

**YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

728876

**ANTENATAL FETÜS VERİLERİNİN ÖRÜNTÜ TANIMA
YÖNTEMLERİYLE TANIMLANMASI**

Matematik Yük. Müh. Nilgün GÜLER

**F.B.E. Matematik Müh. Anabilim Dalında
Hazırlanan**

DOKTORA TEZİ

Tez Savunma Tarihi : 8 Mart 2002

Tez Danışmanı

Jüri Üyeleri

: Prof. Tahir ŞİŞMAN (YTÜ)

: Prof. Dr. Mithat UYSAL (MSÜ)

: Doç. Dr. Mehmed ÖZKAN (BÜ)

: Doç. Dr. Günhan DÜNDAR (BÜ)

: Yrd. Doç. Dr. İbrahim EMİROĞLU (YTÜ)

İSTANBUL, 2002

728876
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

İÇİNDEKİLER

	Sayfa
SİMGE LİSTESİ	iv
KISALTMA LİSTESİ	v
ŞEKİL LİSTESİ	vi
ÇİZELGE LİSTESİ	vii
ÖNSÖZ	viii
ÖZET	ix
ABSTRACT	x
1. GİRİŞ.....	1
1.2 Tezin Amacı ve Önemi	2
2. FETÜSÜN SAĞLIK DURUMUNUN DOPPLER ULTRASONU İLE İZLENMESİ	3
2.1 Umbilikal Arter ve Hipoksiya	4
2.2 OSA ve Hipoksiya	5
2.3 Doppler Ultrasonu ile Fetal Sağlığının Değerlendirilmesi	6
2.4 Doppler Kan Akış Hızı Dalga Boyu	6
2.5 Doppler İndislerinin Hesaplanması	9
3. FETÜSÜN GELİŞİM DURUMUNUN RİSK DEĞERLENDİRME SİSTEMİ.....	11
4. TEMEL BİLEŞEN ANALİZİ (TBA).....	18
4.1 Yöntem	18
4.2 Temel Bileşen Analizinin Gerekliği	19
4.3 Temel Bileşen Sayısının Belirlenmesi	20
5. KARAR TEKNİKLERİ	24
5.1 Karar Tekniklerinin Modellenmesi	24
5.2 Karar Teknikleri	25
5.2.1 k-En Yakın Komşuluk Algoritması (k-EYK)	25
5.2.2 Diskriminant Analizi	27
5.2.3 Diskriminant Fonksiyonları	28
5.2.3.1 Doğrusal Diskriminant Fonksiyonu (DDF)	29
5.2.3.2 Karesel Diskriminant Fonksiyonu (KDF)	30
5.2.3.3 Doğrusal Olmayan Diskriminant Fonksiyonları-Çok Katmanlı Algılayıcı (ÇKA)	30
5.2.3.4 Sonuçlar	32
5.2.4 Karar Ağacı Algoritmaları	35
5.2.4.1 C4.5 Karar Ağacı Algoritması	36
5.2.4.2 Sınıflama ve Regresyon Ağaçları (SRA) Algoritması	37
5.2.4.3 Sonuçlar	38

5.2.5	Radyal Tabanlı Fonksiyonlar (RTF)	40
5.2.5.1	Ağırlıkların Optimize Edilmesi	42
5.2.5.2	RTF Ağının Eğitilmesi	43
5.2.6	Bulanık Yapay Sinir Ağları	44
5.2.6.1	Bulanık-YSA Modeli.....	45
5.2.6.2	Bulanık Yapay Sinir Ağı Karar Mekanizması.....	46
5.2.6.3	Sonuçlar	47
6.	DEĞERLENDİRME TESTLERİ.....	49
6.1	Algoritmaların İstatiksel Tıbbi Değerlendirilmesi	49
6.2	5x2 cs F Testi.....	51
7.	ANTENATAL FETÜSA AİT RİSK DEĞERLENDİRME SİSTEMİ İÇİN KARAR TEKNIĞİNİN SEÇİMİ	54
8.	SINIFLAYICILARIN BİRLEŞTİRİLMESİ : ÇOĞUL SINIFLAYICI İLE FETÜSÜN HIPOKSİK RİSK KOŞULLARININ BELİRLENMESİ.....	58
9.	TARTIŞMA ve SONUÇLAR	60
	KAYNAKLAR.....	62

SİMGE LİSTESİ

δ	Hata değeri
θ	Sinyal ile alyuvar hücrelerinin akış yönü arasındaki açı
Σ	Varyans-kovaryans matrisi
λ_i	i'inci özdeğer sayısı
μ_i	i'inci sınıfın ortalama değeri
κ_i	Doğrusal adaptif ağırlık faktörü
σ_j	j'inci düğüm için ölçekleme parametresi
$b_i(x)$	Taban fonksiyonu
c_k	eşik değeri
f_0	Ultrason iletim frekansı
f_d	Ultrason frekansındaki değişim miktarı
I	Birim matris
N	Örnek sayısı
P	Değişken sayısı
R	Korelasyon matrisi
s	Ortalama ses hızı
T	Dönüştürme matrisi
u_j	j'inci düğüm için gauss fonksiyonunun merkezi
V	Yansıtıcı yada alyuvar hücrelerinin hızı
$w^{(HI)}$	Saklı katman ile giriş katmanı arasındaki ağırlık matrisi
$w^{(TH)}$	Saklı katman ile çıkış katmanı arasındaki ağırlık matrisi
X	Ham veri matrisi(Giriş vektörü)
Y	Çıkış vektörü
$y^{(H)}$	Saklı katmanın çıkış değeri
Z	Standartlaştırılmış değerler matrisi

ULUSLARARASI İNŞAAT MÜHÜRÜ
T.C. İNŞAAT BAKANLIĞI
MİMARLIK BAKANLIĞI
MİMARLIK BAKANLIĞI

KISALTMA LİSTESİ

A.B.D	Ana Bilim Dalı
AA	Aort Atardamarı
CS	Çapraz Sağlamalı
ÇKA	Çok Katmanlı Algılayıcı
DDF	Doğrusal Diskriminant Fonksiyonu
DEKK	Doğrusal En Küçük Kareler
IUGR	Intrauterine Growth Retardation
KDF	Karesel Diskriminant Fonksiyonu
k-EYK	k-En Yakın Komşuluk
LMS	Least Mean Squares
NST	Non-Stress Test
OSA	Orta Serebral Arter
pCO ₂	Karbondioksit konsantrasyonu
PI	Pulsatility İndeksi
pO ₂	Oksijen konsantrasyonu
RI	Rezistans İndeksi
RTF	Radyal Tabanlı Fonksiyon
S/D	Sistolik/Diyastolik Oranı
SP	Standart Sapma
SRA	Sınıflama ve Regresyon Ağaçları
TBA	Temel Bileşenler Analizi
UA	Umbilikal Arter
WI	Haftalık İndeks
YSA	Yapay Sinir Ağları

ŞEKİL LİSTESİ

Sayfa

Şekil 2.1	Fetüstaki hipoksik durumun evreleri.	4
Şekil 2.2	24 haftalık IUGR fetüsün UA'deki Doppler ölçüm değerleri.	8
Şekil 2.3	28'ci haftadaki fetüsün UA'deki Doppler ölçüm değerleri (S/D= 5.4).....	8
Şekil 2.4	Aynı fetüsün 32'inci haftadaki UA'deki Doppler ölçümleri.....	9
Şekil 3.1	Antenatal fetüs risk değerlendirme sistemi	12
Şekil 3.2	Fetüs-1'in Doppler ölçümlerinin 2 boyutlu çizimi	13
Şekil 3.3	Fetüs-1'in Doppler ölçümlerinin üç boyutlu çizimi	14
Şekil 3.4	Fetüs-2 Doppler ölçümlerinin iki boyutlu çizimi	16
Şekil 3.5	Fetüs-2 Doppler ölçümlerinin üç boyutlu çizimi.....	17
Şekil 4.1	Temel bileşenler dönüşümünün iki boyutlu uzayda gösterimi.....	19
Şekil 4.2	Fetüs-2 için özdeğerlerin varyans açıklama oranları.....	22
Şekil 4.3	Fetüs-2 verisinin 2 temel bileşenle gösterimi	23
Şekil 5.1	8-en yakın komşuluk'ta karar verme (Nilsson, 1996).	26
Şekil 5.2	Fetüs-1 ve Fetüs-2 veritabanlarının çeşitli k komşuluk değerleri için doğru sınıflama yüzdeleri	27
Şekil 5.3	2 boyutlu uzayda diskriminant analizi (Tatlıdil, 1996).	28
Şekil 5.4	Diskriminant fonksiyonları a) DDF b) KDF c) ÇKA.....	29
Şekil 5.5	Çok katmanlı algılayıcının yapısı	31
Şekil 5.6:	Tek değişkenli ve çok değişkenli karar ağacı yapıları.....	36
Şekil 5.7	SRA algoritmasının bir adımı.....	38
Şekil 5.8	C4.5'in Fetüs-1 veritabanı için çıkardığı sınıflandırma kuralının şemasal gösterimi.	39
Şekil 5.9	SRA'nın Fetüs-1 veritabanı için çıkardığı sınıflandırma kuralının şemasal gösterimi.	39
Şekil 5.10	C4.5'in Fetüs-2 veritabanı için çıkardığı sınıflandırma kuralının şemasal gösterimi	40
Şekil 7.1	Fetüs-1 için algoritmaların karşılaştırılması	56
Şekil 7.2	Fetüs-2 için algoritmaların karşılaştırılması	57
Şekil 8.1	Çoğul Sınıflandırıcı	58

ÇİZELGE LİSTESİ

Sayfa

Çizelge 2.1	Umbilikal arter sistolik/diyastolik oran diyagramı	7
Çizelge 3.1	Fetüs-1 ve Fetüs-2 veri tabanlarının dağılımı	11
Çizelge 3.2	24 ile 39 haftaları arasındaki bazı fetüslerin UA ve OSA'den alınan Doppler utrason ölçüm değerleri	15
Çizelge 5.1	k-EYK sonuçları	27
Çizelge 5.2	Fetüs-1'e ait ÇKA sonuçları	33
Çizelge 5.3	Fetüs-2'ye ait ÇKA sonuçları	34
Çizelge 5.4	Diskriminant fonksiyonlarının başarı yüzdelerinin karşılaştırılması	35
Çizelge 5.5	Karar ağacı algoritmalarının başarı yüzdeleri	40
Çizelge 5.6	RTF ağlarının başarı yüzdeleri	44
Çizelge 5.7	Bulanık sinir ağı karar sonuçları	48
Çizelge 6.1	2X2 sonuç tablosu	49
Çizelge 6.2	Fetüs-1 için algoritmaların istatistiksel tıbbi başarı tablosu	50
Çizelge 6.3	Fetüs-2 için algoritmaların istatistiksel tıbbi başarı tablosu	50
Çizelge 6.4	Fetüs-1 ile eğitilip Fetüs-2 ile test edilen algoritmaların istatistiksel tıbbi başarı tablosu	51
Çizelge 6.5	Fetüs-1 veritabanı için algoritmaların 5x2 cs F test güven aralığı tablosu	53
Çizelge 6.6	Fetüs-2 veritabanı için algoritmaların 5x2 cs F test güven aralığı tablosu	53
Çizelge 7.1	Algoritmaların eğitim süresi	55
Çizelge 8.1	Fetüs-1 ve Fetüs-2 için çoğul-sınıflandırıcı sonuçları	59

ÖNSÖZ

En başta ve öncelikle yüksek lisans ve doktora programı boyunca beni yönlendirerek, bilgisini ve değerli görüşlerini bana aktararak çalışmalarımda sonsuz emeği geçen Sayın Prof. Dr. S. Fikret Gürgen'e ve her açıdan desteğini gördüğümüz Matematik Müh. Bölüm Başkanı Sayın Prof. Tahir Şişman'a çok teşekkür ederim.

Ayrıca çalışmamın her aşamasında destek olan arkadaşlarım Olcay Taner Yıldız ve Burçak Erdal'a ve hayatım boyunca her zaman desteklerini hissettiğim sevgili anneme, babama ve kardeşlerime çok teşekkür ederim.



ÖZET

Bu çalışmada amacımız, anne karnındaki bebeğin sağlık durumunu analiz eden bir sistem tasarlamaktır. Bu amaçla umbilikal arter(UA) ve orta serebral arterden (OSA) elde edilen Doppler ultrason ölçümleriyle fetüsün sağlık durumu arasındaki ilişki incelenmiştir. Bu amaçla haftalara göre UA ve OSA'dan elde edilen pulsatilite indeksi, rezistans indeksi ve sistolik/diyastolik oran ölçümleri kullanılmıştır.

Çalışmada ilk olarak temel bileşen analizi (TBA) kullanılarak, bu indislerin tek başlarına sonuca etkisi incelenmiştir. Daha sonrada doğrusal diskriminant fonksiyonu (DDF), karesel diskriminant fonksiyonu (KDF), çok katmanlı algılayıcı (ÇKA), radyal tabanlı foksiyon ağı (RTF), k-en yakın komşuluk (k-EYK), C4.5 ve SRA karar ağacı gibi zeki karar verme teknikleri fetüsün hipoksik risk değerlendirme problemine uygulanmıştır. ÇKA ile k-EYK'nin en iyi performansı verdiği gözlemlenirken C4.5 karar ağacı tekniği kolayca anlaşılabilen kural çıkarma özelliği ile dikkat çekmiştir.

Son olarak fetüsün hipoksik ortamda olma riskini değerlendirmek için bulanık kural tabanlı sistem ile RTF ve ÇKA gibi veriye dayalı öğrenme stratejilerini birleştirmeye dayanan karar tekniği kullanılmıştır. Bulanık üyelik dereceleri kullanılarak fetüsün durumunun ciddiyeti değerlendirilip, doktorlar için fetüsün sağlık durumunu iyi, şüpheli ve alarm düzeyini tanımlayan kurallar çıkarılmıştır.

Sonuçlar göstermektedir ki zeki veri analiz yöntemleri fetüsün sağlık durumunun takibi süresince doktorlara yardımcı bir tıbbi sistem olarak kullanılabilecektir.

Anahtar Kelimeler: Doppler ultrason ölçümleri, hipoksiya, diskriminant fonksiyonları, bulanık yapay sinir ağ tekniği, yapay sinir ağları, karar ağacı teknikleri: C4.5 ve SRA

ABSTRACT

In this study, our purpose is to design a system for antepartum fetal evaluation. The task is to investigate the Doppler ultrasound measurements of umbilical artery (UA) and middle cerebral artery (MCA) to relate the health conditions of fetuses. We, thus, use the UA and MCA blood flow indices: pulsatility index (PI), resistance index (RI) and systolic/diastolic ratio (S/D) in terms of weeks (week index: WI as a normalized value).

First of all, we analyze the individual effects of these indices using principal component analysis (PCA). Then intelligent decision techniques such as linear discriminant functions (LDF), quadratic discriminant functions (QDF), multilayer perceptron (MLP), radial basis function network (RBF), k-Nearest Neighbors (k-NN) and decision trees C4.5, classification and regression trees (CART) are applied to antenatal fetal risk assessment problem. It is observed that the performances of MLP and k-NN are better but C4.5 attracts understandable diagnostic clues.

Finally, we make a decision on the basis of fuzzy-rule based system combined with data-based learning strategies such as RBF and MLP networks for assessing the hypoxia suspicion. A fuzzy grade of membership is used for the evaluation of the seriousness of the situation of the fetus and the diagnostic interpretations for doctors such as good, suspicious and alarming conditions of fetus are derived.

The results prove that intelligent data analysis methods are supportive medical tools for physicians during intensive surveillance of fetuses.

Key Words: Doppler ultrasound measurements, hypoxia, discriminant functions, neurofuzzy technique, artificial neural networks, decision tree techniques: C4.5 and CART

1. GİRİŞ

Son yıllarda yapılan çalışmalar umbilikal arterden (UA) ve orta serebral arterden (OSA) elde edilen kan akım ölçümlerinin, plasenta-fetüs kanlanması (perfüzyonunun) ve oksijenizasyonunun değerlendirilmesinde kullanılabileceğini göstermiştir (Gramellini vd.,1992). Bu amaçla en çok kullanılan göstergeler:

- Sistolik/Diyastolik oranı (S/D).
- Rezistans indeksi ($RI=(S-D)/D$)
- Pulsatilité indeksi ($PI=(S-D)/\text{ortalama dalga hızı}$).

Bu göstergeler kan akım hızının belirlenmesinde kullanılırlar ve ultrason sinyali ile kan akış yönü arasındaki açıdan oldukça bağımsızdırlar.

Fetüslerin gebelik boyunca gelişimleri sırasında, UA ve fetal OSA gibi kan damarları akımlarındaki değişimler ve bunlara bağlı göstergeleri tanımlama çabaları büyük bir yol almıştır. Fetüsün kanlanmasını ve oksijenizasyonunu gösteren akımları belirten parametrelerin incelenmesi fetal hipoksi ve asidemi konusuna yeni bir bakış açısı getirmektedir (Chervenak ve Kurcak, 1996). Bu çalışmada amacımız, çeşitli örüntü tanıma (pattern recognition) tekniklerini hipoksi riski altındaki fetüsü tanımlama, izleme ve değerlendirme sisteminde kullanılır duruma getirmektir.

Çalışmada ilk olarak, çok boyutlu verilerin boyut azaltma yöntemlerinden biri olan “Temel Bileşenler Analizi” (TBA) kullanılarak sistemin daha az sayıda boyutla etkin bir sınıflama kararı verebilmesi için temel bileşen değerleri belirlenmiştir.

Daha sonra k-en yakın komşuluk (k-EYK), radyal tabanlı fonksiyon (RTF), doğrusal, karesel ve doğrusal olmayan fonksiyonlar, C4.5 ve SRA karar ağacı gibi iyi bilinen sınıflama teknikleri kullanılarak fetüsün kan akım patternleri değerlendirilmiştir.

Son olarak akıllı hesaplama tekniklerinden bulanık yapay sinir ağı (bulanık YSA) kullanılarak fetüsün hipoksi risk değerlendirmesi yapılmıştır.

Özetle, bu çalışmayla tasarlanan sistem ile UA ve OSA’daki Doppler kan akım parametrelerini kullanarak fetüsün oksijenizasyon durumuyla ilgili risk uyarıları alınacak ve değerlendirilecektir.

1.2 Tezin Amacı ve Önemi

Gelişmekte olan enformasyon teknolojisinin tıp bilimindeki uygulama alanlarından birisi de akıllı medikal karar verme yöntemleridir. Bu yöntemler binlerce giga-byte olarak toplanan medikal görüntü ve test yöntemlerinin sonuçlarını doktorlara ve tüm insanlara yararlı hale getirecek enformasyona dayalı kararları oluşturabilmektedirler.

Bu tezde amaç, anne karnındaki bebeğin (fetüs) sağlık durumunun hamilelik boyunca yapılan Doppler ölçümleri kullanılarak, fetüsün gelişim geriliği ve hipoksik koşullarının önceden belirlenerek gerekli tedavi için karar verme mekanizmasında klinisyenlere yardım eden karar verme yöntemlerinin incelenmesidir.

Bu amaçla, ayırıcı analiz yöntemleri (DDF, KDF), yapay sinir ağları (ÇKA, RTF), karar ağacı teknikleri (C4-5, SRA) ve bulanık yapay sinir ağı gibi karar verme yöntemlerini kullanarak problemi analiz eden bir sistem tasarımı üzerinde çalışılmıştır.

UA ve OSA'dan elde edilen Doppler ultrason verileri kullanılarak fetüsün gelişimi incelenerek gerekli aksaklıkların ortaya konması için istatistiksel temele dayalı bir çok analiz çalışması bulunmaktadır. Ama daha çok mühendislik uygulamalarında kullanılan yapay sinir ağı (YSA) tabanlı yöntemler gibi zeki veri analizi yöntemleriyle, oluşan durumun değerlendirilip karar verilmesini sağlayan bir sistem tasarımı yapılmamıştır. Bu tezde amacımız bu boşluğu doldurmak ve zeki veri analizi yöntemlerini kullanarak, fetüsün hipoksik risk durumunu tanımlayan bir sistem tasarlamaktır.


2. FETÜSÜN SAĞLIK DURUMUNUN DOPPLER ULTRASONU İLE İZLENMESİ

Fetal hipoksi, sıklıkla fetüstaki gelişim geriliği ile birlikte görülen istenmeyen sonuçlardan biridir. Kronik olarak hipoksik ortamda olan bir fetüsün bu duruma karşı korunması sırasında kademeli olarak olası metabolik hasarlara karşı koruyucu nitelikte kan akımı değişimleri olmaktadır (fetüsün korunması ve kompensasyon fazı). Hipoksi durumunun şiddetli ve uzun süreli olması halinde fetüsün hemodinamiğinde beyne, böbreklere, böbrek üstü bezlerine ve kalbe kan akışını arttırmak gibi bir takım tedbirlerle kendini koruma ön plana çıkar. Fetüste gelişim duraklar, vücut gelişim oranları küçülür, fetüsün hareketleri azalır ve alyuvar hücrelerinin sayısının artmasını sağlayan eritropoetin gibi hormonlarla bazı metabolik uyarlamalar yaparak hipoksi durumunun getireceği hasarlar minimuma indirilme çabaları sürdürülür.

Hipoksi durumundaki fetüsün izlenmesinin temel amacı dekompanseasyon fazının engellenmesi, hemodinamisinde kan akım bozukluklarının karakterize edilerek, zamanında tedbirlerin alınmasına gidilmesidir. Şekil 2.1 de, fetal hipoksi durumunun uzun süreli olması durumunda, olası evreler zinciri gösterilmektedir.

Fetüstaki gelişim geriliğinin takibi için çeşitli testler önerilmektedir: non-stress test (NST), fetüsün gelişim oranlarının değerlendirilmesi, Doppler kan akım hız ölçümleri, amniyotik sıvı miktarının değerlendirilmesi, fetüsün biyofizik profilinin incelenmesi. Bu metodlar arasında hipoksi durumun ilk aşamasından itibaren fetüs gelişiminin izlenmesine olanak veren duyarlı metotlardan biri Doppler kan akım hız ölçümleridir (Creasy, 1999). İnvasif olmayan bu tekniklerin bugün fetüs gelişim geriliği yanında pek çok değişik tıp uygulaması da mevcuttur.

Fetüs gelişiminde plasentadan sağlanan oksijen ve besin önemli bir yer tutmasından dolayı, fetüsün sağlığının değerlendirilmesi için umbilikal arterdeki kan akımının incelenmesi büyük önem kazanmaktadır. Ayrıca fetal hipoksi açısından takibi güvenli ve ölçümü kolay olan damarlardan biri OSA'dır (OSA'nın M1 ve M2 bölümlerindeki PI değerlerinin artması olarak ifade edilen "*Serebral Yedekleme Etkisi*" hipoksinin ciddi bulgularından biridir).



Şekil 2.1 Fetüstaki hipoksik durumun evreleri.

2.1 Umbilikal Arter ve Hipoksiya

Günümüzde, fetal Doppler metodunun klinik uygulamalarının bir çoğu plasental arter hemodinamiğiyle yakından ilgilidir. Normal bir hamileliğin ileri dönemlerinde, plasentada devam eden matürasyonun ve “tertiary stem villi” sayısındaki artma nedeniyle UA’daki akış empedansında azalma söz konusudur. Bir çok çalışma umbilikal Dopplerin fetüsün gelişiminin değerlendirilmesinde kullanılabileceğini ispatlamıştır (Trudinger, 1987; Creasy, 1997; De Haan, 1994). Bu çalışmaların bir çoğu UA’daki Doppler hız dalga formunun S/D

oranı, RI yada PI ölçümlerini kullanmaktadır. Bütün bu umbilikal damarsal direnç indisleri normal değerlerinin en üst limitinin üstünde bir değer aldığında (>2 SD) sıklıkla gelişim geriliği ile ilişkilidir. Gelişim geriliği gözlenen fetüsta yapılan çalışmalar göstermektedir ki uterus ve UA'daki akış empedansındaki artış fetal hipoksi ve asidemi ile yakından ilişkilidir. Bununla birlikte, UA'dan elde edilen bu indisler tek başına fetüstaki hipoksinin ve baskının derecesinin değerlendirilmesi için yeterli değildir. Bu yüzden umbilikal Doppler indislerindeki bu değişikliklere, beyindeki arterlerdeki olabilecek değişimler de katılmalıdır.

2.2 OSA ve Hipoksiya

Ana beyin arterlerine giden kan akımları aracılığıyla fetüsün kanlanması değerlendirilebilmektedir. Normal bir gebelikte ikinci yarının başlangıcından itibaren (20.-25. hafta) beyin damarlarındaki diyastolik akımda azalma başlar. Gebeliğin ileri dönemlerinde diyastolik bileşenlerde gözüken artma, beyin kan akımını arttırmak için, gebeliğin sonraki dönemlerinde gelişebilecek ciddi fetal hipoksiye eşlik eden pO_2 'deki azalma ve pCO_2 'deki artma gibi olaylarda kalpten beyne giden kan akımını arttırma çabaları olarak yorumlanır. Placenta için kullanılan Doppler indisleri beyin arterlerindeki kan akımı direnç değişimlerinin değerlendirilmesinde de kullanılabilmektedir.

Fetüs ana beyin arterlerindeki bu Doppler indis ölçümleri, diyastolik serebral kan akımında artış ile birlikte olabilecek hipoksinin doğurduğu vasomotor cevap (beyin kan damarlarında genişlemesi) tanısında oldukça hassastır. Hipoksinin başlangıç evresinde de beyin Doppler indis ölçümleriyle pO_2 arasında iyi bir korelasyon olduğu kanıtlanmıştır (Chervenak, 1996). Yine de hipoksinin ileri dönemlerinde fetal asidozun ciddi olduğu durumlarda diyastolik akımda azalma yüzünden serebral RI de artma gözlenebilmektedir.

Serebral indislerin hipoksinin derecelendirilmesinde kullanımı oldukça zor görünmesine karşı fetüs serebral RI ve PI değerlerinin ölçümleri yapılarak fetal hipoksi takibi söz konusu olabilmektedir. Sadece serebral indis değerlendirilmesi ya da serebro-plasental oranın birkaç günlük takibi fetal hipoksi açısından bilgi verebilmektedir.

Serebro-plasental(OSA-RI/UA-RI) oran aşağıdaki durumlarda da patolojik olabilmektedir:

1. Plasental RI de artışın hipoksi ile birlikte olmadığı ve serebral perfüzyonun normal olduğu durumlar,
2. Plasental direncinin normal olduğu ancak hipoksi olduğu için, serebral direncin anormal azalma durumunun ortaya çıkması,

3. Plasental ve serebral direncin her ikisinin de normal olmadığı durumlar,
4. Her iki indis değeri normal olduğu halde, serebral indis plasental indis değerinden daha küçük bir değerdedir.

Bütün bu durumlarda fetüsün kan akım dağılımının farklı olduğu ve bir çok olayda da bu farklılıkların fetüstaki gelişim geriliği ile ilişkili olabileceği gösterilmiştir. Buna göre OSA-RI/UA-RI değeri 1'den küçük ise hipoksi durumu söz konusu olabilir (Chervenak, 1996). Bu oran da pratikte yaygın olarak kliniklerde kullanılmaktadır.

2.3 Doppler Ultrasonu ile Fetal Sağlığının Değerlendirilmesi

Doppler ultrason yöntemi, fetüsün kalp atım hızının değerlendirmesinde uzun zamandan beri kullanılmaktadır (Campbell vd., 1983; Mari ve Copel, 1996). Son yıllardaki Doppler ultrason teknolojisindeki gelişmeler doğum uygulamalarında anne karnındaki fetüsün sağlığının izlenmesinde büyük atılımları mümkün kılmıştır.

Fetüsün damarlarındaki kan akışının karakteristiği Doppler akış hızının dalga biçimi olarak değerlendirilmektedir. Özellikle diyastolik fazın nabız devrindeki akış hızının azalması fetüstaki gelişim geriliğinin/bozukluğunun bir habercisidir ve S/D'nin almış olduğu değerler, bu geriliğin derecesini belirlemekte de kullanılmaktadır. Bu amaçla genellikle Umbilikal Arter (UA), Aort Atardamarı (AA), Orta Serebral Arter (OSA) kan akış indeksleri incelenmektedir.

2.4 Doppler Kan Akış Hızı Dalga Boyu

Gerçek zamanlı görüntüleme ile darbeli Doppler teknolojisinin bir arada kullanılması damar yapılarının incelenmesine, çap ve sorgulama açılarının ölçülebilmesine imkan vererek, damarlardaki kan akış hızı ve hacminin tahminine olanak sağlamaktadır.

Fetüsün gelişiminin tamamen plasentadan sağlanan oksijen ve besine bağlı olmasından dolayı, fetüs sağlığının değerlendirilmesi için UA kan akışının incelenmesi büyük önem kazanmaktadır.

Hamileliğin ileri dönemlerinde, sistolik hızdaki diklemesine artışla (systolic peak) ilişkili olarak diyastol-sonu akış hızında bir artış söz konusu olup, bu durum gebeliğin ileri dönemlerinde plasenta dolaşımındaki direkt azalma ile ilgilidir. Darbe hızı dalga boyundaki bu değişiklik sistolik/diyastolik oranı (A/B oranı olarakta bilinir) olarak ölçülmektedir. Hamilelikte plasentaya ait kan dolaşımında bozukluklar S/D oranındaki yükselmeye neden


olmakta, dolaşıma bağlı fetal gelişim problemlerini daha da arttırmaktadır (Mari ve Copel, 1996).

UA'deki kan akım sistolik/diyastolik oranı fetüs de perinatal sonuçları belirlemede risk ölçüsü olarak kullanılmaktadır. Çizelge 2.1, Kuzey Amerika Radyoloji Derneği tarafından 1991 yılında yayınlanmış olup, 24-40 gebelik haftaları arasındaki UA'deki olası S/D oranlarını vermektedir (Woo, 2000).

Çizelge 2.1 Umbilikal arter sistolik/diyastolik oran diyagramı


Hafta	Ortalama	Üst Limit
24	3.5	4.25
25	3.4	4.10
26	3.3	3.90
27	3.2	3.75
28	3.1	3.70
29	3.0	3.60
30	2.9	3.50
31	2.8	3.45
32	2.8	3.40
33	2.7	3.30
34	2.6	3.15
35	2.5	3.10
36	2.4	3.00
37	2.4	2.90
38	2.3	2.80
39	2.3	2.65
40	2.2	2.50

Çizelge 2.1'de de görüldüğü gibi UA'deki sistolik/diyastolik oranı hamilelik ilerledikçe düşmektedir. Buna göre sistolik/diyastolik oranının 24'üncü haftadaki yaklaşık 3.5 olan değerinden hamileliğin son dönemlerinde 2.2 değerine kadar düşmektedir. Eğer bu oran üst limitin üzerinde kalırsa fetüs gelişim geriliği gösterebilmektedir. Şekil 2.2, 24 haftalık gelişme geriliği görülen bir fetüse ait patterni (imge) göstermektedir. Burada 24 haftalık bir fetüs için en fazla 4.25 olması gereken sistolik/diyastolik oranı 4.6'dır. Dolaşım problemlerine bağlı fetal gelişim geriliğinde, UA'da diyastolik kan akımı azalırken sistolik/diyastolik oranı artmaktadır.




Şekil 2.2 24 haftalık IUGR fetüsün UA'deki Doppler ölçüm değerleri.
(Burada A sistolik değeri ve B de diyastol sonu kan akım hızını ifade etmektedir. Oranın değeri 4.6 dir.)

Şekil 2.3'de aynı fetüsün 28'inci hafta UA Doppler akım patterni (imge) görülmektedir. Sistolik/diyastolik oranı hala olması gereken oranın üzerindedir. Bu da gelişim geriliğiyle birlikte olan plasental dolaşım bozukluklarının devam ettiğini göstermektedir.



Şekil 2.3 28'ci haftadaki fetüsün UA'deki Doppler ölçüm değerleri (S/D= 5.4)

Şekil 2.4'de 32'inci haftadaki UA oranı görülmektedir. Diyastol-sonu akım bulunmaması yüzünden bu oran sonsuz değerine yükselmiş olup, bu da fetüsün perinatal (doğum sırasında ve sonrasında) sonuçlar açısından ölüm riski taşıyabildiğinin göstergesidir.




Şekil 2.4 Aynı fetüsün 32'inci haftadaki UA'daki Doppler ölçümleri.

2.5 Doppler İndislerinin Hesaplanması

Uterus, plasenta ve fetüs damarlarındaki kan akım patternlerini, miktarlarını ölçmekte kullanılan Doppler ultrasonunun temel prensipleri basit bir örnekle açıklanabilir. Ambulans sireninin üretmiş olduğu sesin frekansı ambulansın belli bir hedeften uzaklaşması veya o hedefe yaklaşmasına göre değişir. Ambulans hedefe yaklaştıkça sirenin sesi keskinleşirken, uzaklaştıkça bu keskinleşme azalır. Benzer olarak, ultrason atımı frekans değişiminin yansımada, hareket eden alyuvar hücrelerinin yoğunluğu ve kan akım hızı ile orantılıdır (Şekil 2.5). Diğer bir söyleyişle, yansıyan sesin frekansı hareket eden alyuvar hücrelerinin hızı ile doğru orantılıdır. Kan akım hızı aşağıdaki formülle hesaplanmaktadır:

$$f_d = 2f_0 \frac{V \cos \theta}{s} \quad (2.1)$$

Burada f_d ultrason dalga frekansındaki değişim miktarı, f_0 kullanılan dalganın iletim frekansı, V alyuvar hücrelerinin (yansıtıcı) hızı, θ sinyal ile alyuvar hücrelerinin akım yönü arasındaki açı, s ortalama ses hızı, ve 2 ise sesin kaynaktan çıkıp tekrar geri dönmesine kadar geçen zaman dilimini temsil etmektedir. Burada dikkat edilmesi gereken nokta, θ açısının 30 derecenin altında olması ve 55 dereceyi aşmamasıdır. Aksi takdirde akım hızının hesaplanmasında büyük hatalar oluşabilmektedir.



Şekil 2.5 Kan akım dalga boyunun nasıl hesaplandığını göstermektedir (Creasy, 1999).

3. FETÜSÜN GELİŞİM DURUMUNUN RİSK DEĞERLENDİRME SİSTEMİ

Fetüsa ait risk değerlendirme sistemi (Şekil 3.1), UA ve OSA'den alınan haftalık Doppler ultrason ölçümlerini (WI, S/D, UA-PI, UA-RI, OSA-PI, OSA-RI) giriş verileri olarak alır, özellik vektörlerini tanımlar ve klinik koşullarla ilişkili olarak çıkışlar üretir. Burada haftalık indeks (WI), normalizasyonu yapılmış gebelik yaşıdır.


Çalışmada iki veri tabanından yararlanılmıştır. İlk veri tabanı (Fetüs-1) gebeliklerinin 20 ile 40 haftaları arasındaki 210 kadının UA Doppler ölçümlerini içermektedir (WI, PI, RI, S/D). Fetüs-1 Mari ve Copel (1996) tarafından yayınlanmış veriden çıkarılmıştır. Çizelge 3.1 Fetüs-1 ve Fetüs-2'ye ait sınıfların veri dağılımını göstermektedir.

Çizelge 3.1 Fetüs-1 ve Fetüs-2 veri tabanlarının dağılımı


	Normal Fetüs	Hipoksik Riskli Fetüs	Toplam
Fetüs-1	143	67	210
Eğitim seti	74(%70)	31(%30)	105
Test seti	74(%70)	31(%30)	105
Fetüs-2	166	12	188
Eğitim seti	94(%94)	6(%6)	100
Test seti	94(%94)	6(%6)	100

Çizelge 2.1'de de görüldüğü üzere gebelik yaşı ilerledikçe UA'daki PI ve RI indeksleri azalmaktadır. Bu indeksler üst limit sınırlarının üzerinde kalırsa fetüste hipoksi riski söz konusudur. Şekil 3.2, Fetüs-1'in Doppler ölçümlerini 2 boyutlu özellik uzayında göstermektedir. %90 eğrisinin üzerinde kalan veriler hipoksik riskli fetüsleri işaret etmektedir.





Şekil 3.3 Fetüs-1'in 3 boyutlu özellik uzayında yayılımını göstermektedir. Şekilden de anlaşılacağı gibi iki sınıf arasında ince bir geçiş şeridi görülmektedir.



Şekil 3.1 Antenatal fetüs risk değerlendirme sistemi



Şekil 3.2 Fetüs-1'in Doppler ölçümlerinin 2 boyutlu çizimi
(‘o’ hipoksik riskli fetüs, ‘*’ normal fetüs)




Şekil 3.3 Fetüs-1'in Doppler ölçümlerinin üç boyutlu çizimi

İkinci veri tabanı (Fetüs-2) gebeliklerinin 24 ile 39 haftaları arasındaki 188 gebe kadının UA ve OSA Doppler ölçüm değerleri, Trakya Üniversitesi Kadın-Doğum A.B.D. tarafından elde edilmiştir, bu ölçüm değerlerine ait bazı sonuçlar Çizelge 3.2’de gösterilmektedir.

Çizelge 3.2 24 ile 39 haftaları arasındaki bazı fetüslerin UA ve OSA’dan alınan Doppler ultrason ölçüm değerleri

Hafta	UA-PI	UA-RI	OSA_PI	OSA_RI
24	0.95	0.65	1.28	0.64
25	1.00	0.66	1.64	0.76
27	1.33	0.72	2.24	0.84
28	1.61	0.75	2.04	0.85
29	0.50	0.38	1.30	0.67
30	0.86	0.59	1.66	0.83
31	1.07	0.67	1.44	0.70
32	0.83	0.57	1.60	0.80
33	1.16	0.58	1.27	0.90
34	0.56	1.71	0.92	2.22
35	0.52	1.67	0.79	2.19
36	0.65	1.46	0.78	1.41
37	0.86	0.56	1.50	0.75
38	0.57	0.41	1.65	0.81
39	0.70	0.53	1.39	0.72
40	0.92	0.60	1.16	0.69





Daha önceki çalışmalardan (Chervenak ve Kurcak, 1996) elde edilen sonuçlar doğrultusunda hipoksik değerlendirme, “OSA-RI/UA-RI oranının 1’den küçük” olması olarak belirlenmiştir. Toplanan Doppler ölçümlerinin 12 tanesi hipoksik riskli, 166 tanesi normal fetüs olarak sınıflandırılmaktadır (Çizelge 3.1). Şekil 3.4 ve Şekil 3.5 bu ölçümlerin iki boyutlu ve üç boyutlu özellikli uzayındaki görünümünü göstermektedir.



Şekil 3.4 Fetüs-2 Doppler ölçümlerinin iki boyutlu çizimi

Önerilen sistemde, fetüsün hipoksi altında bulunma riskini değerlendirmek için UA ve OSA'den alınan Doppler ultrason indekslerinin kullanıldığından bahsedilmiştir. Sistem, öncelikle verinin örneklerini inceleyip temel bileşen analizi yaparak fetal hipoksiye belirli ölçümlerin etkisini görmeye çalışır. Daha sonrada, çeşitli parametrik ve parametrik olmayan karar tekniklerini kullanarak, bu indislerle, fetal hipoksi durumu ve riskini ayırtmaya çalışır.

Çalışmada 5x2 F testi (Alpaydın, 1999) uygulanarak kullanılan tekniklerin istatistiksel açıdan birbirlerine bir üstünlüğü olup olmadığı araştırılmıştır. Bunun için fetüsa ait veri tabanı, 100'er örnek'den oluşan 10 alt küme'ye bölünerek, bu alt kümelerden her seferinde iki alt küme seçilip biri algoritmanın eğitilmesinde, diğeri ise test edilmesinde kullanılarak algoritmaların her biri toplam onar kere çalıştırılmıştır. Algoritmaların hesaplama süresi ve başarı oranı bütün çalıştırmalar sonucunda elde edilen sonuçların ortalaması alınarak hesaplanmıştır.



Şekil 3.5 Fetus-2 Doppler ölçümlerinin üç boyutlu çizimi

4. TEMEL BİLEŞEN ANALİZİ (TBA)

Pearson (1901) tarafından ilk kez önerilen ve Hotelling (1933) tarafından büyük ölçüde geliştirilen Temel Bileşen Analizi (TBA) günümüzde çok geniş bir alanda kullanılmaktadır. Değişkenler arasındaki bağımlılık yapısının yok edilmesi ve/veya boyut indirgeme amacıyla kullanılan TBA başlı başına bir analiz olduğu gibi, başka analizler için veri hazırlama tekniği olarak kullanılmaktadır.

Bu bölümde, fetüs risk tayini probleminde elde ettiğimiz sonuçların yorumlanmasında yardımcı olması için TBA uygulayarak Fetüs-1 ve Fetüs-2 veri tabanlarının boyutları indirgenerek sınıfların özellik uzayında dağılımlarını görselleştirilmesi sağlandı.


4.1 Yöntem

N örnek sayısı ve p değişkenden oluşan veri matrisi X 'in p boyutlu uzaydaki durumu düşünülecek olursa, veri matrisi çok sayıda noktadan oluşan bir bulut olarak ifade edilebilir (Tatlıdil, 1996). Değişkenler arasında tam bağımsızlık söz konusu olamayacağı için bulut biçiminde ifade edilen geometrik şeklin eksenleri birbirlerine dik olmayacak ve tanımında yapılamayacaktır. Halbuki bu noktaları eksenleri birbirine dik bir elipsoid içerisine almak daha ayrıntılı ve açıklayıcı bilgi verecektir. Bu amaçla uygulanan dönüştürmede, noktaların ilk eksenler boyunca sahip oldukları toplam varyans değişmediği gibi yeni eksenler birbirlerine diktir. Hotelling tarafından temel bileşenlerin bulunması için önerilen teknikte X_{pxn} ham veri matrisi kullanıldığında varyans-kovaryans matrisinden, Z_{pxn} standartlaştırılmış değerler matrisi kullanıldığında ise varyans-kovaryans matrisinden yararlanılmaktadır. Birbirlerinden oldukça farklı sonuçlar verebilen bu iki yoldan hangisinin seçileceğine verilerin ölçü birimlerine göre karar verilmektedir. Verilerin ölçü birimleri ve varyansları birbirlerine yakın ise kovaryans matrisi, değilse korelasyon matrisi kullanılmaktadır.

Kullandığımız fetüs verilerinin ölçü birimleri birbirlerine yakın olmadığından Z_{pxn} standartlaştırılmış değerler matrisinin kullanılması uygun olacaktır. Bu durumda dönüştürme T_{pxp} doğrusal dönüştürme matrisi ile yapılır.

$$Y_{pxn} = T_{pxp}^T Z_{pxn} \quad (4.1)$$

Bu dönüştürme sonunda birbirleriyle bağımlı z_{ij} değerlerinden birbirinden bağımsız y_{ij} değerleri elde edilmektedir. Bu dönüşüm Şekil 4.1'de gösterilmektedir.



Şekil 4.1 Temel bileşenler dönüşümünün iki boyutlu uzayda gösterimi.

Temel bileşenlerin özellikleri ve sağladığı yararları kısaca özetleyecek olursak:

- X veri matrisinde değişkenler arasında bağımlılık söz konusu iken y_j vektörleri birbirlerinden bağımsız ve geometrik olarak y_j değerleri dik eksenlere göre elde edilmiştir.
- Eğer ilk m tane bileşen toplam varyansın büyük bir kısmını açıklıyorsa geriye kalan $p-m$ tane temel bileşen ihmal edilebilir. Bu durumda az bir varyans (bilgi) kaybıyla üzerinde çalışılan uzayın boyutu p 'den m 'ye indirgenmiş olur ($p > m$).

4.2 Temel Bileşen Analizinin Gerekliliği

Z matrisinin değişkenleri arasında tam ya da tama yakın bağımsızlık söz konusu olma durumunda, bağımsızlaştırma bir amaç olamayacağı gibi, boyut indirgemeden de önemli bir kazanç sağlanamaz. Çünkü;

$$R = \frac{1}{n-1} \sum_{j=1}^n z_j z_j^T = Z Z^T = I \quad (4.2)$$

özellliği nedeniyle z_j 'lerin y_j 'lere dönüştürülmesinden yine birim ilişki matrisine ulaşılabacaktır. Deneysel noktaların ilişki matrisi yukarıdaki gibi birim matris ise bu noktaların p boyutlu uzayda bir küre oluşturdukları söylenir. Bu kürenin eksenleri z_j 'ler yerine y_j 'ler olması durumunda önemli bir fark yaratmayacaktır. Bu nedenle böyle bir dönüştürme ile y_j 'lerin bulunmasına gerek yoktur. Ayrıca tüm eksenlerde eşit varyans olduğundan, dönüştürülmüş y_j 'lerden m tanesinin seçilerek boyut indirgenmesi de uygun değildir. Hangi durumlarda ilişki

matrisinin birim kabul edileceğini belirlemek için Barlett tarafından genelleştirilmiş varyans kavramını dayanan küresellik testi (4.3) önerilmiştir.

$$-\left[(n-1) - \frac{1}{6}(2p+5)\right] \log |R| \sim \chi^2_{\frac{1}{2}n(p-1)} \quad (4.3)$$

Burada n örnek sayısı, p değişken sayısıdır. Bu testi kullanarak Fetüs-1 ve Fetüs-2 veritabanları için TBA'nın uygun olup olmadığını belirlemeye çalışalım ve aşağıdaki hipotezleri önerelim:

$$\begin{aligned} H_0 : R &= I \\ H_A : R &\neq I \end{aligned} \quad (4.4)$$

Buna göre H_0 hipotezinin reddedilmesi durumunda TBA'nın kullanılması uygundur. Veritabanı bilgilerini (4.3)'de yerine koyarsak:

Fetüs-1 için

$$\left[(210-1) - \frac{1}{6}(2 \cdot 4 + 5)\right] \log(0.021) = 799.09 > 12.59 = \chi^2_{(6,0.05)}$$

Fetüs-2 için

$$\left[(188-1) - \frac{1}{6}(2 \cdot 5 + 5)\right] \log(0.056) = 531.44 > 18.31 = \chi^2_{(10,0.05)}$$

Buna göre H_0 hipotezi reddedilir ve bu verilerle her iki veritabanı içinde TBA'nın uygulanması uygundur.

4.3 Temel Bileşen Sayısının Belirlenmesi

TBA yönteminde, özdeğerlerin bulunmasından sonra m (önemli özdeğer) sayısına karar vermek gerekir. Bilinen en basit yöntemde (standartlaştırılmış veri matrislerinin kullanıldığı durumlarda), birden büyük değerli özdeğerlerin sayısı m sayısını vermektedir veya yaklaşık aynı mantığa dayanan $\sum_{j=1}^m \lambda_j / p \geq 2/3$ koşulunun sağlandığı en küçük m değeri önemli temel

bileşenlerin sayısı olarak belirlenmektedir.

Bir diğer yöntem ise örnek sayısının çok olduğu durumda kullanılan, Anderson (1984) tarafından genel olabilirlik oranından yararlanılarak geliştirilen:

$$(n-1) \sum_{j=m+1}^{m+g} \log \lambda_j + (n-1)g \log \frac{\sum_{j=m+1}^{m+g} \lambda_j}{g} \sim \chi^2_{\frac{g}{2}(g+1)-1} \quad (4.5)$$

dir. Bu yöntemde

$$\begin{aligned} H_0 : \lambda_{m+1} = \dots = \lambda_{m+g} = \lambda_p. \\ H_A : \lambda_{m+1} \neq \lambda_{m+l}; l \neq 1, \dots, g \end{aligned} \quad (4.6)$$

hipotezleri kullanılmaktadır. Burada m önemli bulunan temel bileşen sayısı, g ise ihmal edilen boyut sayısıdır (p=m+g). Bu yöntemde test istatistik değerinin khi-kare tablo değerini aşması durumunda H_0 hipotezi reddedilmekte ve m sayısı bir artırılarak H_0 hipotezi kabul edilinceye kadar sürdürülmektedir.

Kullanılan diğer yöntemler arasında, Cattel tarafından geliştirilmiş olan özdeğerlerin veya varyans açıklama oranlarının çizimi (scree graph) yönteminin kullanımı oldukça pratik ve yaygındır. Bu yöntemde varyans açıklama oranlarındaki hızlı düşüş belirlenerek temel bileşen sayısına karar verilmektedir (Mardia vd., 1989).

R korelasyon matrislerini kullanarak Fetüs-1 ve Fetüs-2'nin özdeğerlerini, öz vektörlerini ve temel bileşen değerlerini bulmaya çalışalım. Fetüs-1'in özdeğerleri

$$\lambda_j : 3.140 \quad 0.633 \quad 0.162 \quad 0.065 \quad = 4 = \sum_{j=1}^4 \lambda_j$$

$$\% : 79 \quad 16 \quad 4 \quad 1 \quad \cong 100$$

Buna göre birinci temel bileşen toplam varyansın % 79'unu (3.140/4) açıklarken diğerleri sırasıyla % 16, % 14 ve % 1'ini açıklamaktadır.

Boyut indirgeme amacıyla kaç tane temel bileşen kullanacağımıza karar vermek için (4.5)'i kullandık. Burada ilk olarak değeri 1'den büyük olan özdeğerlerin önemli öteki özdeğerlerin

önemsiz olduğunu düşünerek $\sum_{j=1}^m \lambda_j / p \geq 2/3$ kuralını sağlayıp sağlamadığına baktığımızda

$$\sum_{j=1}^m \lambda_j / p = 3.140 / 4 = 0.79 > 2/3$$

kuralın sağlanmış olduğunu görürüz. Bu da demektir ki birinci temel bileşen problemi tek başına tanımlamaya yeterlidir.

Buna göre $(R-\lambda_i)t_i=0$ kullanılarak özdeğer vektörleri bulunur ve

$$v_i = \sqrt{\lambda_i} t_i \quad (4.7)$$

kullanılarak temel bileşen hesaplanır:


$$y_{1i} = 5.56x_{1i} + 1.12x_{2i} + 0.29x_{3i} + 0.12x_{4i}$$

Aynı işlemleri Fetüs-2 verisi içinde tekrarlayarak temel bileşenleri bulalım. Fetüs-2'nin özdeğerleri

$$\lambda_j : 2.350 \quad 1.456 \quad 0.92 \quad 0.16 \quad 0.11 = 5 = \sum_{j=1}^5 \lambda_j$$

$$\% : 47 \quad 29 \quad 18 \quad 3 \quad 2 = 99 \approx 100$$

Birinci temel bileşen toplam varyansın % 47'sini (2.350/5) açıklarken diğerleri sırasıyla % 29, % 18, % 3 ve % 2'sini açıklamaktadır. Scree grafik yöntemini kullanarak önemli özdeğerlerin sayısını belirlemeye çalışalım.




Şekil 4.2 Fetüs-2 için özdeğerlerin varyans açıklama oranları

Burada en hızlı düşüş birinci ve ikinci özdeğer arasındadır. Ancak % 47 açıklama oranının yeterli bulunamayacağı düşünülecek olursa ikinci hızlı düşüş noktası ikinci özdeğerden sonra olduğu için temel bileşen sayısı 2 olarak belirlenir ve seçilen ilk iki temel bileşen toplam varyansın %76'sını açıklamaktadır. O halde, iki temel değişken bu problemi tanımlamakta yeterli olacaktır. (4.7) kullanılarak temel bileşenler hesaplanır:

$$y_{1i} = -0.22 x_{1i} + 0.50 x_{2i} + 0.52 x_{3i} + 0.48 x_{4i} + 0.45 x_{5i}$$

$$y_{2i} = 0.13 x_{1i} - 0.47 x_{2i} - 0.44 x_{3i} + 0.51 x_{4i} + 0.55 x_{5i}$$

Şekil 4.3 TBA'den elde edilen 2 yeni temel bileşene göre Fettis-2 verisinin 2 boyutlu uzaydaki dağılımını göstermektedir.



Şekil 4.3 Fettis-2 verisinin 2 temel bileşenle gösterimi

5. KARAR TEKNİKLERİ

5.1 Karar Tekniklerinin Modellenmesi

Temel öğrenme problemi, altı bileşen tarafından tanımlanabilir: X , Y , D , F , P ve L . Sırasıyla, ilk dört bileşen giriş değerleri (nitelik vektörü), çıkış değeri, karar ve karar kural uzayları. Burada X , keyfi bir kümedir, Y , $A \in \{0,1\}$, ve F X 'den D içine bir fonksiyon ailesidir. Beşinci bileşen olan, P , $Z=XY$ olasılık dağılımının ortak ailesidir. Örnekler, bu dağılımlardan rastgele bağımsız olarak seçilirler. Son bileşen, YxD den R reel sayı kümesine giden L kayıp fonksiyonudur. Sınıflayıcı $z_i=(x_i,y_i) \in Z$, $i=1, 2, \dots, N$ örnekleri ile iyi eğitildiyse, tanınmayan örnekleri test etmek için hazır demektir. Çıkış değeri mevcut sınıfları yada aksi takdirde sıfır değerini gösterir. Kayıp fonksiyonu L ve risk fonksiyonu I sınıflandırma performansının ölçüsü olarak tanımlanır. Daha sonra karar kuralının riski yanlış öngörü olasılığı olarak tanımlanır. Sınıflandırmanın ana amacı risk fonksiyonu I 'yi en aza indirgeyerek, optimum sonuca yaklaştırmaktır.

Diğer bir deyişle, sınıflandırmanın genel amacı, verilen sınıfta hatalı sınıflandırma olasılığını küçültmek eğiliminde olan çeşitli bileşenleri belirlemektir. Sonuç olarak, sınıflayıcı tasarlamının amacı gözlenen veri kümesine en uygun sınıflayıcıyı bulmaktır. Bunu yapmak için olasılığı en yüksek değere çıkarmayı denemek gereklidir.

$$P(C | D) = \frac{P(D | C)P(C)}{P(D)} \quad (5.1)$$

Bu formülde C sınıflayıcıyı (bütün özellikleriyle), D gözlenen veri grubunu, ve $P(D|C)$ de C sınıflayıcısının gözlenen D verisini üretme olasılığını temsil eder. (5.1)'e monotonik logaritmik dönüşümü uygularsak

$$\ln P(C | D) = \ln P(D | C) + \ln P(C) - \ln P(D) \quad (5.2)$$

elde ederiz. Böylelikle (5.2)'yi maksimize ederken (5.1)'i de maksimize etmiş oluruz. Verinin olasılık dağılımı, sınıflayıcıdan bağımsız olduğu için, $\ln P(D)$, $\ln P(C|D)$ 'yi en yüksek büyüklüğe çıkaran çözüme hiç bir katkıya sahip olmayacaktır ve bu yüzden ihmal edilebilir. (5.2)'nin ikinci terimi sınıflayıcının kendi olasılığını temsil etmektedir. Bu ise sınıflayıcının daha önceden bilinen olasılığı olduğundan ihmal edilebilir. İlk terim, verinin olasılığı için verilen sınıflayıcıdır. Böylece sınıflayıcı probleminin seçimi, $\ln P(D|C)$ 'yi en yüksek büyüklüğe çıkarmak şartına eşittir.

Üstelik veriler y çıktısı ve x girişi diye 2 bölüme ayrılırsa:

$$\ln P(D | C) = \ln P((x, y) | C) = \ln P(y | x \cap C) + \ln P(x) \quad (5.3)$$

Nihayet, x girdisinin ağa bağlı olmadığını varsayarsak, (5.3)'ün son terimi, $\ln P(D|C)$ 'yi en yüksek büyüklüğe çıkarmakda hiç bir etkiye sahip olmaz. Sonuç olarak, sadece ilk terim olan $P(y|x \cap C)$ 'yi en yüksek büyüklüğe çıkarmaya ihtiyacımız var.

Sınıflandırma probleminde, çıkış 0 ve 1'lerin dizisi olarak tanımlanır ve sınıflayıcının her bir elemanı, p , 0 ile 1 arasında değer alan istenilen y çıktısının benzer elemanının olasılığını temsil eder.

$$\ln P(y | x \cap C) = \prod_{i=1}^n p_i^{y_i} (1 - p_i)^{(1 - y_i)} \quad (5.4)$$

(5.4)'ün logaritmasını en yüksek değere çıkardığımızda

$$\phi = \sum_{i=1}^n (y_i \ln p_i + (1 - y_i) \ln(1 - p_i)) \quad (5.5)$$

zincir kuralını kullanarak herhangi bir α parametresine göre (5.5) en yüksek değere çıkarılabilir:

$$\frac{\partial \phi}{\partial \alpha} = \frac{(y_i - p_i)}{p_i(1 - p_i)} \frac{\partial p_i}{\partial \alpha} \quad (5.6)$$

(5.6)'yi maksimize eden α değerlerini elde etmek için, türevi sıfıra eşitleyalım:

$$y_i - p_i = 0 \quad (5.7)$$

Sonuçta (5.7)'yi sağlayan parametreleri seçerek optimum karara uyan maksimum sınıflandırıcıyı elde edebiliriz.

5.2 Karar Teknikleri

Sınıflandırma probleminin en önemli konusu, sınıflandırma teknikleri arasında o problem için en uygun yaklaşımı seçmektir. Öncelikle bu tekniklere kısaca gözatalım:

5.2.1 k-En Yakın Komşuluk Algoritması (k-EYK)


k-en yakın komşuluk (k-EYK) tekniği yerel, parametrik olmayan bir örüntü tanıma algoritmasıdır (Fukunaga, 1990; Bishop, 1995; Ripley, 1996; Smolensky vd., 1996). Burada, fetüs özellik uzayında bilinmeyen fetüs koşulu en yakın bilinen fetüsler cinsinden ortaya

çıkarılır. Eğitime ihtiyaç duymayan bu teknikte, yeni bir örneğin sınıflandırılma kararı, en yakın k örneğinin çoğunluğuna dayandırılır. Diğer bir deyişle, yerel oy işlemi, en yüksek oy ile bilinmeyen x örneğinin w_i sınıfına ait olup olmadığına karar verir.

$$\text{Eğer } k_i = \max \{k_1, \dots, k_L\} \text{ ise } x \in w_i \quad k_1 + \dots + k_L = k \quad (5.8)$$

burada k_i , en yakın k komşuluğu arasındaki w_i ($i=1, \dots, L$) sınıfına ait komşuluk sayısıdır. Pratikte x örüntüsünü tanımak için, bütün örnekler arasında k tane en az uzaklıktaki örnekler hesaplanır. Burada çeşitli uzaklık kuralları kullanılabilir: minkowski-normu uzaklığı, öklid uzaklığı, mahalnobis ve entropi yada kullback-leibler uzaklığı vb. Gerçekte bu yöntem, yerel ortamda Bayes karar teorisinden yakınsamaktadır (Fukunaga, 1990). Bu işlem ağırlıkların ve gauss ağırlıkların oylanmasına kadar genişletilebilir (parzen penceresi). Ayrıca bu yöntemle elde edilen başarımlar teorik olarak elde edilebilecek en küçük hatanın iki katı kadardır, örnek sayısının artırılması, daha yüksek başarımlı sınıflayıcı seçimi v.b. etkenlerle ancak hata yarıya düşürülebilir (Duda ve Hart, 1973).

k -EYK karar verme problemine bir örnek Şekil 5.1 gösterilmektedir. Şekilde hipoksik riskli fetüsler 2 ile normal fetüsler ise 1 ile etiketlenmiştir. $k=8$ komşuluğunda 1'inci sınıfa ait patternlerin sayısı daha çok olduğu için bilinmeyen X patterninin 1'inci sınıfa ait olduğuna yani fetüsün normal olduğuna karar verilir.




Şekil 5.1 8-en yakın komşuluk'ta karar verme (Nilsson, 1996).

k -EYK'da komşuluk sayısı seçimi çok kritiktir. Bu değer seçilirken dikkat edilmesi gereken husus özellik vektörlerinin sayısına göre ne çok büyük, ne de çok küçük olması gerektiğidir. Burada k 'nın seçiminde çapraz-sağlama (cross-validation) kullanılmaktadır.

Çizelge 5.1 herbir sınıf için başarımlar sonuçlarını ve eğitim zamanını göstermektedir. Çizelgedeki rakamlar sınıfların karakteristik yapıları hakkında bize bilgi vermektedir. Bu da bize göstermektedirki sınıflar birbirinden ayrı bir dağılım göstermektedir. Şekil 5.2 Fetüs-1 ve Fetüs-2 veritabanlarının çeşitli k komşuluk değerleri için doğru sınıflama yüzdeleri göstermektedir.

Çizelge 5.1 k-EYK sonuçları

K	1.Sınıf (%)		2.Sınıf (%)		Tüm veri (%)		Hesaplama zamanı (sn)	
	Fetüs-1	Fetüs-2	Fetüs-1	Fetüs-2	Fetüs-1	Fetüs-2	Fetüs-1	Fetüs-2
1	96	70	95	100	95	98	0.109	0.112
4	91	85	96	99	95	99	0.111	0.112
7	92	83	96	99	94	98	0.111	0.113
10	90	83	96	99	94	98	0.116	0.113




Şekil 5.2 Fetüs-1 ve Fetüs-2 veritabanlarının çeşitli k komşuluk değerleri için doğru sınıflama yüzdeleri

5.2.2 Diskriminant Analizi

Diskriminant analizi, birimleri en az hata ile ait oldukları sınıflara ayırmak için yapılan işlemler topluluğu olarak tanımlanabilir. Diskriminant analizinin temeli, incelenen örneğin sınıfının belirlenmesini sağlayacak bir fonksiyonunun bulunmasıdır. Bu fonksiyonun

bulunmasında, belirlenecek grupların ortalamaları arasındaki farklılığın maksimum olması amaçlanmaktadır (Tatlıdil, 1996).

Problemi şekille ifade etmek için, örneğe ilişkin x_1 ve x_2 özelliklerinin ölçülmüş olduğunu varsayalım. Bu durumda bireyleri iki boyutlu uzayda birer nokta olarak düşünebiliriz. A grubuna ait bölgenin R_1 ile ve B grubuna ait bölgenin R_2 ile gösterimi aşağıdaki şekilde verilmiştir.



Şekil 5.3 2 boyutlu uzayda diskriminant analizi (Tatlıdil, 1996).

Şekil 5.3'ün incelenmesinde de görüldüğü üzere bireylere ilişkin p tane özelliğin olması durumunda bu özelliklerin her birinin ayrı ayrı ele alınarak bireylerin sınıflara ayrılması gerçekten güç ve hatta bazı durumlarda olanaksızdır. Bu nedenle diskriminant analizinde amaç, çok değişkenli problemin tek değişkenli biçime dönüştürülmesidir. Yani tüm değişkenlerin uygun ağırlıklarla katılacağı tek bir değişkenin (fonksiyon) elde edilmesidir.

Bir bireye ait p değişkenden bulunacak olan bağıntı


$$y_i = a_1x_{i1} + a_2x_{i2} + \dots + a_px_{ip} \quad (5.9)$$

biçiminde gösterilebilir. Burada $x_1, x_2, \dots, x_p$ değişkenleri, $a_1, a_2, \dots, a_p$ ise bu değişkenlere ilişkin ağırlıkları (katsayıları) göstermektedir. Bu fonksiyona diskriminant (ayırıcı) fonksiyon denmektedir.

5.2.3 Diskriminant Fonksiyonları

Diskriminant fonksiyonları, genellikle maksimum ayrılabilirlik şartını gözeterek giriş değişkenleri uzayını çıkış değerine dönüştürürler (Fukunaga, 1990; Bishop, 1995; Ripley, 1996). Diskriminant analizi, optimal karar için ayrıştırıcı olarak bilinen özelliklerin veya değişkenin en iyi setini tanımlamak için kullanılan global bir tekniktir. Doğrusal, karesel ve

doğrusal olmayan gibi polinomların çeşitli derecelerinde diskriminant fonksiyonları tanımlanmaktadır (Şekil 5.4).



Şekil 5.4 Diskriminant fonksiyonları a) DDF b) KDF c) ÇKA

5.2.3.1 Doğrusal Diskriminant Fonksiyonu (DDF)

Doğrusal diskriminant fonksiyonu aşağıdaki gibidir:

$$L(x) = \left\{ x' - \frac{1}{2}(\mu_1 + \mu_2)' \Sigma^{-1} (\mu_1 + \mu_2) \right\} \quad (5.10)$$

Bu fonksiyonun kullanılabilmesi için verilerin normal dağılımlı ve grupların ortak varyans-kovaryans matrisine sahip olması gereklidir. Burada μ_1 , μ_2 1'inci ve 2'inci grupların ortalama değeri, Σ ise varyans-kovaryans matrisidir.

Fonksiyonun değeri $L(x) < 0$ ise örnek R_2 bölgesine, değilse R_1 bölgesine sınıflandığı yöntemde risk fonksiyonu ise

$$R_{LDF}(x) = (1 + \exp(L(x) - \log(\hat{q}_2 / \hat{q}_1)))^{-1} \quad (5.11.a)$$

Burada n_1 ve n_2 1 ve 2 gruptaki örnek sayısı olmak üzere:

$$\begin{aligned}\hat{q}_1 &= \frac{n_1}{n_1 + n_2} \\ \hat{q}_2 &= \frac{n_2}{n_1 + n_2}\end{aligned}\quad (5.11.b)$$

5.2.3.2 Karesel Diskriminant Fonksiyonu (KDF)

Verilerin normal dağıldığı ancak, grupların varyans-kovaryans matrislerinin farklı olmaları durumunda kullanılan fonksiyon,

$$Q(x) = \frac{1}{2} \log \left| \frac{\Sigma_2}{\Sigma_1} \right| - \frac{1}{2} \left(\mu_1' \Sigma_1^{-1} \mu_1 - \mu_2' \Sigma_2^{-1} \mu_2 + x' (\Sigma_1^{-1} \mu_1 - \Sigma_2^{-1} \mu_2) \right) - \frac{1}{2} x' (\Sigma_1^{-1} - \Sigma_2^{-1}) x \quad (5.12)$$

biçiminde tanımlanmaktadır. Burada Σ_1 ve Σ_2 1'inci ve 2'inci gruba ilişkin varyans-kovaryans matrisleridir. Yukarıdaki eşitlikte $\Sigma_1 = \Sigma_2 = \Sigma$ alınacak olursa, karesel fonksiyonun doğrusal fonksiyona eşit olacağı görülür.

Fonksiyonun değeri $Q(x) < 0$ ise örneğin R_2 bölgesine, değilse R_1 bölgesine sınıflandığı yöntemde risk fonksiyonu, doğrusal fonksiyonunkine çok benzeyen

$$R_{QDF}(x) = (1 + \exp(Q(x) - \log(\hat{q}_2 / \hat{q}_1)))^{-1} \quad (5.13)$$


eşitliği ile ifade edilmektedir.

5.2.3.3 Doğrusal Olmayan Diskriminant Fonksiyonları-Çok Katmanlı Algılayıcı (ÇKA)

Çok katmanlı algılayıcı (ÇKA), sınıf bölgeleri arasında karar sınırları çizmek için yaygın olarak kullanılan doğrusal ve parametrik olmayan bir diskriminant fonksiyonudur. Genellikle giriş katmanı, bir yada iki saklı katman ve çıkış katmanından oluşmaktadır (Şekil 5.5).

İleri beslemeli bir ağ olan ÇKA (Haykin, 1994; Bishop, 1995; Ripley, 1996) her saklı biriminde tekil ayrıştırıcı fonksiyonlar (5.14) ile elde ettiği çıkış verilerinin denetçiliğinde giriş veriyile öğrenen ileri beslemeli bir ağıdır. Böylece fetüs özellik uzayını alt uzaylara bölüp, sonrada her bir parçayı çıkış düğümünde toplamak ÇKA ile mümkün olmaktadır.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (5.14)$$



Şekil 5.5 Çok katmanlı algılayıcının yapısı

ÇKA'yı eğitmek için genellikle, oldukça popüler bir algoritma olan geriye hata yayılımı (back-propagation, BP) algoritması kullanılır. Bryson ve Ho (1969), Werbos (1974), Parker (1985) ve Rumelhart (1987) vb. tarafından birçok kere geliştirilen geriye yayılım algoritması, çok katmanlı ileri beslemeli ağlar için ağırlık uzayındaki eğimi azaltmakta kullanılan bir optimizasyon algoritmasıdır.

İleri faz ve geri faz olmak üzere iki fazdan meydana gelen bu algoritmanın ileri fazında giriş vektörü ağ'a tanıtılır ve etkisi ağ boyunca katman katman iletilerek, çıkış katmanından çıkış değeri üretilir (5.16).

$$y_i^{(H)} = f^{(H)} \left(\sum_j w_{ij}^{(HI)} x_j \right) \quad (5.15)$$

$$y_i = f^{(T)} \left(\sum_j w_{ij}^{(TH)} y_j^{(H)} \right) \quad (5.16)$$

Burada x girdi değeri, $y^{(H)}$ saklı katmanın çıkış değeri, $w^{(HI)}$ saklı katman ile giriş katmanı arasındaki ağırlık değerleri, $w^{(TH)}$ ise saklı katman ile çıkış katmanı arasındaki ağırlık

değerleridir. İleri faz boyunca yapay sinir ağılarındaki (YSA) ağırlık değerlerinde bir değişme olmaz.

$$E = \frac{1}{2} \sum \sum (y_{ji} - Y_{ji})^2 \quad (5.17)$$

Algoritmanın geri fazında ise hata düzeltme kuralı uygulanmaktadır. Bu kuralda, YSA'nın çıkış değeri (y_{ji}) ile istenilen çıkış değeri (Y_{ji}) arasındaki fark, hata değeri (5.17) olarak adlandırılır ve bu hata değeri (δ) YSA'da geriye doğru iletilerek ağırlık değerleri değiştirilir. Bu işlem istenilen hata değerine ulaşıncaya kadar tekrarlanır. Giriş katmanını I, saklı katmanı H, ve çıkış katmanını (T) ile gösterecek olursak, hesaplama şu şekilde yapılır:

$$\delta_{ji}^{(T)} = (y_{ji} - Y_{ji}) \quad (5.18)$$

$$\delta_{ji}^{(H)} = \sum_k \delta_{ki}^{(T)} f'_{ki}(T) w_{kj}^{(TH)} \quad (5.19)$$

$$\frac{dE}{dw_{jk}^{(TH)}} = \sum_i \delta_{ji}^{(T)} f'_{ji}(T) y_{ki}^{(H)} \quad (5.20)$$

$$\frac{dE}{dw_{jk}^{(HT)}} = \sum_i \delta_{ji}^{(H)} f'_{ji}(H) X_{ki} \quad (5.21)$$

5.2.3.4 Sonuçlar

ÇKA'nın öğrenmesinde saklı katmandaki düğüm sayısı ile öğrenme oranı oldukça önemli bir yere sahiptir. Çizelge 5.3 ve Çizelge 5.4 Fetüs-1 ve Fetüs-2 veri tabanlarının farklı düğüm sayısı ve öğrenme oranları için başarımlarını göstermektedir. Fetüs-1 için en iyi başarımlar öğrenme oranı 0.11 olan 8 saklı katman düğümlü ÇKA'dan elde edilirken, Fetüs-2'de öğrenme oranı 0.11 olan 3 ve 8 saklı katman düğümlü ÇKA'lardan elde edilmiştir.

Çizelge 5.2 Fetüs-1'e ait ÇKA sonuçları

SAKLI KATMANDAKİ DÜĞÜM SAYISI												
Öğrenme oranı	3		4		5		6		7		8	
	Başarı yüzdesi (%)	Cpu-zamanı (sn) (1000 iterasyon)	Başarı yüzdesi (%)	Cpu-zamanı (sn) (1000 iterasyon)	Başarı yüzdesi (%)	Cpu-zamanı (sn) (1000 iterasyon)	Başarı yüzdesi (%)	Cpu-zamanı (sn) (1000 iterasyon)	Başarı yüzdesi (%)	Cpu-zamanı (sn) (1000 iterasyon)	Başarı yüzdesi (%)	Cpu-zamanı (sn) (1000 iterasyon)
0.11	86	0.1	90	0.2	86	0.1	93	0.2	94	0.25	99	0.29
0.21	90	0.1	84	0.1	86	0.1	89	0.2	84	0.25	92	0.29
0.31	74	0.1	86	0.1	76	0.1	87	0.2	76	0.25	87	0.29
0.41	71	0.1	75	0.1	74	0.1	74	0.2	77	0.25	76	0.3
0.51	70	0.1	74	0.1	75	0.1	74	0.2	74	0.25	78	0.3
0.61	74	0.1	82	0.1	75	0.1	74	0.2	74	0.25	74	0.28
0.71	70	0.1	74	0.1	74	0.1	74	0.2	74	0.25	74	0.28
0.81	74	0.1	74	0.1	74	0.1	74	0.2	74	0.25	74	0.28
0.91	74	0.1	74	0.1	74	0.1	70	0.2	74	0.25	74	0.3

Çizelge 5.3 Fetüs-2'ye ait ÇKA sonuçları

	SAKLI KATMANDAKİ DÜĞÜM SAYISI											
	3		4		5		6		7		8	
Öğrenme oranı	Başarı yüzdesi(%)	Cpu-zamanı (sn) (1000 iterasyon)	Başarı yüzdesi(%)	Cpu-zamanı (sn) (1000 iterasyon)	Başarı yüzdesi(%)	Cpu-zamanı (sn) (1000 iterasyon)	Başarı yüzdesi(%)	Cpu-zamanı (sn) (1000 iterasyon)	Başarı yüzdesi(%)	Cpu-zamanı (sn) (1000 iterasyon)	Başarı yüzdesi(%)	Cpu-zamanı (sn) (1000 iterasyon)
0.11	99	0.1	98	0.2	97	0.1	97	0.2	98	0.25	98	0.29
0.21	97	0.1	97	0.1	96	0.1	97	0.2	97	0.25	96	0.29
0.31	98	0.1	95	0.1	97	0.1	97	0.2	94	0.25	97	0.29
0.41	97	0.1	94	0.1	97	0.1	96	0.2	95	0.25	97	0.3
0.51	96	0.1	95	0.1	97	0.1	94	0.2	94	0.25	98	0.3
0.61	94	0.1	95	0.1	97	0.1	97	0.2	95	0.25	97	0.28
0.71	94	0.1	95	0.1	94	0.1	96	0.2	96	0.25	94	0.28
0.81	96	0.1	96	0.1	94	0.1	94	0.2	94	0.25	94	0.28
0.91	94	0.1	94	0.1	94	0.1	94	0.2	95	0.25	94	0.3

Çizelge 5.4'te ise diskriminant fonksiyonlarının üçünde sınıflara göre başarı yüzdeleri gösterilmektedir. Görüldüğü üzere diskriminant fonksiyonlarının üçünde başarı oranları kullanılan diğer algoritmalarından daha yüksektir. DDF ve KDF hesaplamasal olarak ÇKA'ya göre daha basit ve eğitilmesi daha kolaydır fakat model kompleksleştikçe sınıfların ayırımında sorunlarla karşılaşılabilir.

Çizelge 5.4 Diskriminant fonksiyonlarının başarı yüzdelerinin karşılaştırılması

		1.Sınıf (%)	2.Sınıf (%)	Tüm veri (%)	Eğitim zamanı (sn)
Fetüs-1	<i>DDF</i>	95	97	96	0.34
	<i>KDF</i>	96	99	98	0.56
	<i>ÇKA</i>	95	98	97	0.10
Fetüs-2	<i>DDF</i>	71	97	95	0.73
	<i>KDF</i>	81	98	97	0.76
	<i>ÇKA</i>	78	99	98	0.11

5.2.4 Karar Ağacı Algoritmaları

Yaygın kullanılan tek değişkenli (univariate) ve çok değişkenli (multivariate) karar ağacı algoritmaları her bir adımda, sınıflandırma için veriyi en iyi ayıran karar düğümünü belirler (Breiman, 1984).

Tek değişkenli karar ağaçlarının her bir düğümünde, sadece bir özellik kullanılır, ve bu özellik, sürekli değerler alıyorsa, karar formülü


$$x_i > c_k \quad (5.22)$$

dir ve düğüm bu şekilde ikili (binary) bir bölme yapar. Burada x_i i'inci giriş özelliği ve c_k ise uygun olarak seçilen eşik değeridir. Eğer x_i m değerden oluşan ayrık özellik ise düğüm m tane bölüme yapar. Sonuç olarak tek değişkenli karar ağaçları her karar düğümünde tek değişkenin değerine bakarak eksene dik bölmeler yapar ve bu da genellikle çok dallı ağaçlar ve zayıf genelleme ile sonuçlanır.

Çok değişkenli karar ağaçlarında ise, her bir karar düğümü, en iyi giriş özelliğinden değil ama giriş özelliklerinin en iyi doğrusal birleşmesinden seçilir. Her bir düğümde karar, şu biçimdedir:

$$\sum_{i=1}^d w_i x_i > w_0 \quad (5.23)$$

Burada w_i 'ler ağırlık ve w_0 'da eşik değeridir. Şekil 5.6 tek değişkenli ve çok değişkenli karar ağacı algoritmaları tarafından yapılan çeşitli ayrımları göstermektedir.



Şekil 5.6: Tek değişkenli ve çok değişkenli karar ağacı yapıları

5.2.4.1 C4.5 Karar Ağacı Algoritması

Tek değişkenli karar ağacı algoritmalarından olan C4.5, ağacın kökündeki en iyi özelliği seçerek yukarıdan-aşağıya doğru bir ağaç yapısı oluşturarak öğrenir (Breiman vd., 1984; Quinlan, 1993).

Her bir örneğin özellikleri, eğitim örneklerini ne kadar iyi sınıfladığına bakmak için istatistiksel bir teste tabi tutulur. Bu şekilde en iyi özelliği ve bu özelliğin en iyi eşik değeri bulunur. En iyi özellik seçilip, ağacın test düğümünde kullanıldıktan sonra kökün çocuk düğümleri, seçilen özellik sürekli ise, $x_i < a$ ve $x_i > a$, olarak yaratılır. Ayrık özellik durumunda ise kökün yaratılan m tane çocuk düğüm değeri aşağıdaki gibidir.

$$x_i = a_1, x_i = a_2 \dots x_i = a_m \quad (5.24)$$

Burada m x_i değişkeninin olası farklı bütün değerlerinin sayısıdır. Bütün bu işlemler eğitim setindeki bütün örnekler kullanılarak, her bir çocuk düğümündeki en iyi sonucu veren en iyi özelliği belirlemek için yinelemeli bir şekilde tekrarlanır. Agresif arama (Greedy search) algoritması olan C4.5'in bu formu asla işleme konan bir düğüme geri dönmez.

5.2.4.2 Sınıflama ve Regresyon Ağaçları (SRA) Algoritması

Doğrusal çok değişkenli ağaç-kurma algoritmalarından olan SRA'da (Breiman, 1984), en iyi özellik değil ama özelliklerin en iyi doğrusal kombinasyonu seçilir. Bu doğrusal kombinasyon her bir x_i değişkeninin w_i ağırlıklarıyla çarpımından oluşmaktadır.

SRA'da ana işlem değişkenlerin w_i ağırlık değerlerinin belirlenmesidir. Mevcut değişkenlerin katsayılarını bulmak için adım adım (step-wise) algoritması kullanılır. Bu algoritmanın her bir adımında $x_1, x_2, \dots, x_n$ değişkenlerinin en iyi bölmeyi yapan kombinasyonu aranır.

L 'inci döngünün başlangıcında $v \leq c$, bölmeyi yapan doğrusal kombinasyon olsun. Sabit γ için, SRA en iyi bölünmeyi yapacak formu arar.

$$v - \delta (x_1 + \gamma) \leq c, \quad (5.25)$$

Burada $x_1 + \gamma \geq 0$ iken $\delta \geq \frac{v-c}{x_1 + \gamma}$ ve $x_1 + \gamma \leq 0$ $\delta \leq \frac{v-c}{x_1 + \gamma}$ dir.

δ 'nın aranması $\gamma = -0.25, 0.0, 0.25$ değerleri için sürdürülür.

Üç bölünmenin sonuçları ideal bölünme kıstası (partition-merit criterion) kullanılarak karşılaştırılır. δ ve γ 'nin en iyi değerleriyle v 'nin değeri (5.26) kullanılarak güncellenir.


$$v' = w'_1 x_1 + w'_2 x_2 \quad (5.26)$$

burada $w'_1 = w_1 - \delta$ ve $c' = c + \delta\gamma$ dir.

Şekil 5.7 örnek veri setinde SRA algoritmasının ilk adımını göstermektedir. Başlangıç doğrusu $x_1 + x_2 < 0$ olarak verilmiştir. $-0.25, 0$ ve 0.25 olarak gösterilen doğrular $\gamma = -0.25, 0$ ve 0.25 için en iyi ayırıcılardır.

Burada sadece x_1 değişkeninin katsayıları değişmektedir. $\gamma = 0$ doğrusu bir sonraki adım için seçilir.

Bu arama işlemi diğer bütün $x_2, x_3, \dots, x_n$ değişkenleri için tekrarlanarak güncellenmiş $v_1 < c_1$ ayırıcı elde edilir. Döngünün son adımı en iyi c_i 'yi bulmak içindir. Bu aşamada sistem son bölünmedeki karmaşıklığı en aza indirgeyecek olan ayırıcıyı arar. Karmaşıklık belli bir ϵ değerinin altına inene kadar arama işlemi devam eder.




Şekil 5.7 SRA algoritmasının bir adımı


5.2.4.3 Sonuçlar

Eğitim sonunda kural çıkarttıklarından dolayı karar ağaçlarının sonuçlarının anlaşılması ve yorumlanması oldukça kolay olmaktadır. Çizelge 5.5'te de görüldüğü üzere her iki veri tabanında da C4.5 algoritması hipoksik riskli ve sağlıklı fetüslerin sınıflandırmasını SRA'ya göre daha yüksek performansla sonuçlandırmaktadır. Fetüs-2 veritabanında hipoksik riskli fetüslerin sayısı oldukça az olduğundan dolayı SRA algoritması kural çıkaramamıştır. Bu yüzden Fetüs-2 veri tabanının değerlendirilmesinde SRA algoritması değerlendirmenin dışında tutulmuştur.


Şekil 5.8 ve Şekil 5.9 Fetüs-1 için C4.5 ve SRA algoritmasının çıkardığı kurallar şemasal olarak ifade edilmektedir. Şekil 5.10'da da Fetüs-2 için C4.5'in çıkardığı kural şemasal olarak gösterilmektedir.



Şekil 5.8 C4.5'in Fetüs-1 veritabanı için çıkardığı sınıflandırma kuralının şemasal gösterimi.



Şekil 5.9 SRA'nın Fetüs-1 veritabanı için çıkardığı sınıflandırma kuralının şemasal gösterimi.



Şekil 5.10 C4.5'in Fetüs-2 veritabanı için çıkardığı sınıflandırma kuralının şemasal gösterimi

C4.5 algoritmasının çıkardığı kural daha önceki çalışmalardan elde edilen -Şekil 3.4'te de görüldüğü üzere- gebelik yaşı ilerledikçe hipoksik riskli fetüslerin UA'daki Doppler ölçümleri artarken, OSA'deki Doppler ölçümleri azalmaktadır hipotezinide doğrulamaktadır.

C4.5 yöntemi, veri kümesi küçük ve bu kümede az sınıf varsa, çok değişkenli metodlardan daha iyi performans göstermektedir. Ayrıca C4.5 hızlı ve kolay öğrenir bir algoritma olduğu gibi, kuralları da kolayca yorumlanabilir. Fakat değişkenler birbiriyle çok ilişkiliyse, tek değişkenli metod yeterli olmayabilir ve çok değişkenli metodların kullanılması gerekebilir.

Çizelge 5.5 Karar ağacı algoritmalarının başarı yüzdeleri

		1.Sınıf (%)	2.Sınıf (%)	Tüm veri (%)	Eğitim zamanı (sn)
Fetüs-1	C4.5	92	94	94	0.69
	SRA	70	94	88	10.12
Fetüs-2	C4.5	72	97	95	1.01
	SRA	Hipoksik riskli veri sayısı az olduğundan algoritma çıkarım yapamamıştır			

5.2.5 Radyal Tabanlı Fonksiyonlar (RTF)

Melez ağ yapısına bir örnek olan Radyal Tabanlı Fonksiyonlar (RTF), eğiticili ve eğitici-siz öğrenme yapısını aynı ağ üzerinde birleştirdiği için bazı problemlerin çözümünde oldukça

kullanılırdılar. Genelde eğiticişiz olarak öğrenen bir katman ve onu takip eden bir (veya daha fazla) geri besleme methodu ile öğrenen katmanlardan oluşan bir yapıya sahiptirler (Şekil 5.11).

Saklı katmanın gerçeklediği fonksiyona taban fonksiyon denir ve herhangi bir çekirdek (kernel) fonksiyon (5.27) kullanarak çıkış değeri üretir.


$$b_i(x) = e^{-\left[\frac{(x-u_i)^2}{2\sigma_i^2}\right]} \quad i=1,2,\dots,M \quad (5.27)$$

RTF'nin çıkış düğümü ise

$$y = \sum_{i=1}^M w_i b_i(x) \quad (5.28)$$

burada b_i birinci katmandaki j 'inci düğüm karşılık gelen çıkış, x girdi değeri, u_j j 'inci düğüm için gauss fonksiyonunun merkezidir; σ_j j 'inci düğüm için ölçekleme parametresidir ve M 'de birinci katmandaki düğümlerin sayısıdır.

Fetüs özellik uzayını oluşturan yerel reseptör alanlarının kullanımı RTF ile mümkün olmaktadır. Herbir yerel reseptördeki bilgiyi çıkışta değerlendirmekle genel bir risk değerlendirmesi yapmak mümkün olur.



Şekil 5.11 Radyal tabanlı fonksiyon ağı (Michie vd., 1994)

Ayrıca, RTF ağıının doğası gereği karar sürecine bulanıklık kavramının (Hellendoorn, 1997) katılmasında mümkün olabilmektedir. Örneğin, gauss taban fonksiyonu merkezdeki belirli

örneğin yerel bulanıklık derecesini hesaplamakta kullanılabilir. Bu konu bir sonraki bölümde incelenecektir. Sonuç olarak RTF ağları, yapısı itibarıyla yerel bilgiyi özetleyen gaussların ağırlıklı değerlendirilmesi ile global kararı üretirler

5.2.5.1 Ağırlıkların Optimize Edilmesi

Yukarıda RTF'lerin basitçe doğrusal sistemleri çözerek eğitildiğinden bahsetmiştik. Burada tartışılan bir kaç incelik vardır.

$y_{ki}^{(H)}$ i'inci örneğin k'inci RTF'nin çıkış değeri olsun j'inci hedef düğümünün çıkış değeri w_{jk} ağırlıklarıyla çarpılarak elde edilir.

$$y_{ji} = \sum_k w_{jk} y_{ki}^{(H)} \quad (5.29)$$

i örneğinin j hedef düğümü için istenilen çıkış değeri Y_{ji} olsun. Eğer bu (5.17) daki hata ölçümüne yazılacak olursa

$$E(W) = \frac{1}{2} \sum_{ji} \left(\sum_k w_{jk} y_{ki}^{(H)} - Y_{ji} \right)^2 \quad (5.30)$$

(5.30)'un türevi olan (5.31)'in değeri sıfır olduğunda (5.30) minimum değeri alır.

$$\frac{dE}{dw_{rs}} = \sum_k \sum_i w_{rk} y_{ki}^{(H)} y_{ji}^{(H)} - \sum_i Y_{ri} y_{si}^{(H)} \quad (5.31)$$

R, RTF'nin çıkışlarının korelasyon matrisi olsun,

$$R_{jk} = \sum_i y_{ki}^{(H)} y_{ji}^{(H)} \quad (5.32)$$

Eğim (gradyant) sıfırlandığında E'yi minimum yapan w^* ağırlık matrisi bulunur:

$$w_{jk}^* = \sum_r \sum_i Y_{ri} y_{si}^{(H)} (R^{-1})_{rk} \quad (5.33)$$

Böylelikle problem HxH karesel R matrisinin tersi alınarak çözülür. Burada H Radyal tabanlı fonksiyonların sayısıdır.

Eğer R tekil bir matris değilse, matrisin tersi LU ayrıştırıcısı (Renals ve Rohwer, 1989) gibi standart methodlar kullanılarak alınır. Eğer iki RTF'nin merkezleri birbirlerine çok yakınsa R tekil matris olabilir (eğer eğitim örneklerinin sayısı en azından H'in sayısı kadar değilse kesin tekil matristir). Korelasyon matrisinin tekil olmamasını garanti edecek pratik bir yöntem yoktur. Bu sorundan sakınmanın en emin yolu, daha çok hesaplama gerektiren tekil değer

ayırıştırma metodunu kullanmaktadır. Bu metotta önce matris diagonalize edilip, sonra değeri sıfırdan büyük özdeğerlerin tersi alınır, sonra değerler tekrar orijinal koordinatlara çevrilierek matrisin yaklaşık tersi hesaplanır. Bu en küçük kareler (least mean squares - LMS) duyarlılığında ters matrise optimal minimum-norm yakınsamasını sağlar.

Söz konusu probleme başka bir yaklaşım mümkündür (Broomhead ve Lowe, 1988). Bu metod (5.31)'deki E'nin türevinden elde edilen $H \times H$ doğrusal sisteminin çözümü yerine, (5.30)'deki hata formülün kendisine doğrusal sistem oturtmaya odaklanır. p eğitim örneklerinin sayısı olsun.

$$\sum_k w_{jk} y_{ki}^{(H)} = Y_{ji} \quad (5.34)$$

$p=H$ olmadığı sürece bu karesel bir sistemdir. Genel olarak gerçek çözüm yoktur, fakat en küçük kareler duyarlılığında optimal çözüm $y^{(H)}$ 'in psödo-tersi tarafından verilir (Kohonen, 1989). $y_{ji}^{(H)}$ elemanlarından oluşan matris

$$w^* = Y y^{(H)*} \quad (5.35)$$

Bu formül direkt olarak uygulanır. $Y^+ = Y^T (Y Y^T)^+$ birim matrisi (5.35)'ye uygulanarak psödo-ters metodunun (5.33) ile aynı sonucu verdiğini göstermektedir.

$$w^* = Y \tilde{y}^{(H)} (y^{(H)} \tilde{y}^{(H)})^+ \quad (5.36)$$

bütün veri tabanına bağlı olan matrisin tersini yada psödo-tersini almak için gerekli olanlar bunu gerçel zamanda olmayan (batch) metodla yaparlar. Kalman filtrelemesi olarak bilinen gerçel zamanlı (online) varyant olmasında mümkündür (Scalero & Tepedelenlioğlu, 1992). Eğer başka bir örnek, tersin yeniden hesaplanmasını gerektirmeyen (5.32) toplamasına eklenirse, R^{-1} ters korelasyonunun güncellenmesi için gerekli tam ifadenin var olduğu gerçeğine dayandırılmaktadır.

5.2.5.2 RTF Ağının Eğitilmesi

Bir RTF ağının eğitilmesi, RTF birim merkezlerinin, σ ölçekleme parametresinin ve saklı katmandan çıkış katmanına olan ağırlıkların belirlenmesi ile yapılır.

RTF'nin merkezlerini seçmek için bir çok algoritma kullanılmaktadır. Burada önemli olan özellik uzayında merkezlerin dağılımının benzerlik göstermesi yada en azından eğitim verisiyle aynı bölgeyi kapsamasıdır. Bu tezde, merkezler verilerin bir alt kümesi olarak seçilmiştir. Küme merkezlerini bulmak için K-ortalama kümeleme algoritması

kullanılmıştır. Bu algoritmaya göre giriş bilgilerinin yoğun olduğu yerlerde merkezlerde yoğun bir şekilde dağıtılmıştır.

Gauss algılama bölgesi gibi doğrusal olmayan fonksiyonlarla sınırlanan RTF ağırları için merkez noktaları seçildikten sonra fonksiyonlar için uygun varyansların (σ) hesaplanması gerekmektedir. σ ölçekleme parametresi, merkezler arasında geniş bölgelerin oluşmadığını, örneklerle karşılık gelen merkezler olmadığını, vede bunun zıttı olarak bütün örneklerle hemen hemen aynı cevabı veren bir çift merkez olmamasını garanti eder. Bu problem, hacmin, yarıçapa olan bağlılığından dolayı yüksek boyutlu özellik uzaylarında oldukça yaygındır (Prager ve Fallside, 1989). Bu çalışmada, gauss fonksiyonlarının standart sapması, her bir koordinat yönü için o yöndeki en yakın merkeze olan uzaklık olarak alındılar.

Eğitmenin en son adımında doğrusal en küçük kareler (DEKK) yöntemi kullanılarak istenilen hata değerinde çıkış değerlerini üretecek şekilde gizli katmandan çıkış katmanına olan ağırlıklar belirlendi. Çizelge 5.6 her iki veritabanının başarımlarını göstermektedir.

Çizelge 5.6 RTF ağırlarının başarımları yüzdeleri

Veritabanı	1.Sınıf (%)	2.Sınıf (%)	Tüm veri (%)	Eğitim Zamanı (sn)
<i>Fetüs-1</i>	95	98	97	0.25
<i>Fetüs-2</i>	60	99	97	0.44

5.2.6 Bulanık Yapay Sinir Ağları

Bulanık karar verme günümüzde yaygın uygulama alanı olan diğer sınıflama ve karar verme yöntemlerinden biridir. Bulanık karar verme, özellik vektörlerinin bir sınıfa ait olmalarını üyelik fonksiyonu ile değerlendirir. Yani, bir özellik vektörü bir sınıfa tamamen ait değil, belli bir üyelik değeri ile ait olabilir. Bu siyah ve beyaz arasındaki kesin ayrım yerine, gri tonları kullanarak yapılan ayrım olarak düşünülebilir.

Bulanık yapay sinir ağı (Bulanık-YSA) sistemi ise fonksiyon yakınsama özelliğine eş zamanlı olarak öğrenme, birleştirme ve kural tabanlı bilgi çıkarma yeteneğine sahiptir. Bu bölümde temel bulanık-YSA yaklaşımı sunulmuştur.

5.2.6.1 Bulanık-YSA Modeli

Verilen $x \in \mathfrak{R}^n$ girdisine göre çıkış vektörü $y \in \mathfrak{R}^m$ 'nin tanımlamasını üyelik değerine göre oluşturan $y=F(x)$ sinir ağını ele alalım. Burada uzmanın bir takım bulanık kurallar açısından aynı dönüşüm hakkında bilgi sağladığını farzedelim. Kuralın *tanım bölgesi* ifadesi, x 'in sonuca uygulanabilmesi için gerekli koşulları belirler. Giriş uzayının bu bölgesi $b_i(x)$ taban fonksiyonu tarafından tanımlanır. Burada sistem, taban fonksiyonunun sadece ikilik değerler üretmesine izin vermek yerine (*tanım bölgesi* geçerli ise 1, değil ise 0), verilen giriş değeri kuralının ağırlık değerini temsil eden sürekli pozitif değerlere izin verir.

Kuralın sonucunun *sonuç*ı gibi matematiksel bir ifade formunda tanımlanabildiğini farzederek, çıkış değeri $w_i(x)$ 'e eşittir. Burada $w_i(x)$ giriş uzayının (yada giriş alt uzayının) fonksiyonudur ve sabit bir değer, polinom yada başka bir sinir ağı olabilir. Bu notasyon ise (Hollatz ve Tresp, 1992)'de gösterilen Takagi-Sugeno tipi bulanık sistemine uyar.

Girdinin verilen durumu için çeşitli kurallar aktif olabildiği için, aktif kuralların sonuçlarının ortalamasıyla ağırlıklandırılan ağırlık çıkış değerini tanımlarız. Burada ağırlıklandırma oranı verilen girişin taban fonksiyonunu aktiviteye oranlarız.

$$y(x) = \frac{\sum_i w_i(x) b_i(x)}{\sum_j b_j(x)} \quad (5.37)$$

Bu $b_i(x)$ taban fonksiyonu ve $w_i(x)$ sonucunun serbestlik derecesini belirlemek için oldukça genel bir kavramdır. Eğer $b_i(x)$ ve $w_i(x)$ YSA tarafından tanımlanırsa, yerel uzmanların adaptif karışımlarıyla oldukça yakın ilgisi vardır. Diğer bir yandan, taban fonksiyonun doğrusal adaptif κ_i ağırlık faktörü ile $b_i(x) = \exp\left[-(x - c_i)^T \Sigma_i^{-1} (x - c_i)\right]$ çok değişkenli gauss fonksiyonlarına yakınsanır.

$$b_i(x) = \kappa_i \exp\left[-\frac{1}{2} \sum_j \frac{(x_j - c_{ij})^2}{\sigma_{ij}^2}\right] \quad (5.38)$$

ve eğer w_i sabit ise, Moody ve Darken (1989) ve Speccht (1990) tarafından tanımlanan normallizasyonu yapılmış taban fonksiyon ağı elde edilir.

Bazı durumlarda uzman kuralları basit mantıksal ifadeler kullanarak formüle etmek isteyebilir. Örnek olarak: Eğer $[x_1 \in A \text{ ve } x_4 \in B]$ yada $x_2 \in C$ ise $y=C$

$$\text{Tanım bölgesi} : b_i(x) = \exp \left[-\frac{1}{2} \frac{(x_1 - a)^2 + (x_4 - b)^2}{\sigma^2} \right] + \exp \left[-\frac{1}{2} \frac{(x_2 - c)^2}{\sigma^2} \right] \quad (5.39)$$

Sonuç: $w_i(x)=Y$

A, B ve C linguistik değişkenlerin, linguistik değerlerini göstermektedir. Linguistik değerler a, b yada c ortalamalı gauss üyelik fonksiyonlarını tanımlamaktadır. Bütün taban fonksiyonları için gaussların genişlikleri σ 'ya eşit kabul edilmektedir. Bu formülasyon Takagi ve Sugeno (1985)'teki bulanık mantık yaklaşımıyla ilişkilidir. Bulanık üyelik fonksiyonları ve gauss taban fonksiyonları arasındaki bağlantı Wang ve Mendel (1992) tarafından incelenmiştir.

5.2.6.2 Bulanık Yapay Sinir Ağı Karar Mekanizması

Zeki veri analizi yöntemi olarak önerilen bulanık-YSA, bulanık taban ile veri ile sürülen sistemler (data-driven systems) yaklaşımının kural tabanlı bilgi çıkarma özelliklerini birleştirir.

Σ_i köşegen kovaryans matrisi ile gauss taban fonksiyonunun ele alalım. Burada σ_{ij}^2 Σ_i 'nin j'inci köşegen elemanıdır. $A_j^i = \mu_{ij}$ parametresi *Tanım bölgesi*'nin en büyük geçerliğinin bulunduğu giriş uzayının j'inci boyutundaki pozisyonunu tanımlar. $Bölge_{ij} = \sigma_{ij}^2$ parametresi yaklaşık olarak *Tanım bölgesi*'nin j'ninci giriş boyutunda geçerli olduğu bölgeyi tanımlar.

2 boyutlu giriş uzayından seçilen örnek veriyi ele alırsak *Kural₁*:

$$\text{Eğer } x_1 \in A^1_1 (bölge_{11}=R_{11}) \text{ ve } x_2 \in A^1_2 (bölge_{12}=R_{12}) \text{ ise } y=Y_1$$

Burada $\sigma_{11} = R^1_1$, $\sigma_{12} = R^1_2$ ve $w_1=Y_1$ ile gösterilirken $\mu_{11} = A^1_1$ ve $\mu_{12} = A^1_2$ ise gauss merkezleridir. Kurallar ile uygun veri bölgeleri arasındaki ilişki bu şekilde tanımlanır.

Daha sonra bu kuralları YSA'nın eğitilmesinde kullanırız. Bulanık üyelik değerini çıkarmak için RTF tabanlı bulanık-YSA ve ÇKA tabanlı bulanık-YSA tekniklerini kullandık (Gürgeç vd, 2001). RTF tabanlı teknikte öncelikle yerel bulanıklık derecelerini ve bulanık kümeler üyeliklerini hesapladıktan sonra veri ile sürülen sistemler tekniğini kullanarak tek üyelik değerinden bütün üyelik derecesini çıkardık. RTF ağının çıkış değeri risk derecesini üretir (bu tek katmanlı ağın yapısı (5.27) ve (5.28)'de tanımlanmıştı). Sonuç olarak ağ yapısı itibarıyla, üyelik değeri aracılığıyla bulanıklık derecesini üretebilmektedir.

2'inci metotta gauss taban fonksiyonu ilk önce seçilen örneğin yerel bulanıklık derecesini hesaplamak için kullanılır. Daha sonra seçilen komşulukta örnek sınıfa ait ağırlıklandırılmış örnekler hesaplandıktan sonra normalize edilirler yada aynı komşuluktaki bütün örneklerin ağırlıklandırılmış toplamına bölünürler. Her bir eğitim örneği için bulanıklık derecesi atandıktan sonra ÇKA ağı geriye yayılım algoritmasını kullanarak bu verilerin eğitimciğinde eğitilir. ÇKA'nın test fazında ağı bilinmeyen giriş değerleriyle test edilir (Gürgeç vd., 1991). Sonuçlar bulanıklık derecesi olarak yorumlanır.

0 ile 1 arasında üyelik değerleri, takip edilen fetüsün hipoksik risk faktörü olarak yorumlanır. Çünkü, bu değer fetüsün özellik vektörünün uzaydaki risk bölgesine olan uzaklığıyla ilgilidir. Test fazında, bilinmeyen ultrason indisleri ağı uygulanır ve çıkış değerleri hipoksik risk derecesi olarak değerlendirilir. Risk derecesi 0.7 ile 0.95 arasında ise risk derecesi alarm düzeyindedir. Bu fetüsün mevcut durumunu düzeltmek için "acil müdahale" kararı olarak yorumlanabilir. Eğer risk derecesi 0.4 ile 0.7 arasında ise fetüs şüpheli durumdadır ve yakın takibe alınması gerekir. Fetüs üç gün sürekli olarak takip edildikten sonra durumu hakkında karar verilir. Değer 0 ile 0.4 arasında ise fetüs normal değerlere sahiptir.

5.2.6.3 Sonuçlar


Çizelge 5.7 bulanık sinir ağı tekniklerinden elde edilen sonuçları göstermektedir. Çizelgede de görüleceği üzere ÇKA ve RTF ağıları birbirine çok yakın sonuçlar vermiştir.

Bulanık-YSA tekniği, bir takım risk dereceleri ile doğum öncesinde fetüsün risk değerlendirilmesinde kötü koşulların açığa çıkarılmasında uygun bir metod olduğunu kanıtlamaktadır. Doğrusal olmayan ayıraç olarak ÇKA kara bir kutu olarak çalışırken çıkış değeri bulanık mantık ile modellenilebilmektedir. Risk derecesi artarken fetüs için tehlike olasılığında artmaktadır. Risk derecesi 0.7 ile 0.9 arasında gibi oldukça yüksek bir değerde iken fetüs acil olarak doktor gözetimine ihtiyaç duymaktadır.

Sonuç olarak bulanık-YSA yada gri kutu modeli anne karnındaki fetüsün durumunun değerlendirilmesinde risk derecesiyle ilişkili olarak ek bilgi sağlayarak bir çok değişkene ilişkin en iyi kararın verilmesine yardımcı olmak için oldukça yararlı bir metoddur.

Çizelge 5.7 Bulanık sinir ağı karar sonuçları

	Duyarlık	Özgüllük	Gerçek Negatiflik	Gerçek Pozitiflik
<i>Fetüs-1</i>				
Bulanık YSA (ÇKA)	88%	100%	100%	93%
Bulanık YSA (RTF)	100%	95%	90%	100%
<i>Fetüs-2</i>				
Bulanık YSA (ÇKA)	93%	100%	100%	93%
Bulanık YSA (RTF)	98%	100%	100%	98%



a) Global eğitim uzayının yerel bölgeleri

$$\text{Bulanık karar} = \frac{\sum_{\text{aynı sınıf}} d_i}{\sum_{\text{bütün sınıflar}} d_k}$$



b) Eğitim uzayının yerel bölgesi

Şekil 5.12 Risk üyelik fonksiyonları a) RTF tabanlı bulanık-YSM tekniği b) ÇKA tabanlı bulanık-YSM tekniği

6. DEĞERLENDİRME TESTLERİ

6.1 Algoritmaların İstatiksel Tıbbi Değerlendirilmesi

Kullanılan algoritmaların hastalığı teşhis edip etmediği 2x2 lik bir matris aracılığıyla kolayca bulunabilmektedir. Çizelge 6.1 bu hesaplamaların nasıl yapıldığını göstermektedir. Burada, bilinen bir pozitif sonuç (hastalık mevcut) test sonuçlarında da gözüküyorsa bu karara gerçek pozitif (GP), bilinen negatif bir sonuç (hastalık yok) test sonucunda da negatif olarak bulunmuşsa gerçek negatiflik (GN), bilinen pozitif bir sonuç negatif olarak tespit edilmişse yanlış negatif (YN), bilinen negatif bir sonuç pozitif olarak tespit edilmişse yanlış pozitiflik (YP) olarak adlandırılır.

Algoritmanın duyarlılığı, hastalık mevcut iken kullanılan metodun bunu tanıma olasılığı, özgüllük ise hastalık yok iken metodun hastalığın olmadığını bulma olasılığıdır. Burada, duyarlık ve özgüllüğün kullanılan metodun normal ve normal olmayan hasta sayısını değil olasılığını verdiğine dikkat etmek gerekmektedir.

$$\text{Duyarlık} = \frac{GP}{GP + YN} \quad (6.1)$$

$$\text{Özgüllük} = \frac{GN}{GN + YP} \quad (6.2)$$

$$\text{Pozitif olma olasılığı} = \frac{GP}{YP + GP} \quad (6.3)$$

$$\text{Negatif olma olasılığı} = \frac{GN}{GN + YN} \quad (6.4)$$

Çizelge 6.1 2X2 sonuç tablosu

Test Sonuçları	Normal	Anormal
Normal	Gerçek Negatif (GN)	Yanlış Negatif (YN)
Anormal	Yanlış Pozitif (YP)	Gerçek Pozitif (GP)

Çizelge 6.2 ve Çizelge 6.3 Fetüs-1 ve Fetüs-2 veri tabanlarına ait istatistiksel tıbbi analiz sonuçlarını göstermektedir. Önerilen bütün karar verme teknikleri daha önce yapılan

alıřmalardan daha yksek performans verdikleri iin anne karındaki fetsn risk deęerlendirilmesinde uygun birer yntem olarak kullanılabilir.

izelge 6.2 Fets-1 iin algoritmaların istatistiksel tıbbi bařarı tablosu

	Duyarlık	zgllk	Gerek Negatiflik	Gerek Pozitiflik
C4.5	% 87	% 97	% 92	% 94
SRA	% 86	% 90	% 70	% 95
KA	% 95	% 98	% 96	% 98
DDF	% 93	% 98	% 95	% 97
KDF	% 98	% 99	% 97	% 99
k-EYK	% 89	% 98	% 96	% 95
RTF	% 96	% 98	% 95	% 98

izelge 6.3 Fets-2 iin algoritmaların istatistiksel tıbbi bařarı tablosu

	Duyarlık	zgllk	Gerek Negatiflik	Gerek Pozitiflik
C4.5	% 61	% 98	% 72	% 97
KA	% 95	% 99	% 78	% 100
DDF	% 67	% 98	% 72	% 97
KDF	% 75	% 99	% 82	% 98
k-EYK	% 98	% 98	% 70	% 100
RTF	% 81	% 97	% 60	% 99

Ayrıca Fetüs-2 veritabanının güvenilirliğini test etmek için sistemi Fetüs-1 veritabanı ile eğitip Fetüs-2 veritabanı ile test ettik. Elde edilen sonuçların daha düşük performans vermesinin (Çizelge 6.4) sebepleri olarak iki veritabanının farklı kişiler tarafından toplanması ve Fetüs-1 veritabanının sadece UA'den elde edilen verilerden oluşması olarak yorumlanabilir.

Çizelge 6.4 Fetüs-1 ile eğitilip Fetüs-2 ile test edilen algoritmaların istatistiksel tıbbi başarı tablosu

	Duyarlık	Özgüllük	Gerçek Negatiflik	Gerçek Pozitiflik
C4.5	% 58	% 98	% 72	% 96
ÇKA	% 86	% 99	% 78	% 99
DDF	% 64	% 98	% 72	% 97
KDF	% 68	% 99	% 82	% 97
k-EYK	% 91	% 98	% 70	% 99
RTF	% 72	% 97	% 60	% 98

6.2 5x2 cs F Testi

Birden fazla sınıflandırma algoritmasının sonuçlarının karşılaştırıldığı uygulamalarda temel problemlerden biri, önerilen sınıflandırma algoritmaları arasında sınıflandırma doğruluğu açısından istatistiksel bir fark olup olmadığıdır. Bunun için bir çok istatistiksel testler kullanılır (T test, vb). Bu çalışmada biz 5x2 çapraz sağlamalı (cs) F test (Alpaydın, 1999)'ini kullandık. Burada veritabanı eğitim ve test kümesi olmak üzere iki alt kümeye ayrılır. Ve algoritmalar her seferinde bu farklı kümeler üzerinde çalıştırılırlar. Bu testte veritabanı 5 farklı alt kümeye bölünür ve bu alt kümelerin her birinde eşit boyutta 2 kümeye ayrılır (eğitim ve test kümesi olarak). Algoritmalar, her seferinde bu farklı kümeler üzerinde çalıştırılırlar ve algoritmaların başarı oranları ve hesaplama süreleri kaydedilir (Algoritmaların hesaplama süresini bulmak için bütün çalıştırmalar sonucunda elde edilen zamanların ortalaması alınır). Daha sonra eğitim kümesiyle, test kümesi yer değiştirilerek algoritmalar tekrar çalıştırılır, sonuçlar kaydedilir.

$p_i^{(j)}$ iki algoritmanın hata oranları arasındaki farktır ($i=1, \dots, 5$ ve $j=1, 2$). i 'inci alt kümenin ortalama değeri

$$\bar{p}_i = (p_i^{(1)} + p_i^{(2)}) / 2 \quad (6.5)$$

ve tahmini varyansı

$$s_i^2 = (p_i^{(1)} - \bar{p}_i)^2 + (p_i^{(2)} - \bar{p}_i)^2 \quad (6.6)$$

ile hesaplanır.

Eğer $X_1 \sim \chi_n^2$ ve $X_2 \sim \chi_m^2$ ve X_1 ile X_2 birbirinden bağımsız ise (Ross, 1987)

$$\frac{X_1 / n}{X_2 / m} \sim F_{n, m} \quad (6.7)$$

dir. Bundan dolayı,

$$f = \frac{\sum_{i=1}^5 \sum_{j=1}^2 (p_i^{(j)})^2}{2 \sum_{i=1}^5 s_i^2} \quad (6.8)$$

yaklaşık olarak 10 ve 5 serbestlik derecesinde F dağılımına uygundur. Burada f 'in almış olduğu değere bakarak, algoritmaların aynı hata oranına sahip olmasına göre hipotez reddedilir yada hipotez belirli bir güven aralığında kabul edilir.

Daha önceden açıkladığımız sebepten dolayı SRA sınıflama algoritması dışındaki bütün algoritmaları 5x2 cs F testi kullanarak karşılaştırdık, sonuçlar Çizelge 6.5 ve Çizelge 6.6'te gösterilmektedir. Algoritmalarından herhangi birinin diğerlerine göre istatistik açıdan üstün olması için test sonucunun %95'ten daha büyük bir değer vermesi gerekmektedir. Çizelge 6.5'e bakıldığında Fetüs-1 veritabanı için KDF tekniği C4.5'ten, RTF ise DDF'den istatistiksel olarak daha iyi sınıflandırma yapmaktadır. Fetüs-2 veritabanı içinse ÇKA ve k-EYK karar teknikleri RTF'den istatistiksel olarak daha iyi sınıflandırma yapmaktadır. (Çizelge 6.6). Önerilen diğer sınıflandırma algoritmaları arasında doğru sınıflandırma oranı açısından, bu veri tabanları için, istatistiksel olarak bir fark yoktur.

Çizelge 6.5 Fetüs-1 veritabanı için algoritmaların 5x2 cs F test güven aralığı tablosu

C4.5	SRA	ÇKA	DDF	KDF	k-EYK	RTF
0	71.9	80.7	73.3	97.9	80.7	90.9
71.9	0	88.1	73.9	80.4	88.1	75.1
80.7	88.1	0	44.3	50.8	0	32.6
73.3	73.9	44.3	0	86.4	44.3	97.5
97.9	80.4	50.8	86.4	0	50.8	66.9
80.7	88.1	0	44.3	50.8	0	32.6
90.8	75.1	32.6	97.5	66.9	32.6	0

Çizelge 6.6 Fetüs-2 veritabanı için algoritmaların 5x2 cs F test güven aralığı tablosu

C4.5	ÇKA	DDF	KDF	k-EYK	RTF
0	84.7	45.5	44.0	84.7	66.1
84.7	0	76.6	52.0	0	97.0
45.5	76.6	0	52.0	76.6	50.0
44.0	52.0	52.0	0	52.0	56.7
84.7	0	76.6	52.0	0	97.0
66.1	97.0	50.2	56.7	97.0	0

7. ANTENATAL FETÜSA AİT RİSK DEĞERLENDİRME SİSTEMİ İÇİN KARAR TEKNİĞİNİN SEÇİMİ

Bütün metodların kendilerine has avantaj, dezavantaj ve uygulanabilirlikleri vardır. Burada önemli olan uygulama için hangi metodun bu veri tabanları için en uygun olacağının belirlenmesidir. Kullanılan algoritmaların özelliklerini kısaca özetleyecek olursak:

k-EYK, test ölçümleri hakkında kabaca fikire sahip olmak için yerel bilgi çıkarmaktadır. Eğitim verisi ve test verisi aynıdır ve en yakın örnek bilginin yarısını verir. Bu teknik küçük boyutlu verilerde bilinmeyen Doppler ölçümleri hakkında hızlı bir fikir edinmek için kullanılabilir.

Ağ olarak RTF, yerel dağılımları birleştirerek global cevabı üretmektedir. DDF, KDF ve ÇKA metodları arasında, doğrusal olmayanı (ÇKA), karar bölgesi için performans açısından en iyi ve en uygun çözümü vermektedir. Karar ağacı algoritmalarından C4.5 tarafından sağlanan nitelikler arasında en başlıcası, fetüsa ait riskin etkenleri hakkında ön bilgi vermesidir. Diğer taraftan niteliklerin doğrusal birleşmesini aynı zamanda dikkate aldığı için, SRA ağaç algoritması, DDF'ye benzemektedir.

Bizden önceki çalışmalarda fetüsün sağlık durumunun değerlendirilmesinde tek bir metod uygulanmış, hiç birinde birden çok metod bir arada uygulanarak ve bu metodların birbirlerine karşı istatistiksel açıdan bir üstünlükleri olup olmadığı araştırılmamıştır. Biz bu tezde, bu boşluğu doldurmaya ve en uygun sınıflama algoritmasını belirlemeye çalıştık.

Genellikle verinin boyutu, hesaplama zamanı, performans ve üretilen sonucun önemi gibi çeşitli etmenler, uygulanacak tekniğin seçiminde önem taşımaktadır. Bu etmenlere göre, fetüsa ait risk değerlendirilmesinde karar tekniği için en uygun yaklaşım biçimini seçerken

- Doğruluk (yüksek duyarlılık ve özgüllük)
- Öğrenme zamanı
- Anlaşılabilirlik

kriterleri göz önüne alınmıştır. Doğruluk oranı kriteri göz önüne alındığında algoritmaların hepsinin özgüllük ve gerçek pozitiflik oranının oldukça yüksek olduğu gözlenmiştir (Şekil 7.1 ve Şekil 7.2). Kısaca, algoritmalar sağlıklı bir fetüsü kolaylıkla ayırt edebilmektedir. Hipoksik riskli fetüsün tanınmasında ise Fetüs-1 veri tabanında ÇKA, KDF, ve RTF teknikleri; Fetüs-2 veri tabanında ise ÇKA ve k-EYK teknikleri öne çıkmaktadır. Fetüs-2 veritabanı için

SRA'nın sonuçları -kullanılan 10 veri setinden 8 tanesini hipoksik riskli fetüs sayısının yeterli olmadığından dolayı eğitilemediğinden- değerlendirilmede göz ardı edilmiştir.

Eğitim süreleri (Çizelge 7.1) söz konusu olduğunda bütün algoritmaların oldukça kısa sürelerde eğitildikleri gözlenmiştir. SRA 10.12 sn ile en uzun eğitim süresine, ÇKA ve k-EYK ise en kısa eğitim süresine sahiptir.


En son kriter olan anlaşılabilirlik kriterine gelince: DDF ve KDF hesapsal olarak YSA'ya göre daha basit ve eğitilmesi daha kolaydır fakat model karmaşıklıkça sınıfların ayırımında sorunlarla karşılaşabilmektedir.

Kişisel bilgisayarların gücü arttıkça ve karmaşık veri yapılarını modellemedeki yeteneği ile YSA metodları (ÇKA, RTF), diğerlerine oranla çok daha iyi sınıflama başarımı göstermekte ve gün geçtikçe daha fazla kullanılmaktadır. Fakat, uzun eğitim zamanı ve bir uzman tarafından uygulanma ihtiyacı duymaları sebebiyle her zaman tercih edilmemektedirler.


Çizelge 7.1 Algoritmaların eğitim süresi

	Hesaplama Süresi (sn)	
	Fetüs-1	Fetüs-2
C4.5	0.69	1.01
SRA	10.12	--
ÇKA	0.3	0.35
DDF	0.34	0.73
KDF	0.56	0.76
k-EYK	0.11	0.11
RTF	0.25	0.44

Sonuç olarak, uygulamada basitlik ve küçük boyutlu verilerde hızlı sonuç vermesi nedeniyle k-EYK, doğruluk ve hız söz konusu olduğunda ÇKA ve daha çok analitik bilgiyi göstermeye ihtiyaç duyulduğunda C4.5'in kullanılması uygun olabilir.



Şekil 7.1 Fetus-1 için algoritmaların karşılaştırılması




Şekil 7.2 Fetüs-2 için algoritmaların karşılaştırılması

8. SINIFLAYICILARIN BİRLEŞTİRİLMESİ: ÇOĞUL SINIFLAYICI İLE FETÜSÜN HİPOKSİK RİSK KOŞULLARININ BELİRLENMESİ

Farklı sınıflandırma algoritmaları içerikleri ve öğrenme farklılıkları nedeni ile aynı problem için değişik ayıracılar üretebilmektedir. Dolayısıyla sınıflandırıcılar farklı hatalar yapabilmektedirler. Bu sebeple, birden çok sınıflandırıcıyı bir araya getirerek ortak bir karara varılması sınıflandırma performansını arttırabilmektedir. Değişik karakterde sınıflandırıcılar kullanmak ve bu sınıflandırıcıları çoğullamak başarımı arttırabilmekte ve sonuçları daha güvenilir kılmaktadır (Xu vd., 1992).

Bu amaçla, k-EYK, DDF, KDF, ÇKA, RTF ve C4.5 ağaç algoritması gibi farklı öğrenme algoritmalarından oluşan çoğul-sınıflandırıcı bir sistem tasarlayarak fetüsün hipoksik risk altında bulunma koşullarını değerlendirdik. Çoğul sınıflandırıcı, teorik olarak kendini oluşturan sınıflandırıcılardan daha az başarılı olamaz ve bu uygulamada da elde edilen sonuçlar bunu kanıtlamaktadır.

Global ve yerel sınıflayıcılar farklı öznelilik uzayı bölgelerinde çalıştıklarından dolayı başarı oranları ve hata yaptıkları örüntüler farklılık gösterir. Bu yüzden, birden fazla global ve yerel sınıflayıcının birleşmesinden oluşan öğrenme sistemlerinde sınıflayıcılar farklı örüntülerde hata yapacağından dolayı sistemin hata oranı azalacaktır. Şekil 8.1 de birden fazla sınıflayıcıdan oluşan bir ağırlıklı consensus sistemi görülmektedir.



Şekil 8.1 Çoğul Sınıflandırıcı

Her bir öğrenme algoritmasının öznelilik uzayında oluşturduğu ayıraçlara bağlı olarak, farklı örüntülerdeki hataları giderilmeye çalışılmıştır.

Önerilen ağırlıklı konsensus sisteminde, bütün sınıflayıcılar birlikte eğitilirler ve test örneği sisteme sunulur. Bütün sınıflayıcıların ürettiği kararlar daha sonra ayrı bir birleştirici tarafından birleştirilerek (ağırlıklı ortalama alınarak) son karar değerine varılır.

Çizelge 8.1 Fetüs-1 ve Fetüs-2 için çoğul-sınıflandırıcı sonuçları

	Duyarlık	Özgüllük	Gerçek Negatiflik	Gerçek Pozitiflik
Fetüs-1	% 95	% 100	% 99	% 98
Fetüs-2	% 89	% 98	% 81	% 99

Çizelge 8.1’de çoklu-sınıflandırıcıdan elde edilen sonuçlar gösterilmektedir. Algoritmalar tek başlarına kullanıldıklarında da oldukça iyi performans verirken; çoklu sınıflandırıcı kullanıldığında performansları daha artmaktadır ve daha güvenilir bir karar üretmektedirler. Bu sonuç Çizelge 8.1’de net bir şekilde görülmektedir.

9. TARTIŞMA ve SONUÇLAR

OSA ve UA'dan elde edilen kan ölçümlerini kullanarak fetüsün sağlık durumunun doğumdan önce tahmini bir çok çalışmada kullanılmıştır (Wladimiroff vd., 1987; Mari vd., 1989). Gramellini ve arkadaşları (1992) hamilelik ayına göre küçük olan fetüslerin teşhis etmekte OSA_RI /UA_RI oranı için 1.08 cutoff değerini kullanarak değerlendirdiklerinde %70 doğruluk bulmuşlardır. Makhseed ve arkadaşlarının (2000) hamileliklerinin 29'uncu ve 42'inci haftaları arasında olan 70 fetüs üzerinde yaptıkları çalışmada OSA_RI/UA_RI oranının 1.05 üzerinde olduğu yerde fetüs gelişimini normal altında olan değerler için ise anormal kabul ederek yaptıkları çalışmada %60 duyarlık, %72 özgüllük elde etmişlerdir.

Tasarlanan sistemde, çeşitli hamilelik dönemlerindeki fetüslerin UA ve OSA'deki PI, RI, S/D değerleri alınıp sisteme giriş vektörü olarak okutulmuş ve daha önce yapılan çalışmalardan çok daha yüksek duyarlık ve özgüllük elde edilmiştir. Sonuçlar göstermektedirki önerilen bütün karar verme teknikleri anne karnındaki fetüsün risk değerlendirilmesinde uygun birer yöntem olarak kullanılabilir. Örneğin k-EYK'nın ürettiği yerel bilgi küçük veri tabanları için uygunken, RTF ağı bu yerel bilgiyi genellemektedir. Ayırıştırıcı fonksiyonlar ve karar ağaçları gibi global yaklaşımlar ise, karar bölgelerinin sınırlarını çizmekte oldukça yararlıdır. Kullanılan ayırıştırıcının doğrusal olmama derecesi arttıkça, sistemin doğruluk oranı artar. Mahalanobis uzaklığının kullanıldığı DDF, ÇKA ve C4.5 ve SRA, fetüsa ait risk oranının tahmininde karşılaştırılabilir performanslara sahiptirler. Bu tekniklerden C4.5 algoritması, problem için kolayca anlaşılabilir ve uygulanabilir bir çözüm sunmaktadır.

Özet olarak çalışmada, aşağıdaki sonuçlar çıkarılmıştır:

1. Önerilen sistem Doppler ultrasonundan elde edilen PI, RI, S/D oranı indekslerini kullanarak antenatal risk değerlendirmesini yapmaktadır. Elde edilen veriler göstermektedir ki sistemin sonuçları doktorların kararlarını destekler niteliktedir.
2. k-EYK, RTF, DDF, KDF, ÇKA gibi ayırıştırıcı fonksiyonlar, C4.5 ve SRA gibi karar ağaçları gibi çeşitli karar teknikleri kullanılarak verilen veri ile 5x2 çapraz sağlamalı F testi (Çizelge 6.5 ve Çizelge 6.6) ile karşılaştırıldı ve kullanılan bu tekniklerden KDF ve RTF'nin Fetüs-1 veritabanını ÇKA ve k-EYK'nın ise Fetüs-2 veritabanı istatistiksel olarak daha iyi sınıflandırdığı gözlemlenmiştir.
3. Kullanılan teknikler doğru karar sınırları çizmesi, analitik avantaj ve kullanım kolaylığı gibi kriterler üzerinde karşılaştırıldı ve k-EYK, C4.5 ve ÇKA'nın dikkat çekici şekilde daha iyi performans verdiği gözlemlendi.

4. Bulanık mantık başarı ile uygulanarak risk faktörü puanlaması gerçekleştirildi.

5. Bu çalışmada, antenatal fetüsa ait risk değerlendirmesinde doktorlara kararlarında yardımcı bir sistem geliştirildi. Bu sistem yeni teşhis teknikleri ve veri analiz yöntemleri ile geliştirilebilir.



KAYNAKLAR

- Alpaydın, E., (1999), "Combined 5X2 cv F Test for Comparing Supervised Classification Learning Algorithms", *Neural Computation*, 11:1975-1982.
- Anderson, T.W., (1984), *An Introduction to Multivariate Statistical Analysis*, Wiley & Sons Inc., New York.
- Bektaş, M.S., Başaran, F., Eskiizmirli, S., Erkmen, M.A. ve Yorukan, S., (1996), "A Computerized Diagnostic System for the Interpretation of Umbilical Artery Blood Flow Velocity Waveforms", *European Journal of Obstetrics & Gynecology and Reproductive Biology*, 164:37-42.
- Bishop C.M., (1995), *Neural Networks for Pattern Recognition*, Clarendon Press, Oxford.
- Breiman, L., Friedman, J. ve Olshen, H., (1984), *Classification and Regression Trees*, R.A. & Stone, C. J.
- Broomhead, D.S. ve Lowe, D., (1988), "Multi-variable Functional Interpolation and Adaptive Networks", *Complex Systems*, 2:321-355.
- Campbell, S., Reasens, D., Grifflin D.R., vd., (1983), "New Doppler Technique for assessing uteroplacental blood flow", *Lancet*, 1:675-677.
- Chervenak, F. ve Kurcak, A., (1996), *The Fetus as a Patient*, The Parthenon Publishing Group, UK.
- Creasy, R. K. ve Resnik R., (1999), *Maternal-Fetal Medicine: Chapter 15 Doppler Ultrason Assessment of Blood Flow*, WB Saunders, Philadelphia.
- De Haan, (1994), *Pathophysiologic Back-grounds of Changes in Doppler Flow Indices*, In Van Geijn HP, Copray FJA eds., Elsevier, Amsterdam.
- Duda O.R. ve Hart E.P., (1973), *Pattern Classification and Scene Analysis*, John Wiley & Sons Inc., New York.
- Efron, B., (1982), "The Jackknife, the Bootstrap, and Other Resampling Plans," *SIAM NSF-CBMS, Monograph*.
- Fukunaga, K., (1990), *Introduction to Statistical Pattern Recognition*, Academic Press.
- Gramellini D., Folli C. M., Raboni S., Vadora E., Merialdi A., (1992), "Cerebral-Umbilical Doppler Ratio as a Predictor of Adverse Perinatal Outcome", *Obstet. Gynecol.*, 79:416-420.
- Güler, N., Gürgen, F. ve Varol, F., (1999), *Decision of Normal and Growth Retarded Pregnancies by Discriminant Functions Using Umbilical Arterial Blood Flows Velocity Waveforms*, *Advance in Intelligent Systems and Computer Science*, World Scientific and Engineering Society Press, Danvers.

- Gürgen, F., Aikawa, K. ve Shikano, K., (1991), "Phoneme Recognition with Neural Networks Using a Novel Fuzzy Training Algorithm", IJCNN'91, Congress, Singapore.
- Gürgen, F., Güler, N. ve Varol, F., (2000), "Antenatal Fetal Risk Assessment by Blood-Flow Velocity Waveforms", IEEE Engineering in Medicine and Biology magazine, 19:88-93.
- Gürgen, F., Güler, N. ve Varol F., (2001), "Antenatal Fetal Risk Assessment Using a Neurofuzzy Technique", IEEE EMB, November/ December 2001.
- Hair, J.F., Anderson, R.E. ve Tatham, R.L., (1995), Multivariate Data Analysis with Readings, Prentice Hall.
- Haykin S., (1994), Neural Networks, Macmillan College Publishing Company, Inc., New York.
- Hecker, K., Snijders, R., Campbell, S. ve Nicolaides, K., (1995), "Fetal Venous, Intracardiac and Arterial Blood Flow Measurements in Intrauterine Growth Retardation: Relationship with Fetal Blood Gases", Am. Obstet. Gynecol., 173:10-15.
- Hellendoorn, H. ve Driankov, D., (1997), Fuzzy Model Identification, Springer, Berlin.
- Hollatz, J. ve Tresp, V., (1992), A Rule-based Network Architecture 757-761, Artificial Neural Networks II, I. Aleksander ve J. Taylor, (Ded.), Elsevier, Amsterdam.
- Kohonen, T., (1989), Self-Organization and Associative Memory, Springer-Verlag, Berlin.
- Mardia, K.V., Kent, J.T., ve Bibby, J.M., (1989), Multivariate Analysis, Academic Press, Seventh Editions, London.
- Mari G, Moise K. J., Deter R. L., Kirshon B., Carpenter R. J. ve Huhta J. C., (1989), "Doppler Assessment of the Pulsatility Index in Cerebral Circulation of the Human Fetus", Am J Obstet Gynecol, 160:698-703.
- Mari G. ve Deter R. L., (1992), "Middle Cerebral Artery Flow Velocity Waveforms in Normal and Small for Gestational Age Fetuses", Am. J. Obstet. Gynecol., 166:1260-1262.
- Mari, G. ve Copel, A.J, (1996), Doppler Ultrason: Fetal Physiology and Clinical Application., Chapter 13: Sonography in Obstetrics and Gynecology: Principal and Practice.
- Makhseed M., Jirous J., Ahmed M. A. Ve Viswanathan D. L., (2000), "Middle Cerebral Artery to Umbilical Artery Resistance Index Ratio in the Prediction of Neonatal Outcome", Int J Gynecol Obstet , 71:119-125.
- Maulik, D., Yarlagadda, P. ve Downing, G., (1990), "Doppler Velocimetry in Obstetric", Obstet. Gynecol. Clin. North Am., 17:163-86.
- Michie, D., Spiegelhalter D.J. ve Taylor C.C., (1994), Machine Learning, Neural and Statistical Classification, published on Internet.
- Moody J. ve Darken, C., (1989), "Fast Learning in Networks of Locally-Tuned Processing Units", Neural Computation, 1:281-294.

- Moody, J. ve Darken, C.J., (1988), "Learning with Localized Receptive Fields", Connectionist Models Summer School.
- Morrison, D.F., Multivariate Statistical Methods, McGraw-Hill Publishing Company.
- Nilsson, N.J., (1996), Introduction to Machine Learning.
- Prager, R.W., ve Fallside, F., (1989), "The Modified Kanerva Model for Automatic Speech Recognition", Computer Speech and Language, 3:61-82.
- Quinlan, J.R., (1986), "Induction of Decision Trees", Machine Learning, 1: 81-106.
- Quinlan, J.R., (1993), "C4.5: Programs for Machine Learning", Morgan Kaufmann, San Mateo, CA.
- Ripley, B.D., (1996), Pattern Recognition and Neural Networks., Cambridge Press.
- Ross, S. M., (1987), Introduction to Probability and Statistics for Engineers and Scientist, John Wiley & Sons Inc., New York.
- Rumelhart, D.E., Hinton, G.E. ve Williams, R.J., (1987), Learning Internal Representations by Error Propagation, in Rumelhart, D. E. and McClelland, J. L., editors, Parallel Distributed Processing, 1: 318-362, MIT Press, Cambridge MA.
- Scalero, R. ve Tepedelenlioglu, N., (1992), "A Fast New Algorithm for Training Feedforward Neural Networks", IEEE Transactions on Signal Processing, 40:202-210.
- Sharma, S., (1996), Applied Multivariate Techniques, John Wiley & Sons Inc., New York.
- Smolensky, P., Mozer M.C. ve Rumelhart D.E., (1996), Mathematical Perspectives on Neural Networks, Lawrence Erlbaum Associates, Publishers, Mahwal, NJ.
- Smyth, P. ve Buntine, W., Probabilistic Machine Learning Putting Theory in to Practice. Tutorial Notes: wray@Heuristicrat. pjs@galway.jpl.nasa.gov.
- Specht, D. F., (1990), "Probabilistic Neural Networks", Neural Networks, 3:109-117.
- Takagi, T., ve Sugeno M., (1985), "Fuzzy Identification of Systems and Its Applications to Modelling and Control", IEEE Trans. Systems, Man and Cybernetics, 15(1):116-132.
- Tatlıdil, H., (1996), Uygulamalı Çok Değişkenli İstatiksel Analiz, Cem Web Ofset Ltd., Ankara.
- Tresp, V., Hollatz, J. ve Ahmad, S., (1993), Network Structuring and Training Using Rule-Based Knowledge, 871-878, Advances in Neural Information Processing Systems 5, S. J. Hanson, J. D. Cowan ve C. L. Jiles, (Darl.), Morgan Kaufmann, San Mateo, CA.
- Trudinger B.J., Stevens D., Connely A., vd., (1987), "Umbilical Artery Flow Velocity Waveforms and Placental Resistance: The Effects of Embolization of Umbilical Circulations", Am. J. Obstet. Gynecol., 157:1443-1449.

Twomey, J.M. ve Smith, A.E., (1998), "Bias and Variance of Validation Methods for Function Approximation Neural Networks Under Condition of Sparse Data", IEEE Trans. on Systems, Man. & Cybernetics, 28: 417-430.

Wang, L. X. ve Mendel, J.M., (1992), "Fuzzy Basis Functions, Universal Approximation, and Orthogonal Least-Squares Learning", IEEE Trans. Neural Networks, 3(5).

Werbos, P., (1975), Beyond Regression: New Tools for Prediction and Analysis in the Behavioural Sciences, PhD. thesis, Harvard University. Ayrıca Harvard / MIT Cambridge projesinde rapor olarak basılmıştır.

Wladimiroff, J.W., Wijngaard, J. A., G. W. V. D., Degani, S., Noordam, M. J., Eyck J. V. ve Tonge, H. M., (1987), "Cerebral and Umbilical Arterial Blood Flow Velocity Waveforms in Normal and Growth Retarded Pregnancies", European Journal of Obstetrics & Gynecology and Reproductive Biology, 69, No.5:705-709.

Woo, J., (2000), Doppler Blood Flow Velocity Waveforms, www.obstetrics-gynecology.com

Xu, L., Kryzak A. ve Suen, C. Y., (1992), "Methods of Combining Multiple Classifiers and Their Application to Handwriting Recognition", IEEE Transactions on Systems, Man., and Cybernetics, 22, No. 3.

Yıldız, O. T., (2000), Multivariate Decision Trees for Machine Learning, Master thesis, Boğaziçi University.

ÖZGEÇMİŞ

Doğum tarihi	24.11.1971	
Doğum Yeri	İstanbul	
Lise	1985-1988	İstanbul Ataköy Lisesi
Lisans	1988-1992	Yıldız Teknik Üniversitesi Mühendislik Fak. Matematik Mühendisliği Bölümü
Yüksek Lisans	1993-1996	Yıldız Teknik Üniversitesi Kimya-Metalürji Fak. Matematik Mühendisliği Bölümü
Doktora	1996-2002	Yıldız Teknik Üniversitesi Kimya-Metalürji Fak. Matematik Mühendisliği Bölümü

Çalıştığı kurumlar

1991-1993	Ünkar Uluslararası Nakliyat ve Ticaret A.Ş.
1994-1994	Tübitak Marmara Araştırma Merkezi Yapay Zeka Böl.
1994- Devam ediyor	YTÜ Fen Bilimleri Enstitüsü Araştırma Görevlisi