, I., Ubeyli, E.D. 2004. Detecting variability of internal carotid arterial Doppler signals by Lyapunov exponents. Medical Eng. & Physics. 26: 763-771.
- [28] Hao, B.L. 1989. Elementary Symbolic Dynamics and Chaos in Dissipative Systems. World Scientific. Singapore.

- [29] Hardalaç F. 1997. Transcranial Doppler sinyalleri için en iyi spektral analiz metodunun belirlenmesi. Doktora Tezi. Fırat Üniversitesi Fen Bilimleri Enstitüsü. Elazığ. 1-70.
- [30] Haykin S. 1994. Neural Networks: A Comprehensive Foundation, Macmillan, New York.
- [31] Haykin, S., Li, X.B. 1995. Detection of signals in chaos. Proceedings of the IEEE. 83:95-122.
- [32] Hegger, R., Kantz, H., Schreiber, T. 1999. Practical implementation of nonlinear time series methods: The TISEAN package. CHAOS. 9: 413.
- [33] Hornero, R., Espino, P., Alonso, A., Lopez, M. 1999. Estimating Complexity from EEG Background Activity of Epileptic Patients. IEEE Eng. in Medicine and Biology. 18: 73-79.
- [34] Hudson, D.L., Cohen, M.E., Deedwania, P.C. 1998. Chaotic ECG Analysis Using Combined Models. Proc. of the 20th Annual Int. Conf. Of the IEEE Eng. in Med. And Biology Society. 3: 1553-1556.
- [35] Iokibe, T., Fujimoto, Y. 2001. Predicting Combustion Pressure of Automobile Engine Employing Chaos Theory. Proceedings of 2001 IEEE Int. Symp. On Comp Intell. In Robotics and Automation. 511-516.
- [36] Isliker, H., Kurths, J. 1993. A test for stationarity: finding parts in time series apt for correlation dimension estimates. International J. Bifurcation and Chaos. 3: 1573-1579.
- [37] Jang J.S.R. 1992. Self-learning fuzzy controllers based on temporal backpropagation. IEEE Trans. On Neural Networks. 3 (5): 714-723.
- [38] Jang J.S.R. 1993. ANFIS: Adaptive-network-based fuzzy inference system. IEEE Trans. Syst. Man. Cybern. 23 (3): 665-685.
- [39] Jang, J.S.R., Sun, C.T., Mizutani, E. 1997. Neuro-fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence, Prentice Hall, N.J.
- [40] Kandel A. 1992. Fuzzy expert systems. CRC Press, Boca Raton, FL.
- [41] Kantz, H., Schreiber T. 2005. Nonlinear Time Series Analysis, Cambridge University Press.
- [42] Kantz H. 1994. A robust method to estimate the maximal Lyapunov exponent of a time series. Phys. Lett. A. 185: 77-87.
- [43] Kaplan D.T., Glass L. 1992. Direct Test for Determinism in a Time Series. Physical Review Letters. 68(4): 427-430.

- [44] Kennel, M. B. Brown, R., Abarbanel, H. D. I. 1992. Determining embedding dimension for phase-space reconstruction using a geometrical construction. *Physics Rev. A*. 45: 340-353.
- [45] Keunen, R.W., Pijlman, H.C., Visee, H.F., Vliegen, J.H., Tavy, D.L., Stam, K.J. 1994. Dynamical chaos determines the variability of transcranial Doppler signals. *Neurol Res*. 16: 353-358.
- [46] Keunen, R.W., Vliegen, J.H., Stam, C.J., Tavy, D.L. 1996. Nonlinear transcranial Doppler analysis demonstrates age-related changes of cerebral hemodynamics. *Ultrasound Med Biol*. 22: 383-390.
- [47] Lee C.C. 1990. Fuzzy logic in control systems: fuzzy logic controller. *IEEE Trans. On Systems, Man, and Cybernetics*. 20(2): 404-435.
- [48] Liebert, W., Pawelzik, K., Schuster, H.G. 1991. Optimal embeddings of chaotic attractors from topological considerations. *Europhysics Letters*. 14(6): 521-526.
- [49] Lupetin, R.A., Davids, D.A., Beckman, I., Dash, N. 1995. Transcranial Doppler sonography, part 1: principles, technique and normal appearances. *Radiographics*. 15: 179-191.
- [50] Martin, P.J., Evans, D.H., Finst, P.P., Naylor, A.R. 1994. Transcranial color-coded sonography of the basal cerebral circulation: reference data from 115 volunteers. *Stroke*. 25: 390-396.
- [51] Mitchell, R. H., Taylor, K.P., Jenkins, J.G. 1995. Using Chaotic Attractors As A Means of Discriminating Neonatal Heart Rate Variability. *IEEE 17th Ann. Conf. On Eng. in Medicine and Biology Society*. 2: 951-952.
- [52] Mitchell T. 1997. *Machine Learning*, McGraw Hill.
- [53] Moore A. W. 1992. Fast, Robust Adaptive Control by Learning only Forward Models, *Advances in Neural Information Processing Systems*, Morgan Kaufmann.
- [54] Morgan, G.E., Mikhail, M.S. 1996. *Neurophysiology and Anesthesia in Clinical Anesthesiology*, 2nd Edition, Appleton and Lange.
- [55] Nauck, D., Kruse, R. 1996. Designing neuro-fuzzy systems through backpropagation, *Fuzzy Modelling: Paradigms and Practice*, Kluwer.
- [56] Nauck, D., Nauck, U., Kruse, R. 1996. Generating classification rules with the neuro-fuzzy system NEFCLASS. *Proc. Biennial Conference of the North American Fuzzy Info. Proc. Society NAFIPS'96*, Berkeley, June.
- [57] Nauck, D., Kruse, R. 1997. A neuro-fuzzy method to learn fuzzy classification rules from data. *Fuzzy Sets and Systems*. 89: 277-288.

- [58] Nauck, D., Kruse, R. 1998. Obtaining Interpretable Fuzzy Classification Rules from Medical Data. Artificial Intelligence in Medicine.
- [59] Nauck, D., Nauck, U., Kruse R. 1999. NEFCLASS for Java – new learning algorithms. Proc. IEEE 18th Int. Conf. of the North American Fuzzy Information Processing Society (NAFIPS99), New York, 472-476.
- [60] Otis, S.M., Ringelstein, E.B., Zwiebel, W.J. 1992. Transcranial Doppler sonography, Introduction to Vascular Sonography, W.B. Saunders Company, Philadelphia.
- [61] Pandya, A.S., Macy, R. B. 1996. Pattern Recognition with Neural Networks in C++. IEEE Pres.
- [62] Pedrycz W. 1989. Fuzzy control and fuzzy systems, Wiley, New York.
- [63] Pierson, D., Moss, F. 1995. Detecting periodic unstable points in noisy chaotic and limit cycle attractors with applications to biology. Phys. Rev. Lett. 75. 2124.
- [64] Plagianakos, V.P., Tzanaki, E. 2001. Chaotic Analysis of Seismic Time Series and Short Term Forecasting Using Neural Networks. IEEE Int. Joint Conf. on Neural Networks. 3: 1598-1602.
- [65] Pourcelot L. 1974. Applications Cliniques De L'examen Doppler Transcutane: Coloques. De L'institut National De La Sante Et De La Recherche Medicale. 34: 213-240.
- [66] Quinlan J.R. 1986. Induction of Decision Trees. Machine Learning, 1:81-106.
- [67] Quinlan J.R. 1993. C4.5: Programs for Machine Learning, Morgan Kaufmann, San Mateo, California.
- [68] Rao, T.S., Gabr, M.M. 1984. An introduction to bispectral analysis and bilinear time series models. Lecture notes in statistics, Springer-Verlag, Berlin, Heidelberg, New York.
- [69] Rosenstein, M. T., Collins, J. J., De Luca, C. J. 1993. A practical method for calculating largest Lyapunov exponents from small data sets. Physica D. 65: 117-134.
- [70] Rumelhart, D.E., McClelland, J.L. 1986. Parallel Distributed Processing: Explorations in the Microstructure of Cognition, I & II. MIT Press, Cambridge MA.
- [71] Sauer, T., Yorke, J. 1993. How many delay coordinates do you need?. Int. Journal of Bifurcation and Chaos. 3: 737-744.
- [72] Schreiber, T., Schmitz, A. 1996. Improved surrogate data for nonlinearity tests. Phys. Rev. Lett. 77(4): 635-638.

- [73] Schreiber T. 1997. Detecting and analyzing non-stationarity in a time series with nonlinear cross-predictions. *Phys. Rev. Lett.* 78: 843-846.
- [74] Schreiber, T., Schmitz, A. 1997. Discrimination power of measures for nonlinearity in a time series. *Phys. Rev. E.* 55: 43-54.
- [75] Schreiber T. 1999. Interdisciplinary application of nonlinear time series methods, *Physics Reports.* 308 (1).
- [76] Serhatlioglu, S., Hardalac, F., Guler, I. 2003. Classification of Transcranial Doppler Signals Using Artificial Neural Network. *Journal of Medical Systems.* 27: 205-214.
- [77] So, P., Ott, E., Schiff, J., Kaplan, T., Sauer, T., Grebogi, C. 1996. Detecting unstable periodic orbits in chaotic experimental data. *Phys. Rev. Lett.* 76: 4705.
- [78] Sprott, J.C. 2002. *Chaos and Time-Series Analysis*, Oxford University Pres, New York.
- [79] Stremler F.G. 1977. *Introduction to Communication Systems*. Addison Wesley. Reading Mass.
- [80] Takagi, T., Sugeno, M. 1983. Derivation of fuzzy control rules from human operator's control actions. *Proc. Of the IFAC Symp. On Fuzzy Information, Knowledge Representation and Decision Anlysis.* 55-60.
- [81] Takagi, T., Sugeno, M. 1985. Fuzzy identification of systems and its applications to modelling and control. *IEEE Trans. On Systems, Man, and Cybernetics.* 15: 116-132.
- [82] Takens, F. 1981. Detecting Strange Attractors in Turbulence. *Lecture Notes in Math.* 898: 226-381, Springer, New York.
- [83] Takens, F. 1993. Detecting Nonlinearities in Stationary Time Series. *Int. Journal of Bifurcation and Chaos.* 3(2): 241-256.
- [84] Taşkın, E. 1997. İnsan Elektroensefalogramının Korelasyon Boyutunun Hesaplanması. Yüksek Lisans Tezi. Boğaziçi Üniversitesi Biyomedikal Mühendisliği Enstitüsü. İstanbul. 1-82.
- [85] Taylor, K.J.W., Holland, S. 1990. Doppler ultrasound Part 1. basic principles, instrumentation and pitfalls. *Radiology.* 174 (2): 297-307.
- [86] Theiler, J. 1990. Estimating fractal dimension. *Journal of the Optical Society of America. A* 7: 1055-1073.

- [87] Theiler, J., Eubank, S., Longtin, A., Galdrikian B., Farmer J.D., 1992. Testing for Nonlinearity in Time Series: The Method of Surrogate Data. *Physica D.* 58: 77-94.
- [88] Theiler, J., Linsay, P.S., Rubin, D.M. 1993. Detecting Nonlinearity in data with long coherence times, A.S. Weigend and N.A. Gershenfield eds., "Time Series Prediction: Forecasting the future and understanding the past", Santa Fe Institute Studies in the Science of Complexity, Proc. Vol. XV, Addison-Wesley, Reading, MA.
- [89] Theiler, J., Prichard, D. 1994. Constrained-realization Monte-Carlo method for hypothesis testing. *Physica D.* 94: 221-235.
- [90] Tong H. 1990. Non-linear Time Series – A Dynamical System Approach, Oxford University Press.
- [91] Tsukamoto, Y. 1979. An approach to fuzzy reasoning method. *Advances in Fuzzy Set Theory and Applications*, 137-149, North-Holland, Amsterdam.
- [92] Ubeyli, E.D., Guler, I. 2005. Adaptive neuro-fuzzy inference systems for analysis of internal carotid arterial Doppler signals. *Computers in Biology and Medicine.* 35: 687-702.
- [93] Ubeyli, E.D., Guler, I. 2005. Determining variability of ophthalmic arterial Doppler signals using Lyapunov exponents. *Computers in Biology and Medicine.* 35: 405-420.
- [94] Visee, H.F., Keunen, R.W., Pijlman, H.C., Vliegen, J.H., Tavy, D.L., Stam, K.J., Giller, C.A. 1995. The physiological and clinical significance of nonlinear TCD waveform analysis in occlusive cerebrovascular disease. *Neurol. Res.* 17: 384-388.
- [95] Vliegen, J.H.R., Stam, C.J., Rombouts S.A.R., Keunen, R.W.M. 1996. Rejection of the 'filtered noise' hypothesis to explain the variability of transcranial Doppler signals: a comparison of original TCD data with Gaussian-scaled phase randomized surrogate data sets. *Neurol. Res.* 18: 19-24.
- [96] Wang, L.X., Mendel, J.M. 1992. Generating fuzzy rules by learning from examples. *IEEE Transactions on System, Man and Cybernetics.* 22(6): 1414-1427.
- [97] Wang, H., Chen G., Lee J. 2004. Complex Dynamical Behaviours of Daily Data Series in Stock Exchange. *Physics Letters. A* 333:246-255.
- [98] Webber, C.L. Jr., Zbilut, J.P. 1994. Dynamical assessment of physiological systems and states using recurrence plot strategies. *Journal of Applied Physiology.* 76:965-973.

- [99] Weds, P.N.T., Taylor, K.J.W., Burns, P.N., Wells, P.N.T. 1995. Basic principles and Doppler physics, Clinical Applications of Doppler Ultrasound, Raven Press, New York..
- [100] Williams, G.P. 1997. Chaos Theory Thamed, Taylor & Francis Publisher, London.
- [101] Wolf, A., Swift J.B., Swinney, H.L., Vastano, J.A. 1985. Determining Lyapunov exponents from a Time Series. Physica D. 16 (3): 285-317.
- [102] Yang, H., Duan, X. 2003. Chaotic Characteristics of Electricity Price and Its Forecasting Model. Canadian Conf. On Electrical and Computer Eng. 1: 659-662.
- [103] Yu, D., Lu, W. Harrison, H.G. 1999. Detecting Dynamical Nonstationarity in Time Series Data. Chaos. 9(4).
- [104] Zadeh, L.A. 1965. Fuzzy sets. Information and Control. 8:338-353.
- [105] Zadeh, L.A. 1973. Outline of a new approach to the analysis of complex systems and decision processes. IEEE Transactions on System, Man and Cybernetics. 3(1):28-44.
- [106] Zbilut, J.P., Guilian, A., Webber, C.L. Jr. 1998. Recurrence quantification analysis and principle components in the detection of short complex signals. Physics Letters A, 237:131-135.
- [107] Zhang Z. 2002. Association Rule Mining, Springer.
- [108] Zweig, M.H., Campbell, G. 1993. Receiver-operating characteristic (ROC) plots: a fundamental evaluation tool in clinical medicine. Clinical Chemistry. 39(4): 561-577.
- [109] Zwiebel, W.J., Taylor, K.J.W., Burns, P.N., Wells, P.N.T. 1995. Cerebrovascular Doppler applications, Clinical Applications of Doppler Ultrasound, Raven Press, New York.