

**T.C.
MARMARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**TİP 2 DIABETES MELLITUSLU HASTALARDA
24 SAATLİK KAN BASINCI DEĞİŞİMİNİN
ÖNGÖRÜLMESİNE YÖNELİK UZMAN SİSTEM TASARIMI**

Zehra Aysun ALTIKARDEŞ

**DOKTORA TEZİ
ELEKTRONİK-BİLGİSAYAR EĞİTİMİ ANABİLİM DALI
ELEKTRONİK-HABERLEŞME EĞİTİMİ PROGRAMI**

**DANIŞMAN
Doç. Dr. Hasan ERDAL
2. DANIŞMAN
Prof. Dr. A. Fevzi BABA**

İSTANBUL 2012

T.C.
MARMARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

TİP 2 DIABETES MELLITUSLU HASTALARDA
24 SAATLİK KAN BASINCI DEĞİŞİMİNİN
ÖNGÖRÜLMESİNE YÖNELİK UZMAN SİSTEM TASARIMI

Zehra Aysun ALTIKARDEŞ
(141201020040072)

DOKTORA TEZİ
ELEKTRONİK-BİLGİSAYAR EĞİTİMİ ANABİLİM DALI
ELEKTRONİK-HABERLEŞME EĞİTİMİ PROGRAMI

DANIŞMAN
Doç. Dr. Hasan ERDAL
2. DANIŞMAN
Prof. Dr. A. Fevzi BABA

İSTANBUL 2012

ÖNSÖZ

İnsanların akademik bilgileri ile birlikte bilgeliklerinin de yükselmesi felsefesini benimsemiş ve bu camia içinde bu felsefeyi yaşam biçimi yapmış kişileri örnek almış ve almaya devam edeceğim. Saygıdeğer danışmanlarım Sayın Doç.Dr. Hasan Erdal Bey ve Prof.Dr. A. Fevzi Baba Bey lisans yıllarımdan beri her zaman dostluklarını ve desteklerini ortaya koymuşlardır. Bana güvendikleri, hep yanımda yer aldıkları ve bu çalışmamda danışmanım olmayı kabul ettikleri için kendilerine minnet duyduğumu ifade etmek istiyorum.

Disiplinlerarası bir çalışma ortaya koymanın en büyük zorluğu; birbirinin dilinden anlayan, birbirine güvenen ve ortak çalışma zamanı yaratan bir ekibin oluşturulmasının zorluğu olduğunu bu tez çalışması ile bizzat öğrenmiş bulunmaktayım. Birçok denemeden sonra tam umutsuzluğa düştüğüm anda, pozitif yaklaşımı, geniş vizyonu ve engin bilgisiyle imdadıma yetişen tıp fakültesi öğretim üyesi Sayın Prof.Dr. Ali Serdar Fak Bey'e özellikle teşekkür etmek istiyorum.

Tıp fakültesi öğretim üyesi Sayın Prof.Dr. Hakan Tezcan ve Dr. Davut Bilgin'e tıbbi verilerin toplanması sırasındaki emeklerinden ve bu çalışmaya olan katkılarından dolayı kendilerine çok teşekkür ediyorum.

Sayın Prof.Dr. Ali Serdar Fak ve Sayın Prof.Dr. Hakan Tezcan Hocalarımızın nezinde T.C. Sağlık Bakanlığı Marmara Üniversitesi Eğitim ve Araştırma Hastanesi bünyesinde bu tez çalışması için emeği geçen herkese ve özellikle gönüllü olarak bu çalışmaya katılan hastalarımıza teşekkür ediyorum. Hastalarımıza acil şifalar diliyorum.

Bu çalışmaya emek ve zamanlarını harcayan, değerli önerilerde bulunan, tez izleme komitesi üyeleri Sayın Prof. Dr. A.Yılmaz Çamurcu Bey' e ve Sayın Prof. Dr. İsmail Ertürk Bey'e teşekkür ediyorum.

İnsanların bazen kapana kısıldığını hissettiği ve nasıl yol alacağını bilemediği zamanlar olur. İşte akademik yaşantım için böyle hissettiğim bir durumda; beni dinleme, anlama ve yol gösterme büyüklüğünü gösteren, kendi branşımda doktora yapmam konusunda beni teşvik eden eski rektör yardımcımız Sayın Prof.Dr. İrfan Güney Bey'e şükranlarımı sunuyorum.

M.E.B. bünyesinde beş yıl Elektronik branşında öğretmenlik yaptıktan sonra akademik hayata atılmam için beni teşvik eden en iyi dostum Sayın Doç.Dr. Hayriye Korkmaz Hanım’a, bu yoldaki rehberliği ve desteği için teşekkür ediyorum.

Lisansüstü eğitimim boyunca öğrencilik işlerim ile yakından ilgilenen, hassasiyet gösteren ve dostluğunu hep hissettiren Fen Bilimleri Enstitüsü Sekreteri Sayın Nebahat Arslan Avcı Hanım’a ve nezninde enstitü yönetim kurulu üyelerine ve çalışanlarına teker teker teşekkürü bir borç biliyorum.

Bu çalışma; Bilimsel Araştırma Projeleri Komisyonu tarafından FEN-C-DRP-110908-0225 proje numarasıyla desteklenmiştir. Emeği geçen tüm BAPKO çalışanlarına teşekkür ediyorum.

Doktora eğitimi hayatımda önemli bir zaman dilimini kapsadı. Doktora’ya girme aşamasından bugüne kadar; benimle birlikte üzülen, sevinen, sıkılan, mutlu olan eşim Sayın Halit Altıkardeş Bey’e, her anımda yanımda olup, sevgisiyle inancımı yitirmeme izin vermediği için teşekkür ediyorum. Eşim olduğu için mutluluk duyuyorum.

Doktora tez aşamasında başıma gelen en güzel sürpriz kızım oldu. Sevgili Can’ım ve Melek’im sizleri çok seviyorum. Sizlerle bu çalışmadan dolayı daha az vakit geçirmiş olabilirim ama ileride benimle gurur duyacağımızı umarım.

Canım kardeşlerim Ozan ve Burak, manevi desteğiniz için sizlere teşekkür ediyorum.

Sevgili anneciğim Sayın B. Nevber Toylan Hanım ve babacığım Sayın Hüseyin Toylan Bey, sizlere beni dünyaya getirmekle kalmayıp, iyi yetiştirdiğiniz, güzel örnekler olduğunuz için teşekkür ediyorum. Emeklerinizin karşılığını ödeyememek olsamda, sizleri sevindireceğinden emin olduğum için doktora tez çalışmamı sizlere atfediyorum.

Bu çalışmanın faydalı olmasını dilerim. Sevgi ve saygılarımla...

İÇİNDEKİLER

SAYFA

ÖNSÖZ.....	i
İÇİNDEKİLER	iii
ÖZET.....	vii
YENİLİK BEYANI.....	xv
SEMBOLLER	xvii
KISALTMALAR	xix
ŞEKİLLER	xxi
TABLolar	xxiii
BÖLÜM I	
GİRİŞ	1
I.1 AMAÇ VE GEREKÇE.....	1
I.1.1 Materyal ve Yöntem.....	2
I.2 ÇALIŞMANIN LİTERATÜRDEKİ YERİ	4
BÖLÜM II	
ÇALIŞMANIN TIP BİLİMİNDEKİ YERİ.....	7
II.1 DIABETES MELLITUS HASTALIĞI (DM)	7
II.1.1. DM Hastalığının Tarihçesi	7
II.1.2. DM Tanımı ve Sınıflanması	8
II.1.3. DM'nin Vücutta Oluşturduğu Hasarlar (Complications)	11
II.1.3.1. Kardiyovasküler Hastalıklar	11
II.1.3.2. Retinopati.....	12
II.1.3.3. Nefropati	13
II.1.3.4. Nöropati	14
II.1.4. DM' nin Dünyadaki ve Türkiye'deki Yeri	14
II.2 HİPERTANSİYON HASTALIĞI (HT).....	16
II.2.1. HT Hastalığının Tarihçesi.....	17
II.2.2. HT Hastalığının Tanımı ve Sınıflandırılması	18

II.2.3.	HT' nin Vücutta Oluşturduğu Hasarlar (Complications).....	19
II.2.4.	HT' nin Dünyadaki ve Türkiye' deki Yeri.....	21
II.3	TİP 2 DM, HT VE KVH ARASINDAKİ ETKİLEŞİM (Risk Faktörleri, Morbidite, Mortalite)	23
II.4	DİPPER – NON DİPPER PATTERN TANIMI	27
II.4.1.	Tip 2 DM Hastalarında Hedef Organ Hasarı ve Dipper - NonDipper Patern İlişkisi	31
BÖLÜM III		
ÇALIŞMADA KULLANILAN TIBBİ VERİLERİN		
NİTELİK TANIMLARI VE ÖLÇÜTLERİ		33
III.1	NİTELİKLERİN (ATTRIBUTES) TANIMLANMASI	34
III.1.1	Demografik Verilerin Niteliklerinin Tanımlanması	34
III.1.2	Laboratuvar Tetkikleri Sonucunda Elde Edilen Verilerin Niteliklerinin Tanımlanması	34
III.1.3	Otonomik Fonksiyonun Değerlendirilmesine Yönelik Testler	36
III.1.4	Cihaz Ölçümleri ile Elde Edilen Verilerin Niteliklerinin Tanımlanması	37
III.1.4.1	EKG (Elektrokardiogram - Electrocardiography).....	37
III.1.4.2	EKO (Ekokardiyogram - Echocardiography)	39
III.1.4.3	Holter Cihazı	41
III.2	VERİLERİN TIBBİ ÖLÇÜTLERİ.....	41
BÖLÜM IV		
ÇALIŞMANIN BİLİŞİM TEKNOLOJİLERİNDEKİ YERİ		43
IV.1	VERİ MADENCİLİĞİ	44
IV.1.1	Veri Madenciliği Tanımlarıyla Tarihçesi	45
IV.1.2	Veri Madenciliği Uygulamalarında Ortaya Çıkan Zorluklar	50
IV.1.3	Veri Madenciliği Tekniği Model Oluşturma Yaklaşımları	51
IV.1.4	Veri Madenciliği'nde Sınıflandırma Problemleri için Kullanılan Yöntemler.....	56
BÖLÜM V		
24 SAATLİK KAN BASINCI ÖZELLİĞİNİ ÖNGÖRMEYE		
YÖNELİK UZMAN SİSTEM TASARIMI		59
V.1	SİSTEM MİMARİSİ BİRİNCİ KISIM	60
V.2	SİSTEM MİMARİSİ İKİNCİ KISIM	65
V.2.1	Verilerin Yüklenmesi.....	65

V.2.2 Verilerin Analizi ve Filtrelmesi.....	68
V.2.2.1 İlk Denek Grubu	68
V.2.2.2 İkinci Denek Grubu	71
V.2.3 Verilerin Sınıflandırılması ve Öngörü.....	74
V.2.3.1 Aşama – 1	74
V.2.3.2 Aşama – 2	75
V.2.3.3 Aşama – 3	78
V.2.4 Verilerin Sınıflandırılması ve Öngörü Deneyleri.....	80
V.2.4.1 Deney-1.....	80
V.2.4.2 Deney-2.....	88
V.2.4.3 Deney-3.....	94
V.2.4.4 Deney-4.....	100
V.2.4.5 Deney-5.....	113
V.2.4.6 Deney-6.....	119
V.2.4.7 Deney-7.....	122
V.2.4.8 Deney-8.....	125
V.2.4.9 Deney-9.....	128
V.2.4.10 Deney-10.....	131
BÖLÜM VI	
SONUÇ VE ÖNERİLER.....	133
VI.1 ÇALIŞMANIN DEĞERLENDİRİLMESİ	135
VI.1.1 Hasta Açısından	135
VI.1.2 Maliyet Açısından.....	135
VI.1.3 Tıp ve Bilişim Alanında Disiplinler Arası Yapılan Çalışmalar Açısından.....	136
VI.2 TIP UZMANININ DEĞERLENDİRMESİ	137
VI.3 ÖNERİLER	140
KAYNAKÇA	143
EKLER	155
ÇALIŞMADA KULLANILAN TIBBİ TERİMLER SÖZLÜĞÜ.....	157
ÖZGEÇMİŞ	159

ÖZET

TİP 2 DIABETES MELLITUSLU HASTALARDA 24 SAATLİK KAN BASINCI DEĞİŞİMİNİN ÖNGÖRÜLMESİNE YÖNELİK UZMAN SİSTEM TASARIMI

Bu tez çalışması Marmara Üniversitesi Tıp Fakültesi İç Hastalıları Anabilim Dalı, Hipertansiyon ve Ateroskleroz Ünitesi Polikliniği ve Endokrinoloji Bilim Dalı ile Marmara Üniversitesi Fen Bilimleri Enstitüsü Elektronik-Bilgisayar Eğitimi ABD. tarafından ortaklaşa gerçekleştirilmiştir. Disiplinlerarası bu çalışma prospektif, gözlemsel bir çalışma olarak düzenlenmiştir. Tedavi/girişim üzerine herhangi bir müdahale planlanmamıştır. Bu çalışmanın yapılabilmesi için Marmara Üniversitesi Tıp Fakültesi Klinik Araştırma Etik Kurulu izni alınmıştır. Bununla birlikte çalışmaya katılan tüm hastalar bilgilendirilmiş ve yazılı onayları alınmıştır.

Bu çalışmada, Akıllı Sağlık Programı tasarlanmıştır. Görsel açıdan estetik olduğu kadar kullanımı da kolay olan arayüz tasarımı gerçekleştirilmiştir. Böylece tıp doktorlarının hasta verilerini saklayabilecekleri, değiştirebilecekleri bir veritabanı yazılım çözümü sunulmuştur.

Bu bağlamda, farklı profilde iki denek grubu oluşturulmuştur. Deneklerden demografik ve tıbbi 47 adet (holter ölçümleri dahil) nitelikliğe ait veriler toplanarak veritabanı hazırlanmıştır. Bu veritabanındaki veriler genel kullanıcı lisansı (General public licience) ile sunulan veri madenciliği programı olan Weka 3.7.4 ortamına aktarılmıştır.

Amaç, Holter cihazıyla gerçekleştirilen 24 saatlik kan basıncı takibi sonucu elde edilen 9 adet niteliğe ait verilere ihtiyaç duyulmaksızın, non-dipper/dipper patern sınıflamasını ve öngörüsünü doktor teşhisine en yakın doğrulukta yapabilecek yazılım modeli oluşturmaktır. Bu çalışmanın her aşamasında, istatistiksel analiz yöntemleri ile yapay zeka teknikleri bir araya getirilerek, veri tabanında yer alan çok sayıdaki veri için ilk denek grubu üzerinde yapılan çalışmalarda maximum %89.47 ve ikinci denek grubunda ise %100 doğrulukla sonuca gidilebilmiştir. Bu başarı oranlarını veren modellerde giriş nitelik sayıları holter cihazı ölçümleri de kullanılmadan, ilk denek grubunda 47'den 13'e, ikinci denek grubunda ise 36'dan 2'ye indirgenmiştir.

Bu çalışma için tasarlanan 24 Saatlik Kan Basıncını Öngörmeye Yönelik Uzman Sistemin mimarisi iki ana kısımdan meydana gelmektedir: Birinci kısımda .NET Framework üzerinde hekimlerin kullanımına yönelik tasarlanmış bir kullanıcı arayüzü vardır. Arayüz sayesinde üyelik işlemlerini gerçekleştiren kullanıcı yani tıp doktoru, hasta ile ilgili demografik, klinik, laboratuvar ve test verilerini SQL server 2008 üzerindeki veritabanına kayıt edebilmekte, silebilmekte ve güncelleyebilmektedir. Bu çalışmada; veri madenciliği tekniği, sınıflandırma ve öngörü yaklaşımı kullanılması tercih edilmiştir. Sistemin ikinci kısmını oluşturan çalışma WEKA (Waikato Environment for Knowledge Analysis) programında 3.7.4 Developer versiyonunda gerçekleştirilmiştir. Sınıflandırma ve öngörü yaklaşımı için karar ağaçları, bayes ve yapay sinir ağları yöntemleri uygulanmıştır.

C4.5 karar ağacı algoritmasının Weka 'daki implementasyonu olan J48 algoritması, bayes yöntemi için NaiveBayes algoritması ve yapay sinir ağı yöntemi içinde yer alan RBF (Radial Basis Function) ile MLP (Multi Layer Perceptron) algoritmaları kullanılarak nondipper/dipper sınıflandırması ve öngörüsü yapan modeller geliştirilmiştir.

Bölüm 1'de tezin amacı gerekçeleriyle sunulmuş, yöntem ve materyaller anlatılmıştır. Çalışmanın özgünlüğünü ve literatürdeki yerini belirtmek amacıyla konuya en yakın çalışmalardan seçilen örnekler sunulmuştur.

Bölüm 2'de tez çalışmasının tıp bilimindeki yeri başlığı altında, özellikle bilişim alanı çalışanları için, konuya vakıf olabilmelerini sağlayacak kadar tıbbi bilgi olabildiğince anlaşılır şekilde sunulmuştur. Hastalıkların tanımları, tarihçeleri, prevalansları (belirli bir nüfusta, belirli bir zaman dilimi içerisinde, çalışma kapsamında yer alan, belirli bir hastalık veya hastalıklara sahip kişilerin oranı) ile birlikte niçin bu hastalıkların seçildiği, nondipper/dipper patern sınıflaması ile hastalıkların ilişkisi belirtilerek tez konusunun tıbbi açıdan önemi belirtilmeye çalışılmıştır.

Bölüm 3'te ise, yazılımın girdilerini oluşturan 47 adet tıbbi nitelik tanımlanmış ve ölçütleri belirtilmiştir.

Bölüm 4'te tez çalışmasının bilişim teknolojilerindeki yeri başlığı altında, veri madenciliği tanımlaması tarihi gelişimi ile birlikte verilmiş, model oluşturma yaklaşımları, aşamaları, sınıflandırma ve öngörü tekniğinde tercih edilen yöntemler üzerinde durulmuştur.

Bölüm 5’te ise çalışmanın uygulama aşamaları, teorik bilgileri, matematiksel ifadeleri ve deney sonuçları sunulmuştur. Çalışma bulguları, 100’ün üzerinde gerçekleştirilen deney içinden seçilen 10 deneye tez kitabında yer verilerek özetlenmiştir.

Bölüm 6’da ise tüm bu bilgiler ışığında varılan nokta, sonuçların etkileri ve gelecek çalışmalara yol göstermesi açısından öneriler sunulmuştur. Tıp uzmanının çalışma sonuçları ile ilgili değerlendirmesi de bu bölümde bulunmaktadır.

Bu çalışma; Bilimsel Araştırma Projeleri Komisyonu tarafından FEN-C-DRP-110908-0225 proje numarasıyla desteklenmiştir.

Ocak, 2012

Zehra Aysun ALTIKARDEŞ

ABSTRACT

EXPERT SYSTEM DESIGN TO PREDICT 24 HOUR AMBULATORY BLOOD PRESSURE FEATURES IN TYPE 2 DIABETES MELLITUS PATIENTS

This study was held in collaboration with Marmara University Faculty of Medicine, Department of Internal Diseases, Hypertension and Atherosclerosis Unit Polyclinic and Department of Endocrinology and the Marmara University Institute for Graduate Studies in Pure and Applied Sciences Department of Electronics and Computer Education.

This interdisciplinary study was composed as a prospective, observational study. Any kind of intervention was not planned about the treatment/intervention. In order to perform this study, the permission of the Clinical Research Ethics Committee of Marmara University Faculty of Medicine has been taken. However, all patients participating in the study were informed and their written consent was obtained.

In this study, Intelligent Health Platform was designed. A graphical user interface was designed which was user friendly. Thus, a software solution was presented to the doctors with which they could store patients data and modify database.

In this context, different profiles of two groups of subjects were created. 47 different attributes of demographic and medical data (including holter measurements) were collected and thus database prepared. The data collected in this database was transferred to Weka 3.7.4 (General Public Licence) data mining software offered by Waikito University.

The goal was to create a software model that could make the classifications and predictions of dipper/non-dipper patterns with the nearest accuracy to the doctor's diagnosis without the need of those 9 data obtained by 24-hour blood pressure monitoring with Holter device. At every stage of this study, by combining statistical analysis methods and artificial intelligence techniques, the results of maximum 89.47% accuracy in studies made on subject group one and 100% accuracy on subject group two were obtained, from a large number of data in the database. In models that gave these success rates, the number of input attributes was reduced from 47 to 13 in the first group of subjects and from 36 to 2 in the second group of subjects without the use of Holter device measurements.

The architecture of this Expert System for Prediction of 24-hour blood pressure which has been designed for this study consists of two main parts: In the first part, there is user interface designed for use of physicians over .NET Framework. User who realized membership proceeding with interface, namely medical doctor, can save demographic, clinical, laboratory and test data of relevant patient to the database over SQL server 2008, can delete and update. In this study, data mining technique, classification and use of prediction approach have been preferred. The second part of system, the study has been realized in WEKA (Waikato Environment for Knowledge Analysis) program 3.7.4 Developer version. Decision trees for classification and prediction approach and Bayesian methods and neural networks have been applied

The algorithm J48 which is the implementation of C4.5 decision tree algorithm in Weka, the NaiveBayes algorithm for Bayesian method and the RBF (Radial Basis Function) included in artificial neural network method and the MLP (Multi Layer Perceptron) algorithms have been used and the nondipper / dipper classification and predicted models have been developed.

In Chapter 1, the aim of the thesis was presented with the reasons, methods and materials were described. Selected study samples closest to the subject were given in order indicates the study's originality in the literature.

In Chapter 2, under the title 'place of the thesis study in the science of medicine', especially for staff of informatics area, enough medical information was clearly presented to allow them comprehend the subject. The significance of the subject of the thesis under medical literature was specified, by explaining the definitions of diseases, histories and the prevalence along with why these diseases were selected and classifying dipper/nondipper patterns along with the relationship of the diseases.

In Chapter 3, 47 different medical attributes forming the entries of the software were defined and their criteria specified.

In Chapter 4, under the title 'place of the thesis in informatics technologies', the explanation of data mining was made with its the historical development and modelling approaches, stages, classification and the preferred methods on prediction techniques were emphasized.

In Chapter 5, implementation phases, theoretical information, mathematical expressions and experimental results of the study were presented. The study results were summarized with selected 10 experiments.

In section 6, point reached in the light of all this information, the effects of the results and recommendations were presented to guide future studies. Medical expert's assessment of study results are also in this section.

This study was supported by the Scientific Research Projects Unit under the project number FEN-C-DRP-110908-0225.

Jan, 2012

Zehra Aysun ALTIKARDEŞ

YENİLİK BEYANI

TİP 2 DIABETES MELLITUSLU HASTALARDA 24 SAATLİK KAN BASINCI DEĞİŞİMİNİN ÖNGÖRÜLMESİNE YÖNELİK UZMAN SİSTEM TASARIMI

Literatür taramalarında yapay zeka teknikleri kullanılarak, 24 saatlik kan basıncı takip cihazı verilerine ihtiyaç duyulmadan, “Non-dipping” özelliğın öngörülmesine, sınıflanmasına yönelik benzer bir çalışmaya rastlanılmamıştır. Bu tez çalışması özgün bir çalışmadır.

Türkiye’de ve dünyada mortalite ve morbidite oranı önemli boyutta olan kardiyovasküler hastalıkların riskini ön görmek için hedef organ hasarını belirlemek önemlidir. Bu nedenle “Non-dipping” / “Dipping” özelliğın tesbiti gerekmektedir.

Günümüz koşullarında tıp doktorları bu özelliğı teşhis ederken demografik bilgiler (7 adet), laboratuvar tetkiki (6 adet), otonomik testler (10 adet), EKG ve EKO ölçümleriyle elde edilen nitelikler (15 adet) ve 24 saatlik kan basıncı takibi sonucu (9 adet) elde edilen toplam 47 adet niteliğeye ait veriyi kullanmaktadırlar.

Bu çalışmanın bilimsel katkısı; yapay zeka tekniklerinden veri madenciliğı yöntemleri içinde yer alan sınıflandırma yaklaşımı Radial Basis Function algoritması, ilk denek grubu üzerinde kullanılarak, nitelik sayısı, non-invazif yöntem olan 24 saatlik kan basıncı takip cihazı (Ambulatory Blood Pressure Monitoring – Holter Cihazı) ile elde edilen gece/gündüz, sistolik ve diastolik kan basınçlarına ait 9 adet nitelik kullanılmaksızın 47’den 13’e indirgenmiş ve %89.47 doğru sınıflandırma başarısı, %100 belirginlik ve % 80 duyarlılık ile doktor teşhisine en yakın doğrulukta “Non-dipping” / “Dipping” özelliğı öngören model ortaya konmuştur. İkinci denek grubu üzerinde ise nitelik değeri 36’dan 2’ye indirgenerek J48 karar ağacı, RBF ve MLP (Çok Katmanlı Algılayıcı) algoritmaları ile oluşturulan modellerle nondipper /dipper sınıflaması ve öngörüsü %100 doğruluk, %100 belirginlik ve %100 duyarlılık ile elde edilmiştir. Literatürde “Non-dipping” özelliğın öngörülmesine, bu yöntemle sınıflandırılmasına yönelik benzer bir çalışmaya rastlanılmamıştır. Bu tez çalışması özgün bir çalışmadır. Bu konuda yapılmış ilk disiplinler arası çalışmadır.

Böylece kardiyovasküler açıdan daha yüksek risk altındaki kişiler pratik ve hızlı bir yöntemle anlaşılabilir, gereken tedavileri daha kolaylıkla

planlanabilecektir. Böylece; hasta yaşam kalitesi ve maliyetler açısından sonuçlar bölümünde belirtilen olumsuzlukları ortadan kaldırmaya yönelik fayda sağlanabilecektir.

Veri madenciliği yönteminde denek sayısının dolayısıyla tıbbi veri sayısının çokluğu çalışmanın güvenilirliği açısından önem arz etmektedir. Bu bağlamda, bu pilot çalışmanın, sürdürülen disiplinler arası projenin ilk bölümünü oluşturduğunu belirtmek önemlidir.

Bu çalışmada kullanılan veritabanı, T.C. Sağlık Bakanlığı Marmara Üniversitesi Eğitim ve Araştırma Hastanesi Hipertansiyon ve Ateroskleroz Ünitesi'nde, gönüllü hastalardan toplanan verilerle oluşturulmuştur. Tip 2 diabetes ve normotansif hasta profilinden oluşan 65 kişilik ilk denek grubu için 08.05.2009 tarih/MAR-YÇ-2009-0166 numaralı ve non-diabetik ve hipertansif hasta profilinden oluşan 29 kişilik ikinci denek grubu için de 90.09.2011.0108 numaralı Marmara Üniversitesi Tıp Fakültesi Klinik Araştırma Etik Kurulu izni alınmıştır. Bu hastaların verilerinin girilmesi ve bundan sonra da yapılan çalışmalarda tıp doktorlarının kullanımına sunulmak üzere, web tabanlı ve kullanıcı dostu bir veritabanı otomasyon programı oluşturulmuştur.

Ocak, 2012

Doç. Dr. Hasan ERDAL

Prof. Dr. A. Fevzi BABA

Z. Aysun ALTIKARDEŞ

SEMBOLLER

λ	: Bir perceptron'un hedefe varması için gereken adım büyüklüğü yani ağırlıkların değişim miktarıdır.
$\emptyset$	: Eşik değeri
P_h	: Temel fonksiyon kullanan gizli unitler
m_h	: Unit h'nin lokal merkezi
s_h	: İlk katman parametreleri (h lokal unitin yayılması)
w_i	: İkinci katman ağırlıkları

KISALTMALAR

DM	: Diabetes Mellitus
HT	: Hipertansiyon
KVH	: Kardiyovaskuler Hastalıklar
KB	: Kan Basıncı
ADA	: Amerikan Diyabet Derneği
GDM	: Gestasyonel Diabetes Mellitus
WHO	: Dünya Sağlık Örgütü
IDF	: Uluslararası Diyabet Federasyonu
TURDEP	: Türkiye Diyabet Epidemiyoloji
ISH	: Uluslararası Hipertansiyon Derneği
IFG	: Bozulmuş Açlık Kan Şekeri
LDL	: Düşük Yoğunluklu Lipoprotein
HDL	: Yüksek Yoğunluklu Lipoprotein
KVH	: Kardiyovasküler Hastalıklar
ABPM	: Ambulatory Blood Pressure Monitoring-24 Saatlik KB Takibi
BELC	: Bel çevresi (cm)
BSA	: Body Surface Area -Vücut Yüzeyi (m ²)
BMI	: Body Mass Index -Vücut Kitle Endeksi (kg/m ²)
A1C	: Hemoglobin A _{1c}
AKS	: Açlık kan şekeri (mg/dlt)
Kreatinin	: Kreatin (mg/dlt)
Malb	: Mikroalbuminüri (mg)
LDL	: Low Density Lipoprotein (mg/dlt)
ABI	: Ankle brachial index (kol-ayak bileği arter basıncı indeksi)
S V1	: EKG'de V ₁ derivasyonunda S dalgası
R V5	: EKG'de V ₅ derivasyonunda R dalgası
V 1	: Valsalva 1. ölçüm
V2	: Valsalva 2. ölçüm
Vm	: Valsalva manevrasına kalp hızı yanıtı

DSD	: Derin solunumda kalp hızı değişkenliği (vuru/dk)
AKH	: Ayağa kalkınca kalp hızı değişkenliği
OrH	: Ortostatik hipotansiyon
HDKBF	: Handgript testi
PH	: Parasempatik hasar
SH	: Sempatik hasar
LA	: Left atrium - Sol atrium (mm)
Ao	: Aort kökü (mm)
SWth	: Sol ventrikül septal duvar kalınlığı
PWth	: Sol ventrikül arka duvar kalınlığı
LVEDD	: Diyastol sonu çapı (mm)
LVESD	: Sistol sonu çapı (mm)
ME	: Mitral erken doluş (m/s)
MA	: Mitral geç doluş (m/s)
MDT	: Mitral deceleration time - Mitral deselerasyon zamanı (m/s)
AoIVRT	: Aortic isovolumic relaxation time - Aortik izovolumik relaksasyon zamanı (ms)
LVM	: Left ventricular mass – Sol ventrikül kütlesi (gr)
LVMi	: Left ventricular mass index - Sol ventrikül kütle indeksi (gr/m ²)
dt sis	: Gündüz sistolik kan basıncı
dt dias	: Gündüz diyastolik kan basıncı
nt sis	: Gece sistolik kan basıncı
nt dias	: Gece diyastolik kan basıncı
mask HT	: Maskelenmiş hipertansiyon
MLP	: Multilayer Perceptron - Çok Katmanlı Algılayıcı
CRISP-DM	: CRoss – Industry Standard Process for Data Mining
IDE	: Integrated Development Environment - Tümüleşik geliştirme ortamı
CLR	: Program Ortak Dili - Common Language Runtime
WPF	: Windows Presentation Foundation
WEKA	: Bilgi Analiz Ortamı -Waikato Environment for Knowledge Analysis
RBF	: Radyal Tabanlı Fonksiyonlar - Radial Basis Function
MLP	: Çok Katmanlı Algılayıcı – Multi Layer Perceptron

ŞEKİLLER

SAYFA NO

Şekil II. 1 Glukozun normal emilimi ve glukozun kanda kalması.....	8
Şekil II. 2 Pankreasın yeri	9
Şekil II. 3 Plak tarafından tıkanan koroner arterler ile sağlıklı	12
Şekil II. 4 Retinopati	13
Şekil II. 5 Yaş ve Cinsiyete göre Kırsal ve Kentsel kesimde DM ve IGT prevalansları	16
Şekil II. 6 Dünya Geneline 2000 Yılı Hipertansif Hasta Sayısı ve Prevalansları ile 2010 Yılı Hipertansif Hasta Sayısı ve Prevalanslarına Ait Öngörüler.....	22
Şekil II. 7 Türkiye’de Yerleşim Alanına ve Cinsiyete Göre	22
Şekil II. 8 AVRUPA B Bölgesi için WHO/ISH Risk Şeması.....	25
Şekil II. 9 Spacelab 90217 Holter Cihazı Parçaları.....	28
Şekil II. 10 Holter Cihazının Vücuda Monte Edilmiş Hali	28
Şekil II. 11 Spacelab 90217 Holter Cihazı ile Ölçülmüş Dipper /Non-Dipper verileri ve paternleri	30
Şekil III. 1 ABI için KB Ölçümü	36
Şekil III. 2 Elektrokardiyogram Grafiği.....	38
Şekil III. 3 a) EKG Dalgası b) EKG Dalgası Ölçüm Noktaları	39
Şekil III. 4 EKO Cihazı ile Bakılan Kalp Özellikleri.....	40
Şekil IV. 1 Veri Madenciliği Tarih Şeridi	46
Şekil IV. 2 Endüstriyel İşletmeler için Genel Veri Madenciliği Süreci	47
Şekil IV. 3 Verilerin Yolculuğu	49
Şekil IV. 4 Gözetimli Öğrenme Akış Şeması.....	53
Şekil IV. 5 Sınıflandırma ve Öngörü Yaklaşımı	55
Şekil IV. 6 Model Oluşturma Yöntemlerinin Gözetimli ve Gözetimsiz Öğrenme Tekniği Olarak Gruplandırılması	56
Şekil V. 1 Uzman Sistemin Yeri.....	59
Şekil V. 2 Akıllı Sağlık Uzman Sistem Mimarisi.....	62
Şekil V. 3 Uzman Sistem Kullanıcı Arayüzü Giriş Ekranı	63

Şekil V. 4 Visual Studio Hasta Kayıt Ekranı Tasarım Örneği	64
Şekil V. 5 Akıllı Sağlık Programı Hasta Sorgulama Arayüzü - Excel'e Veri Transferi	66
Şekil V. 6 Excel Formatındaki Verilerin Weka 3.7.4 Ortamına Transferi	66
Şekil V. 7 CSV formatında Hasta Verileri	67
Şekil V. 8 ARFF Formatındaki Hasta Verileri.....	67
Şekil V. 9 İlk Gruba ait Toplam 39 Nitelik için Oluşturulan Histogram	70
Şekil V. 10 İkinci Gruba ait Toplam 39 Nitelik için Oluşturulan Histogram	73
Şekil V. 11 Öz Nitelik Seçimi ile Holter Cihazı Verilerinin Önemi.....	77
Şekil V. 13 Deney-1 Karar Ağacı Modeli.....	84
Şekil V. 14 Deney- 2 Eğitim Veri Kümesi ile Oluşturulan Karar Ağacı Modeli	92
Şekil V. 15 ThresholdCurve (Class Non-Dipper) ROC Altındaki Alan = 0.7556.....	99
Şekil V. 16 Biyolojik Sinir Hücresi	101
Şekil V. 17 Yapay Sinir Hücresi	101
Şekil V. 18 Sigmoid Fonksiyon Grafiği.....	102
Şekil V. 19 Perceptron Modeli.....	103
Şekil V. 20 MLP Modeli	104
Şekil V. 21 Gradient descent'in kullandığı hata fonksiyonu $w^2 + 1$	106
Şekil V. 22 Deney-4 MLP Modeli Şeması.....	109
Şekil V. 23 ThresholdCurve (Class Non-Dipper) ROC Altındaki Alan = 0.9444.....	112
Şekil V. 24 RBF Ağı	114
Şekil V. 25 ThresholdCurve (Class Non-Dipper) ROC Altındaki Alan = 0.8444.....	118
Şekil V. 26 Deney- 6 Karar Ağacı Modeli.....	120
Şekil V. 27 ThresholdCurve (Class Non-Dipper) ROC Altındaki Alan = 1.....	121
Şekil V. 28 ThresholdCurve (Class Non-Dipper) ROC Altındaki Alan = 1.....	124
Şekil V. 29 Deney-8 MLP Modeli Şeması.....	125
Şekil V. 30 ThresholdCurve (Class Non-Dipper) ROC Altındaki Alan = 1.....	127
Şekil V. 31 4- Kat Çapraz Doğrulama İşleyişi.....	129

TABLÖLAR

SAYFA NO

Tablo II. 1 Diabetes Hastalığının Etiyolojik Olarak Sınıflandırılması	11
Tablo II. 2 Dünya Geneline Tip 2 DM ve IGT Prevelansları	15
Tablo II. 3 Kan Basıncının Sınıflandırılması.....	19
Tablo II. 4 Avrupa B Bölgesi için Yaş Parametresine göre Risk Dağılımı	25
Tablo II. 5 Hastalığın Teşhisini Etkileyen Faktörler	27
Tablo III. 1 Çalışmada Kullanılan Tıbbi Verilerin Elde Edildikleri Kaynaklara Göre Sınıflandırılması.....	33
Tablo V.1 YAS Niteliği İstatistik Değerleri.....	69
Tablo V. 2 İlk ve İkinci Denek Grubu için Çalışmada Kullanılan Nitelikler	72
Tablo V. 3 Algoritmaların Başarı Yüzdelerinin Kıyaslanması	75
Tablo V. 4 İlk Denek Grubu- 64 kişi	75
Tablo V. 5 İlk Denek Grubu- 56 kişi (Holter Cihazı Verileri Dahil ve Null data yok).....	76
Tablo V. 6 İkinci denek grubu- 24 kişi (Holter Cihazı Verileri Dahil).....	76
Tablo V. 7 Nondipper/Dipper Öngörüsü için Değerlendirmeye Alınan	78
Tablo V. 8 İlk denek grubu- 56 kişi (Holter Cihazı Verileri Dahil Değil).....	79
Tablo V. 9 İkinci denek grubu- 24 kişi (Holter Cihazı Verileri Dahil Değil).....	79
Tablo V. 10 Deney – 1 Nitelik Sayısı	80
Tablo V. 11 Deney – 1 Gerçek ve Tahmin Karşılaştırma Tablosu	83
Tablo V. 12 Deney – 1 Sonuç Değerlendirmesi.....	86
Tablo V. 13 Deney – 1 Hata Matrisi	86
Tablo V. 14 Deney – 2 Nitelik Sayısı	88
Tablo V. 15 Deney – 2 Sonuç Değerlendirmesi.....	90
Tablo V. 16 Deney – 2 Hata Matrisi	90
Tablo V. 17 Deney – 2 Eğitim Veri Seti	91
Tablo V. 18 Deney – 2 Test Veri Seti	92
Tablo V. 19 Deney – 2 Test Veri Kümesi Tahmin Sonuçları	93
Tablo V. 20 Deney – 2 Test Veri Kümesi Gerçek ve Tahmin Karşılaştırılması.....	93
Tablo V. 21 Deney – 2 Nitelik Sayısı	94

Tablo V. 22 Deney – 3 NaiveBayes Modeli.....	97
Tablo V. 23 Deney – 3 Gerçek ve Tahmin Karşılaştırma Tablosu	98
Tablo V. 24 Deney – 3 Sonuç Değerlendirmesi	98
Tablo V. 25 Deney – 3 Hata Matrisi.....	99
Tablo V. 26 Deney – 4 Nitelik Sayısı.....	100
Tablo V. 27 Terimlerin Karşılıkları.....	102
Tablo V. 28 Deney – 4 Gerçek ve Tahmin Karşılaştırma Tablosu	109
Tablo V. 29 Deney - 4 MLP Modeli.....	110
Tablo V. 30 Deney – 4 Sonuç Değerlendirmesi	111
Tablo V. 31 Deney – 4 Hata Matrisi.....	111
Tablo V. 32 Deney – 5 Gerçek ve Tahmin Karşılaştırma Tablosu	116
Tablo V. 33 Deney – 5 Sonuç Değerlendirmesi	117
Tablo V. 34 Deney – 5 Hata Matrisi.....	117
Tablo V. 35 Deney – 6 Nitelik Sayısı.....	119
Tablo V. 36 Deney – 6 Gerçek ve Tahmin Karşılaştırma Tablosu	119
Tablo V. 37 Deney – 6 Sonuç Değerlendirmesi	120
Tablo V. 38 Deney – 6 Hata Matrisi.....	120
Tablo V. 39 Deney – 7 Gerçek ve Tahmin Karşılaştırma Tablosu	122
Tablo V. 40 Deney – 7 Sonuç Değerlendirmesi	123
Tablo V. 41 Deney – 7 Hata Matrisi.....	123
Tablo V. 42 Deney – 8 Gerçek ve Tahmin Karşılaştırma Tablosu	125
Tablo V. 43 Deney – 8 MLP Modeli	126
Tablo V. 44 Deney – 8 Sonuç Değerlendirmesi	126
Tablo V. 45 Deney – 8 Hata Matrisi.....	127

BÖLÜM I

GİRİŞ

Bu tez çalışması Marmara Üniversitesi Tıp Fakültesi İç Hastalıkları Anabilim Dalı, Hipertansiyon ve Ateroskleroz Ünitesi Polikliniği ve Endokrinoloji Bilim Dalı ile Marmara Üniversitesi Fen Bilimleri Enstitüsü Elektronik-Bilgisayar Eğitimi Bölümü tarafından ortaklaşa gerçekleştirilmiştir. Disiplinlerarası bu çalışma prospektif, gözlemsel bir çalışma olarak düzenlenmiştir. Tedavi/girişim üzerine herhangi bir müdahale planlanmamıştır.

Bu çalışmanın yapılabilmesi için Marmara Üniversitesi Tıp Fakültesi Klinik Araştırma Etik Kurulu izni alınmıştır. Bununla birlikte çalışmaya katılan tüm hastalar bilgilendirilmiş ve yazılı onayları alınmıştır.

I.1 AMAÇ VE GEREKÇE

Diabetes Mellitus halk dilinde “Şeker Hastalığı” olarak bilinen, toplumda çok sık rastlanan ve önemli kardiyovasküler (dolaşım) morbidite (görülme sıklığı) ve mortaliteye (ölüm oranı) sebep olan bir hastalıktır.

Diyabetik hastalarda kardiyovasküler riski artıran bir dizi klinik ve laboratuvar bozukluk tanımlanmış olup bunların bir kısmı hastaların tanı ve tedavilerinin planlanmasında kullanılmaktadır. Diyabetik hastalarda hipertansiyon (yüksek kan basıncı hastalığı) çok sıktır ve hipertansiyon diyabetle birlikte kalp ve damar hastalığı (kalp krizi, infarktüs, kalp yetersizliği, felç, ani ölüm, böbrek yetersizliği) riskini belirgin olarak artırır. Hipertansiyonu olan hastalarda, henüz söz konusu hastalık belirtileri ortaya çıkmadan bazı organ hasarı bulguları saptanabilir. Bu hasarlara “hedef organ hasarı” denir. Bu durum bazen muayene ile bazen de bazı tetkiklerle anlaşılabilir [1].

Bu hasarlarla ilişkili olan bir durum da, kan basıncı düzeyinde gece normalde beklenen düşüşün olmamasıdır.

Arteriyal kan basıncı değerlerinde gece fizyolojik düşüşün olmamasının (“non-dipping” özelliğın) hem diyabetik, hem de non-diyabetik hastalarda başta hedef organ hasarı olmak üzere artmış kardiyovasküler morbiditeyle ilişkisi son yıllarda ortaya konmuştur [2,3]. “Non-dipping” özellik (veya “non-dipper” hastalar) ancak 24 saatlik ambulator kan basıncı kaydı (Holter kan basıncı tetkiki) ile değerlendirilebilmektedir. Bu tetkik non-invazif (hastanın vücuduna herhangi bir şekilde iğne vb. araç ile girişimin olmaması) bir yöntem olmakla birlikte hastanın 24 saat bir kayıt cihazını taşıması ve en az iki kez hastane / sağlık kurumuna gitmesini gerektirmesi nedeniyle çoğu zaman zahmetli ve pahalıca bir tıbbi yöntemdir.

“Non-dipper” hastaların, muayene bulgularına ve poliklinikteki ilk değerlendirme sırasında yapılabilecek basit laboratuvar tetkiklerinin sonucuna göre tahmin edilebilmesi (öngörülebilmesi) klinik açıdan önem taşımaktadır. Böylece kardiyovasküler açıdan daha yüksek risk altındaki kişiler pratik ve hızlı bir yöntemle anlaşılabilir ve gereken tedavileri daha kolaylıkla planlanabilecektir.

Bilişim teknolojileri açısından tıbbi olarak “Non-Dipping / Dipping” özelliğı öngörmeye yönelik bir çalışma yapılabilmesi için denek grubuna ait niteliklerin değerleri ile veritabanı oluşturulması, veri madenciliğı tekniğı kullanılarak öncelikle tıbbi 47 adet niteliğın içinden holter cihazına ait verilerin çıkarılması ve toplam nitelik sayısının mümkün olduğunca aza indirgenerek tıp doktorunun teşhisine en yakın doğruluk ve güvenilirlikte sonuç veren modelin ortaya konması ve bunun için bir sistem tasarımının yapılması amaçlanmıştır.

I.1.1 Materyal ve Yöntem

Marmara Üniversitesi Tıp Fakültesi İç Hastalıları Anabilim Dalı, Hipertansiyon ve Ateroskleroz Ünitesi Polikliniğı’ nin ve İç Hastalıkları Poliklinikleri’ nin çalışma ölçütlerine uygun hastalar, çalışma kapsamına alınmıştır. Tedavi altında olan veya olmayan, tanısı eski veya yeni tanı konmuş, 18 yaşından büyük, kadın veya erkek tip 2 diyabetes mellituslu hastalar veya tanısı eski veya yeni konmuş, tedavi altında olan veya olmayan hipertansiyon hastaları çalışma adayı olarak belirlenmiştir. Ofis kan basıncı ölçümleri normal olan ve antihipertansif ilaç kullanmayan hastalar çalışmaya kabul edilmiştir. Kan basıncı sınıflaması ve “dipper” / “non-diper” değerlendirmesinde Amerika Birleşik Devletleri Birleşik Ulusal Kurul Kılavuzları -JNC 7 ölçütü temel alınmıştır [4].

Bir hastanın bu çalışmanın dışında tutulma ölçütleri ise; klinik takipte olamayacak durumda olmak ve hastanın çalışmaya katılmayı kabul etmemesi idi. Ayrıca akut koroner sendrom hastaları, kalp yetersizliği öyküsü veya tanısı olan hastalar da çalışma dışı tutulmuştur.

Çalışmadaki tüm deneklerde klinik değerlendirme ve ilgili tüm laboratuvar tetkikleri her hasta için en geç 4 haftalık bir zaman sürecinde tamamlanmıştır.

Bu çalışma için tasarlanan 24 Saatlik Kan Basıncını Öngörmeye Yönelik Uzman Sistemin mimarisi iki ana kısımdan meydana gelmektedir: Birinci kısımda .NET Framework üzerinde hekimlerin kullanımına yönelik tasarlanmış bir kullanıcı arayüzü vardır. Arayüz sayesinde üyelik işlemlerini gerçekleştiren kullanıcı yani tıp doktoru, hasta ile ilgili demografik, klinik, laboratuvar ve test verilerini SQL server 2008 üzerindeki veritabanına kayıt edebilmekte, silbilmekte ve güncelleyebilmektedir. Bu çalışmada; veri madenciliği tekniği, sınıflandırma ve öngörü yaklaşımı kullanılması tercih edilmiştir. Sistemin ikinci kısmını oluşturan çalışma WEKA (Waikato Environment for Knowledge Analysis) programında 3.7.4. Developer versiyonunda gerçekleştirilmiştir. Sınıflandırma ve öngörü yaklaşımı için karar ağaçları, bayes ve yapay sinir ağları yöntemleri uygulanmıştır.

C4.5 karar ağacı algoritmasının Weka 'daki uyarlaması olan J48 algoritması, bayes yöntemi için NaiveBayes algoritması ve yapay sinir ağı yöntemi içinde yer alan RBF (Radial Basis Function) ile MLP (Multi Layer Perceptron) algoritmaları kullanılarak nondipper/dipper sınıflandırması ve öngörüsü yapan modeller geliştirilmiştir.

1.2 ÇALIŞMANIN LİTERATÜRDEKİ YERİ

Literatür taraması sırasında yapay zeka teknikleri kullanılarak tıp alanında özellikle diabet, kanser, kardiyovasküler hastalıklara yönelik yapılmış çalışmalar incelenmiştir. Bu konularda Türkiye’de ve dünyada yapılmış pek çok çalışmaya rastlanmakla beraber, non-dipper/dipper patern teşhisine yönelik herhangi bir yapay zeka yöntemi ile yapılmış çalışmaya rastlanılmamıştır. Tıbbi içeriği bu tez çalışmasına en yakın olan örnekler seçilerek, bu bölümde irdelenmiş ve bu tez çalışması ile karşılaştırılmıştır.

Brezilya Pernambuco Federal Üniversitesi Elektrik ve Sistem Mühendisliği Bölümü ile aynı üniversite bünyesinde yeralan hastanenin kardiyoloji bölümü hipertansiyon kliniği arasında gerçekleştirilmiş disiplinlerarası bir çalışmada, non-lineer istatistik uygulamalarda sınıflama problemlerinin çözümü için kullanılan yapay sinir ağı modelleme yöntemi bu kez, sol ventrikül hipertrofisinin teşhisi için kullanılmıştır. Bu yöntem için 21 ile 81 yaş aralığında kadın ve erkeklerden oluşan heterojen gruba ait 101 bireysel kayıt alınarak veritabanı oluşturulmuştur. Bu grubun %27’si normotansif, %73’ü ise hipertansif değerlere sahiptir. Giriş verileri antropometrik ölçümler, biyografikal veriler, nabız ve kan basıncı ile ilgili ofis ölçümleri, biokimya serisi ve hormonlar ile ABPM, elektrokardiyogram ve elektrokardiyografik verilerden oluşmuştur. Bu çalışmanın sonucunda; bazı iyileştirmelerden sonra bu yapay sinir ağı sisteminin tıbbi karar destek sisteminin geliştirilmesinde kullanılmasının, esnekliği ve dayanıklılığı nedeniyle tıbbi teşhis sağlama görevine uygun olacağı ortaya konmuştur [5].

Başka bir araştırmada ise; Genetik Algoritma ve Ağırlıklı k-En yakın Komşular- WkNN yöntemleri, Tip 2 Diabetes Mellitus (DM) hastalarda koroner hastalığı komplikasyonları tahmini için bir öğreticiyle öğrenme yaklaşımı olup, komplikasyonun varlığı/yokluğu sınıflandırmasını yapmak için kullanılmıştır. Kuzey İrlanda’da Ulster Hastanesi’nde kaydedilmiş potansiyel risk faktörleri analizi ile araştırma gerçekleştirilmiştir. Yaş, sigara alışkanlığı, sistolik kan basıncı, diastolik kan basıncı, toplam kolesterol, HDL, LDL, HbA1c, üriner albümin-kreatinin oranı, microalbümin, kreatinin, BMI, rastgele kan şekeri, cinsiyet, trigliserid, ağırlık, üre değerleri uzman tarafından veritabanından alınmıştır. Tip 2 DM hastalarda koroner kalp hastalıkları komplikasyonları tahmini önemli bir klinik görev olduğu, dahası bu araştırmanın amacının koroner kalp hastalığı hasarı olup olmadığı sınıflandırmasının

yapılabilmesi olduğu belirtilmiştir. Bu çalışmanın sonucunda; araştırmacılar ve klinik çalışanları açısından sınıflandırma, hibrid yaklaşımlar ve tıbbi veritabanlarından yararlanılarak veri madenciliği yöntemleri ile çözümsel yaklaşımların getirilebildiği ve gelecekte de bu tür çalışmalar için cesaretlenilmesi önerilmiştir [6].

Çin Halk Cumhuriyeti Chongqing’de bulunan Southwest ve Dajiang Hastanelerinden 352 vakaya ait kalp hastalığı veri tabanı, önerilen sistemlerin performanslarını değerlendirmek için kullanılmıştır. Beş önemli kalp hastalığının teşhisi için, MLP-Multilayer Perceptron yani Çok Katmanlı Algılayıcı gruplamasına dayanan komite (gruplama) makinaları önerilmiştir. Özellikle, rastgele alt uzay ve bagging yöntemlerini içeren iki gruplama yöntemi düşünülmüştür. MLP gruplamalı komite makinaları ile tek MLP’ye göre %95.28 doğruluk (accuracy) ile daha iyi performans elde edilmiştir [7].

Selçuk Üniversitesi’ndeki akademisyen bir grup, kalp hastalığını teşhis etmek için bilgi kazancına dayanan özellik seçme algoritması, bulanık ağırlıklandırma ön- işleme ve yapay bağışıklık tanıma sistemleri bileşimine dayanan hibrid bir sistem ile %50-50 eğitime ve test veri kümesi ayırımı yaparak, %92.59 sınıflama doğruluğu yakalamışlardır [8].

Diğer bir çalışma olarak bu grup, Kaliforniya Üniversitesi Bilgisayar Bölümünün UCI Machine Learning veritabanını kullanarak, Pima yerli kadınları üzerinde diabetes hastalığının teşhisine yönelik olarak, Temel Bileşenler Analizi (Principle Component Analyze) ile ANFIS- Adaptive Neuro- Fuzzy Inference System yaklaşımlarını kullanmış ve %89.47 doğruluk ile sınıflama yapmışlardır[9].

Yine aynı grup diğer bir çalışmada, k-NN tabanlı veri ağırlıklandırma ön- işleme yöntemi ile bulanık kaynak dağılım mekanizmalı YBTS sınıflama algoritmasını birleştiren bir uzman sistemi, kalp hastalığı veri kümesinin sınıflamasına uygulayarak %87 sınıflama doğruluğu elde etmişlerdir [10].

[11] numaralı çalışma ise; Fuzzy Kural Tabanlı Karar Destek Sistemi, koroner arter hastalığı teşhisine yöneliktir. Ioannina Üniversitesinde, 199 hastadan alınan 19 parametre değerlendirilerek hastalığın varlığı/yokluğu tesbit edilmiştir. Sonuç olarak yerel etik komitesinden izinli şekilde yapılan bu çalışmada, duyarlılık (sensitivity) ortalama %80 ve özgüllük (specificity) oranı ise %65 ile 110 bireyde hastalık var ve kalan bireyler normal yani hastalık yok olarak tesbit edilmiştir. Bu yöntemin tıbbi ve diğer alanlara uygulamanın kolay olduğu belirtilmiştir.

Selçuk ve Erciyes Üniversiteleri akademisyenlerinden oluşan bir grubun 60 hasta ve 54 sağlıklı gönüllüden oluşan bir denek grubuna ait verilerle yaptığı bu çalışmada, Atherosclerosis (damar sertliği) hastalığını teşhis etmek için Fast Fourier Transformation, Temel Bileşenler Analizi, k-NN tabanlı veri ağırlıklandırma ön-işleme ve Artificial Immune Recognition System – Yapay Bağışıklık Tanıma Sistemi’ne dayanan hibrid bir sistem ile Atherosclerosis hastalığının teşhisinde %100 sınıflama doğruluğu elde edilmiştir [12].

BÖLÜM II

ÇALIŞMANIN TIP BİLİMİNDEKİ YERİ

Bu çalışmanın konusu olan ve Diabetes Mellitus (DM- halk ağzında şeker hastalığı), Sistemik Hipertansiyon (HT - yani yüksek tansiyon) hastalıklarını daha iyi tanıtabilmek amacıyla tarihçesi, tanımı, sınıflandırılması, dünyadaki ve Türkiye'deki prevalansları (belirli bir nüfusta, belirli bir zaman dilimi içerisinde, çalışma kapsamında yer alan, belirli bir hastalık veya hastalıklara sahip kişilerin oranı) bu bölümde incelenmiştir. Kardiyovasküler hastalıklar (KVH) yani kalp-damar hastalıkları tanımları yapılarak, risk faktörleri, morbidite (bir toplulukta herhangi bir hastalık için görülme sıklığı) ve mortalite (belirli bir nüfus topluluğunun gözlem altında tutularak oluşturulan yaşama ve ölüm istatistiklerine göre elde edilen sonuçlardan, her bir yaşta bir yıl içerisinde kaç kişinin hayatta kalacağını, kaç kişinin öleceğinin öngörüldüğü tablolardır) oranları incelenerek, hedef organ hasarı ve non-dipper paterninin tesbitinin gereği vurgulanmıştır. Bu bağlamda, tezin halk sağlığı ve sistemi açısından arz ettiği önem belirtilmeye çalışılmıştır.

II.1 DIABETES MELLITUS HASTALIĞI (DM)

Diabetes Mellitus hastalığının çok eski tarihlere dayanan kayıtları olduğu ve tüm zamanlarda yaygın olup, giderek daha çok tehdit oluşturduğu bilinmektedir. Bu hastalığı daha iyi tanıtabilmek amacıyla tarihçesi, tanımı, sınıflandırılması, dünyadaki ve ülkemizdeki prevalansları bu bölümde incelenmiştir.

II.1.1. DM Hastalığının Tarihçesi

Antik çağlardan beri ciddi bir sağlık problemi olarak fark edilen DM ile ilgili en eski kayıtlar M.Ö. 1550 yılında Eski Mısır'ın başkenti Thebes'de yazılmış Ebers olarak adlandırılan medical papürüslerdir [13,14].

Diyabet terimi (Yunanca: διαβήτης, diabētēs), MS. 2. yüzyılda Roma İmparatorluğu döneminde Aretaeus of Cappadocia tarafından ortaya konmuştur.


Diabētēs teriminin “sifon” anlamı, aşırı derecede idrara çıkmanın eşlik ettiği bir hastalığı isimlendirmekte kullanılmasının asıl nedenidir [15,16].

17. yüzyılda İngiliz Doktor Thomas Willis DM hastalarının idrarının tatlı olduğunu tekrar keşfederek, şekersiz şeker hastalığı denilen ve vücudumuzun su dengesini ayarlayan bir hormon olan antidiüretik hormon eksikliği sonucu ortaya çıkan benzer isimli Diabetes Insipidus ile Diabetes Mellitus'un ayırımını yapmıştır[17].

18. yüzyılda William Cullen tarafından, “diabetes” kelimesinin yanına Latince mellis = tatlı ya da bal anlamına gelen kelimedenden türetilmiş Mellitus eklenmiştir ve günümüzde tıp literatüründe kullanılmaktadır [16].


II.1.2. DM Tanımı ve Sınıflanması

Yiyeceklerde bulunan basit şeker “Glukoz” olarak adlandırılır. Karbonhidratlar, ince bağırsak içinde parçalanır böylece yiyeceklerdeki glukoz ortaya çıkar. Daha sonra bağırsak hücreleri tarafından emilen glukoz, kan dolaşımı vasıtasıyla tüm vücut hücrelerine taşınır ve düzgün çalışmaları için onlara enerji sağlanmış olur. Ancak glukoz hücrelere girmek için insüline ihtiyaç duyar. Yani kanda bol miktarda glukoz olsa dahi hücre yeterli insulin olmadan glukozu enerjiye çeviremez. Bu durum Şekil II.1’de görülmektedir.



Şekil II. 1 Glukozun normal emilimi ve glukozun kanda kalması [18]

DM kalıtsal ve edinsel faktörlerin etkileşimi ile Şekil II.2’ de vücudumuzdaki yeri görülen pankreas adlı salgı bezinin ürettiği insülin hormonunun (Beta hücreleri) eksikliği veya etkisizliği sonucu gelişen kronik hiperglisemiye – kana geçen glukozun kullanılamaması sonucu kan şekeri yükselmesi- karbonhidrat, yağ ve protein dengesi bozukluğuna akut komplikasyonların eşlik etmesiyle yaşam boyu süren bir hastalıktır [19]. Diyabet klinik olarak polidipsi (çok su içme), poliüri (çok idrar yapma), polifaji (fazla yeme), pruritis (kaşıntı), kilo kaybı gibi belirtiler ve hastalığa özgü retinopati (göz dibinde retina tabakasının bozukluğu), nöropati (sinir hücrelerinin bozukluğu) ve nefropati (böbrek bozukluğu) gibi komplikasyonlarla tanınabilir [20-23].



Şekil II. 2 Pankreasın yeri [18]

WHO, 1985 yılında diyabet hastalığını insüline bağımlı diyabet (IDDM) ve insüline bağımlı olmayan diyabet (NIDDM) olarak ayırmış ve klinik bir sınıflama yapmıştır. Ancak bu sınıflamanın sınırlayıcı yönleri söz konusuydu. Çünkü diyabet heterojen bir hastalıktır; iki sınıf arasında ve kendi içlerinde etiyolojik ve fenotipik farklılıklar söz konusudur [24].

1997 yılında Amerikan Diyabet Derneği (American Diabetes Association-ADA) etiyolojik açıdan Tip 1 ve Tip 2 diyabet sınıflamasını önermiştir [25].

Diyabet hastalığı etiyolojik açıdan 4 ana sınıf altında toplanmıştır. Bunlar;

1. Tip 1 diabetes: Beta hücre yıkımı, çoğunlukla mutlak insülin eksikliği sonucu gelişen diyabet formudur.

A. Otoimmün

B. İdyopatik

2. Tip 2 diabetes: Etiyopatogenetik olarak insülin direncinin ve insülin sekresyon bozukluğunun bir arada bulunması ile ortaya çıkan bir hastalıktır. İleri yaş, obezite, fiziksel aktivite azlığı, gestasyonel diyabet öyküsü, hipertansiyon ve dislipidemisi olan kişilerde daha sık görülür. Sıklıkla kuvvetli bir genetik yatkınlık görülür, ancak genetiği karmaşıktır (poligenik) ve tam olarak tanımlanamamıştır. Tüm diyabetli hastaların % 85-90'lık kısmını oluşturur. Hastaların çoğu obezdir. Bu hastalarda tanı yıllarca gecikebilir, diyabetin klinik belirtileri ortaya çıkana kadar geçen zaman 10-12 yıl kadar uzun olmaktadır. Bu dönemde henüz tanısı konmamış tip 2 diyabetliler arasında hastalık bazen diyabete bağlı makrovasküler ve/veya mikrovasküler hastalıkların ortaya çıkmasıyla tanınabilmektedir. Ketoasidoza eğilim söz konusu olmamakla birlikte ağır stres hallerinde veya enfeksiyonların seyri sırasında ortaya çıkabilmektedir [26-28].

3. Diğer çok özel diyabet tipleri

- Beta hücre fonksiyonlarında genetik bozuklukla karakterize
- İnsülin etkisinde genetik bozukluklar
- Pankreas bezinin dış salgı hastalıkları
- Endokrinopatiler (hormon hastalıkları)
- İlaç ya da diğer kimyasallara bağlı diyabet
- Enfeksiyonlar-konjenital rubella, sitomegalovirus, vb.
- İmmunolojik mekanizma ile gelişen bazı seyrek diyabet formları
- Diyabete eşlik eden genetik sendromlar- Down sendromu

4. Gestasyonel (gebelik sürecindeki) Diabetes Mellitus (GDM) [29-33]

Günümüzde kabul gören etiyolojik açıdan diyabet hastalığının sınıflandırılması

Tablo II.1'de gösterilmiştir [34].

Tablo II. 1 Diabetes Hastalığının Etiyolojik Olarak Sınıflandırılması [34]

Aşamalar Tipler	Normoglisemi	Hiperglisemi			
	Normal Glukoz Düzeni	Bozulmuş Glukoz Toleransı ya da Bozulmuş Açlık Glukozu	İnsilün Gereksinimi Yok	Diabetes Mellitus Kontrol için İnsilün Gereksinimi	Yaşamak için İnsilün Gereksinimi
Tip 1	x	x	x	x	x
Tip 2	x	x	x		
Diğer Özel Tipler	x	x	x		
Gestasyonel Diabetes	x	x	x		

II.1.3. DM'nin Vücutta Oluşturduğu Hasarlar (Complications)

DM komplikasyonları ile ilgili olarak kolesterol ve ateroskleroz terimlerinin tanımları aşağıda yapılmıştır [35].

Kolesterol; İnsan bedeninin hücre duvarını yapmak için kullandığı yağ benzeri bir maddedir. Yediğimiz hayvan yağlarından emilerek karaciğer tarafından üretilir. Kolesterolün kanda taşınması, vücudumuzun lipoproteinler adı verilen protein paketleri sayesinde kolesterolü bir araya getirmesiyle mümkün olur.

Kolesterolün Düşük Yoğunluklu Lipoprotein-LDL ve Yüksek Yoğunluklu Lipoprotein-HDL olarak iki farklı çeşidi vardır. LDL damarlarda biriktiği için "kötü" olarak kabul edilir. HDL kolesterolü damarlardan ayırarak vücuttan uzaklaştırılması ya da işleme için karaciğere götürdüğünden dolayı "iyi" olarak belirtilir.

Yüksek kan şekeri seviyeleri ile yüksek kolesterol arasında bir ilişki bulunmaktadır.


Ateroskleroz yani damar sertliği; Kolesterol oranının çok yükselerek kan damarlarının duvarlarında birikmesi ve damarların daralması olayıdır. Bu olay, kalp krizi ve inme riskini çok büyük oranda artırır.

DM'un KVH, retinopati, nefropati, nöropati gibi önde gelen komplikasyonları aşağıda açıklanmıştır [36].

II.1.3.1. Kardiyovasküler Hastalıklar

Yüksek kolesterol ve buna bağlı olarak artan kalp hastalığı riski, diyabetin tipik komplikasyonları arasındadır. DM hastalarının %50'ye yakını, yüksek kolesterol değerlerine sahiptir. Tip 2 diyabet teşhisi konanların çoğunda teşhis anında koroner kalp hastalığı saptanmaktadır. Koroner kalp hastalığı, kalbin damarlarının

daralmasıdır. Bu bağlamda, ateroskleroz diyabetik ölümlerinin %80'inden sorumludur ve bu ölümler genellikle kalp krizine bağlı olarak gerçekleşmektedir. Plak tarafından tıkanan koroner arterler ile sağlıklı ve ölü kalp kas dokusu Şekil II.4'de görülmektedir.



Şekil II. 3 Plak tarafından tıkanan koroner arterler ile sağlıklı ve ölü kalp kas dokusu [37]

II.1.3.2. Retinopati

Görme eylemi; göz küresinin en içteki tabakası olan retinadaki (ağ tabaka) görme hücrelerinin, görsel olarak uyarılması ve bu uyarının görme yolları vasıtasıyla, beyindeki görme merkezine iletilmesiyle gerçekleşmektedir.

DM hastalığında, retinada erken evrelerde olan temel değişiklikler; kılcal damarlar dâhil olmak üzere damarlarda tıkanıklar, damar duvarlarından sızıntılardır. Daha geç evrelerde ise anormal yeni damar oluşumları ortaya çıkabilmektedir. Retinopati hastalığı sonucunda gözde meydana gelen değişiklikler Şekil II.5'de görülmektedir.



Şekil II. 4 Retinopati [18]

Diyabet süresinin artmasıyla, retinopati gelişme riski de artmaktadır. Yeni tanı konan tip 2 diyabetli hastalarda retinopati sıklığı % 20 iken, diyabet süresi 15 yıl olanlarda % 70'e kadar yükselmektedir.

İki çok merkezli çalışma tartışmaya yer bırakmayacak şekilde, retinopatinin hem ortaya çıkmasında, hem de ilerlemesinde kan şekeri ayarının önemli etkenlerden birisi olduğunu göstermiştir. Bunlar; Diyabet Kontrol ve Komplikasyon Çalışması (Diabetes Control and Complication Trial-DCCT) ve Birleşik Krallık Prospektif Diabet Çalışması (United Kingdom Prospective Diabetes Study-UKPDS)'dir. İyi kan şekeri ayarının olumlu etkisi, 1441 adet tip 1 diyabetli hastayı kapsayan DCCT gibi çok merkezli ve 10 yıl gibi uzun süreli bir çalışmada ortaya konmuştur. Yine 5000 civarında tip 2 diyabetli hastayı kapsayan UKPDS çalışmasında da iyi kan şekeri ayarının olumlu etkisi gösterilmiştir.

Diyabetik retinopati gelişmiş ülkelerde 20-74 yaş arası popülasyonda önde gelen körlük nedenleri arasındadır.

II.1.3.3. Nefropati

Böbreklerin görevi, kanda biriken nitrojen zengin atıkların temizlenmesi ve vücudumuzda uygun sıvı dengesinin temin edilmesidir.

Her böbrek 600 bin - 2 milyon arasında nefron adı verilen küçük ünitelerden meydana gelmiştir. Kalpten dakikada atılan tüm kanın $\frac{1}{4}$ 'ü böbreklerden geçerken,

nefronlar sayesinde atıklardan temizlenir ve bu atıklar idrara dönüştürülerek üreterler (idrar kanalı) aracılığı ile idrar kesesine gönderilir. Oradan da vücudun dışına atılır. Böbrekteki nefronların hasar görmesine nefropati adı verilir. Diyabete bağlı olarak gelişen böbrek hastalığı ise diyabetik nefropati olarak bilinir. Uzun dönemde ortaya çıkabilen komplikasyonlardan biridir. Bu durumda vücutta kalması gereken bazı maddeler idrarla atılır. Diğer taraftan vücutta atılması gereken bazı maddeler ise atılamadığı için kanda ve dokularda birikir.

II.1.3.4. Nöropati

Vücudumuzda esas olarak 2 tip sinir mevcuttur: Motor ve duysal sinirler ve Otonomik sinirler. Motor ve duysal sinirler; vücudumuzdaki tüm kasların hareketini kontrol ederler. Bu sinirler sıcaklık, dokunma ve acı gibi duyularını hissetmeyi sağlarlar. Otonomik sinirler; bizim kontrolümüzde olmadan, otomatik olarak vücut fonksiyonlarını düzenlerler. Örneğin; akciğerlerde nefes alıp-verme, salgı bezlerinde terleme, sindirim sisteminde sindirim ve atılım, göz kasları ile göz bebeğinin açılıp kapanması gibi vücudumuzun tüm otonomik fonksiyonlarını düzenlemektedirler.

Nöropati, diyabetin en sık görülen komplikasyonlarından biri olup sinir hasarıdır ve her iki sinirde de oluşabilir.

Genel olarak glukozillenmiş hemoglobin (HbA1C) değerinin yüksek seyretmesi ve sinirlerde şekerin (sorbitol) birikmesinin nöropati gelişmesinde etken olabileceği düşünülmektedir. DM hastalarının yarısından fazlasında nöropati vardır. DM hastalığının süresi uzadıkça ve bu süre içinde kan şekeri kontrolsüz ise gelişme olasılığı artmaktadır.

II.1.4. DM' nin Dünyadaki ve Türkiye'deki Yeri

DM, ciddi metabolik hastalıklar arasında prevalansı nüfus artışına, yaşlanmaya, kentleşmeye, fiziksel aktiviteye ve obezite prevalansının yükselmesine bağlı olarak tüm dünyada giderek artan epidemik bir hastalıktır. Sinsi seyirli bir hastalık olduğundan prevalansının saptanması güçlük yaratmaktadır. Hemen hemen tüm toplumlarda görülmesine karşın diyabet prevalansı ırka bağlı olarak anlamlı farklılıklar göstermektedir [24, 38].


Diyabetes Mellitus, dünya genelinde ve tüm yaş gurplarında WHO'nun yaptığı hesaplara göre, 2000 yılında prevalansı % 2.8 iken 2030 yılında % 4.4 olarak hesap edilmiştir. 2000 yılında; dünyada toplam 171 milyon olan diyabetli hasta

sayısı, 2003 yılı itibarı ile 194 milyon olmuş ve 2030 yılında 366 milyona ulaşması beklenmektedir[16,29,38-41]. Diyabetli hasta sayının yaklaşık olarak % 97'si tip 2 DM sınıflamasına girmektedir[33,42]. Dünya’da tip 2 diyabet prevalansının önümüzdeki on yıl içinde yaklaşık olarak %40 artarak 150 milyondan 210 milyona ulaşması beklenmektedir [43]. Dünya genelinde tip 2 DM’un oluşturduğu tehlikeyi daha iyi gözönüne sermek için Tablo II.1’deki verilen tip 2 DM ve IGT prevalansları sunulmuştur [44].

Tablo II. 2 Dünya Genelinde Tip 2 DM ve IGT Prevelansları [44]

Prevalans	Tip 2 DM	İGT
% 0-4.9	Bantu, Tanzanya, Rusya, Polonya, Çin(kent)	Brezilya, Polonya, Malta, Çin (kent), Şili
% 5-9.9	ABD, İtalya, Malezya, Türkiye, Brezilya	İtalya, Rusya, Tunus, Türkiye
% 10-19.9	Polinezya, Çin, Fiji, Hindistan, G. Afrika, Malta	ABD, Malezya, Puerto Rico, Hindu
% 20-29.9	Hindu (kırsal), Fiji	Mikronezya, Kiribati, Nauru
% 40-49	Mikronezya, Nauru	
% 50 üzeri	Pima yerlileri ABD	

Ülkemizde diyabet sıklığını belirlemeye yönelik 1997–1998 yıllarında gerçekleştirilen ve rastgele olarak seçilmiş 20 yaş ve üzerindeki 24,788 kişiyi kapsayan ‘Türkiye Diyabet Epidemiyoloji (TURDEP) Çalışması’nın sonuçlarına göre, ülkemizde tip 2 diyabet prevalansı % 7.2, IGT sıklığı ise % 6.7’dir. Bu oranlara dayanarak 2000 yılı nüfus sayısına göre, ülkemizde 2,6 milyonun üzerinde diyabetli ve 1,8 milyon civarında IGT’li kişinin yaşadığı sanılmaktadır [27,39,45,46]. Ülkemiz açısından konunun öneminin daha çok anlaşılması için Şekil II.6’ da 1997-1998 yılları arasındaki TURDEP çalışması sonuçlarına istinaden yaş ve cinsiyete göre kırsal ve kentsel kesimde DM ve IGT prevalans grafikleri sunulmuştur [46].



Şekil II. 5 Yaş ve Cinsiyete göre Kırsal ve Kentsel kesimde DM ve IGT prevalansları A- Kentsel ve Erkek B- Kentsel ve Kadın C- Kırsal ve Erkek D- Kırsal ve Kadın için [46]

2006 yılında Anadolu Kardiyoloji dergisinde yayınlanan orijinal araştırma sonucuna göre Türkiye’de 305bin olan DM insidansı hızla artmakta, prevalansı da benzer şekilde yükselmektedir [47].

II.2 HİPERTANSİYON HASTALIĞI (HT)

Kanın damar duvarına yaptığı basınç, “kan basıncı” olarak isimlendirilmektedir. KB’nın değerleri, doku perfüzyonu (beslenme) sağlayacak kadar yüksek ama zarar vermeyecek kadar da düşük ise normal KB olarak kabul edilmektedir. “Hipertansiyon” ise en yalın haliyle, kan basıncının normal olarak kabul edilen sınırların üstüne çıkması olarak tanımlanmaktadır. Bu bölümde HT’nin tarihçesi, tanımı, sınıflandırılması, dünyadaki ve ülkemizdeki yeri, HT ile ilgili iki önemli kavram olan Dipper ve Non-Dipper terimlerinin açıklanması, bu tez kapsamında özellikle Tip 2 DM, Hipertansiyon ve KVH arasındaki etkileşim anlatılmaktadır [48].

II.2.1. HT Hastalığının Tarihçesi

İnsanın dünyada varolmaya başlamasıyla birlikte, sağlık problemlerinin gündeme gelmiş olması çok olasıdır. Buna rağmen, tıbbi çalışmaların tam nerede, ne zaman ve nasıl başladığı hakkında çok kesin bilgiler bulunmamaktadır. Bununla birlikte, kronolojik sıraya dikkat edilerek, bilinen tarih içindeki en önemli çalışmalara ait bilgiler aşağıda verilmeye çalışılmıştır.

Eski Mısır'da M.Ö. 3000-1500 yıllarında yazılmış olan Ebers ve Edwim Smith papürüslerinde kalp ve damarlardan oluşan bir sistemin betimlendiği, kalbin hareketleri ile ilgili bilgilerin yer aldığı bilinmektedir.

M.S. 2600 yılları civarı Eski Çin'de ilk nabız ölçme uygulaması yapılmıştır. Kişinin vücudunun 11 değişik noktasından 200 değişik veri elde edilmiştir. Yaklaşık olarak bu işlem birkaç saat almıştır.

M.Ö. 460-377 yıllarında Antik Yunan'da, Hipokrat 4 kalp boşluğu olduğunu ve aortik kapağın yalnızca bir yöne açıldığını iddia etmiştir.

M.Ö. 300 Celsus, içinde ilk kez kalp hastalığı için 'cardius' kelimesini kullandığı ansiklopediyi yazmıştır.

M.S. 130-201 arasında yaşayan Galen, kan dolaşımını araştırmış ve şemasını ortaya koymuştur. Ancak şema bugünkü bilgilerimize göre yanlıştır.

Ortaçağda kalp anatomisindeki en önemli gelişmeler, İslam dünyasından dört doktor tarafından sağlanmıştır. Bunlar; Ali Hüseyin Gilani (948); kalp kapakları, kapakçıkları, aort kapağının açılış kapanışını tarif etmiştir. İbni-Sina (980-1037); kılcaldamarlar ve damarlar arasında anastomoz bulunduğunu iddia etmiştir. Abul Sahl (1027); aort kapaklarından tek yönlü akışı ve akciğer arterinin oksijensiz kanı sağ karıncıklardan ciğerlere taşıdığını ileri sürmüştür ve Alaaddin Karşi İbn al-Nafis (1200); akciğer ve koroner dolaşım sistemlerini anlatmış ve İslam tıbbının ilk bağımsız anatomi kitabını da kaleme almıştır.

1733 yılında İngiltere'de tabiat bilim öğrencisi olan Stephen Hales yere yatırdığı atın femoral arterlerine kanül sokarak kan basıncını ölçmüştür. 1828'lerde Poiseuille, 1896'larda Riva Rocci arkasından Bright'ın yaptığı çalışmalar olayı geliştirmiştir. Kan basıncının üzerine esas araştırmalar 1934'lerde Goldblatt ve arkadaşları tarafından bilimsel temellere dayandırılmıştır. 1898'lerde renin maddesinin Tigerstedt ve Bergman, 1940'larda anjiyotensinin Page ve Braun-Mendez, sonraları norepinefrinin Von Euler tarafından bulunmaları ile yeni ufuklar

açılmıştır. Guyton ve arkadaşları tarafından kan basıncını etkileyen multi faktörler entegre analiz sistemi ile bilgisayarla belirtilmeye başlanmıştır. Zamanımızda ise kan basıncı üzerine pek çok önemli araştırmalar yapılmaktadır [49 - 51].

II.2.2. HT Hastalığının Tanımı ve Sınıflandırılması

Yaşamın sürmesi için kalpten vücudun her yerine damarlar aracılığı ile kan iletilmesi gerekir. Kan önce büyük atar damarlara (arterler), daha sonra küçük atar damarlara-arterioller ve oradan da kılcal damarlara-kapillerler geçer. Kapillerler aracılığıyla kan tüm dokulara dağılır. Dokularda oluşan atık maddeler ve karbondioksit kapillerler aracılığıyla kana geçer ve bu kirli kan toplardamarlar-venler aracılığı ile kalbe döner. Bu sırada kalp, geri dönen kanı toplamak için gevşemiştir. Daha sonra kalp kasılır ve kirli kanı temizlenmek üzere akciğerlere gönderir. Akciğerlerde temizlenen kan yeniden kalbe döner ve yeniden kasılan kalp ile kan arterlere dokuların oksijen ve besin ihtiyaçlarının karşılanması için pompalanır.

Kan dolaşımının sağlanması için bir basınca gereksinim vardır. Kan basıncı, kalpten pompalanan kanın bu damar duvarlarına çarpma gücü olarak tanımlanabilir. Bunu şu örnekle daha iyi açıklamak mümkündür [52].

Kan basıncını, evlerde kullanılan suyun musluktan akması için gereken basınç gibi düşünmek mümkündür. Su borusundaki basıncın düzeyini etkileyen iki faktör vardır. Bunlar;

1. Su borusundaki suyun miktarıdır ve borudaki su azalırsa basınç düşer,
2. Su borusunun direncidir ve borunun çapı azalırsa direnç artar dolayısıyla basınç yükselir.

Benzer şekilde kan dolaşımı için gerekli olan basıncı da oluşturan iki faktör vardır. Şöyle ki;

1. Damarlarda bulunan kan miktarı: Kalbin atma sayısına ve her atımda pompalanan kan miktarına bağlıdır. Nabız, kalbin bir dakika içinde kaç kere kasıldığını, yani kalbin hızını yansıtır. Kalp her kasılmasıyla 5-6 litre/dakika miktarında kanı atardamarlar içine pompalar ve damarların esneyebilme özelliğinden dolayı atardamarlarda buna bağlı bir genişleme olur. Ardından damar eski durumuna geri dönmek ister. Bu genişleme, damarların yüzeysel seyrettiği el bileği, dirsek içi, kasık, şakak, ayak bileği gibi yerlerde nabız dalgası-titreşimi olarak hissedilir. Yetişkinlerde istirahatteki ortalama kalp (nabız) hızı 60-80/dk olup 50-100/dk arası genelde normal kabul edilmektedir. Yeni doğanlarda 130, bir yaşında 120,

çocuklarda 90 kadardır. Nabız sayısı harareti yükselten hastalıklarda, sinirli ruh halinde, yemeklerden sonra, yorgunlukla çoğalır; uykuda ve istirahatte ise yavaşlar.

2. Damarların direnci: Damarda gevşeme, damar direncini azaltarak kan basıncının düşmesine sebep olur. Damarda kasılma ise damar direncini artırarak kan basıncını yükseltir.

Yukarıda belirtilen iki faktörden birinde ya da ikisinde birden meydana gelen anormallik kan basıncını yükseltebilir. Kan dolaşımı için gereken basıncın normalden fazla olmasına halk arasında “Yüksek Tansiyon” denir. Tıp alanında ise “Sistemik Hipertansiyon” tıbbi terimi ile ifade edilir ve birimi mmHg-civa basıncıdır. Kan basıncı ölçülürken iki değere bakılır. Bunlar;

Sistolik kan basıncı – (Halk deyimiyle büyük tansiyon), kalbin kasılması sırasında ölçülen kan basıncıdır.

Diastolik kan basıncı - (Halk deyimiyle küçük tansiyon), gevşemesi esnasında damarlar içindeki kanın basıncıdır [53].

Hipertansiyon için yapılan sınıflamalarda zaman içinde belirgin farklılıklar olmuştur. Yaygın olarak kabul gören WHO/ISH’nin 2003 yılında yaptığı aşağıda Tablo II.2’de görülmekte olan sınıflandırmadır.

Tablo II. 3 Kan Basıncının Sınıflandırılması[54]

Kategori	Sistolik (mmHg)	Diastolik (mmHg)
Optimal	<120	<80
Normal	120-129	80-84
Yüksek normal	130-139	85-89
Hipertansiyon 1.derece	140-159	90-99
2.derece	160-179	100-109
3.derece	≥180	≥110
İzole sistolik hipertansiyon	≥ 140	<90

II.2.3. HT’ nin Vücutta Oluşturduğu Hasarlar (Complications)

Suyun musluktan akması için gereken basınç yükseldiğinde borularda patlama ve aşınmalara yol açabilmektedir. Bunun gibi, yüksek tansiyonunda uzun süre kontrol altına alınmadığı durumlarda, insanlar üzerinde de çeşitli sorunların olması kaçınılmazdır.

HT’ nin komplikasyonları kalp, beyin, göz ve böbreklerde özellikle ortaya çıkmaktadır. Oluşabilecek komplikasyonlar şunlardır:

Hipertansif Kalp Hastalıkları: Ateroskleroz nedeniyle kalbi besleyen damarların daralması ve tıkanması sonucu koroner arter hastalığı oluşmaktadır. Hipertansiyon, koroner arter hastalığı için nicel açısından en yüksek risk faktörüdür ve bu hastalık öyküsüne sahip olanların %75'inde yüksek tansiyon bulunmaktadır [55]. Hatta oluşan ani tıkanıklıklar sonucu, kalp dokusunun bir bölümünün ölmesi ile ani kalp krizleri gelişebilmektedir. Kalpte oluşan komplikasyonların diğerleri aşağıda belirtilmiştir.

- Sol ventrikül hipertrofisi, hipertansiyon hastalarının %25 'inde görülür ve ilk olarak ortaya çıkan hasarlar arasındadır [56].
- Diyastolik disfonksiyon
- Koroner arter hastalığı: Kalp kasına oksijenden ve besin maddelerinden zengin “temiz” kanı getiren yani kalp kasını besleyen damarlara “koroner damar (koroner arter) ” adı verilir. Koroner damarlar bir çeşit atardamardır (arter) ve sol kulakçıktan çıkan ana damarın (aorta) dallarıdır. Koroner arter hastalığı kalp kaslarını besleyen atardamarların damar sertliği (ateroskleroz) nedeniyle daralması ve / veya tıkanması sonucu ortaya çıkar. Koroner kalp hastalığı, koroner yetmezlik ve koroner kalp hastalığı deyimleri de koroner arter hastalığı yerine kullanılan benzer terimlerdir. Koroner arter hastalığı erişkinlerde en çok ölüme neden olan hastalıklar arasında birinci sıradadır [57].
- Hipertansif kişide kalp devamlı kalınlaşmış ve yüksek basınçlı bir damar sistemine kan pompalamak zorunda kalan kalp giderek büyür ve duvarları kalınlaşır. Zamanla pompalama görevini yeterince yapamaz. Bu durum kalp yetmezliğidir. Kalp yetmezliği olan hastaların %91'de hipertansiyon olduğu tespit edilmiştir. Yüksek kan basıncı, kalp yetmezliği riskini normal kan basıncı olanlara göre 3 kat arttırmaktadır. Amerika Birleşik Devletleri'nde yılda 400,000 ölüm ve 2milyon olayda hipertansiyon kalp yetmezliğinin önlenabilir etmeni olarak ortaya çıkmaktadır [55].
- Kardiyak aritmiler
- Ani kardiyak ölüm

Hipertansif Beyin Hastalıkları: Hipertansiyon iki şekilde beyinde inmeye (felç) yol açmaktadır. İlki, beyne giden damarların ani tıkanmasıyla beyin dokusunun bir

bölümünün ölmesidir ki bu, “iskemik inme” olarak isimlendirilir. Burada inmenin %85 nedeni hipertansiyondur [56].

İkincisi, “hemorajik (kanamalı) inmedir”. Hipertansiyon sonucu beyindeki küçük damarlar çatlayarak beyin dokusuna kanama yapmaktadır. Bu inme türünün %15 nedeni yine hipertansiyondur [56].

Beyinde oluşan diğer komplikasyonlar aşağıdaki gibidir.

- Bilişsel işlev bozuklukları
- Demans
- Hipertansif ensefalopati

Hipertansif Göz Hastalıkları: Hipertansiyon gözdeki küçük damarlarda çatlamalara yol açarak göz komplikasyonlarına, büyük atardamarlardaki anevrizma denilen baloncukların genişlemesine ve hatta yırtılmasına veya patlamasına yol açarak çok tehlikeli durumlara neden olabilmektedir. Bu durum hipertansif retinopati olarak isimlendirilmektedir.


Hipertansif Böbrek Hastalıkları: Hipertansiyon böbreğin damar sistemine zarar vererek, kanı süzme işlevini yeterince yapamaz hale getirmektedir. Bu durum kronik böbrek yetmezliği olarak adlandırılmaktadır [56].

II.2.4. HT’ nin Dünyadaki ve Türkiye’ deki Yeri

Hipertansiyon çok sık karşılaşılan bir hastalıktır. Erişkinlerin (18 yaşından büyüklerin) en yaygın uzun süreli hastalığıdır. Hipertansiyonun yaygın olmasının yanı sıra kalıcı sakatlıklara ve ölüme yol açması önemini artırmaktadır. Bu özellikleri nedeniyle hipertansiyon aynı zamanda sosyal ve ekonomik bir sorundur. Hastaların azımsanamayacak bir kısmının kan basıncı yüksekliğinin farkında olmaması bu hastalığın önemini daha da artırmaktadır.


Dünyadaki hipertansiyon hastalığının prevalansını tespit etmek amacıyla yapılan çalışma sonucuna göre; 2000 yılında yetişkin nüfusunun %26.4’ünün hipertansiyon hastası olduğu tespit edilmiştir. Bu oran cinsiyetler açısından incelendiğinde %26.1 oranında kadın ve %29.2 oranında ise erkeklerden oluştuğu ortaya konmuştur. Bu orana karşılık gelen yetişkin sayısının 333 milyonunun ekonomik olarak gelişmiş ve 639 milyonunun ise ekonomik olarak gelişmekte olan ülkelerde olmak üzere toplam 972 milyon yetişkin sayısına denk geldiği tahmin edilmiştir. Bu duruma göre 2025 yılında hipertansiyon hastalığının prevalansı öngörülmeyle çalışılmış ve Şekil II.7’de görüldüğü üzere oranın %29.2’ye

yükseleceği ve bu orana karşılık gelen yetişkin sayısının da %60'lık bir artışla 1,56 milyar olacağı öngörülmüştür [48,58].



Şekil II. 6 Dünya Geneline 2000 Yılı Hipertansif Hasta Sayısı ve Prevalansları ile 2010 Yılı Hipertansif Hasta Sayısı ve Prevalanslarına Ait Öngörüler [58]

Türk Hipertansiyon ve Böbrek Hastalıkları Derneği tarafından 2003 yılında yapılan taramada çıkan sonuçlara göre, Türkiye’de 18 yaş üstü erişkinlerde hipertansiyon prevalansı % 31.8 olarak saptanmıştır. Bu prevalansa göre ülkemizde 2003 yılı itibari ile 15 milyon civarında hipertansif birey olduğu söylenebilmiştir.



Şekil II. 7 Türkiye’de Yerleşim Alanına ve Cinsiyete Göre Hipertansiyon Prevalansı [59]

Bu çalışmada, ülkemizdeki kadın ve erkekler için hipertansiyon prevalansları Şekil II.8’de görüldüğü üzere, ülke genelinde, %36.1 ile hipertansif kadınların oranının, hipertansif erkeklere göre belirgin şekilde yüksektir [59].

Türk Hipertansiyon Prevalans Çalışması, Türkiye’deki erişkin hipertansif nüfusun yalnız % 40’ının kan basıncı yüksekliğinin farkında olduğunu ve yalnız % 31’inin antihipertansif tedavi aldığını göstermiştir. Çalışmaya ait sonuç raporuna göre; Hipertansiyonun bu denli yüksek prevalansı, düşük farkında olma ve kontrol edilme oranları yanında normotansif bireylerin % 63’ü de (yaklaşık 21 milyon kişi) pre-hipertansif aralıktadır.

Hipertansiyon ve Ateroskleroz Derneği tarafından bu sonuçları destekleyici bilgilendirmeye göre Türkiye’deki hastaların yarısı hipertansiyon hastası olduklarını bilmemektedir. Tanısı konmuş hastaların da ancak %34’ü verilen ilaçları düzgün olarak kullanmaktadır. Karadeniz, Güneydoğu Anadolu ve Doğu Anadolu Bölgelerinde hipertansiyon sıklığı Marmara ve Ege Bölgelerine nazaran daha fazladır [59].

II.3 TİP 2 DM, HT VE KVH ARASINDAKİ ETKİLEŞİM (Risk Faktörleri, Morbidite, Mortalite)

Halk sağlığı açısından yaygınlığı nedeniyle önemli yer tutan HT, DM ve KVH’lar yaşam kalitesinin düşmesi, teşhis ve tedavi sağlık giderlerinin önemli bir maliyet oluşturması yanı sıra morbidite ve mortalite oranları açısından da azımsanamayacak orana sahip oldukları yapılan istatistiksel çalışmalarla ortaya konmuştur.

Hastalara Tip 2 DM teşhisi konduğu anda %30’unda HT bulunduğu, %70’in de ise hastalığın seyri sırasında ortaya çıktığı klinik çalışmalarda görülmüştür[60,61]. 2004 yılında Sağlık Bakanlığı tarafından yürütülen Türkiye’nin Hastalık Yüku çalışması sonuçlarına göre, Türkiye’de her 4 ölümden 1’inin nedeninin hipertansiyon olduğu belirlenmiştir[62].

Dünya çapında yaklaşık olarak yılda 7,1 milyon kişinin hipertansiyona bağlı olarak öldüğü tahmin edilmektedir [63]. Hipertansiyon, sanayileşmiş toplumlarda mortalite ve morbiditenin en önemli nedenleri olan koroner arter hastalığı ve inme için majör risk faktörlerinden biridir [64-66]. 1 milyondan fazla kişiyi içeren çalışmalar, sistolik kan basıncı 115 mmHg’nın, diastolik kan basıncı ise 75 mmHg’nın üzerine çıktıkça iskemik kalp hastalığı ve inme riskinin arttığını göstermiştir. Sistolik kan basıncında her 20 mmHg, diastolik kan basıncında ise her 10 mmHg’lik artış, iskemik kalp hastalığı ve inmeden dolayı mortalite iki kat


artmaktadır [67]. Tip 2 diyabet hastalarında ateroskleroz 2-10 kat daha fazla sıklıkla görülmekte ve KVH'lar %40-50 oranında mortalite sebebi teşkil etmektedir[68].

Amerika Birleşik Devletleri'nde yıllık olarak 500,000 yeni kalp yetmezliği hastası belirlenmektedir. Epidemiyolojik araştırmalar yeni başlangıçlı kalp yetmezliği için risk faktörleri arasında ileri yaş, koroner arter hastalığı, hipertansiyon, sol ventrikül hipertrofisi ve diabetes mellitusun olduğunu göstermektedir [69].

Framingham çalışması, kadında ve erkekte değişik kan basıncı seviyelerinde ek olarak diğer kardiovasküler risk faktörlerinin sayısı ne kadar fazla ise ise, gelecek 10 yıl zarfında kardiovasküler olayların o nispette fazla olacağını göstermiştir. Bu nedenle hipertansiyonlu bir hastanın ilk değerlendirmesinde, bireysel tedavi ve prognoz tayini için hastanın kardiovasküler risk durumunun tayininin önemi büyüktür. Tüm hipertansiyon klavuzlarında yalnız kan basıncı düzeyine bakarak değil, onunla birlikte major kardiovasküler risk faktörleri, hedef organ hasarı ve birlikte bulunan hastalıklar dikkate alınarak bireysel bir yaklaşım tavsiye edilmektedir[70].

Avrupa Hipertansiyon Derneği ve Avrupa Kardioloji Derneği'nin 2003 yılında yayınlanmış kılavuzunda hastalarda prognozun belirlenmesi amacıyla toplam kardiovasküler olay riskini, Framingham Çalışması'nın verilerinden yararlanarak düşük, orta, yüksek ve çok yüksek risk gruplarına ayırmıştır. Bu risk gruplarında 10 yıllık kardiovasküler hastalık riski sırasıyla;

< %15, %15-20, %20-30 ve > %30 dur. Risk grupları kardiovasküler risk faktörlerinin sayısına, hedef organ hasarının, diabetes mellitusun ve eşlik eden klinik durumların-hastalıkların varlığına göre belirlenmektedir [70]. WHO/ISH organizasyonunun 2003 yılı kardiyovasküler hastalıklarla ilgili olarak yaptığı çalışma sonucu Avrupa – Amerika –Afrika gibi bölgelerin altında da alt bölgeler oluşturulmuştur ve Türkiye bu alt bölgelerden EUR: B yani AVRUPA B bölgesi içinde yer almaktadır. Avrupa B biölgesine ait risk dağılımları renkler ile Şekil II.9'da diyabetli ve diyabetli olmayan gruplar halinde gösterilmiştir[71]. Tablo II.3'de de kardiyovasküler hastalık riski Avrupa B bölgesi için yaş parametresine göre belirtilmiştir [72].



Şekil II. 8 AVRUPA B Bölgesi için WHO/ISH Risk Şeması

Tablo II. 4 Avrupa B Bölgesi için Yaş Parametresine göre Risk Dağılımı

AVRUPA BÖLGESİ: B									
RİSK Kategorisi	Yaş Grubu (yıl)				RİSK Kategorisi	Yaş Grubu (yıl)			
	<50	50-59	60-69	70+		<50	50-59	60-69	70+
<10%	95.99%	76.50%	35.12%	14.75%	<10%	97.44%	83.87%	53.78%	29.44%
10-19.9%	2.02%	7.84%	26.21%	29.32%	10-19.9%	1.49%	7.77%	14.83%	19.99%
20-29.9%	1.10%	6.72%	10.56%	14.01%	20-29.9%	0.61%	6.44%	20.61%	27.80%
30-39.9%	0.48%	4.81%	11.45%	19.84%	30-39.9%	0.22%	0.87%	5.25%	9.78%
≥40%	0.40%	4.13%	16.67%	22.09%	≥40%	0.24%	1.05%	5.54%	12.99%

Hipertansiyonlu hastaların yaklaşık %2 sini düşük riskli hastalar, %60 ını orta riskli hastalar ve yaklaşık olarak üçte birini de yüksek riskli (çok yüksek riskli) hastalar oluşturmaktadır [70]. Sistolik kan basıncında her 20 mmHg lık bir yükselmenin yahut diastolik kan basıncında her 10 mmHg lık yükselmenin, inmeden ölüm oranını iki katından fazla ve koroner arter hastalığından ölüm oranını da iki kat artırdığı saptanmıştır. Tedavi görmeyen hipertansiyonluların yaklaşık %50 si koroner arter hastalığı yahut konjestif kalp yetersizliğinden, %33 ü inmeden ve %10-15 i böbrek yetersizliğinden ölmektedirler. Framingham kohortu da dâhil birçok prospektif takip çalışmasını içeren ‘the Pooling Project’ verilerine göre, diastolik kan basıncı 80-87 mmHg arasında olan beyaz ırktan erkeklerde 8,6 yıl periyodunda majör bir koroner olay geçirme riski, diastolik kan basıncı 80 mmHg nın altında olanlardan %52 oranında daha fazla bulunmuştur. Bu rölatif risk artışı, mutlak risk artışı olarak ifade edilirse 8,6 yıllık periyodda %3,5 erkek hastanın majör bir koroner olay geçirmesi anlamına gelmektedir. Hipertansif popülasyonun büyüklüğü göz önünde bulundurulursa, hipertansiyona bağlı kardiovasküler olayların ne kadar büyük bir sosyal problem olduğu anlaşılır.

Major risk faktörleri olan hipertansiyon, hiperkolesteremi ve sigara kullanımı ile KVVH’lar dünyadaki mortalite ve morbiditenin en önemli ortak nedenleri arasındadır [73].

Tablo II. 5 Hastalığın Teşhisini Etkileyen Faktörler[74]

KVH için Risk Faktörleri	Hedef Organ Hasarı	İlişkilendirilmiş Klinik Durumlar
- Sistolik ve dastolik KB (Kademe 1-3) - Erkek > 55 Yaş - Kadın > 65 Yaş - Sigara Alışkanlığı - Toplam Kolesterol>6,1 mmol/l (240 mg/dl) - LDL Kolesterol> 4,0 mmol/l (150 mg/dl)* - HDL Kolesterol E <1,0 mmol/l (<40 mg/dl) K < 1,2 mmol/l (< 45 mg/dl) 50 yaş öncesi 1.derece akrbada KVH öyküsü - Obezite - Fiziksel Hareketsizlik - egzersiz yapmama	- Left Ventricular Hypertrophy (EKG ya da EKO) - Mikroalbümin (20-30 mg/gün) - Aterosklerotik plak genişlemesine (aort, karotis, koroner, ilyak, uyluk atardamarı) radyolojik ya da ultrasonik kanıt - Hipertansif retinopati kademe 3 ya da 4	- Diyabet - Beyin Damarı Hastalıkları - İskemik inme - Beyin Kanaması - Geçici iskemik atak - Kalp hastalıkları - Miyokard infarktüsü - Angina - Koroner revaskülarizasyon - Konjestif kalp yetersizliği - Böbrek hastalıkları - Plazma kreatinin konstrasyonu: - K> 1,4 - E > 1,5 mg/dl (120, 133µmol/l) - Albüminüri > 300 mg/ gün - Periferik vasküler hastalıklar

*Toplam ve LDL kolesterol'ün daha düşük seviyeleri yükselmiş riski betimlemek için bilinmektedir fakat bu tabloda kullanılmadılar; K:Kadın, E:Erkek

II.4 DİPPER – NON DİPPER PATTERN TANIMI

Sağlıklı bireylerde gündüz KB ortalama değerine göre, gece uykusu sırasında ortalama KB değeri %10 ve üzeri şeklinde düşüş göstermektedir. Bu duruma “Dipper Paterni” denilmektedir. Bu fizyolojik durumun bozularak gece uykusu esnasında ortalama KB değerinin düşmemesi ise “Non-Dipper Paterni” olarak adlandırılmaktadır [75, 76]. Spacelab marka 90217 model holter cihazı ve yazılımı uluslararası kabul görmüş ve hasta tarafından belinde ya da cebinde taşınabilen 24 saatlik kan basıncı takip cihazıdır. Sistemde kullanılan bu cihazın parçalarına ait fotoğraf Şekil II.9’da görülmektedir. Fotoğrafın sol tarafında kola takılan manşon ile kablosu, sağ üstte cihazı bele sabitlemeye yarayan kemer ve sağ altta kan basınçlarını ölçen elektronik hafıza aygıtı görülmektedir. Bu cihaz Şekil II.10’daki fotoğrafta görüldüğü gibi vücuda monte edilmektedir. Bu cihaz kullanılarak elde edilen dipper ile non-dipper verileri ve paternleri Şekil II.11 a, b, c ve d’de görülmektedir.




Şekil II. 9 Spacelab 90217 Holter Cihazı Parçaları [61]



Şekil II. 10 Holter Cihazının Vücuda Monte Edilmiş Hali [61]

Overall Summary							
Systolic:	AVG	STD	MIN		MAX		Dipping
Diastolic:	135	19.26 mmHg	100	(06:35 Fri)	184	(14:27 Thu)	21.3%
MAP:	82	10.39 mmHg	65	(01:35 Fri)	112	(14:45 Thu)	18.2%
Pulse Pressure:	98	11.90 mmHg	78		132		16.4%
Heart Rate:	53	11.79 mmHg	34		88		
	78	12.91 bpm	55		99		
				Reading(s)	Time		
Percent of Systolic above limits:				75.4%	68.1 %		
Percent of Diastolic above limits:				59.6%	51.2 %		
Wake Period(s) 08:00 - 00:00							
Systolic:	AVG	STD	MIN		MAX		
Diastolic:	146	14.52 mmHg	120	(22:45 Thu)	184	(14:27 Thu)	
MAP:	88	8.47 mmHg	70	(08:45 Fri)	112	(14:45 Thu)	
Pulse Pressure:	104	9.75 mmHg	85		132		
Heart Rate:	58	10.71 mmHg	36		88		
	87	6.60 bpm	73		99		
				Reading(s)	Time		
Percent of Systolic readings > 120mmHg:				97.6%	98.0 %		
Percent of Diastolic readings > 80mmHg:				81.0%	82.4 %		
Number of Wake Period(s) readings: 42							
Sleep Period(s) 00:00 - 08:00							
Systolic:	AVG	STD	MIN		MAX		
Diastolic:	115	9.22 mmHg	100	(06:35 Fri)	132	(04:05 Fri)	
MAP:	72	4.45 mmHg	65	(01:35 Fri)	80	(05:35 Fri)	
Pulse Pressure:	87	6.02 mmHg	78		96		
Heart Rate:	43	5.58 mmHg	34		54		
	62	5.57 bpm	55		77		
				Reading(s)	Time		
Percent of Systolic readings > 120mmHg:				13.3%	16.6 %		
Percent of Diastolic readings > 80mmHg:				0.0%	0.0%		
Number of Sleep Period(s) readings: 15							


a) Dipper Verileri



b) Dipper Pattern

Overall Summary							
Systolic:	AVG	STD	MIN	MAX	Dipping		
Diastolic:	123	10.57	mmHg	105 (06:37 Wed)	155 (08:47 Wed)	0.1%	
MAP:	78	8.16	mmHg	61 (15:47 Tue)	95 (14:47 Tue)	5.1%	
Pulse Pressure:	94	10.04	mmHg	73	126	2.2%	
Heart Rate:	45	8.20	mmHg	25	64		
	76	9.86	bpm	52	99		
Percent of Systolic above limits:			Reading(s)	58.3%	58.0 %		
Percent of Diastolic above limits:				35.4%	35.8 %		
Wake Period(s) 09:00 - 23:00							
Systolic:	AVG	STD	MIN	MAX			
Diastolic:	123	10.00	mmHg	108 (15:47 Tue)	153 (22:07 Tue)		
MAP:	80	8.96	mmHg	61 (15:47 Tue)	95 (14:47 Tue)		
Pulse Pressure:	95	11.23	mmHg	73	126		
Heart Rate:	43	7.82	mmHg	29	64		
	81	10.00	bpm	60	99		
Percent of Systolic readings > 120mmHg:			Reading(s)	59.3%	63.9 %		
Percent of Diastolic readings > 80mmHg:				44.4%	47.4 %		
Number of Wake Period(s) readings: 27							
Sleep Period(s) 23:00 - 09:00							
Systolic:	AVG	STD	MIN	MAX			
Diastolic:	123	11.50	mmHg	105 (06:37 Wed)	155 (08:47 Wed)		
MAP:	76	6.38	mmHg	69 (00:07 Wed)	95 (08:47 Wed)		
Pulse Pressure:	93	8.45	mmHg	79	117		
Heart Rate:	48	8.07	mmHg	25	60		
	71	7.79	bpm	52	86		
Percent of Systolic readings > 120mmHg:			Reading(s)	57.1%	52.6 %		
Percent of Diastolic readings > 80mmHg:				23.8%	21.6 %		
Number of Sleep Period(s) readings: 21							

c) Non-Dipper Verileri



d) Non-Dipper Patern

Şekil II. 11 Spacelab 90217 Holter Cihazı ile Ölçülmüş Dipper /Non-Dipper verileri ve paternleri

Bu patolojik durum bireye 24 saatlik KB ölçüm cihazı takılarak gündüz ve gece boyunca yapılan tansiyon takibi sonucu saptanabilmektedir. Son on yıl boyunca

sınırlı klinik kullanımı ile önemli bir araştırma aracı haline gelen 24 Saatlik KB takibi Ambulatory Blood Pressure Monitoring- ABPM non-invasive bir yöntemdir. Yakın zamana kadar, ABPM'nin klinik kullanımında sadece beyaz önlük hipertansiyonu olan hastaların belirlenmesi üzerinde durulmaktaydı ancak elde edilen kanıtlar bu tetkikin hedef organ hasarı belirlemede ve risk öngörüsündeki önemine dikkati çekmiştir.

ABPM ile saptanabilen non-dipper paternin, kardiyovasküler mortalite ve morbidite açısından önem taşıdığına işaret edilmektedir[60, 61,77, 78].

II.4.1. Tip 2 DM Hastalarında Hedef Organ Hasarı ve Dipper - NonDipper Patern İlişkisi

Bireylerin yaşam kaliteleri üzerinde büyük etkisi olan uyku ile sağlık arasında çift yönlü bir ilişki vardır ve bireyin sağlıklı olarak fonksiyonlarını yerine getirebilmesi açısından önemlidir. Huzursuz geçen uyku dönemi tıbbi ve psikiyatrik morbidite ve tüm nedenlere bağlı ölümlerdeki artışın yanı sıra kötü sağlık sonuçları (inflamasyon, insülin direnci, metabolik sendrom, non-dipper paterni) için risk faktörleri ile bağlantılıdır. Yapılan klinik ve epidemolojik çalışmalar hipertansif hastalarda”non-dipper” özelliğın KVH riskini bağımsız olarak daha da arttırdığını göstermektedir. Ayrıca DM’lu hastalarda da hipertansiyondan bağımsız olarak önemli oranlarda “non-dipper” özellik bulunmaktadır.

Bugün dipper/nondipper KB özelliğı klinik olarak ancak 24 saatlik KB kaydı ile ayırt edilir. Non-invazif bir yöntem olmakla birlikte, hastanın 24 saat bir kayıt cihazını taşıması türlü olumsuzluklar içerir:

Birincisi, hastanın cihazı taktırıp söktürmek için en az iki sefer hastaneye gelmesi, bunun için randevu almak için uğraş vermesi gerekmektedir. Bu da bireyin zaman, emek ve maddi (yol- telefon) harcama yapması demektir.

İkincisi ise, bu cihazı 24 saat boyunca taşımanın hastaya verdiği fiziksel (üst değıştirme, banyo yapamama, rahat uyuyamama vb.) ve ruhsal olumsuzluktur.

Cihazın yaptığı bu olumsuzluklar kişinin uyku kalitesinin de düşmesine neden olmaktadır. Bu yüzden başka bir olumsuzluk daha ortaya çıkmaktadır: Hastanın gece uyku kalitesinin düşmesi (sık sık uyanması, dönememesi vb.) dolayısıyla kalp basıncı değıerlerinin etkilenip, doğru veri kaydı elde edilememesi sorununu gündeme getirmektedir.

Hastaya holter cihazı takılmasının sađlık kurumuna ve devlete de getirdiđi maliyetler vardır. Bunlar;

Sađlık güvencesinden dolayı hastaların bir kısım giderleri SGK ya da özel sigortalara ek yükler getirmektedir.

Bu cihazların alımı, aynı anda daha çok hastaya hizmet verebilmek amacıyla sayılarının arttırılmaya çalışılması maliyeti arttırmaktadır.

Bu cihazın hastaya takılıp-çıkartılması ve verilerin elektronik ortama aktarılması işlemleri için eğitimli eleman gereksinimi de hem eğitim hem de istihdam maliyeti getirmektedir.

Sonuç olarak; Marmara Üniversitesi Hastanesi Hipertansiyon ve Ateroskleroz Ünitesi ile birlikte, ABPM ölçümü olmaksızın sadece klinik muayene ve laboratuvar tetkikleri ile elde edilen hasta parametrelerine dayanılarak, Non- Dipper özelliđin ön görülüp görülemeyeceđine ışık tutmaya yönelik ortak bir çalışma yürütölmektedir. DM ve HT hastalarda zaten çođu zaman yapılması gereken klinik ve laboratuvar incelemeleri sonuçlarını kullanarak ve yapay zekâ tekniklerini, istatistiksel analiz ve veri madenciliđi algoritmalarını kullanma yolu ile dipper/non-dipper hastaları ayırt etmek-saptamak amacı mevcuttur.

BÖLÜM III

ÇALIŞMADA KULLANILAN TIBBİ VERİLERİN NİTELİK TANIMLARI VE ÖLÇÜTLERİ

Bu bölümde; çalışmada kullanılan tıbbi verilerin ölçütleri ve nitelik tanımları sunulmuştur. Denek gruplarındaki hastalara ait tıbbi veriler, Tablo III.1’den de görüldüğü üzere 4 ayrı kaynaktan toplanmaktadır: Birinci kaynak hekimin hastaya sorarak öğrendiği demografik veriler, ikinci kaynak laboratuvar tetkikleri sonucunda elde edilen veriler, üçüncü kaynak otonomik fonksiyon testlerinden elde edilen veriler ve dördüncüsü ise kardiyolojik değerlendirmeler amacıyla hastaya bağlanan cihazlardan elde edilen ölçümlerdir. Tüm kaynaklardan gelen verilerin toplamı 47’dir.

Tablo III. 1 Çalışmada Kullanılan Tıbbi Verilerin Elde Edildikleri Kaynaklara Göre Sınıflandırılması

Demografik veriler	Laboratuvar tetkikleri	Otonomik Testler	Cihaz ölçümleri			
			EKG	EKO	Holter	
Cinsiyet	A1C	V1	S V1	SWth	dt sis	
Yaş	AKS	V2	R V5	PWth	dt dias	
Boy	Kreatinin	Vm		LVEDD	nt sis	
Kilo	Malb	DSD		LVESD	nt dias	
BELC	LDL	AKH		ME	24h sis	
BSA	ABI	OrH		MA	24h dias	
BMI		HDKBF		MDT	mask HT	
		PH		AoIVRT	%sisD	
		SH		LVM	%diasD	
		Ewing		LVMi		
				EF		
				LA		
				Ao		
						Genel Toplam
7	6	10	2	13	9	47

III.1 NİTELİKLERİN (ATTRIBUTES) TANIMLANMASI

Aşağıda çalışma boyunca denek gruplarından elde edilen verilerin nitelik tanımlamaları yapılmıştır.

III.1.1 Demografik Verilerin Niteliklerinin Tanımlanması

Hastaların kayıtları sırasında kimlik bilgileri verilerin takibi açısından veritabanına kayıt edilmiş ancak çalışma içerisinde aktif olarak kullanılmamış, hatta gözardı edilmiştir.

CINSİYET : Bireyin cinsiyet verisidir.

YAS : Bu çalışmaya denek olarak katılan bireyler 18 yaşından büyüktür.

BOY : Bireyin boy bilgisi cm cinsinden tanımlanmıştır.

KILO : Bireyin ağırlık bilgisi kg cinsinden tanımlanmıştır.

BELC : Bireyin bel çevresi bilgisi cm cinsinden tanımlanmıştır.

BSA : Body Surface Area'nın kısaltmasıdır. Vücut yüzey alanı anlamındadır.

DuBois Formülü'ne göre hesaplaması şu şekildedir ve birimi m^2 'dir [79].

$$BSA (m^2) = 0.007184 \times Boy(cm)^{0.725} \times Ağırlık(kg)^{0.425} \quad (1)$$

BMI : Body Mass Index'in kısaltmasıdır. Vücut kitle endeksi anlamındadır ve şu formül ile hesaplanır. Birimi Kg / m^2 'dir [79].

$$BMI = Ağırlık(kg) / Boy(m)^2 \quad (2)$$

III.1.2 Laboratuvar Tetkikleri Sonucunda Elde Edilen Verilerin Niteliklerinin Tanımlanması

A1C : Hemoglobin A_{1c} , diğer ismiyle glukozillenmiş hemoglobin, şeker hastalığında tedavinin etkinliğini ölçmek, kimi zaman da şeker hastalığı tanısı koymak için kullanılan bir kan tahlilidir. Hemoglobin A_{1c} sıklıkla HbA_{1c} olarak da kısaltılır. Şeker hastalığı tedavisinde geçmiş iki-üç ay ait kan şekeri profili hakkında bilgi verdiği için geçtiğimiz yıllarda artan sıklıkla kullanılmaya başlamıştır. %5-6 aralığındadır[80].

AKS : Açlık kan şekeri - Normal bir kişide açlık kan şekeri 100 mg veya daha düşük, 2 saatlik tokluk kan şekeri ise 140 mg veya daha düşük olmalıdır. Diabetik demek için açlık kan şekeri 125 mg veya daha yüksek, tokluk kan şekeri ise 200 mg üzerinde olmalıdır. Birimi mg/dlt 'dir.

Kreatinin : Kreatin, organizmada bulunan kristalleşebilir azotlu bileşik. Fosfat bileşiği vücutta enerji deposu görevi yapar. Kreatinin, bir molekül su kaybederek


kreatin ve kreatin-fosfat üzerinden kaslarda oluşan temel maddedir. Birimi mg/dlt'dir [81].

Malb : Mikroalbuminüri maddesini belirtir. Normalde kandaki albuminüri ya da proteinüri denilen protein, böbrekten süzülerek idrara geçmez. Ama diyabetli kişide şeker normal değerlerde tutulmamışsa, böbrek hasarı başlamışsa, böbrek hasarının erken evresinde protein idrarımızın içine doğru süzülerek idrara geçer ve idrar tetkiklerinde protein görülür. Bu da gelecekte kalp krizi ihtimalinin artışı beliren kötü bir habercidir. 24 saatlik (bir gün boyunca biriktirilen) idrarda bulunan protein miktarının tespitiyle böbrek hasarının derecesi belirlenebilir [82].

Sağlıklı insanların idrarında günde 25 mg. albuminden daha az albumin atılmaktadır. İdrarla atılan albumin miktarının günde 30-300 mg. düzeyinde olması mikroalbuminüri varlığını gösterir. 5 yıldan uzun süreli diyabetli olan hastaların % 4-15'inde mikroalbuminüri görülmektedir. Birimi mg'dır [83].

LDL : Low Density Lipoprotein'in kısaltmasıdır. Düşük yoğunluklu lipoprotein kanda kolesterol taşıyan ve yoğunluğu 1.019-1.063 g/mL arasında olan lipoprotein sınıfına karşılık gelir. Karaciğerde üretilen çok düşük yoğunluklu lipoprotein metabolizması sonucu oluşur. LDL tanecikleri 18-25 nm çapındadır, taşıdığı lipidlerin yanı sıra apolipoprotein B-100 (apoB-100) ve apoE proteinlerini içerir. LDL seviyesi ile kalp hastalıkları arasındaki bağlantıdan dolayı sıkça "kötü" kolesterol olarak anılır. LDL'in başlıca işlevi, kolesterol ve trigliserit üreten hücre ve dokulardan bu molekülleri alıp bunlara gereksinimi olan hücre ve dokulara taşımaktır. Yapısında %21 protein, %11 trigliserit, %22 fosfolipid, %37 kolesterol ester, %8 serbest kolesterol ve %1 serbest yağ asitleri bulunur. Vücuttaki toplam kolesterolün %70'i LDL'de bulunmaktadır. Birimi mg/dlt'dir.

ABI : Ankle Brachial Index'in kısaltmasıdır. Kolda ölçülen kan basıncının ayak bileğinde ölçülen kan basıncına oranı. Normalde ayak bileği basıncı kol basıncından 10-20 mmHg yüksektir. Cut off değeri 0.9'dur (mgHg/mgHg $\geq$ 1) [84,85].



Şekil III. 1 ABI için KB Ölçümü [86]

III.1.3 Otonomik Fonksiyonun Değerlendirilmesine Yönelik Testler

Visseral ya da vejetatif sinir sistemi olarak da bilinen otonomik sinir sistemi, istemsiz yaptığımız hareketleri gerçekleştirir. Parasempatik ve sempatik sinir sistemi diye ikiye ayrılır. Bunlar [87,88];

Sempatik Sinir Sistemi: Doku ve organlara gönderdiği sinyallerle vücudun aktivitesini, enerji tüketimini artırıcı yönde davranan sistemdir. Örneğin sempatik sinirler kalbin çalışma hızını ve atardamarlardaki kan basıncını artırır. Sempatik sistem aynı zamanda organizmanın korku, öfke, heyecan ya da şiddetli ağrı gibi stres yaratan durumlarda tepki oluşturmasını sağlar. Örneğin kas aktivitesi gerektiren stres durumlarında; hipotalamusun uyarılmasıyla sempatik sistem canlının kanındaki glikoz yoğunluğunun arttırma, damarlarda kan basıncını yükseltme, kas gücünü arttırma gibi bazı değişiklikler meydana getirerek canlının stresle başa çıkmasında etkili olur.

Parasempatik Sinir Sistemi: Parasempatik sistem doku ve organlara gönderdiği sinyallerle genel olarak vücutta enerjinin korunmasını sağlayacak yönde etki ederek hareketlerimizi yavaşlatır. Örneğin; kalp atışının yavaşlaması gibi...

Otonomik sinir sistemi fonksiyonlarını değerlendirmeye yönelik olarak yapılan testlerin sonucunda elde edilen veriler aşağıda sıralanmıştır [89]:


- V 1** : Valsalva 1. ölçüm
V2 : Valsalva 2. ölçüm
Vm : V1 ve V2 değerlerinin ortalaması –Valsalva manevrasına kalp hızı yanıtı
DSD : Derin solunumda değişkenlik- kalp hızı yanıtı (vuru/dk)
AKH : Ayağa kalkınca kalp hızı değişkenliği
OrH : Ortostatik hipotansiyon
HDKBF : Handgript testi
PH : Parasempatik hasar
SH : Sempatik hasar
Ewing : Kalp damar bozukluğunun tesbiti için bir dizi otonomik test yapılır. Bu testlerin değerlendirmeleri 0-2 arasında puanlandırılır. Bu puanların etkileşiminin ewing skorunda hangi karşılığa geldiği tespit edilerek değerlendirmeye alınır.

III.1.4 Cihaz Ölçümleri ile Elde Edilen Verilerin Niteliklerinin Tanımlanması

III.1.4.1 EKG (Elektrokardiogram - Electrocardiography)


Sağlıklı kalp elektrikli bir pompa gibi çalışarak, güçlü kan akışını tedarik ederken Şekil III.2’den de görüldüğü gibi elektriksel bir sinyal üretir. EKG, kalbin elektriksel etkinliğini ölçen noninvaziv bir yöntemdir. Eğer kalp hastalığı varsa oluşan elektrik sinyalindeki zayıflama ya da bozulma böylece gözlemlenebilir. EKG aşağıda belirtilen hastalıkların teşhisinde yararlıdır:

- Anormal kalp ritimleri,
- Önceki kalp krizi bulguları,
- Gelişen kalp krizi bulguları,
- Kararsız angina,
- Hipertansiyona bağlı kalp büyümesi veya kalp kası kalınlaşması (hipertrofi)
- Doğumsal kalp anomalileri,
- Anormal kan elektrolitleri ile ilgili bulgular,
- Kalp iltihabı (miyokardite, perikardit) bulgusu.




Şekil III. 2 Elektrokardiyogram Grafiği[37]

SV1 - RV5 : EKG ölçümlerinde elde edilen S ve R dalgaları Şekil III.3 a'da görülmektedir. Bu ölçüm için bağlanan elektrodların yerleri de Şekil III. b' de görülmektedir.



a)



Şekil III. 3 a) EKG Dalgası b) EKG Dalgası Ölçüm Noktaları [90]

III.1.4.2 EKO (Ekokardiyogram - Echocardiography)

EKO ses ötesi dalgaları kullanarak (ultrasound- ultrason) kalbin ve kalp içinde akım halindeki kanın görüntülenmesi ve incelenmesi yöntemidir. Aslında bir çeşit gelişmiş ultrason incelemesidir ve radar cihazlarının çalışma ilkelerine çok benzer.


EKO cihazı, elde tutulabilen küçük bir kutu, ölçme probu ve bu cihazdan gelen sinyalleri görüntüye ve sese çeviren bilgisayar ve monitör sistemlerinden oluşur. Prob göğüs duvarıyla temas eder halde kalp üzerinde yavaşça gezdirilir ve bu cihazın yaydığı ses ötesi dalgalar kalbe ve ilgili dokulara çarpıp geri yansır. Geri yansıyan bu dalgalar yine prob tarafından algılanır ve ekranda kalbin görüntüsü oluşur. Bu görüntü, kalbin tüm anatomik yapısına ek olarak, kalbin kasılması, kapakçıkların açılıp kapanması gibi hareketleri de gerçek zamanda canlı olarak izleme olanağı verir. Ayrıca kalp içinde dolaşan kandan yansıyan dalgalar da kapakların fonksiyonları (kapaktaki darlık, yetmezlik vb.) hakkında ve kalbin pompalama gücü hakkında çok değerli bilgiler verir.

EKO ölçümleri temel olarak iki farklı yöntemle yapılır: Birincisi Transtorasik ekokardiyografi (TTE), ses dalgaları göğüs duvarı üzerinde gezdirilen probtan kalbe doğru gönderilir (Şekil). Günlük uygulamalardaki tetkikler sıklıkla bu yolla yapılır. İkincisi ise Transözofageal ekokardiyografi (TEE), seyrek olarak bazı hastalıklarda kalbin daha ayrıntılı görüntülenmesi gerekebilir. Bu durumda yemek borusunun (özofagus) kalple komşuluğundan yararlanılır. Bu amaçla kullanılan daha ince ve yumuşak özel bir prop ağız boşluğundan geçilerek yemek borusu içine ilerletilir.

Kalp göğüs boşluğunda yemek borusunun hemen arkasında yer aldığı için bu yakın mesafeden kalbin daha net ve daha ayrıntılı görüntüleri elde edilir. Bu tetkik sırasında hastanın rahatsız olmaması ve öğürmemesi için kısa süreli hafif yatıştırıcı ve uyuşturucu ilaçlar verilir. Hasta kısa bir dinlenme süresinden sonra evine dönebilir.

TTE çok önemli hatta bazen yaşamsal bilgiler sunan ve bunu sağlarken hastaya hiç bir zarar veya risk oluşturmadan uygulanabilen ender tıbbi tetkiklerden birisidir [57].

Ekokardiografik ölçümler Amerikan Ekokardiyografi Derneği'nin kabulleri doğrultusunda ve sol ventriculer kütlesi de Pen Convention formülüne göre hesaplanmıştır [91,92].



Şekil III. 4 EKO Cihazı ile Bakılan Kalp Özellikleri [37]

EKO ile elde edilen veriler ve anlamları aşağıda sıralanmıştır:

SWth : Ön duvar kalınlığı

PWth : Arka duvar kalınlığı

LVEDD : Diyastol çapı (mm)

LVESD : Kasıldığı zamanki çapı (mm)

ME : Mitral erken doluş (m/s)

MA : Mitral geç doluş (m/s)

MDT : Mitral Deselerasyon Zamanı (Mitral Deceleration Time) (m/s)

AoIVRT : Aort İzovolumik Relaksasyon Zamanı (m/s)

- LVM** : Sol ventriküler kütle -Left ventricular mass (gr)
LVMi : Sol ventriküler kütle indeksi - Left ventricular mass index (gr/m²)
EF : Otonomik enjeksiyon fraksiyonu
LA : Left atrium – Sol kulakçık (mm)
Ao : Aort kökü

III.1.4.3 Holter Cihazı

Holter kan basıncı ölçme cihazı ile 24 saatlik kayıt sonucu elde edilen verilerin tanımları aşağıda yapılmıştır:

- dt sis** : Gündüz sistolik kan basıncı ölçüm değeri olup birimi mmHg'dir.
dt dias : Gündüz diyastolik kan basıncı ölçüm değeri olup birimi mmHg'dir.
nt sis : Gece sistolik kan basıncı ölçüm değeri olup birimi mmHg'dir.
nt dias : Gece diyastolik kan basıncı ölçüm değeri olup birimi mmHg'dir.
24h sis : 24 saatlik sistolik kan basıncı değerleri, birimi mmHg'dir.
24h dias : 24 saatlik diastolik kan basıncı değerleri, birimi mmHg'dir.
mask HT: Maskelenmiş hipertansiyon kan basıncı ölçüm değeri olup birimi mmHg'dir.

$$\%sisD : \frac{dtsis-ntsis}{dtsis} \times 100 \quad (3)$$

$$\%diasD : \frac{dtdias-ntdias}{dtdias} \times 100 \quad (4)$$

III.2 VERİLERİN TIBBİ ÖLÇÜTLERİ

Denek grubundaki hastalardan yukarıda bahsedilen veriler toplanmadan önce, hastalar normal klinik gerekler dâhilinde kapsamlı bir fiziki muayeneden geçirilmiştir. Ayrıca bir göz hastalıkları hekimi tarafından da göz dibi incelemesi yapılmış ve hipertansif retinopati varlığı değerlendirilmiştir.

Transtoraksal ekokardiyografi verileri için, tüm incelemeler hasta sol yan yatar pozisyonda ve sakin solunum sırasında gerçekleştirilmiştir. Her hasta için en az 3 kalp siklusunda ölçüm yapılmış ve ortalama değer alınmıştır. Sol ventrikül septum kalınlığı (SWth), sol ventrikül arka duvar kalınlığı (PWth), sol ventrikül enddiastolik çap (LVEDD) ölçümleri yapılmıştır. Ventriküler ölçümler Amerikan Ekokardiyografi Derneği önerileri doğrultusunda [91] gerçekleştirilmiş ve sol ventrikül kütle:

$$LVM = ((LVEDD + SWth + PWth)^3 - (LVEDD)^3) - 13.6 \quad (5)$$

formülü ile hesaplanmış ve sol ventrikül kütle indeksi hastanın sol ventrikül kütesinin vücut alanına bölünmesi ile bulunmuştur[92].

Ayrıca relatif duvar kalınlığına (RDK) göre hipertrofi tipleri konsantrik veya eksantrik hipertrofi olmak üzere iki ayrı grupta incelenmiştir. Enddiyastoldeki ölçümlerde RDK değeri aşağıdaki orana göre hesaplanmıştır:

$$RDK = \frac{SWth + PWth}{LVEDD} \quad (6)$$

RDK değeri 0.44' ten büyük olanlar konsantrik sol ventrikül hipertrofisi (kSVH), RDK değeri 0.44' ten küçük olanlar ise eksantrik sol ventrikül hipertrofisi (eSVH) olarak tanımlanmıştır [93].

Çalışmadaki tüm deneklerde klinik değerlendirme ve ilgili tüm laboratuvar tetkikleri her hasta için en geç 4 haftalık bir zaman sürecinde tamamlanmıştır.

BÖLÜM IV

ÇALIŞMANIN BİLİŞİM TEKNOLOJİLERİNDEKİ YERİ

“Verilere yeterince işkence yaparsanız sizin dilinizden konuşurlar.”

Hasan Erdal

Bu bölümde veri madenciliği ve kullanım alanları hakkında temel kavramlar üzerinde durulmuştur.

Bilimsel araştırmalarda, araştırmacı tarafından gözlemlerden elde edilen sayısal olan ya da olmayan sonuçlara “Veri” denilmektedir. Veriler yayınlanmış kaynaklardan, tasarlanmış bir denemeden, anket sonuçlarından veya gözlem sonuçlarının toplanmasından olmak üzere dört farklı biçimde elde edilebilmektedir.

Kapsam bakımından veri toplama, “tam sayım” ve “örneklem” olarak ikiye ayrılır. Kitleyi oluşturan tüm birimlerden veri elde etme tam sayımdır. Ancak bunun yerine bu kitleyi tanımlayabilecek örnek grubundan verilerin toplanması ise örneklemidir.

Verilerin yararlı olabilmesi için toplama sürecinin hızlı, maliyetinin düşük ve verilerin doğru olması gerekmektedir[94].

Bu tez çalışması için zaman faktörü, kaynaklar ve uygulama olanakları gözönüne alındığında tüm kitleyi ölçmenin zorluğu ortadadır. Bu nedenle, Bölüm I’de belirtilen kıstaslara uygun olarak homojen yapıda diyabetli ve hipertansiyon hastalarından oluşan 65 kişilik birinci örneklem kümesi ile diyabet olmayan ve normotansif hastalardan oluşan 29 kişilik ikinci örneklem kümesi oluşturulurken basit rastgele örneklem seçimi yöntemi tercih edilmiştir.

İki ayrı örneklem kümesinden toplanan veriler arasında direk görülemeyen ancak yararlı olabilecek ilişkiler, literatürde pattern ya da örüntü olarak geçmektedir.

IV.1 VERİ MADENCİLİĞİ

Teknolojik gelişimin getirdiği yeniliklere paralel olarak, miktarı günden güne artan verileri saklama koşulları değişmektedir. Kağıt içerikli dosya arşivleme yöntemleri günümüzde yerini; maliyetinin gittikçe ucuzlaması, daha kolay ulaşılabilir ve aynı zamanda güvenli olması nedeniyle sayısal ortamlarda bilgi depolama yöntemlerine terk etme aşamasındadır. Bu da günden güne sayısal ortamda çoğalan veri yığınları, dolayısıyla verilerin depolanması ve yönetilmesi konusunda bir takım zorluklar anlamına gelmektedir. Bundan dolayı yeni veri tabanı mimarileri geliştirilmek durumunda kalınmış ve karar destek sistemlerinin bir bileşeni olarak ilişkisel veri tabanları ile veri ambarları kullanımı giderek yaygınlaşmıştır.

Veri tabanı, veri ambarı, “World Wide Web” gibi bir çok veri alanlarında gün geçtikçe daha fazla veri birikmekte, buna karşılık veriyi inceleyecek bilim adamlarının, mühendislerin ve analistlerin sayısı bu kadar hızlı artmamaktadır[95].

Bu verilerin sunduğu bilgileri kavramak, güçlü veri analizi araçları olmadan insani yetenekleri aşmaktadır. Kısacası bu durum; karar vericiyi veri zengini, aynı zamanda bilgi fakiri yapmaktadır [96,97].

Yapay zeka tekniklerinin ortaya çıkış amacı, insanoğlunun bilgi ve tecrübelerinden yararlanarak sorunları çözme yeteneğini bilgisayarlara kazandıracak metodolojileri bulmaya ve geliştirmeye çalışmasıdır. Böylece insan gibi düşünme, öğrenme, davranma ve karar verme yetisine sahip bilgisayarlar tasarlamayı amaçlamasıdır. Veri madenciliği de; veri tabanında biriken veri setleri üzerinde yapay zeka algoritmaları ile istatistiksel analiz yöntemlerinin bir kombinasyonunun kullanılması sonucu, önceden öngörülemeyen karar verme süreçlerinde kullanışlı olabilecek faydalı bilgilerin çıkarımını yapabilen bir yöntemdir. Bu yöntem test sonuçlarının tahmini, ürün geliştirme, tıbbi teşhis ve tedavi sürecinin belirlenmesi amaçlarına yönelik olarak tıp alanında, biyoloji, genetik, kimya, uzay, eğitim, yüzey analizi ve coğrafi bilgi alanları ile özellikle rekabet avantajı kazandırması nedeniyle pazarlama, işletme, bankacılık gibi daha birçok alanda kullanım alanı bulmuştur.

Başarılı bir veri madenciliği uygulaması için; veri madenciliğinin her adımında, insan zekası ve bilgi birikimi sürece dahil olmalı, insan faktörü kadar veri madenciliği araçlarının da önemi gözardı edilmemelidir. Veri madenciliği alanındaki projeler tamamen otomatik araçlar yoluyla yürütüldüğünden, kullanılacak yazılımın

hafıza kullanımı, veri depolama mimarisi, hız ve geçerlilik gibi karakteristikleri de seçimi açısından önem arz etmektedir [98].

SPSS Clementine, SAS Enterprise Miner, IBM Intelligent Miner for Data, DBMiner, Statistica Data Miner ve XLMiner gibi ticari amaçlı paket yazılımlar ile özellikle üniversitelerin bünyesinde geliştirilmiş, ticari amaç olmadan kullanıma sunulan Weka, Yale, Knime ve Orange gibi yazılımlar, en yaygın olarak kullanılan veri madenciliği yazılımları arasında sayılabilir.

IV.1.1 Veri Madenciliği Tanımlarıyla Tarihçesi

Geleneksel teknikler kullanılarak birikim halindeki veriler üzerinde, bütün ilişkilerin yaklaşık %5'inin bulunması söz konusu iken, veri madenciliği tekniğinde ise saklı kalan %95'lik ilişkileri ortaya çıkarma kapasitesi olup, sunulan hipotezin güvenilir olarak kanıtlanması daha mümkündür. Geleneksel teknikleri, veri tabanlarına söz söyleyen bir insan; veri madenciliği tekniğini ise, veri tabanını dinleyen bir insan olarak betimlemek yerinde olacaktır [99,100].


2000'li yıllara kadar daha çok yapay zeka alanında çalışan teorisyenler tarafından tartışılan, anlaşılması güç ve yabancı bir teknoloji olarak görülen veri madenciliği, geçmişte bilgi yönetimi veya bilgi mühendisliği ismiyle anılmaktaydı [100,101].

Veri madenciliği yönteminin daha iyi kavranması amacıyla, tarihsel olarak gelişimini de yansıtmaları açısından literatürde yer alan tanımlarından bazı örnekler seçilerek aşağıda sunulmuştur:

- 1992 yılında Flawley ve meslektaşları tarafından; veri içerisinde gizli kalmış, önceden bilinmeyen ama potansiyel olarak kullanışlı olan anlamlı bilginin çıkarımını veri madenciliği olarak tanımlanmıştır [102].
- Fayyad ile arkadaşları veri madenciliğini 1996 yılında, kabul edilebilir etkinlik sınırlarına sahip bilgisayar tekniklerini kapsayan, veriler üzerinden olağandışı örüntülerin (veya modellerin) sıralamalarını, keşif algoritmaları ve veri analiz işlemleriyle üreten bilgi keşfi sürecinin bir adımı olarak tanımlamışlardır [103].
- 1998 yılında David J. Hand ise veri madenciliğini, istatistik, veritabanı teknolojisi, örüntü tanıma, makine öğrenme ile etkileşimli yeni bir disiplin ve

geniş veritabanlarında önceden tahmin edilemeyen ilişkilerin ikincil analizi olarak tanımlamıştır [104].

- Berry ve Linoff tarafından 2000 yılında veri madenciliği; içerisinde varolan anlamlı örüntü ve kuralları ortaya çıkarmak amacıyla, büyük miktarlardaki verinin otomatik ve yarı otomatik araçlar yardımıyla incelenme ve analiz edilme süreci olarak tanımlanmıştır [105].
- Han ve Kamber; “Çeşitli mimarilerde depolanmış olan büyük miktarlardaki verilerden ilgi çekici bilginin keşfedilmesi süreci veri madenciliğidir.” şeklindeki tanımı 2001’de yapmışlardır [106].
- Yine aynı sene Swift veri madenciliğini, veri ambarındaki çok çeşitli verilere dayanarak önceden keşfedilmemiş bilgileri ortaya çıkarma ve çıkarılan bu bilgileri, karar verme, eylem planını gerçekleştirme amacı için kullanma süreci olarak tanımlamıştır [107].
- 2003 yılında Guifci veri madenciliğini, veriye sahip olan kişi ya da kurum için, kuralları ve ilişkileri keşfederek, önceden bilinmeyen açık ve yararlı sonuçlar elde etmek amacıyla, çok miktardaki verinin seçilmesi, incelenmesi ve modellenmesi süreci olarak tanımlamıştır [108].




Şekil IV. 1 Veri Madenciliği Tarih Şeridi [109]

Veri madenciliğinin yeni bir çalışma alanı olduğu söylemek çok doğru olmayacağı gibi yeni bir buluş olduğunu düşünmek de o derecede yanlış olacaktır. Çünkü çeşitli disiplinleri bir araya getiren veri madenciliği yeni bir açılım, yeni bir paradigmadır ve veri tabanlarında bilgi keşfi çalışmalarının devamı olarak bugün

kullanılan anlamıyla tam karşılığını 1990'lı yıllarda bulmuştur (Şekil IV.1) [97, 110]. Bilimsel çalışmaların paylaşılması ve tartışılması amacıyla ilk uluslararası veri madenciliği konferansı “The First International Conference on Knowledge Discovery and Data Mining” Ağustos 1995’de Montreal Kanada’da gerçekleştirilmiş ve ilk süreli yayın “Journal of Data Mining and Knowledge Discovery” 1997 yılında yayımlanmaya başlanmıştır [111-113].

Uzun bir geçmişe sahip veri madenciliği sürecinde, gerçekleştirilen uygulamalar arasında oluşan farklılıkları minimuma indirmek amacıyla Şekil IV.1’de açılımı görülmekte olan standart bir süreç geliştirilmesi için 1996 yılında CRISP–DM (CRoss – Industry Standard Process for Data Mining) konsorsiyumu bünyesinde iki yüzden fazla araştırmacı çalışarak tüm uygulamacılara yol gösterecek bir standart süreç modeli hazırlamışlardır. Avrupa Komisyonu tarafından fonlanan bu çalışma dokümanı CRISP-DM 1.0 1999 yılında, güncellenmiş hali ise 2000 yılında CRISP–DM 1.031 adı ile yayımlanmıştır. Veri madenciliği araçları standartlaştırma çalışmaları da günümüzde yapılmaktadır [97,114].




Şekil IV. 2 Endüstriyel İşletmeler için Genel Veri Madenciliği Süreci [115]

Veri madenciliği tekniğinin bu tez çalışmasıyla tıp alanına uygulanmasına yönelik izlenmesi gereken en önemli 5 temel aşama Şekil IV. 2’de görüldüğü gibi [116]; verileri seçme, temizleme ve ön işleme, dönüştürme, modelleme ve değerlendirmedir. Bu aşamaların açıklamaları aşağıda yapılmıştır [117]:

- **Veri seçimi:** İlk aşama uygun örneklem kümesindeki hastalardan elde edilen verilerin seçilmesidir. Bu veriler nümerik, metin veya ikilisayı sisteminde kodlanmış içeriklere sahiptirler. Örneğin hasta cinsiyeti metin; kreatinin nümerik ve ortostotik hipotansiyon (OrH) var – yok şeklinde ikili sayı sisteminde kodlanmış veri tipleridir.
- **Veri temizleme ve ön işleme:** Seçilen örneklem kümesinde yer alan hatalı kayıtların çıkarıldığı, eksik nitelik değerlerinin ne yapılacağına belirlendiği ve değişikliklerin gerçekleştirildiği ikinci aşamadır. Bu aşama da gerçekleştirilen işlemlerle, elde edilecek bilginin kalitesinin artırılması hedeflenmektedir.
- **Veri boyutu indirgeme:** Örneklem kümesinden ilgisiz niteliklerin çıkarıldığı ve tekrarlı kayıtların ayıklandığı üçüncü aşamadır. Böylece, model oluşturma için harcanan sorgulama süreci kısaltılarak zaman kazanılmış olmaktadır.
- **Veri madenciliği - modelleme:** Veri madenciliği algoritmasının (sınıflandırma, kümeleme vb.) belirlenerek uygulanması ve oluşturulan model ile bilgi çıkarımı yapılması aşamasıdır.
- **Değerlendirme:** Veri madenciliği tekniği ile keşfedilen örüntülerin yani bilgilerin geçerlilik, yenilik, yararlılık ve basitlik kıstaslarına göre değerlendirildiği son aşamadır.

Böylece tekrarlı olarak kullanılabilecek bir model ortaya konabildiği gibi artan ya da yenilenen verilerle tekrarlanması gereken bir çalışma da ortaya çıkabilmektedir.



Şekil IV. 3 Verilerin Yolculuğu [96]

IV.1.2 Veri Madenciliği Uygulamalarında Ortaya Çıkan Zorluklar

Veri madenciliği uygulamalarında; kayıp, artık, null değerli ya da dinamik veriler ile yaşanan sorunların yanı sıra veri boyutlarının ve gürültünün olumsuz etkisi en çok karşılaşılan zorluklar olup, aşağıda detayları verilmiştir [118].

- Örneklem kümesinde yer alan bazı deneklerin (instances) ya da bunlar için bazı niteliklerin (attributes) veya nitelik değerlerinin olmamasıdır. Bu eksik veriler; hatalı ölçümlerden, veri toplama sürecindeyken deney basamaklarında yapılan değişikliklerden ya da birbirine benzer ancak özdeş olmayan iki veri kümesinin birleştirilmesinden kaynaklanmaktadır.

Bu çalışmadaki iki örneklem kümesini oluşturan hasta profilleri birbirinden değişik olduğundan veri toplama sırasında ikinci örneklem kümesi için SH, ABI, LDL gibi 11 adet nitelik ölçümlenmemiştir. Dolayısıyla bunlar iki veri kümesi birleştirildiğinde eksik veriler olarak karşımıza çıkmaktadır.

- Örneklem kümesinin büyük olması örüntülerin varlığını ortaya çıkarması açısından bir avantaj gibi görünmesine rağmen, bu durum elde edilen örüntü sayısının da çok büyümesi anlamına gelmektedir. Bu yüzden veri tabanı boyutu veri madenciliği sistemleri için önemli problemlerden biri olup, sezgisel/buluşsal bir yaklaşımla arama uzayı taranarak, örneklem kümesinin yatay ve dikey boyutta indirgenmesi gerekmektedir [118].

Bu tür bir zorlukla bu çalışma sırasında karşılaşılmamıştır.

- Veri toplanması sırasında oluşan sistem dışı hatalara gürültü denmektedir ve gürültü sistem tarafından tanınarak ihmal edilmelidir.

Bu çalışma sırasında raw datalar tıp uzmanı tarafından titizlikle incelenmiş ve ölçümden ya da kayıt sırasındaki hatalardan dolayı gürültülü olarak tanımlanabilecek veriler yeniden alınarak düzeltilmiştir.

- Hipotezin doğruluğunu ortaya koymaya uygun olmayan, gereksiz nitelikler de veritabanında yer alabilmektedir ve bunlar “artık veri” olarak isimlendirilmektedir. “Selection attributes” yani özellik seçimi algoritmaları bu artık nitelikleri elemek için geliştirilmişlerdir. Özellik seçimi algoritmaları, yeterli ve gerekli sayıdaki niteliklerin küçük alt kümesini işaret ederek hedefe daha kolay ulaşmaya yardımcı olmaktadır.

Bu çalışma sırasında öncelikle çalışmada yer alan tıp uzmanı doktorların konu hakkındaki bilgi birikimleri, literatürde yer alan çalışmalar ve tecrübeleri

doğrultusunda nitelik seçimi için ön fikirleri alınmıştır. Bu bilgiler, özellik seçimi algoritmalarının (ileri ki konularda daha detaylı olarak sunulacak best first, greedy step vb.) sonuçları ile birlikte yorumlanarak nitelik sayısı ilk denek grubu için 47'den 13'lere, ikinci denek grubu 36'dan 2'ye kadar indirgenerek, arama uzayı küçültülmüş ve sınıflama işleminin kalitesi arttırılmıştır [119].

- Null veriler, niteliğin bilinmeyen ya da uygulanamaz bir değere sahip olduğunu göstermektedir. Null verili denek kayıtları (instances) tamamıyla ihmal edilebildiği gibi, null değerler yerine en fazla frekansa sahip bir değer veya ortalama bir değer atanabilir [120,121].

Bu çalışmanın veri toplama sürecinde, bazı deneklerden bazı verilerin alınamamasından dolayı null veriler oluşmuştur. Null verisi olan deneklerin tamamı, insan faktörü ve sağlığını etkileyen bir çalışma olması gözönünde bulundurularak örneklem kümesinden çıkarılmıştır. Böylece 65 kişilik örneklem kümesi 56'ya, 29 kişilik örneklem kümesi ise 24'e indirgenmiştir.

- Dinamik veri tabanlarının içeriği sürekli olarak yenilenmektedir. Bu da sürekli olarak elde edilen örüntülere değişen yeni verilerin yansıması anlamına gelmektedir.

Bu çalışmada böyle bir zorlukla karşılaşılmamıştır.

IV.1.3 Veri Madenciliği Tekniği Model Oluşturma Yaklaşımları


Veri madenciliği tekniğinde bilgi çıkarımı gerçekleştirilebilmek için iki farklı model oluşturma yaklaşımı kullanılmaktadır. Bunlar [122]:

1. Tahmin edici yaklaşımlar
 - Sınıflandırma ve Öngörü (Classification- Prediction)
 - Zaman Serileri (Time series)
 - Regresyon (Regression)
2. Tanımlayıcı yaklaşımlar
 - Kümeleme (Clustering)
 - Özetleme (Summarization)
 - Birliktelik kural madenciliği (Association rule mining)

VI.1.3.1 Sınıflandırma ve Öngörü

Sonuçları bilinen veri kümesiyle bir model geliştirilmektedir ve bu model sonuçları bilinmeyen veri kümelerinin sonuç değerlerini öngörmek için kullanılmaktadır. Örneğin bir bankanın kredi tahsisi sırasında; müşterinin önceki dönem verileri ile oluşturulan model kullanılarak, müşteriye verilmesi düşünülen kredinin geri dönüp dönmeyeceği öngörüsü yapılabilmektedir.

Bu yaklaşımda, önceden tanımlanan bir sınıfa göre etiketlenen veri kümeleri eğitim veri kümesini oluşturmaktadır. Etiketle tanımlanmayanlar ise test veri kümesini meydana getirmektedir. Eğitim veri kümesinden hareket edilerek, test veri kümesindeki verilerin hangi sınıfa ait olduğunu tespit etmeye çalışan iki adımlı bir süreç içermektedir. Bu nedenle, Gözetimli öğrenme - Supervised Learning öğrenme çeşidi içinde yer alan algoritmalar kullanılmaktadır. Şekil IV.4' te görülen gözetimli öğrenme akış şeması incelendiğinde, hata miktarlarının sisteme öğrenme olarak giriyor olduğu anlaşılmaktadır.




Şekil IV. 4 Gözetimli Öğrenme Akış Şeması [123]

Sınıflandırma ve tahmin yaklaşım modelleri şu karşılaştırma kriterleri gözönüne alınarak değerlendirilebilmektedir [96].

- Tahmin doğruluğu - Predictive Accuracy: Modelin yeni ya da daha önceden bilinmeyen bir veri sınıf etiketinin doğru olarak tahmin edilme yeteneğidir.
- Hız - Speed: Modelin geliştirilmesindeki hesaplama maliyetine karşılık gelir.

- Sağlamlık - Robustness: Modelin, gürültülü ya da kayıp veri verildiğinde doğru tahmin yapma yeteneğidir.
- Ölçeklendirilebilirlik -Scalability: Büyük miktarlarda veri verildiğinde, modeli etkin bir şekilde kurma yeteneğidir.
- Yorumlanabilirlik (Interpretability): Model tarafından sağlanan anlaşılma seviyesidir.

Bu tez çalışmasında da; hastaların Holter cihazı verileride dahil olmak üzere tüm verilerini inceleyen tıp uzmanları tarafından non-dipper/dipper teşhisi yani sınıflaması yapılmıştır. Veri tabanında kayıtlı olan bu veri kümelerinden yalnızca Holter cihazı verileri çıkartılarak, aynı hastalar için non-dipper/dipper öngörüsünü tıp doktorunun teşhisine en yakın şekilde yapan model bu yaklaşımla ortaya konmaya çalışılmıştır (Şekil IV.5).




Şekil IV. 5 Sınıflandırma ve Öngörü Yaklaşımı

IV.1.4 Veri Madenciliği'nde Sınıflandırma Problemleri için Kullanılan Yöntemler

Veri madenciliğinde sınıflandırma operasyonları bir dizi teknik ya da yöntem kullanılarak gerçekleştirilir. Bu yöntemlerin gözetimli ve gözetimsiz öğrenme tekniği gruplarından hangisi içinde yer aldığı Şekil IV.6'da görülmektedir.

Bu yöntemlerden bazıları :

- Karar ağacı ile sınıflandırma yöntemi
- Kural tabanlı sınıflandırma yöntemi
- Bayes ile sınıflandırma yöntemi
- Yapay sinir ağları ile sınıflandırma yöntemi
- Vaka tabanlı nedenleşme ile sınıflandırma yöntemi
- Genetik algoritma ile sınıflandırma yöntemi



Şekil IV. 6 Model Oluşturma Yöntemlerinin Gözetimli ve Gözetimsiz Öğrenme Tekniği Olarak Gruplandırılması [124]

Her yöntem için çeşitli algoritmalar kullanılmaktadır. Aşağıda sınıflama için kullanılan algoritmalarından örnekler verilmiştir [125].

- Çok katmanlı algılayıcı yapay sinir ağları
- Geriye yayılım (Back-propagation) algoritması
- ANFIS (Adaptive Network Based Fuzzy Inference System)
- Yapay Bağışıklık Tanıma Sistemi (Artificial Immune Recognition System) Sınıflama Algoritması
- Bulanık Kaynak Dağılımlı Yapay Bağışıklık Tanıma Sistemi (Fuzzy- AIRS)
- Bulanık kaynak dağılım mekanizması
- C4.5 Karar Ağaçları
- RBF Algoritması

Bu tez çalışmasında veri madenciliği sınıflandırma ve tahmin yaklaşımı için C4.5 Karar Ağaçları, Naivebayes, RBF ve Çok katmanlı algılayıcı yapay sinir ağları algoritmaları tercih edilmiştir. Bir sonraki bölümde deneylerin sunumu sırasında detaylı bilgi verilmiştir.

BÖLÜM V

24 SAATLİK KAN BASINCI ÖZELLİĞİNİ ÖNGÖRMEYE YÖNELİK UZMAN SİSTEM TASARIMI

Uzman sistemler, yapay zeka uygulamalarının bir dalı olarak 1960'ların ortalarından itibaren geliştirilmeye başlanmıştır (Şekil V.1). Buradaki temel fikir uzmanın bilgilerini sisteme aktararak, sistemi, yaptığı çıkarımlar ile uzmanın ulaştığı sonuçlara varabilir hale getirmektir [126].



Şekil V. 1 Uzman Sistemin Yeri [127]

Özellikle gerçek dünyada çözümlenmesi zor olan problemlerin olduğu tıp alanındaki uzman sistem uygulamalarının sayısı gün geçtikçe çoğalmaktadır. Tıp uzmanı bilgi ve tecrübeleri doğrultusunda, özellikle Holter cihazı verilerine dayanarak non-dipper / dipper özelliğe karar vermektedir. Bu çalışmada, toplanan verilerin analiz sürecinde uygulanan yapay zeka algoritmaları ile elde edilen çıkarımların test verilerine uygulanması sonucu, Holter cihazı verileri olmadan uzmanın vardığı nondipper/dipper patern sonucuna varan sistem geliştirilmiştir.

Böylece yine tıp alanındaki bir probleme daha zahmetsiz ve maliyeti düşük bir çözüm yolu üretilmeye çalışılmıştır.


Bu çalışmada geliştirilen 24 Saatlik Kan Basıncını Öngörmeye Yönelik Uzman Sistemin mimarisi Şekil V.2’de görüldüğü üzere iki ana kısımdan oluşmaktadır: Birinci kısım, .NET Framework üzerinde tıp doktorunun kullanımına yönelik tasarlanmış bir kullanıcı arayüzünden oluşmaktadır. Arayüz sayesinde üyelik işlemlerini gerçekleştiren kullanıcı yani tıp doktoru, hasta ile ilgili demografik, klinik, laboratuvar ve test verilerini SQL server 2008 üzerindeki veritabanına kayıt edebilmekte, silebilmekte ve güncelleyebilmektedir. İkinci kısım ise, bilişim uzmanının tasarladığı ve tıp doktoru tarafından girilen verilere göre kan basıncı özelliğini öngörmeye yönelik bir uzman sistemden oluşmaktadır. Söz konusu uzman sistemde veri madenciliği aşamaları, WEKA (Waikato Environment for Knowledge Analysis) programında gerçekleştirilmiştir. Bu program Yeni Zelanda Waikato Üniversitesi’nde Java programlama dili ile geliştirilmiş ve GNU General Public License ile kullanıma sunulmuştur.

V.1 SİSTEM MİMARİSİ BİRİNCİ KISIM

Yazılımcıların en önemli yardımcılarından birisi de geliştirme ortamlarıdır. Microsoft Visual Studio görselliği ön planda olan ve sürükle bırak mantığı ile program yazmaya elverişli, standart bazı kodları otomatik olarak oluşturabilen bir derleyici yani tümleşik geliştirme ortamıdır (IDE). Microsoft Windows, Windows Mobile, Windows CE, .NET Framework., NET Compact Framework ve Microsoft Silverlight tarafından desteklenen tüm platformlar için yönetilen kod ile birlikte yerel kod ve Windows Forms uygulamaları, web siteleri, web uygulamaları ve web servisleri ile birlikte konsol ve grafiksel kullanıcı arayüzü uygulamaları geliştirmek için kullanılır. Bir web uygulaması olarak geliştirilen uzman sistem kullanıcı arayüzü, Visual Studio 2010 ortamında C# ile kodlanmıştır. Bu programa ait giriş ekranı Şekil V.3’de görülmektedir.

Kullanıcı arayüzü ekranlarının Visual Stüdio’da hazırlanışına örnek olması açısından, Şekil V.4’de hasta kayıt ekranlarından bir tanesi tasarım örneği olarak sunulmuştur. Kullanıcı arayüzü tasarımı veri tabanına kaydedilen verileri silip, değiştirebilecek şekilde oluşturulmuştur.

Microsoft Sync Framework çevrimdışı uygulamalar, hizmetler ve cihazlar için işbirliği sağlayan kapsamlı bir eşitleme platformudur. Geliştiriciler herhangi bir ağ üzerinden, herhangi bir protokol kullanarak herhangi bir veriyi, herhangi bir uygulamayı entegre ederek senkronizasyon ekosistemleri inşa edebilmektedirler.



Şekil V. 2 Akıllı Sağlık Uzman Sistem Mimarisi

Sync Framework, dolařım saęlama, paylařma ve evrimdiřı veri alma teknolojileri ve araları sunmaktadır. Sync Framework'un nemli bir yn, zel saęlayıcıları oluřturma yeteneęidir. Saęlayıcılar, peer-to-peer senkronizasyonuna izin veren, Sync Framework eřitleme iřlemine katılmak iin herhangi bir veri kaynaęı saęlamaktadırlar. Bu alıřmada web ortamında yelik iřlemini gerekleřtiren kullanıcıların farklı zamanlarda, farklı yerlerden veritabanlarına eriřimleri sırasında senkronizasyon saęlanarak, hattın kesilmesi sırasında da meydana gelecek aksaklıkların giderilmesini ve veritabanı senkronizasyonun eřitlenerek sorun yařanmamasını saęlamak amacıyla kullanılmıřtır [128].


The image shows two overlapping windows from the Marmara University system. The background window is the main login screen, titled 'MARMARA NİVERSİTESİ'. It features the university's logo and text: 'MARMARA NİVERSİTESİ İ HASTALIKLARI ANA BİLİM DALI HİPERTANSİYON VE ATEROSKLEROZ NİTESİ AKILLI SAęLIK PROGRAMI'. Below this, there are input fields for 'Kullanıcı Adı' (Username) and 'Şifre' (Password), and a link for 'Üye Deęilseniz Tıklayınız' (Click here if you are not a member). The foreground window is titled 'ÜYE KAYIT PANELİ' (User Registration Panel) and is for 'DOKTOR KAYIT' (Doctor Registration). It contains a form with the following fields: AD (Name), SOYAD (Surname), NVAN (Title), ANABİLİM DALI (Department), TEL (Phone), MOBİL TEL (Mobile Phone), E-POSTA (Email), KULLANICI ADI (Username), ŞİFRE (Password), ŞİFRE ONAYLAMA (Confirm Password), a CAPTCHA image showing 'n 8 j 3', GİZLİ SORU (Secret Question), and GİZLİ YANIT (Secret Answer). Each field has a red asterisk indicating it is required. At the bottom right of the form is a button labeled 'EKLE' (Add) with a plus icon. A red note at the bottom states: '* ile işaretli alanlar doldurmak zorunludur.' (Fields marked with * are mandatory).

Şekil V. 3 Uzman Sistem Kullanıcı Arayüzü Giriř Ekranı

Microsoft Silverlight, WPF (Windows Presentation Foundation) trevi grsel programlama teknięiyle multimedia, grafik, animasyon ve interaktif uygulamaların tek eklenti zerinden yrtlmesini saęlamaktadır. Bu program ile oluřturulan ierik, Adobe Flash'ın aksine derlenmemektedir. Vektr grafik ve animasyonların iřaretleme dili biiminde kodlanmasını saęlayan grsel geliřtirme dili XAML, ierdięi belgedeki Javascript deęerlerine ulařıp alıřtırabilmesi sayesinde,

XAML belgeleri HTML/Ajax/Javascript içerikleri tarafından düzenlenip, programlanabilmektedir. Böylece uygulamalar masaüstü arabirim zenginliğinden hiçbir şey kaybetmeden web ve mobil ortamlara taşınabilmektedir.

Esas amacı web tabanlı zengin interaktif uygulamaların hazırlanabilmesi için bir teknoloji platformu oluşturmak olan Silverlight, özellikle Microsoft'un .NET tabanlı dillerine desteği ile dikkati çekmektedir. .NET Framework ile beraber gelen CLR- Common Language Runtime 'ın bir kısmını taşıyan Silverlight, böylece istemci tarafında platform bağımsız olarak MultiThread ve MultiCore desteğine sahip olmaktadır. Silverlight; Windows 2000, Xp, 2003 ve Vista, Mac OS 10.4.8+ Intel üzerinde Internet Explorer 8.0 ve Mozilla Firefox 3, alpha 5 tarayıcılarıyla çalıştırılmaktadır.



Şekil V. 4 Visual Studio Hasta Kayıt Ekranı Tasarım Örneği

Sistem mimarisinin ikinci aşaması olan veri madenciliği ile veritabanındaki verilerden non-dipper/dipper öngörüsünü yapabilmek tezin başlıca amacıdır. Birinci kısım ile verilerin daha kolay depolanabilir ve ulaşılabilir olması için fayda sağlanmaya çalışılmıştır.


V.2 SİSTEM MİMARİSİ İKİNCİ KISIM

Önerilen sistemin ikinci kısmında; Şekil IV.3'te görüldüğü gibi örneklem kümeleri üzerinde yapay zeka algoritmaları ve istatistiksel analiz yöntemleri bileşimi uygulanarak bilgi çıkartılması tekniği olan veri madenciliği kullanılmıştır.


Makine öğrenimi - Machine Learning (ML); mevcut veri kümelerinin analiziyle bilgisayarların “öğrenme” tekniklerini geliştiren, yapay zekanın bir dalını temsil etmektedir. Bu şekilde, geçmiş tecrübelerinden bilgi çıkararak, yeni bir uyarana karşı uygun tepki verebilmeleri mümkün olabilmektedir [129]. Bu bağlamda, Yeni Zelanda Waikato Üniversitesi tarafından Java programlama dilinde geliştirilerek, ticari amaç gütmeyen (GNU General Public License) kullanıma sunulmuş olan ve programcının kendi kodlamasına olanak tanıyan Weka 3.7.4 Developer versiyonu bu çalışmada tercih edilmiştir [130, 131].

V.2.1 Verilerin Yüklenmesi


Weka'nın Explorer, The Knowledge Flow ve Experimenter olarak isimlendirilen 3 farklı kullanıcı arayüzü bulunmaktadır. Bu çalışmada hasta verileri depolama ortamından Şekil V.5'te görüldüğü üzere Excel tablolarında çekilmiştir. Weka veri depolama formatı ise Andrew Donkin tarafından oluşturulan “ARFF” - **Andrew's Ridiculous File Format** biçimidir. Weka 3.7 versiyonundan itibaren Şekil V.6'da görülen converter program parçacığı eklenerek, Excel formatındaki dosyaların Explorer ortamına aktarımı sağlanmıştır. Ancak daha önceki Weka sürümleri kullanıldığı takdirde veriler, **Comma Seperated Value- CSV** formatında virgül ile ayrılmış kayıt değerleri listesi olarak Excel'den Weka'ya yüklenmektedir. CSV formatına dönüştürülmüş verilerin bir kısmı Word dökümanı olarak Şekil V.7'te görülmektedir.



Şekil V. 5 Akıllı Sağlık Programı Hasta Sorgulama Arayüzü - Excel'e Veri Transferi




Şekil V. 6 Excel Formatındaki Verilerin Weka 3.7.4 Ortamına Transferi



Şekil V. 7 CSV formatında Hasta Verileri

Weka Explorer, CSV dosyalarını doğrudan okuyabilmekte ve Şekil V.7’de görülen ARFF formatına dönüştürebilmektedir. Böylece, hasta verileri Weka Explorer tarafından işlenmek için hazırlanmış olmaktadır.



Şekil V. 8 ARFF Formatındaki Hasta Verileri

V.2.2 Verilerin Analizi ve Filtrelenmesi

Bu çalışma için oluşturulan iki denek grubuna ait özellikler, bu deneklerden elde edilen verilerin sınıflandırma işleminden önce geçirdikleri aşamalar, sınıflandırma ve öngörü çalışmaları için yapılmış deneyler ve sonuçları açıklanmaktadır.

V.2.2.1 İlk Denek Grubu

Bu aşamada ilk denek grubunu oluşturan 40'ı kadın olmak üzere, tip 2 diabetli ve normotansif toplam 65 gönüllü hastanın verileri weka ortamına aktarılmıştır. Veri toplandıktan sonraki aşama anlamlı yollarla bilgiyi organize etmektir. Bu bağlamda analize başlanmıştır.

İlk olarak veri toplama sürecinde, bazı deneklerden bazı verilerin alınamamasından dolayı oluşan null veriler tespit edilmiştir. Çalışmanın, hedef organ hasarı ve dolayısıyla KVH ve sonuçlarını öngörmeye olabilecek etkileri gözönünde bulundurularak, null verisi olan deneklerin tamamı örneklem kümesinden çıkarılmış, böylece instance yani denek sayısı 56'ya indirgenmiştir.

Veri tablolarında denekler (instances) satırlarda, nitelikler (attributes) ise sütunlarda yer almaktadırlar.

Bu çalışmada CINSİYET, OrH, EF, maskHT ve class patern yani non-dipper/dipper niteliklerine ait veriler nominal yani kategorik, diğer tüm niteliklere ait veriler ise nümerik veri tipinde tanımlanmıştır.

Weka Explorer arayüzü önileme basamağı, denekleri ve nitelikleri çeşitli filitleme olanakları sunmaktadır. Bu filitrelerden, supervised-öğreticili filitleme yöntemi içinde yer alan NominaltoBinay filitresi kullanılmıştır. Böylece kadın ve erkek gibi öznitelikleri farklı iki string değere sahip veriler, 1 ve 0 gibi ikili forma aktarılmıştır.

Şekil V.9'da daha önce Tablo III.1'de belirtilmiş olan Holter cihazı verileri olmadan, her biri ayrı bir tıbbi niteliğe ait olmak üzere toplam 39 adet histogram görülmektedir. Yatay ekseninde sınıf sınırları, dikey ekseninde sınıf frekansları işaretlenmiştir. Taban uzunluğu sınıf genişliğine, yüksekliği sınıf frekansına karşılık gelen ve üstüste bindirilmiş dikdörtgenler çizilmiştir. Burada mavi renk dipper (32), kırmızı renk ise non-dipper (24) class patternini temsil etmektedir.

Örneğin YAS niteliğine ait;

$$\text{Aritmetik ortalama (Mean)} = \frac{\sum f x_0}{n} = \frac{2855}{56} = 50.982 \quad \text{ve} \quad (7)$$

$$\text{Standart Sapma (StdDev)} = \sqrt{\frac{\sum (x_0 - \bar{x})^2}{n-1}} = 7.581' \text{ dir.} \quad (8)$$

Tablo V.1’de YAS niteliğine ait sınıf sınırları ile frekansları görülmektedir. YAS histogramı incelendiğinde;

En küçük değer (Min) : 31

En büyük değer (Max) : 68

Ortanca Değer (Median) : 49.5


Değişim aralığı (Range) : 68 - 31 = 37 (9)

olduğu anlaşılmaktadır.

Tablo V.1 YAS Niteliği İstatistik Değerleri

Sınıf Sınırları	Frekans
31 – 38.4	3
38.4 – 45.8	12
45.8 – 53.2	20
53.2 – 60.6	15
60.6 - 68	6

Şekil V.9 ile 56 deneğe ait class pattern dahil olmak üzere 39 ayrı niteliğe ait veriler üzerinde, non-dipper/dipper dağılımı yukarıdaki örnekte olduğu gibi incelenebilmektedir.



Şekil V. 9 İlk Gruba ait Toplam 39 Nitelik için Oluşturulan Histogram

Holter cihazı verileri dahil olmak üzere, tüm nitelikler içinde non-dipper/dipper öngörüsünü en iyi sonuçla tesbitini sağlamaya yarayacak nitelikleri seçmek amacıyla Best First, Greedy stepwise, LineerForwardSelection ve Gain Ratio AttributeEval-Ranker öz nitelik seçim algoritmaları koşturulmuş ve aşağıdaki örnek sunulan sonuçtaki nitelikler sırasıyla ortaya çıkmıştır.

Örnek :

Arama Metodu: Greedy Stepwise (forwards).

En iyi alt küme için merit değeri: 0.887

Seçilen nitelikler: 17, 20, 21, 35 : 4 adet

Bunlar

- ntsis
- %sisD
- %diasD
- EF

Bu örneğin sonucu, diğer nitelik seçim algoritmaları sonuçları ile aynıdır ve Holter cihazı verilerinin nondipper/dipper özelliğın tesbitinde önemli yer tuttuğının ifadesidir.

Ancak çalışmada Holter verileri kullanılmayacağı için bu veriler veritabanından çıkarıldığında tekrar nitelik seçim algoritmaları koşturulmuş ve EF niteliğinin Holter cihazı ile elde edilen veriler olmadan bir anlam ifade etmediğı sonucuna varılmıştır.

V.2.2.2 İkinci Denek Grubu


Çalışma daha sonra, 13'ü kadın olmak üzere non-diabetik ve hipertansif toplam 29 gönüllü hasta ile ikinci bir denek grubu oluşturularak devam ettirilmiştir. İkinci denek grubunda da veri toplama sürecinde, bazı deneklerden bazı verilerin alınamamasından dolayı null veriler oluşmuştur. Birinci grupta belirtilen nedenden dolayı null verisi olan deneklerin tamamı, örneklem kümesinden çıkarılarak 29 kişilik örneklem kümesi 24'e indirgenmiştir. Veri tipleri ilk grup ile aynı şekilde tanımlanmıştır. Ancak hasta profili değışikliğinden dolayı ikinci grup hastalardan 11 niteliğe ait veri alınmamıştır. Dolayısıyla tüm niteliklerin sayısı class pattern hariç olarak 36'dır. Verileri toplanmayan niteliklere ait hücreler Tablo V.2 'de turuncu ile belirginleştirilmiştir.

Tablo V. 2 İlk ve İkinci Denek Grubu için Çalışmada Kullanılan Nitelikler

Demografik veriler	Laboratuar tetkikleri	Otonomik Testler	Cihaz ölçümleri				
			EKG	EKO	Holter		
Cinsiyet	A1C	V1	S V1	SWth	dt sis		
Yaş	AKS	V2	R V5	PWth	dt dias		
Boy	Kreatinin	Vm		LVEDD	nt sis		
Kilo	malb	DSD		LVEDS	nt dias		
BELC	LDL	AKH		ME	24h sis		
BSA	ABI	OrH		MA	24h dias		
BMI		HDKBF		MDT	mask HT		
		PH		AoIVRT	%sisD		
		SH		LVM	%diasD		
		Ewing		LVMi			
				EF			
				LA			
				Ao			
						Genel Toplam	
7	6	10	2	13	9	47	1.denek grubu
7	2	9	0	12	6	36	2. denek grubu

*Turuncu ile işaretlenen niteliklerden 2.denek grubu hastaları için veri toplanmamıştır.

Şekil V.10'da ikinci gruba ait tüm nitelikler için histogramlar görülmektedir. Burada mavi renk dipper (17), kırmızı renk ise non-dipper (7) class patterni temsil etmektedir.



Şekil V. 10 İkinci Gruba ait Toplam 37 Nitelik için Oluşturulan Histogram

Holter cihazı verileri dahil iken tüm nitelikler içinde non-dipper/dipper öngörüsünü en iyi sonuçla tesbit edecek nitelikleri belirlemek için yine Best First, Greedy stepwise, LineerForwardSelection ve Gain Ratio AttributeEval-Ranker öz nitelik seçim algoritmaları koşturulmuş ve aşağıdaki örnekte sunulan sonuç elde edilmiştir.

Örnek :

Arama Metodu: Greedy Stepwise (forwards).

En iyi alt küme için merit değeri: 0.832

Seçilen nitelikler: 14, 15, 21, 24 : 4 adet

- %sisD
- %diasD
- OrH
- Ewing

Holter cihazı ile alınan verilerin önemi bir kez daha ortaya çıkmıştır.

Bu çalışmada Holter Cihazı verileri tamamen veritabanından çıkarılarak yapılan modelleme çalışmalarının başlangıçlarında tekrar öznelik seçimi için algoritmalar koşturulmuş ve çıkan sonuçlara göre nitelikler filtrelenerek, sayıları indirgenmiştir.

V.2.3 Verilerin Sınıflandırılması ve Öngörü

Nominal ve nümerik veri tipindeki nitelik değerleri için Weka’da öngörü modeli oluşturulabilmektedir. Weka sınıflama aracı içinde 76 adet sınıflandırma/regresyon algoritması yer almaktadır. Sınıflandırma aracı ile uygulanan öğrenme yöntemleri arasında Decision trees, rule learners, naive Bayes, Bayes’ nets, decision tables, locally weighted regression, support vector machines, instance-based learners, logistic regression, voted perceptron, multi-layer perceptron yer almaktadır.

Weka paketi içerisinde yer alan sınıflandırma yöntemlerini kullanırken ön tanımlı (default) parametreler tercih edilmiştir.

V.2.3.1 Aşama – 1

Bu çalışmada bu kadar çeşitli yöntem içinden hangisi ile çalışmaya başlanacağına öncelikli olarak karar verilmesi gerekmiştir. Bunun için Weka’nın Experimenter arayüzünde aynı veritabanı üzerinde tabloda belirtilen her algoritma için 10 –fold Cross validation değerlendirilmesi yapılmış ve sonuçlar Tablo V.2’ de sunulduğu üzere çok büyük farklar olmamakla birlikte, ileride daha detaylı açıklanacak olan C4.5 karar ağacı algoritmasının Weka’daki implementasyonu olan J48 algoritmasının % 62.40 ile en başarılı olacağı sonucunu vermiştir.

Tablo V. 3 Algoritmaların Başarı Yüzdelерinin Kıyaslanması

<i>Algoritma</i>	<i>Başarı Yüzdesi (%)</i>
bayes.BayesNet	54.20
bayes.NaiveBayes	60.10
bayes.NaiveBayesUpdateable	60.10
functions.MultilayerPercentLayer	54.63
functions.RBFNetwork	56.53
functions.VotedPerceptron	57.07
lazy.LWL	56.80
rules.DecisionTable	49.97
rules.OneR	49.87
rules.ZeroR	57.33
trees.J48	62.40

V.2.3.2 Aşama – 2

Veri madenciliği yöntemi kullanılarak, Holter cihazı verilerinin nondipper/dipper teşhisindeki öneminin ortaya konması bu aşamada düşünülmüştür. Böylece tıp doktorlarının teşhis sırasında bu cihaza ait verilere ihtiyaçlarının olduğu desteklenmiştir. Bu amaçla, holter cihazı verileri dahil ilk denek grubu için 47, ikinci denek grubu için 36 niteliğe ait verileri içeren veritabanı üzerinde, Aşama 1’de incelenen algoritmaların koşturulması sonucunda nondipper/dipper sınıflandırma ve öngörü modeli için nasıl bir başarı yüzdesi elde edildiği incelenmiştir. Elde edilen sonuçlar Tablo V.2 – V.4 ‘te sunulmuştur.

Tablo V. 4 İlk Denek Grubu- 64 kişi
(Holter Cihazı Verileri Dahil ve Null data mevcut)

Algoritma	10-fold Cross Validation Sonuçları	%66 Eğitim Kümesi ile Test Sonuçları
J48	%95.31	%100.00
Decision Table	%98.44	%100.00
MLP	%76.56	%72.73
BayesNet	%98.44	%95.45
NaiveBayes	%81.25	%72.73
RBF	%71.88	%77.27
LWL	%98.44	%100.00

Tablo V. 5 İlk Denek Grubu- 56 kişi (Holter Cihazı Verileri Dahil ve Null data yok)


Algoritma	10-fold Cross Validation Sonuçları	%66 Eğitim Kümesi ile Test Sonuçları
J48	%98.21	%100.00
Decision Table	%98.21	%100.00
MLP	%83.93	%73.68
BayesNet	%100.00	%94.74
NaiveBayes	%78.57	%68.42
RBF	%64.29	%63.16
LWL	%98.21	%100.00

Tablo V. 6 İkinci denek grubu- 24 kişi (Holter Cihazı Verileri Dahil ve Null data yok)

Algoritma	10-fold Cross Validation Sonuçları	%66 Eğitim Kümesi ile Test Sonuçları
J48	%91.67	%75.0
Decision Table	%87.50	%87.5
MLP	%70.83	%75.0
BayesNet	%95.83	%87.5
NaiveBayes	%79.17	%50.0
RBF	%79.17	%62.5
LWL	%91.67	%87.5

Tablolar incelendiğinde yazılım için de, Holter cihazı ölçümleri ile elde edilen verilerin nondipper/dipper teşhisinde karar vermeyi önemli ölçüde kolaylaştırdığı sonucuna varılmıştır.

Yine aynı amaçla nitelik seçim algoritmaları greedy stepwise (forwards), best first ve lineer forward selection koşturulmuş ve Şekil V.11’de görülen sonuçlar elde edilmiş ve ilk dört attributes sıralamaları ile birlikte yerlerini korumuşlardır.



Şekil V. 11 Öz Nitelik Seçimi ile Holter Cihazı Verilerinin Önemi

Holter cihazı verilerinin non-dipper/dipper özelliğini teşhis etmede ne derece önem arz ettiği ortaya konmuştur.

V.2.3.3 Aşama – 3

Holter cihazı ölçümleri ile elde edilen veriler ve null data olmadan (Tablo V.7) denek grupları üzerinde uygulanan sınıflandırma algoritmaları ile elde edilen başarı yüzdeleri Tablo V.8 ve 9’ da ortaya konmuştur.

Deneylerde işleme konmayan nitelikler tablolarda yeşil ile boyanmıştır.

Tablo V. 7 Nondipper/Dipper Öngörüsü için Değerlendirmeye Alınan 38 Adet Nitelik

Demografik veriler	Laboratuar tetkikleri	Otonomik Testler	Cihaz ölçümleri			
			EKG	EKO	Holter	
Cinsiyet	A1C	V1	S V1	SWth	dt sis	
Yaş	AKS	V2	R V5	PWth	dt dias	
Boy	Kreatinin	Vm		LVEDD	nt sis	
Kilo	Malb	DSD		LVESD	nt dias	
BELC	LDL	AKH		ME	24h sis	
BSA	ABI	OrH		MA	24h dias	
BMI		HDKBF		MDT	mask HT	
		PH		AoIVRT	%sisD	
		SH		LVM	%diasD	
		Ewing		LVMI		
				EF		
				LA		
				Ao		
						Genel Toplam
7	6	10	2	13	0	38

Tablo V. 8 İlk denek grubu- 56 kişi (Holter Cihazı Verileri Dahil Değil)
ve Null Data Yok

Algoritma	10-fold Cross Validation Sonuçları	%66 Eğitim Kümesi ile Test Sonuçları
J48	%67.86	%36.84
Decision Table	% 42.86	%63.16
MLP	%51.79	%36.84
BayesNet	%53.57	%57.89
NaiveBayes	%57.14	%47.37
RBF	%46.43	%63.18
LWL	%50	%57.89

Tablo V. 9 İkinci denek grubu- 24 kişi (Holter Cihazı Verileri Dahil Değil)
ve Null Data Yok

Algoritma	10-fold Cross Validation Sonuçları	%66 Eğitim Kümesi ile Test Sonuçları
J48	%54.17	%62.5
Decision Table	%58.33	%62.5
MLP	%70.83	%75.0
BayesNet	%50.00	%62.5
NaiveBayes	%70.83	%50.0
RBF	%75.00	%50.0
LWL	%54.17	%62.5

Tablo V.8 ve 9’ da görülen başarı yüzdelerini % 70 ‘in üzerine çekmek ve nitelik sayısını indirmek ilk hedef olarak ortaya konmuştur.

V.2.4 Verilerin Sınıflandırılması ve Öngörü Deneyleri

Bu çalışmada yapılan deneyler, kullanılan algoritmalar ve elde edilen sonuçlar belirtilmiştir.

V.2.4.1 Deney-1

Deney Grubu Profili : İlk Denek Grubu

Uygulanan Yöntem : Karar Ağaçları

Algoritma : J48

Model Tasarım Süresi : 0.02 seconds

Nitelik Sayısı : 21

Tıp alanında önde gelen literatür çalışmaları ışığında ve öznelik seçimi için fikir veren algoritmaların sonuçları göz önüne alınarak, aşağıdaki tabloda yeşil ile işaretlenen niteliklere ait veriler değerlendirilmeye alınmamıştır. Böylece nitelik sayısı 21'e indirgenmiştir. Her yapılan deneyde değerlendirme dışında bırakılan nitelikler, "Nitelik Sayısı Tablosu"nda yeşil ile kapatılmıştır (Tablo V.10).

Tablo V. 10 Deney- 1 Nitelik Sayısı

Demografik veriler	Laboratuar tetkikleri	Otonomik Testler	Cihaz ölçümleri				
			EKG	EKO	Holter		
Cinsiyet	A1C	V1	S V1	SWth	dt sis		
Yaş	AKS	V2	R V5	PWth	dt dias		
Boy	Kreatinin	Vm		LVEDD	nt sis		
Kilo	malb	DSD		LVESD	nt dias		
BELC	LDL	AKH		ME	24h sis		
BSA	ABI	OrH		MA	24h dias		
BMI		HDKBF		MDT	mask HT		
		PH		AoIVRT	%sisD		
		SH		LVM	%diasD		
		Ewing		LVMi			
				EF			
				LA			
				Ao			
						Genel Toplam	
7	6	10	2	13	9	47	1.denek grubu
2	2	6	1	10	0	21	İndirgenik Durum

Karar ağaçları güvenilir ve etkin karar vermeye yaygın şekilde yardımcıdırlar. Doğruluk oranlarının yüksekliği ve ortaya çıkarılan bilginin kolay anlaşılmasını sağlayan grafik gösterimlerinden dolayı sınıflandırmada tercih edilmektedirler [132, 133]. Karar ağaçları özel bir uygulanabilirlik alanı olmamakla birlikte, tıp biliminin alt alanlarında, sağlık hizmetleri uygulamalarında [132] ve karar verme seviyelerinde geniş kullanım alanına sahiptirler. Çeşitli hastalardan veri toplamak tıbbi bilgilerin çıkarımına ve karar destek sistemine yardımcı olabilmektedirler.

Endüktif öğrenme algoritmalarından biri olan karar ağaçları, verilerin / örneklerin eğitmede kullanılmasıyla sınıflandırma ağacının oluşmasını sağlamaktadır. Temeli böl ve yönet (divide and conquer) stratejisine dayanmaktadır [134, 135]. Bu yöntemin avantajı, anlaşılabilir kurallara dönüştürülebilmeleridir [136]. Karar ağaçları temel olarak tıbbi veriler için teşhis modelleri oluşturmakta kullanılmaktadır [137, 138]. Tıbbi verilerden kalıplar/pattern keşfedilmeye çalışıldığında [139], yetersiz kaldıkları ortaya çıkmaktadır.

J. Ross Quinlan tarafından 1986 yılında Sydney Üniversitesi'nde öne sürülmüş C4.5 karar ağaçları, ID3 (Iterative Dichotomiser 3) eşleştirme öğrenme algoritmasına (matching learning algorithm) dayanmakta ve örneklerden öğrenmenin en iyi bilinen aracı kabul edilmektedir [133, 140, 141]. C4.5 örnek edinme / kıyaslama ile öğrenme sistemidir (benchmark learning system) ve sınıflama performansı en iyi olanlardan birisidir [142]. Buradaki kıyaslama veya başkalarından öğrenme: en iyi yöntemlerin, uygulamaların ve örneklerin sürekli olarak araştırılması anlamında dinamik bir kavramdır. Temelde ID3 algoritmasının gelişmiş versiyonu 1993 yılında aynı araştırmacı tarafından yayınlanmıştır [143,144]. Ayrıca çok yaygın olarak kullanılan karar ağacı sisteminin ticari versiyonu C5.0'dır [136,141]. J48 karar ağacı algoritması C4.5'in Weka'daki java uygulamasıdır (klon).

J48 algoritması Enformasyon Kazancı Teorisine (Information Gain Theory) dayanarak, verilerden ilgili özellikleri seçmek için otomatik işlem yeteneğine sahiptir. Enformasyon kazancının en iyi olduğu noktadan örnekleri bölen yinelemeli algoritmadır. IF-THEN kurallarına dayalı bir karar ağacı ve "üyelik fonksiyon kümeleri -membership function sets" çıktısı verir [145]. Ağaç yapısı, denekleri bölme ve ağacın en iyi kök değişkeninin seçilmesi süreci ile başlayıp yukarıdan aşağıya doğru inşası gerçekleştirilmektedir [136]. J48, anlamlı olmayan diğer bir deyişle

zayıf dalları kesmek için etkin bir budama işlemi yapabilmektedir. Bunun nedenlerinden biri, karar ağaçlarının amacının veri keşfetmek değil, veriler üzerinde basit bir sınıflandırma modeli oluşturmak olmasındandır. Başka bir nedeni ise, karar ağacının sezgisel (heuristic) araması çok daha kaliteli kuralları bulmasını engellemektedir. Karar ağaçları, ağaç yapımında sadece bir yol takip ederler ve dolayısıyla alternatif yollar boyunca olabilecek daha iyi kuralları kaçırabilmektedirler. Son zamanlarda, bir varyant karar ağacı algoritması, yüksek-kazanç-bölme ağaç yöntemi, iş zekası yüksek ve faydalı kalıpları keşfetmek için önerilmiştir [146]. Tıbbi veriler üzerinde uygulanması araştırılmalıdır.

Sınıflandırıcı özniteliği seçmek için öncelikle sistemin entropisi hesaplanmıştır[147]. Sistemin entropisi S;

$$\text{Dipper}(N_{pos}) = 32$$

$$\text{Non_Dipper}(N_{neg}) = 24$$

$$\text{Toplam Veri Sayısı (Toplam)} = N_{pos} + N_{neg} = 56 \quad (10)$$

$$p_+ = N_{pos}/\text{Total} \quad (11)$$

$$p_+ = 32/56 = 0.571$$

$$p_- = N_{neg}/\text{Total} \quad (12)$$

$$p_- = 24/56 = 0.4285$$

$$H(S) = -p_+ \log_2(p_+) - p_- \log_2(p_-) = 0.9853 \quad (13)$$

Eğitim için ayrılan deneklere ait enformasyon kazancı kullanılarak, en iyi sınıflandırıcı tek bir öznitelik hesaplandı.

Herbir nitelik değeri için;

$$\text{Gain}(S, A_i) = H(S) - \sum_{v \in \text{Values}(A_i)} P(A_i = v) H(S_v) \quad (14)$$


En iyi enformasyon kazancı olan nitelik kök olarak belirlenmektedir.

Bu deneyde 56 deneğin % 66'sı eğitim için ayrılmıştır. Böylece, J48 algoritması 19 denek üzerinde test edilmiştir. Şekil V.12'de ortaya çıkan karar ağacı modeli

görülmektedir. Tablo V.11’da test edilen herbir deneğe ait gerçek class değeri ile programın tahmini olan class değeri belirtilerek, hatalı sonuçlar işaretlenmiştir.

Tablo V. 11 Deney – 1 Gerçek ve Tahmin Karşılaştırma Tablosu

Denek	Gerçek	Tahmin	Hata	Olasılık
1	dipper	nondipper	+	1
2	nondipper	dipper	+	1
3	dipper	dipper		1
4	nondipper	nondipper		1
5	nondipper	nondipper		1
6	nondipper	nondipper		1
7	dipper	nondipper	+	1
8	dipper	dipper		1
9	dipper	dipper		1
10	nondipper	nondipper		1
11	dipper	dipper		1
12	dipper	dipper		1
13	nondipper	dipper	+	1
14	dipper	dipper		1
15	nondipper	dipper	+	1
16	nondipper	nondipper		1
17	nondipper	nondipper		1
18	dipper	dipper		1
19	nondipper	nondipper		1



Şekil V. 12 Deney-1 Karar Ağacı Modeli

Denekleri Doğru Sınıflandırma	14	% 73.6842	
Denekleri Yanlış Sınıflandırma	5	% 26.3158	
Kappa istatistik (κ)		0.4751	(15)
Ortalama mutlak hata (Mean Absolute Error)		0.2632	(16)
Ortalama Karesel Hatanın Karekökü (Root mean squared error)		0.513	(17)
Bağıl mutlak hata (Relative absolute error)		%52	(18)
Root relative squared error		% 98.8372	(19)

Non-parametrik doğrulama nedeniyle, tüm modellerin başarısı için kullanılabilir. Bu istatistik denklem 1 ile hesaplanır. κ istatistik değeri, [-1 1] sınırları arasında olmalıdır. Eğer değer < 0 ise, model tahminleri ve gözlenen değerler arasında bir ilişki yok anlamına gelmektedir. Değer = 0 ise, ilişkinin tamamen tesadüfen olduğuna işaret etmektedir. κ istatistiği subjektif değerlendirmedir. 0.4751 değeri ise, Silman Tablosuna göre ortalama başarı anlamına gelmektedir [148,149].

$$\kappa = \frac{(a+d) - [(a+c)(a+b) + (b+d)(c+d)]/n}{n - [(a+c)(a+b) + (b+d)(c+d)]/n} \quad (15)$$

$$\text{Ortalama Mutlak Hata} = \frac{|p_1 - a_1| + \dots + |p_n - a_n|}{n} \quad (16)$$

$$\text{Ortalama Karesel Hatanın Karekökü} = \sqrt{\frac{(p_1 - a_1)^2 + \dots + (p_n - a_n)^2}{n}} \quad (17)$$

$$\text{Bağıl mutlak hata} = \frac{|p_1 - a_1| + \dots + |p_n - a_n|}{|a_1 - \bar{a}| + \dots + |a_n - \bar{a}|} \quad (18)$$

$$\text{Root relative squared error} = \sqrt{\frac{(p_1 - a_1)^2 + \dots + (p_n - a_n)^2}{(a_1 - \bar{a})^2 + \dots + (a_n - \bar{a})^2}} \quad (19)$$

Tablo V. 12 Deney -1 Sonuç Değerlendirmesi

	TP Oranı	FP Oranı	ROC Alanı	Class
	0.7	0.222	0.739	Non-Dipper
	0.778	0.3	0.739	Dipper
Ağırlıklı Ort.	0.737	0.259	0.739	

Tablo V. 13 Deney-1 Hata Matrisi

Hata Matrisi		
a	b	sınıflandırma
7	3	a = Non-Dipper
2	7	b = Dipper
Doğruluk % =		$(7+7)/(7+2+3+7) = 73.6842$

Aşağıda belirtilen kriterler üzerinden hata matrisindeki hata sayılarına bakılarak, karar ağacı modeli performansı değerlendirilir. Kriterler:

True Positive (TP): Tıp uzmanının Holter bulgularına göre non-dipper teşhisi koyduğu denek, program tarafından da hasta (nondipper) tesbit edildi.

True Negative (TN): Tıp uzmanının Holter bulgularına göre dipper teşhisi koyduğu denek, program tarafından da normal (dipper) tesbit edildi.

False Positive (FP): Tıp uzmanının Holter bulgularına göre dipper teşhisi koyduğu denek, program tarafından hasta (nondipper) tesbit edildi.

False Negative (FN): Tıp uzmanının Holter bulgularına göre non-dipper teşhisi koyduğu denek, program tarafından normal (dipper) tesbit edildi.

Sağlam kişilerden oluşan denek grubu verildiğinde testin pozitif olma olasılığı, testin duyarlılığıdır. Duyarlılık formülü:

$$\begin{aligned}
 \text{Duyarlılık} &= (TP / (TP+FN)) \\
 &= (7 / (7+3)) \\
 &= 0.70 \\
 &= \%70
 \end{aligned}
 \tag{20}$$

Bir testin Özgüllük oranı, hastalığı olan deneklerde testin negative olma olasılığıdır.
Özgüllük için formül:

$$\begin{aligned}\text{Özgüllük} &= (TN) / (TN+FP) & (21) \\ &= (7 / 7+2) \\ &= 0.7777 \\ &= \%78\end{aligned}$$

V.2.4.2 Deney-2

Deney Grubu Profili	: İlk Denek Grubu
Uygulanan Yöntem	: Karar Ağaçları
Algoritma	: J48
Model Tasarım Süresi	: 0.02 seconds
Nitelik Sayısı	: 9

Tablo V. 14 Deney- 2 Nitelik Sayısı

Demografik veriler	Laboratuar tetkikleri	Otonomik Testler	Cihaz ölçümleri			Genel Toplam	
			EKG	EKO	Holter		
Cinsiyet	A1C	V1	S V1	SWth	dt sis		
Yaş	AKS	V2	R V5	PWth	dt dias		
Boy	Kreatinin	Vm		LVEDD	nt sis		
Kilo	malb	DSD		LVESD	nt dias		
BELC	LDL	AKH		ME	24h sis		
BSA	ABI	OrH		MA	24h dias		
BMI		HDKBF		MDT	mask HT		
		PH		AoIVRT	%sisD		
		SH		LVM	%diasD		
		Ewing		LVMI			
				EF			
				LA			
				Ao			
7	6	10	2	13	9	47	1.denek grubu
0	0	7	0	2	0	9	İndirgenik Durum

56 denekten oluşan veri kümesi % 66'sı eğitim veri seti kalanı ise test veri kümesi olarak bölünmüştür. Tablo V.17'de görüldüğü üzere eğitim veri kümesi 37 denekten oluşmaktadır. Tablo V.18'de 19 denekten oluşan test veri kümesi sunulmuştur.

İlk olarak J48 karar ağacı algoritması ile eğitim veri kümesini eğitme işlemi gerçekleştirilmiş ve Şekil V.13'de görülen karar ağacı modeli % 81.08 doğruluk oranı ile elde edilmiştir.

Eğitim veri kümesinin yani sistemin entropisi, sınıflandırıcı özneliği seçmek için hesaplanmıştır. Sistemin entropisi S aşağıdaki gibi hesaplanır;

$$\text{Dipper}(N_{pos}) = 18$$

$$\text{Non_Dipper}(N_{neg}) = 19$$

$$\text{Toplam Veri Sayısı (Toplam)} = N_{pos} + N_{neg} = 37 \quad (10)$$

$$p_+ = N_{pos}/Total \quad (11)$$

$$p_- = N_{neg}/Total \quad (12)$$

$$p_+ = 18/37 = 0.4864$$

$$p_- = 19/37 = 0.5135$$

$$H(S) = -p_+ \log_2(p_+) - p_- \log_2(p_-) = 0.9994 \quad (13)$$

Eğitim için ayrılan deneklere ait enformasyon kazancı kullanılarak en iyi sınıflandırıcı tek bir öznelik hesaplandı.

Herbir nitelik değeri için;

$$\text{Gain}(S, A_i) = H(S) - \sum_{v \in \text{Values}(A_i)} P(A_i = v) H(S_v) \quad (14)$$

En iyi enformasyon kazancı olan nitelik kök olarak belirlenmektedir.

DSD en iyi kök için örnek hesaplama aşağıda gösterilmiştir.

- Nümerik veri tipi olduğu için herbir DSD verisinin altına class object değeri yazılır.

3	4	5	6	7	8	9	9.5	11	12	13	14	15	17	18	19	19.6	20	22	26	31	41
D	D	N	D	N	N	D	N	N	N	D	D	D	D	N	D	D	D	D	D	D	D
	N	N	N	N	N	N		N	N	N	N										
				N	D			D	D												
									N												

- En kalıcı değişimin 18 verisinde olduğu belirlenir. Deneğe ait **DSD verisi>18** ise class object değeri kesinlikle **dipper** olur.

$$\text{info}([11,19],[7,0]) = (30/37) \times \text{info}[11,9] + (7/37) \times \text{info}[7,0] \quad (22)$$

$$= 0.8108 \times 0.9478 + 0.1891 \times 0$$

$$= 0.7685 \text{ bits}$$

$$\text{Gain(DSD)} = 0.9994 - 0.7685 \quad (14)$$

$$= 0.2309 \text{ bits}$$

- DSD değeri ≤ 18 ise durumu daha belirgin hale getirmek için diğer bir nitelik seçimine geçilir.

Bu deneyde eğitim ile elde edilen model, Tablo V.18’te görülen test kümesi üzerine uygulandığında, deneklere ait nondipper/dipper özelliğın program tarafından öngörüsü Tablo V.19’deki gibi gerçekleşmiştir. Çıkan sonuçların doğruluk tesbiti için class object’te tanımlı olan nondipper/dipper sonuçları silinmeden önce test veri kümesi kayıt edilmiştir. Tablo V.20’de test veri kümesinde her deneğē ait gerçek ve tahmin sonuçların karşılaştırılması görölmektedir. Eğitim veri kümesi ile elde edilen karar ağacı modeli test veri kümesi üzerinde uygulandığında 19 denekten 4’ünü hatalı olarak öngörmüştür.

Denekleri Doğru Sınıflandırma	15	% 78.9474	
Denekleri Yanlış Sınıflandırma	4	% 21.0526	
Kappa istatistik (κ)		0.4571	(15)
Ortalama Mutlak Hata		0.3139	(16)
Ortalama Karesel Hatanın Karekökü		0.4482	(17)
Bağıl mutlak hata		% 62.02	(18)
Root relative squared error		% 88.5518	(19)

Tablo V. 15 Deney -2 Sonuç Değerlendirmesi

	TP Oranı	FP Oranı	ROC Alanı	Class
	0.6	0.143	0.8	Non-Dipper
	0.857	0.4	0.8	Dipper
Ağırlıklı Ort.	0.789	0.332	0.8	

Tablo V. 16 Deney-2 Hata Matrisi

Hata Matrisi		
a	b	sınıflandırma
3	2	a = Non-Dipper
2	12	b = Dipper
Doğruluk % =		$(12+3)/(12+2+2+3) = 78.9474$

$$\begin{aligned}
 \text{Duyarlılık} &= (TP) / (TP+FN) \\
 &= (3 / (3+2)) \\
 &= 0.60 \\
 &= \%60
 \end{aligned}
 \tag{20}$$


$$\begin{aligned}
\text{Özgüllük} &= (TN) / (TN+FP) \\
&= (12 / (12+2)) \\
&= 0.8571 \\
&= \% 86
\end{aligned}
\tag{21}$$

Tablo V. 17 Deney- 2 Eğitim Veri Seti

File Edit View										
ilk_56_holtersiz_9a_train.arff										
Relation: WekaExcel-weka.filters.unsupervised.attribute.Remove-R40-42-weka.filters.supervised.attribute.NominalToB										
No.	1: Vm Numeric	2: DSD Numeric	3: AKH Numeric	4: OrH Numeric	5: HDKBF Numeric	6: PH Numeric	7: SH Numeric	8: LA Numeric	9: MDT Numeric	10: class patern Nominal
1	1.35	12.0	0.95	1.0	10.0	1.5	1.0	35.2	230.0	nondipper
2	1.09	5.0	1.25	0.0	15.0	2.0	1.5	33.0	177.0	nondipper
3	1.35	22.0	1.2	1.0	16.0	0.0	0.0	38.0	212.0	dipper
4	1.51	4.0	1.3	1.0	30.0	1.0	0.0	43.0	258.0	dipper
5	1.13	9.0	1.18	1.0	10.0	1.5	1.0	40.0	232.0	dipper
6	1.68	14.0	1.39	1.0	7.0	0.5	1.0	29.1	192.0	dipper
7	2.19	8.0	1.03	1.0	11.0	1.5	0.5	38.5	210.0	nondipper
8	1.34	13.0	1.22	0.0	10.0	0.5	1.5	37.1	157.0	dipper
9	1.16	31.0	1.23	1.0	10.0	0.5	1.0	42.0	178.0	dipper
10	1.385	6.0	1.07	1.0	30.0	1.0	0.0	36.0	193.0	dipper
11	1.63	11.0	1.29	1.0	23.0	0.5	0.0	39.2	241.0	nondipper
12	1.52	9.0	1.2	0.0	10.0	1.0	2.0	39.0	232.0	nondipper
13	1.48	19.6	1.9	1.0	20.0	0.0	0.0	45.0	206.0	dipper
14	1.305	19.0	1.44	1.0	10.0	0.0	1.0	33.3	207.0	dipper
15	1.49	13.0	1.22	1.0	10.0	0.5	1.0	39.0	163.0	nondipper
16	1.48	18.0	1.45	1.0	23.0	0.0	0.0	38.5	255.0	nondipper
17	1.26	7.0	1.18	1.0	5.0	1.0	1.0	45.0	279.0	nondipper
18	1.1	4.0	1.12	1.0	5.0	2.0	1.0	33.5	186.0	nondipper
19	1.075	3.0	1.03	1.0	6.5	2.5	1.0	32.9	138.0	dipper
20	1.265	8.0	1.07	1.0	11.0	1.0	0.5	34.0	294.0	nondipper
21	1.24	14.0	1.25	1.0	5.0	0.5	1.0	45.0	282.0	nondipper
22	1.16	12.0	1.15	1.0	23.0	1.0	0.0	46.2	161.0	nondipper
23	1.275	7.0	1.12	1.0	18.0	1.0	0.0	38.9	130.0	nondipper
24	1.49	17.0	1.23	1.0	3.0	0.0	1.0	45.5	158.0	dipper
25	1.08	12.0	1.14	1.0	10.0	1.5	1.0	45.2	175.0	dipper
26	1.61	7.0	1.19	1.0	20.0	1.0	0.0	34.1	164.0	nondipper
27	1.23	5.0	1.03	0.0	15.0	1.5	1.0	38.0	190.0	nondipper
28	1.175	12.0	1.0	1.0	10.0	2.0	1.0	41.1	111.0	nondipper
29	1.405	11.0	1.21	1.0	20.0	0.5	0.0	36.7	261.0	nondipper
30	1.4	8.0	1.11	1.0	1.5	1.0	1.0	44.0	124.0	dipper
31	1.365	20.0	1.41	1.0	25.0	0.0	0.0	36.8	148.0	dipper
32	1.2	6.0	1.25	1.0	13.0	1.5	0.5	37.0	278.0	nondipper
33	2.01	26.0	1.18	1.0	18.0	0.0	0.0	39.0	191.0	dipper
34	1.66	11.0	1.12	1.0	8.0	0.5	1.0	30.8	162.0	dipper
35	1.49	9.5	1.18	0.0	20.0	1.0	0.5	38.5	224.0	nondipper
36	1.55	15.0	1.25	1.0	10.0	0.0	1.0	39.6	198.0	dipper
37	1.94	41.0	1.43	0.0	11.0	0.0	1.0	34.8	131.0	dipper

Tablo V. 18 Deney- 2 Test Veri Seti

File Edit View										
ilk_56_holtersiz_9a_test_19.arff										
Relation: WekaExcel-weka.filters.unsupervised.attribute.Remove-R40-42-weka.filters.supervised.attribute.NominalToB										
No.	1: Vm Numeric	2: DSD Numeric	3: AKH Numeric	4: OrH Numeric	5: HDKBF Numeric	6: PH Numeric	7: SH Numeric	8: LA Numeric	9: MDT Numeric	10: class patern Nominal
1	1.15	11.0	1.04	1.0	8.0	1.0	1.0	40.3	124.0	
2	1.33	9.0	1.22	1.0	30.0	1.0	0.0	37.0	202.0	
3	1.27	7.0	1.07	1.0	25.0	1.0	0.0	37.0	269.0	
4	1.395	19.0	1.21	1.0	20.0	0.0	0.0	38.0	237.0	
5	1.24	5.0	1.27	1.0	30.0	1.0	0.0	39.0	212.0	
6	2.37	10.0	1.05	1.0	30.0	1.0	0.0	41.0	195.0	
7	1.14	4.0	1.06	1.0	34.0	1.5	0.0	40.7	215.0	
8	1.41	10.0	1.51	1.0	14.0	1.0	0.5	41.0	194.0	
9	1.4	12.0	1.15	1.0	20.0	0.5	0.0	30.2	160.0	
10	1.08	7.0	1.15	1.0	8.0	2.0	1.0	45.0	232.0	
11	1.69	9.0	1.22	1.0	10.0	1.0	1.0	42.3	130.0	
12	1.81	14.0	1.07	0.0	10.0	0.5	2.0	41.8	224.0	
13	1.35	13.0	1.21	1.0	10.0	0.5	1.0	42.0	228.0	
14	1.36	11.0	1.23	1.0	10.0	0.5	1.0	33.4	165.0	
15	1.17	9.0	1.08	1.0	28.0	1.5	0.0	37.6	186.0	
16	1.13	12.0	1.25	1.0	5.0	1.0	1.0	48.0	200.0	
17	1.355	11.0	1.09	1.0	11.0	0.5	0.5	31.0	311.0	
18	1.24	12.0	1.22	1.0	8.0	0.5	1.0	39.7	174.0	
19	1.17	11.0	1.05	1.0	10.0	1.0	1.0	41.0	154.0	



Şekil V. 13 Deney- 2 Eğitim Veri Kümesi ile Oluşturulan Karar Ağacı Modeli

Tablo V. 19 Deney-2 Test Veri Kümesi Tahmin Sonuçları

Classifier output				
=== Predictions on test set ===				
inst#	actual	predicted	error	prediction
1	1:?	1:dipper	0.571	
2	1:?	1:dipper	1	
3	1:?	2:nondippe	1	
4	1:?	1:dipper	1	
5	1:?	1:dipper	1	
6	1:?	1:dipper	1	
7	1:?	1:dipper	1	
8	1:?	2:nondippe	1	
9	1:?	2:nondippe	1	
10	1:?	1:dipper	0.571	
11	1:?	1:dipper	0.571	
12	1:?	2:nondippe	0.75	
13	1:?	1:dipper	0.571	
14	1:?	1:dipper	0.571	
15	1:?	1:dipper	1	
16	1:?	1:dipper	0.571	
17	1:?	2:nondippe	1	
18	1:?	1:dipper	0.571	
19	1:?	1:dipper	0.571	

Tablo V. 20 Deney-2 Test Veri Kümesi Gerçek ve Tahmin Karşılaştırılması

Classifier output				
=== Predictions on test set ===				
inst#	actual	predicted	error	prediction
1	2:nondippe	1:dipper	+	0.571
2	1:dipper	1:dipper		1
3	2:nondippe	2:nondippe		1
4	1:dipper	1:dipper		1
5	1:dipper	1:dipper		1
6	1:dipper	1:dipper		1
7	1:dipper	1:dipper		1
8	2:nondippe	2:nondippe		1
9	1:dipper	2:nondippe	+	1
10	1:dipper	1:dipper		0.571
11	1:dipper	1:dipper		0.571
12	2:nondippe	2:nondippe		0.75
13	1:dipper	1:dipper		0.571
14	2:nondippe	1:dipper	+	0.571
15	1:dipper	1:dipper		1
16	1:dipper	1:dipper		0.571
17	1:dipper	2:nondippe	+	1
18	1:dipper	1:dipper		0.571
19	1:dipper	1:dipper		0.571

V.2.4.3 Deney-3

Deney Grubu Profili:	İlk Denek Grubu
Uygulanan Yöntem:	Bayes
Algoritma:	Naivebayes
Model Tasarım Süresi:	0.01 seconds
Nitelik Sayısı:	16

Tablo V. 21 Deney- 2 Nitelik Sayısı

Demografik veriler	Laboratuar tetkikleri	Otonomik Testler	Cihaz ölçümleri				
			EKG	EKO	Holter		
Cinsiyet	A1C	V1	S V1	SWth	dt sis		
Yaş	AKS	V2	R V5	PWth	dt dias		
Boy	Kreatinin	Vm		LVEDD	nt sis		
Kilo	malb	DSD		LVESD	nt dias		
BELC	LDL	AKH		ME	24h sis		
BSA	ABI	OrH		MA	24h dias		
BMI		HDKBF		MDT	mask HT		
		PH		AoIVRT	%sisD		
		SH		LVM	%diasD		
		Ewing		LVMi			
				EF			
				LA			
				Ao			
						Genel Toplam	
7	6	10	2	13	9	47	1.denek grubu
2	2	6	1	5	0	16	İndirgenik Durum

Bayesian analiz, Bayes Teoremine dayandırılarak yapılan analiz anlamındadır. Bu yaklaşımın asıl fikri; istatistiğe göre bir teori, bir öneri ya da bir nedensellik ilişkisi olsun, her kapsamdaki belirsizlik olasılıklarla ifade edilmelidir [150]. Bir olayın olasılığı, o olaya ilişkin kanı derecesi (ön bilgi- prior) ve denemeden elde edilmiş verinin birleştirilmiş halidir. Bu birleştirme Bayes Teorimine yani koşullu olasılığa dayanmaktadır. Burada bahsedilen olasılık “Tümevarım Olasılığıdır”. Amaç denemeler yaparak olasılığı “1” yani kesinliğe vardırmaktır. Burada herhangi bir varsayım sözkonusu değildir ve yapılan denemeler ile doğruluk kuvvetlendirilmektedir.

Bayes sınıflandırıcılar istatistiksel yöntem olup, verilen bir üyeliğin belli bir sınıfa ait olup olmaması gibi sınıf üyeliği olasılıklarını tahmin edebilmektedirler. Bayes Teoremine göre, test edilen bir denek için öngörülen class (C_i), nitelik değerleri kümesi $V = V_1 \wedge V_2 \wedge \dots \wedge V_n$ ve en yüksek koşullu olasılık hesabı : [151,152]:

$$P(C_i | V) = \frac{P(C_i) * P(V | C_i)}{P(V)} \quad (23)$$

Fakat gerçekte, eğitim seti etkileyici olsa bile, genellikle denekler bütün teoriyi kapsamaz ve $P(V | C_i)$ uygun çıktı sağlamaz[152].

Naive Bayes ise hem tahmin edici hem de tanımlayıcı bir sınıflama yöntemi olup, her ilişkide koşullu bir olasılık türetmek için hedef değişkenle, bağımlı ve bağımsız değişkenler arasındaki ilişkiyi analiz etmektedir. Bu bağlamda, naive yaklaşımla olasılık şu şekilde hesaplanır[153]:

$$P(V | C_i) = \prod_{j=1}^n P(v_j | C_i) \quad (24)$$

Burada “naive” sıfatı, tüm niteliklerin bağımsız oldukları varsayımının kuvvetini belirtmektedir. Olasılık indüksiyonu için en basit ve yaygın test yöntemi Naive Bayes’tir[1]. Özellikle giriş vektörlerinden dolayı matrisin boyutu yüksek olduğunda tercih edilmektedir [140,154].

Naive Bayes, modelin öğrenilmesi esnasında, her çıktının öğrenme kümesinde kaç kere meydana geldiğini hesaplanır ve elde edilen bu değere “öncelikli olasılık” denir. Bunu şu basit örnekle açıklamak mümkündür. Bir banka kredi kartı başvurularını “iyi” ve “kötü” risk sınıflarında gruplandırmak istemektedir. İyi risk çıktısı toplam 5 vaka içinde 2 kere meydana geldiyse iyi risk için öncelikli olasılık 0,4’tür. Bu durum, “Kredi kartı için başvuran biri hakkında hiçbir şey bilinmiyorsa, bu kişi 0,4 olasılıkla iyi risk grubundadır” olarak yorumlanır. Naive Bayes aynı zamanda her bağımsız değişken/bağımlı değişken kombinasyonunun meydana gelme sıklığını bulur. Bu sıklıklar öncelikli olasılıklarla birleştirilmek suretiyle tahminde kullanılır [118,155].

Denekler üzerinde yapılan deney-3 sonucunda ortaya çıkan NaiveBayes modeline ait ortalama doğruluklar ve standart sapma değerleri Tablo V.21’de belirtilmiştir. Algoritmaların karşılaştırması literatürde ortalama değerlere göre yapılmaktadır.

$$\text{Mean}_{\text{CINSİYET_dipper}} = \frac{\sum f x_0}{n} = \frac{21}{32} = 0,6563 \quad (7)$$

$$\begin{aligned} \text{Standart Sapma (StdDev)} &= \sqrt{\frac{\sum (x_0 - \bar{x})^2}{n-1}} \\ &= \sqrt{\frac{(1-0,6563)^2 \cdot 21 + (0-0,6563)^2 \cdot 11}{32-1}} \\ &= 0,476 \end{aligned} \quad (8)$$

Olasılık yoğunluk fonksiyonu ise;

$$\begin{aligned} f_{(\text{CINSİYET}=1/\text{dipper})} &= \frac{1}{\sqrt{2\pi} \cdot \sigma} e^{-\frac{(x-\mu)^2}{2 \cdot \sigma^2}} \\ &= \frac{1}{\sqrt{2\pi} \cdot 0,475} e^{-\frac{(1-0,6563)^2}{2 \cdot 0,475^2}} \\ &= 1 \end{aligned} \quad (24)$$

$$\text{Prior probability}_{\text{dipper}} = \frac{\text{dipper nesnelerin sayısı}}{\text{Tüm nesnelerin sayısı}} \quad (25)$$

$$\text{Prior probability}_{\text{nondipper}} = \frac{\text{nondipper nesnelerin sayısı}}{\text{Tüm nesnelerin sayısı}} \quad (26)$$

$$\text{Posterior probability } X_{\text{dipper}} = \text{Prior probability}_{\text{dipper}} \times \text{Likelihood } X_{\text{dipper}} \quad (27)$$

$$\text{Posterior probability } X_{\text{nondipper}} = \text{Prior probability}_{\text{nondipper}} \times \text{Likelihood } X_{\text{nondipper}} \quad (28)$$

Böylece son olasılık değerleri bulunmuş olur.

Tablo V. 22 Deney-3 NaiveBayes Modeli

Attributes	Non-dipper (0.43)				Dipper (0.57)			
	Mean	Standard deviation	Weight sum	Precision	Mean	Standard deviation	Weight sum	Precision
CINSIYET	0.5417	0.4983	24	1	0.6563	0.475	32	1
YAS	52.4167	7.4848	24	1.48	49.765	7.4896	32	1.48
A1C	6.7329	0.9391	24	0.1339	6.2797	1.2729	32	0.1339
ABI	1.2365	0.1417	24	0.0224	1.1536	0.1341	32	0.0224
RV5	8.9762	4.0888	24	0.9286	9.6049	3.6009	32	0.9286
DSD	9.572	3.3067	24	1.7273	13.5483	8.1716	32	1.7273
AKH	1.1684	0.1278	24	0.0328	1.2203	0.1644	32	0.0328
OrH	0.7917	0.4061	24	1	0.9375	0.2421	32	1
HDKBF	14.1435	6.0035	24	1.8056	15.6858	9.4516	32	1.8056
SH	0.7083	0.5937	24	0.5	0.5938	0.5068	32	0.5
Ewing	1.75	0.878	24	0.5	1.3281	0.8534	32	0.5
SWth	11.4447	1.6894	24	0.2654	10.7149	1.3881	32	0.2654
ME	0.7499	0.1561	24	0.0184	0.7915	0.1576	32	0.0184
MDT	210.7639	52.9363	24	4.1667	190.8854	40.0796	32	4.1667
AoIVRT	111.5686	17.5674	24	2.3529	108.4559	20.0463	32	2.3529
LWM	480.2853	124.6689	24	8.7061	478.0181	101.4912	32	8.7061

Tablo V. 23 Deney – 3 Gerçek ve Tahmin Karşılaştırma Tablosu

Denek	Gerçek	Tahmin	Hata	Olasılık
1	dipper	dipper		0.551
2	nondipper	dipper	+	0.941
3	dipper	dipper		0.999
4	nondipper	nondipper		0.55
5	nondipper	nondipper		0.925
6	nondipper	nondipper		0.863
7	dipper	nondipper	+	0.941
8	dipper	dipper		0.674
9	dipper	dipper		1
10	nondipper	nondipper		0.742
11	dipper	dipper		0.784
12	dipper	dipper		0.742
13	nondipper	dipper	+	0.998
14	dipper	dipper		0.829
15	nondipper	nondipper		0.917
16	nondipper	dipper	+	0.508
17	nondipper	nondipper		0.922
18	dipper	dipper		0.933
19	nondipper	nondipper		0.847

Denekleri Doğru Sınıflandırma	15	%78.9474	
Denekleri Yanlış Sınıflandırma	4	%21.0526	
Kappa istatistik		0.5824	(15)
Ortalama Mutlak Hata		0.3216	(16)
Ortalama Karesel Hatanın Karekökü		0.4478	(17)
Bağıl mutlak hata		%63.5565	(18)
Root relative squared error		%86.2846	(19)

Tablo V. 24 Deney – 3 Sonuç Değerlendirmesi

	TP Oranı	FP Oranı	ROC Alanı	Class
	0.7	0.111	0.756	Non-Dipper
	0.889	0.3	0.756	Dipper
Ağırlıklı Ort.	0.789	0.201	0.756	


Tablo V. 25 Deney – 3 Hata Matrisi

Hata Matrisi		
a	b	sınıflandırma
7	3	a = Non-Dipper
1	8	b = Dipper
Doğruluk % =		$(8+7)/(8+1+3+7) = 78.9474$

$$\begin{aligned}
 \text{Duyarlılık} &= (TP / (TP+FN)) \\
 &= (7 / (7+3)) \\
 &= 0.70 \\
 &= \%70
 \end{aligned}
 \tag{20}$$

$$\begin{aligned}
 \text{Özgüllük} &= (TN / (TN+FP)) \\
 &= (8 / (7+1)) \\
 &= 1.00 \\
 &= \%100
 \end{aligned}
 \tag{21}$$

Bu deneyde Şekil V.14'te görülen ROC alanı 0.7556'dır. ROC grafiğinin sol üst köşedeki 1 noktasına yaklaşması, modelin tahmin başarısının çok iyi olduğuna işaret etmektedir. Bu değişikliğin sayısal gösterimi için ROC altındaki alan hesaplanmaktadır. Bu alan büyüdükçe tahmin başarısı büyümektedir. En düşük performans için ROC alanı 0.5'e eşittir [149,156].

**Şekil V. 14** ThresholdCurve (Class değeri Non-Dipper) ROC Altındaki Alan = 0.7556

V.2.4.4 Deney-4

Deney Grubu Profili	: İlk Denek Grubu
Uygulanan Yöntem	: Yapay Sinir Ağları
Algoritma	: MLP
Model Tasarım Süresi	: 0.31 seconds
Nitelik Sayısı	: 13

Tablo V. 26 Deney- 4 Nitelik Sayısı

Demografik veriler	Laboratuar tetkikleri	Otonomik Testler	Cihaz ölçümleri				
			EKG	EKO	Holter		
Cinsiyet	A1C	V1	S V1	SWth	dt sis		
Yaş	AKS	V2	R V5	PWth	dt dias		
Boy	Kreatinin	Vm		LVEDD	nt sis		
Kilo	malb	DSD		LVESD	nt dias		
BELC	LDL	AKH		ME	24h sis		
BSA	ABI	OrH		MA	24h dias		
BMI		HDKBF		MDT	mask HT		
		PH		AoIVRT	%sisD		
		SH		LVM	%diasD		
		Ewing		LVMi			
				EF			
				LA			
				Ao			
						Genel Toplam	
7	6	10	2	13	9	47	1.denek grubu
1	2	4	1	5	0	13	İndirgenik Durum


Yapay sinir ağları (YSA), beynin belirli bir işi veya fonksiyonu yerine getirme yönteminin matematiksel modellemesidir.

Basit biyolojik sinir sisteminin çalışma şeklini simüle etmek için ilk tasarlanan bir sinir hücresi yani nörondur. Nöronlar çeşitli şekillerde birbirlerine bağlanarak ağı oluştururlar ve bu ağlar öğrenme, hafızaya alma ve veriler arasındaki ilişkiyi ortaya çıkarma kapasitesine sahiptirler.


Biyolojik sistemlerde öğrenme, nöronlar arasındaki sinaptik (synaptic) bağlantıların ayarlanması ile olur. Doğumla başlayan yaşayarak öğrenme süreci

içinde, yaşayıp tecrübe ettikçe sinaptik bağlantılar ayarlanır ve hatta yeni bağlantılar oluşur. Böylece öğrenme gerçekleşir. YSA için de durum aynıdır. Öğrenme, eğitme yoluyla örnekler kullanarak olur. Öğrenmenin gerçekleşmesi girdi/çıkı verilerinin işlenmesiyle, yani eğitme algoritmasının bu verileri kullanarak bağlantı ağırlıklarını (weights of the synapses) bir yakınsama sağlanana kadar, tekrar tekrar ayarlamasıyla olur [156].

Biyolojik sinir hücresi Şekil V.15’de, yapay sinir hücresi Şekil V.16’da görülmektedir. Table V.26’da sinir hücresi tanımlamalarına karşılık gelen yapay sinir hücresi terimleri belirtilmiştir.




Şekil V. 15 Biyolojik Sinir Hücresi



Şekil V. 16 Yapay Sinir Hücresi

- **Girişler (x_n)** : Dış ortamdan ya da diğer hücrelerden, bu hücreye giren verilerdir.
- **Ağırlıklar (w_n)**: İlgili girişin hücre üzerindeki etkisini belirleyen katsayıdır.
- **Toplama Fonksiyonu**: Bir hücreye gelen net veriyi hesaplayan fonksiyondur.
- **Aktivasyon Fonksiyonu**: Toplama fonksiyonundan gelen net veriyi bir işlemden geçirerek çıktığı belirler. Çok katmanlı algılayıcı gibi bazı modeller bu fonksiyonun türevinin alınabilir bir fonksiyon olmasını şart koşturmaktadır. Günümüzde en yaygın olarak kullanılan aktivasyon fonksiyonu sigmoid fonksiyonudur (Şekil V.17). Bu fonksiyonun eşitliği,

$$f(x) = \frac{1}{1+e^{-x}} \quad (29)$$



Şekil V. 17 Sigmoid Fonksiyon Grafiği

- **Hücrenin Çıktısı**: Aktivasyon fonksiyonu tarafından belirlenen çıktı değeri, dış dünyaya ya da başka bir hücreye gönderilmektedir.

Tablo V. 27 Terimlerin Karşılıkları


Sinir Sistemi	Yapay Sinir Ağı
Nöron	İşlem Elemanı/Nöron
Dentrit	Toplama Fonksiyonu
Hücre Gövdesi	Aktivasyon Fonksiyonu
Akson	Eleman Çıkışı
Sinaps	Ağırlıklar

Perceptron, 1958 yılında Rosanblatt tarafından sınıflandırma amacı ile geliştirilmiştir [157].

Bir veya birden fazla giriş değeri için bir çıktı değeri üreten modeldir ve ağı üretmiş olduğu bu çıktı değeri 0 ya da 1'dir. Perceptron ağırlık değerlerinin değişimine olanak tanıdığı için eğitilebilen bir ağıdır. Ağı ürettiği çıktı değeri, beklenen değerden farklı olduğunda eşik değeri ve ağırlıklar değiştirilir. Perceptron modelinde toplam girdi eşik değeri olan 0'den büyük ise çıktı 1, değilse 0'dır.

Şekil V.18'de perceptron modelinde ağı toplam girdisi görülmektedir [158].

$$NET = \sum_{i=1}^n w_i x_i \quad (30)$$



Şekil V. 18 Perceptron Modeli [159]


Perceptron ile sadece AND, OR ve NOT problemlerine çözüm getirilebilmektedir. Ancak XOR problemlerinin çözümü Çok Katmanlı Algılayıcı - MLP (Multi Layer Perceptron) ile çözümlenmiştir. Bir başka deyişle, nonlinear çözüm yaklaşımı sunulmuştur.

MLP üç katmandan oluşmaktadır (Şekil V.19). Gizli katman sayısı birden fazla olabilmektedir. Her bir katmanda en az bir işlem elemanı bulunur. Bir önceki katmandaki tüm işlem elemanları bir sonraki katmandaki işlem elemanlarına bağlantı içermektedir. Bu ağda bilginin akışı ileri yönlüdür. Dolayısıyla "feed-forward network - ileri beslemeli ağ" dır. Öğrenme ve eğitme algoritması olarak

Rumelhart ve arkadaşlarının 1986’da geliştirdiği, türeve dayalı geriye yayılım (back propagation) algoritmaları tercih edilmektedir [160].

Geri yayılım algoritması adını hatayı yayma biçiminden alır. Bu algoritmada elde edilen çıktı ve olması gereken çıktı arasındaki fark yani hata, tüm ağırlıklara yansıtılır. Geri yayılım algoritmasında eğitime rastgele bir ağırlık kümesi ile başlanır, birçok uygulamada ağın başarısı ağa atanan ilk ağırlık değerlerinin uygun seçilmesine bağlıdır.

Yapay sinir ağlarının eğitiminde hatayı en aza indirmek için genellikle, hata fonksiyonunun yönünü bulmaya ve hata fonksiyonunu azaltmaya çalışan dereceli azaltma (gradient descent) tabanlı algoritmalar kullanılır.



Şekil V. 19 MLP Modeli

WEKA’da yapay sinir ağı deneyinin analizi sırasında 4 temel etki önemlidir. Bunlar: learning rate, momentum, eğitim süresi (training time) ve eğitimde epochs. Bu deneyde geçen terimler ve anlamları [159, 161]:

- **epoch:** Olası girdiler için ağırlıkların güncellenme sayısıdır.
- **Error:** Ölçülen çıktı değeriyle beklenen değer arasındaki farktır. Örneğin, eğer biz çıktı olarak 0 bekleyip de 1 aldığımızda hata (error) değeri -1' dir.

- **Target Value, T:** Perceptrondan öğrenmesini beklediğimiz değerdir. Örneğin, eğer AND fonksiyonuna [1,1] girdisini verirse bekleyeceğimiz sonuç 1 'dir.
- **Output , O :** Perceptron'un verdiği çıktıdır.
- x_i : Nöron' a verilen girdi
- w_i : Xi inci girdinin ağırlık değeri
- **Learning Rate:** Bir perceptron'un hedefe varması için gereken adım büyüklüğü yani ağırlıkların değişim miktarıdır.
- **momentum:** MLP ağıının öğrenmesi esnasında yerel bir optimum noktaya takılıp kalmaması için ağırlık değişim değerinin belirli bir oranda bir sonraki değişime eklenmesini sağlar.
- **threshold:** Giriş ve çıkış katmanındaki işlem elemanları birbirleriyle bağlantılı durumdadır. Bu tür ağlarda sonucu sıfırdan farklı kılmak için threshold (eşik değeri) mevcuttur.

İleriye doğru hesaplama (feedforward); ağıın çıktısını hesaplama sürecidir. Gelen girdiler $(x_1, x_2, \dots, x_i)$ hiçbir değişiklik olmadan gizli katmana gönderilir. Bu katmandaki her düğüm, giriş katmanındaki bütün düğümlerden gelen bilgileri ağırlıklarının $(w_1, w_2, \dots, w_i)$ etkisiyle alır. Ara katmana gelen net bilgi formülü (30) numaralı formülde verilmiştir.

En iyi performans yani en az hata miktarını verecek şekilde, ara katman ve ara katmandaki nöron sayısını belirleyecek kesin bir yöntem bulunmamaktadır. Bu nedenle ağıın performansını en iyiye ulaştırmak için deneme yanılma yöntemi kullanılmaktadır.

Gradient descent, MLP ağırlıklarını bulmak için kullanılan standart matematiksel optimizasyon algoritması ile en iyi sonuca ulaşılır. Ağdaki her bir ağırlık, her bir parametreyle ilgili karesel hata türevi (derivatives of squared error) hesaplanarak bulunmaktadır. Gizli katmanı olmayan basit bir algılayıcı için hesaplama örneği;

Sigmoid fonksiyon ifadesi (29) numaralı formülde verilmiştir.

Squared-error loss fonksiyonu kullanılmıştır. Tek bir eğitim deneği için;


$$E = \frac{1}{2}(y - f(x))^2 \quad (31)$$

$f(x)$ burada ağıın öngörüsü, y deneğin sınıf etiketi, $\frac{1}{2}$ factor sadece kolaylık sağlamak için dahil edilir ve zaten türev alınınca düşecektir.

Gradient descent ile minimize edilmesine örnek:

Şekil V.20’de gibi bir varsayımsal hata fonksiyonu ele alındığında, X-ekseni optimize edilmesi varsayımsal olan parametre w ’yi temsil etmektedir. w^2+1 ‘in türevi $2w$ olur. Özellikle herhangi bir noktada fonksiyonun eğimini ortaya çıkarmak için türevi anlamak önemlidir. Türev negatif ise, eğim sağa aşağı, eğer türev pozitif ise, eğim sola aşağı doğrudur ve türev boyutu düşüşün ne kadar sarp olduğunu belirler. Gradient descent yinelemeli optimizasyon prosedürü, fonksiyon parametrelerini ayarlamak için bu bilgiyi kullanır. Türev değerini alıp, learning rate (λ) ile yani küçük bir sabit ile çarpılır. Bu deneyde $\lambda = 0.3$ ’tür. Ancak örnek için bu değeri 0.1 kabul edelim. O anki parametre değerinden sonuç değeri çıkartılır. Bu yeni parametre değeri üzerinde en küçük değere ulaşılan kadar aynı işlemler tekrar edilir.

Örneğin o anki $w = 4$ ise, fonksiyonun türevi o noktada 8 olur. Bu değer λ ile çarpıldığında 0.8 değeri bulunur. $4 - 0.8 = 3.2$ bulunur. Bu yeni parametre içinde işlem tekrar edildiğinde; $2w = 3.2 \times 2 = 6.4$ olur. Bu değer λ ile çarpıldığında 0.64 değeri bulunur. $3.2 - 0.64 = 2.56$ yeni parametre değeridir ve 2.048 gibi devam eder. Şekil V.21’deki x ekseninde işaretlenmiş olan küçük çarpı işaretleri bu değerleri göstermektedir. 0’a en yakın noktaya kadar devam edilmiştir. Bu nokta varsayımsal hata fonksiyonudur.



Şekil V. 20 Gradient descent’in kullandığı hata fonksiyonu

Belirli bir w_i ağırlığı getirisi ile ilgili olarak farklılaşan hata fonksiyonu:

$$\frac{dE}{dw_i} = (f(x) - y) \frac{f(x)}{dw_i} \quad (32)$$

Burada $f(x)$ perceptron (algılayıcı) çıkışı ve x girdilerin ağırlıklı toplamıdır.

Sağ taraftaki ikinci faktörü hesaplamak için, $f_{(x)}$ sigmoid fonksiyonunun türevi gereklidir.

$$\frac{df_{(x)}}{dx} = f_{(x)}(1 - f_{(x)}) \quad (33)$$

Bu türevi belirtmek için $f'_{(x)}$ ifadesi de kullanılmaktadır. Burada x değil w_i ile ilgili türev aranmaktadır.

$$x = \sum_i w_i a_i \quad (34)$$

w_i ile ilgili $f_{(x)}$ türevi;

$$\frac{df_{(x)}}{dw_i} = f'_{(x)} a_i \quad (35)$$

Bunu hata fonksiyonun türev formülünde yerine koyalım,

$$\frac{dE}{dw_i} = (f_{(x)} - y) f'_{(x)} a_i \quad (36)$$

Belirli bir a örnek vektörü (“bias”ı temsil eden 1 tarafından genişletilmiş) için bütün w değişimlerinin hesabını veren ifadedir. Her bir eğitim örneği için bu hesaplama tekrar edilir, belirli bir w_i ağırlığı ile ilişkili değişiklikler eklenir. Bunun için λ ile çarpılır, sonuç o anki w_i değerinden çıkartılır. Ama bütün bunlar hiçbir gizli katman olmadığı varsayımı ile. Gizli bir katman olunca;

i 'inci gizli katman unit çıkışını $f_{(x_i)}$, j girişinden i 'inci gizli katmana olan bağlantının ağırlığı w_{ij} ve i 'inci gizli katman unitten çıkışa olan ağırlığı w_i varsayalım. Bu durum Şekil V.19'da görülmektedir. Önceki gibi, $f_{(x)}$ çıkış katmanındaki tek bir unit çıkışıdır. Aslında w_i ağırlıkları için güncelleme kuralı temelde yukarıdaki ile aynıdır, a_i dışında. i 'inci gizli birim çıktısı tarafından a_i değiştirilir:

$$\frac{dE}{dw_i} = (f_{(x)} - y) f'_{(x)} f_{(x_i)} \quad (37)$$

Ancak, ağırlıkları w_{ij} güncellemek için karşılık gelen türevlerinin hesaplanması gerekir. Zincir kuralı uygulanılarak elde edilir.

$$\frac{dE}{dw_{ij}} = \frac{dE}{dx} \frac{dx}{dw_{ij}} = (f_{(x)} - y) f'_{(x)} \frac{dx}{dw_{ij}} \quad (38)$$

İlk iki faktör önceki denklemdeki ile aynıdır. Üçüncü faktörü hesaplamak için,

$$x = \sum_i w_i f_{(x_i)} \quad (39)$$

sonra

$$\frac{dx}{dw_{ij}} = w_i \frac{df_{(x_i)}}{dw_{ij}} \quad (40)$$

Ayrıca,

$$x = \sum_j w_{ij} a_j \quad (41)$$

bu nedenle

$$\frac{df_{(x_i)}}{dw_{ij}} = f'_{(x_i)} \frac{dx_i}{dw_{ij}} = f'_{(x_i)} a_j \quad (42)$$


Sonuçta,

$$\frac{dE}{dw_{ij}} = (f_{(x)} - y) f'_{(x)} w_j f'_{(x_i)} a_j \quad (43)$$

Yukarıdakilerin hepsi, her eğitim deneği için hesaplanmaktadır. Bu derivasyon, bir gizli katman ile bir algılayıcı için geçerlidir. İkinci bir gizli katman olduğunda, aynı strateji ilk gizli katmanın giriş bağlantılarına ait ağırlıkları ikinci kez yenilemek için uygulanabilir ve hata çıkış unitten ikinci katmana oradan da ilk yere kadar yayılır. Bu hata yayılım mekanizmasından dolayı, kapsamlı gradient descent stratejisinin bu versiyonuna “Backpropagation –Geri yayılım” denmektedir [130].

Tablo V. 28 Deney – 4 Gerçek ve Tahmin Karşılaştırma Tablosu

Denek	Gerçek	Tahmin	Hata	Olasılık
1	dipper	dipper		1
2	nondipper	dipper	+	1
3	dipper	dipper		1
4	nondipper	nondipper		0.513
5	nondipper	nondipper		0.994
6	nondipper	nondipper		0.997
7	dipper	dipper		1
8	dipper	dipper		1
9	dipper	dipper		1
10	nondipper	nondipper		0.9
11	dipper	dipper		1
12	dipper	dipper		0.505
13	nondipper	nondipper		0.783
14	dipper	dipper		0.873
15	nondipper	nondipper		0.997
16	nondipper	nondipper		0.684
17	nondipper	nondipper		0.61
18	dipper	nondipper	+	0.505
19	nondipper	nondipper		0.541

**Şekil V. 21** Deney-4 MLP Modeli Şeması

Tablo V. 29 Deney - 4 MLP Modeli

		Sigmoid Node 2	Sigmoid Node 3	Sigmoid Node 4	Sigmoid Node 5	Sigmoid Node 6	Sigmoid Node 7
NİTELİKLER	Threshold	1.27	-3.31	-2.33	-0.30	-0.20	1.93
	YAS	-3.49	1.88	-5.34	-7.62	0.37	-2.35
	A1C	1.58	-4.63	0.97	2.93	0.34	1.84
	ABI	3.56	0.49	-3.93	-5.66	-2.15	-2.33
	RV5	-1.07	-0.62	1.10	2.17	0.04	0.12
	DSD	0.96	0.68	4.17	2.68	-0.80	0.79
	OrH	-2.03	-0.26	2.21	3.38	0.83	-0.18
	HDKBF	-1.78	6.48	-5.94	-1.19	2.69	-4.01
	SH	-1.58	-1.18	1.42	-1.52	-3.08	-1.24
	SWth	-3.06	-4.22	-6.77	-7.52	-1.85	-3.26
	ME	0.37	2.19	1.15	2.86	-0.31	-1.08
	MDT	-0.59	1.56	-3.25	-4.22	-2.16	2.37
	AoIVRT	0.18	2.30	2.33	-1.21	1.34	-5.38
	LVM	4.07	1.30	1.22	1.91	0.55	-1.97
Class dipper	Threshold	5.55	-7.40	-7.08	-7.75	4.58	6.16
Sigmoid Node 0	-3.29						
Class non-dipper	Threshold	-5.54	7.39	7.08	7.74	-4.57	-6.16
Sigmoid Node 1	3.29						

Bu deneyde MLP modeli için;

gizli katman sayısı: 6

λ : 0.7

$\emptyset$: 0.4

epoch : 500

seed : 1

Denekleri Doğru Sınıflandırma	17	%89.4737
Denekleri Yanlış Sınıflandırma	2	%10.5263
Kappa istatistik		0.7889 (15)
Ortalama Mutlak Hata		0.2162 (16)
Ortalama Karesel Hatanın Karekökü		0.3458 (17)
Bağıl mutlak hata		%42.7147 (18)
Bağıl Karesel Hatanın Karekökü (Root relative squared error)		%66.6248 (19)

Tablo V. 30 Deney – 4 Sonuç Değerlendirmesi


	TP Oranı	FP Oranı	ROC Alanı	Class
	0.9	0.111	0.944	Non-Dipper
	0.889	0.1	0.944	Dipper
Ağırlıklı Ort.	0.895	0.106	0.944	

Tablo V. 31 Deney – 4 Hata Matrisi

Hata Matrisi		
a	b	sınıflandırma
9	1	a = Non-Dipper
1	8	b = Dipper
Doğruluk % =		$(9+8)/(9+1+1+8) = 89.4737$

$$\begin{aligned}\text{Duyarlılık} &= (TP) / (TP+FN) \\ &= (9 / (9+1)) \\ &= 0.9 \\ &= \%90\end{aligned}\tag{20}$$

$$\begin{aligned}
 \text{Özgüllük} &= (TN / (TN+FP)) \\
 &= (8 / (8+1)) \\
 &= 0.89 \\
 &= \%89
 \end{aligned}
 \tag{21}$$



Şekil V. 22 ThresholdCurve (Class değeri Non-Dipper)
ROC Altındaki Alan = 0.9444

V.2.4.5 Deney-5

Deney Grubu Profili	: İlk Denek Grubu
Uygulanan Yöntem	: Yapay Sinir Ağları
Algoritma	: RBF Network
Model Tasarım Süresi	: 0.04 seconds
Nitelik Sayısı	: 13 (Tablo V.26)

RBF-Radial Basis Function (Radyal Tabanlı Ağlar) ileri beslemeli ağ yapısında olan popüler bir yöntemdir. Giriş katmanı sayılmazsa yalnız iki katmanı vardır ve MLP'den farkı, gizli katman unitlerinin hesaplama performanslarıdır. Her bir gizli unit temelde giriş uzayındaki belirli bir noktayı temsil eder ve onun çıktısı ya da aktivasyonu, sadece farklı bir nokta olan denek ile o nokta arasındaki mesafeye bağlıdır. Sezgisel olarak, bu iki nokta daha yakın olduğunda aktivasyon daha güçlüdür. Bu mesafeyi bir benzerlik ölçütü haline dönüştürmek için doğrusal olmayan bir dönüşüm fonksiyonu kullanılır. Her bir gizli birim için genişliği farklı olabilen çan şeklindeki Gaussian aktivasyon fonksiyonu yaygın olarak bu amaç için kullanılır ve genişliği her bir gizli unit için farklı olabilir. Gizli unitler RBFs olarak isimlendirilir çünkü denek uzayındaki noktalar için verilen bir gizli unit aynı aktivasyon formunu hypersphere ya da hyperellipsoid olarak üretir. (Çok katmanlı algılayıcıda, bir hyperplanedir.)

RBF ağının çıkış katmanı MLP'ninki ile aynıdır: Sınıflandırma problemlerinde, gizli birimlerin çıkışlarının lineer kombinasyonlarını alır ve sigmoid fonksiyonu sayesinde aktarır.


Böyle bir ağın öğrendiği parametreler:

- RBFs'lerin merkezleri ve genişlikleri,
- Ağırlıklar, gizli katmandan elde edilen çıkışların lineer kombinasyon formu için kullanılır.

MLP'ye göre en önemli avantajı, parametrelerin ilk kümesi ikinci kümeden bağımsız olarak hesaplanabilir ve hala doğru sınıflandırıcılar üretir.

Parametrelerin ilk kümesini belirlemek için k-means clustering - kümeleme kullanılmaktadır. Her sınıfa ait k temel fonksiyonları elde etmek için her sınıfı bağımsız olarak, kümelendirir. Prototip denekleri, sezgisel olarak ortaya çıkan RBFs temsil eder. Sonra ilk parametreler sabit tutularak, parametrelerin ikinci kümesi öğrenilebilir.

Kısacası; bu ağ tasarımı çok boyutlu uzayda eğri uyurma yaklaşımı izlenir. Bu sebeple RBF ağının eğitimi aslında çok boyutlu uzayda eğitim verilerine en uygun yüzeyi bulma problemidir. Giriş katmanından gizli katmana dönüşüm radyal tabanlı aktivasyon fonksiyonları ile doğrusal olmayan sabit bir dönüşümdür. Gizli katman ile çıkış katmanı arasındaki dönüşüm ise uyarlamalı ve doğrusaldır.



Şekil V. 23 RBF Ağı [164]

- P_h : temel fonksiyon kullanan gizli unitler
- m_h : unit h'nin lokal merkezi,
- s_h : ilk katman parametreleri (h lokal unitin yayılması)
- w_i : ikinci katman ağırlıkları

Her bir unit için, bir lokal merkez vardır ve merkezler temel fonksiyonlar için giriştir. Yerellik (Locality) kavramı, m_h 'yi yani h unitinin pozisyonu ile verilen x girişi arasındaki benzerliği ölçmek için bir uzaklık fonksiyonu gerektirir. Bu mesafe sıkça Euclidean uzaklığı olarak ölçülür [162]. Fonksiyon cevabı Gaussian olacak şekilde seçilmiştir. Fonksiyon $x = m_h$ olduğu yerde maximum olur, benzerlik azaldıkça düşüş olur. Fonksiyon eşitliği;

$$p_h^t = \exp \left[- \frac{\|x^t - m_h\|^2}{2s_h^2} \right] \quad (44)$$

x^t instance cluster h 'ye aitse, temel fonksiyon P_h^t sıfırdan farklı tanımlanır. merkezlerini belirlemek için k-means kümeleme ve adaptif rezonans teorisi gibi pek çok yöntem vardır.

Sezgisel s_h değerlerini ve en iyi merkezlerle başlamak yerine k-means kümeleme kullanarak m_h değerlerinin bulunuşu ile ilgili algoritma aşağıda sunulmuştur[163]:

Repeat

For all (x^t, r^t) in random order

For $h = 1, \dots, H$

$$p_h^t = \exp (||x^t - m_h||^2 / 2s_h^2)$$

For $i = 1, \dots, K$

$$y_i^t = \sum_l^H w_{ih} p_h^t + w_{i0}$$

For $i = 1, \dots, K$

$$\Delta w_{ih} = \eta \sum_l^H (r_i^t - y_i^t) p_h^t$$

$$\Delta w_{i0} = \eta \sum_l^H (r_i^t - y_i^t) p_{i0}^t$$

For $j = 1, \dots, K$

$$\Delta m_{hj} = \eta \sum_l^N (\sum_l^K (r_i^t - y_i^t) w_{ih}) p_h^t ((x^t - m_{hj}) / s_h^2)$$

$$\Delta s_h = \eta \sum_l^N (\sum_l^K (r_i^t - y_i^t) w_{ih}) p_h^t (||x^t - m_{hj}|| / s_h^2)$$

$$w_h = w_h + \Delta w_h$$

$$m_h = m_h + \Delta m_h$$

$$s_h = s_h + \Delta s_h$$

Eğitim hatası (training error) bulunması:

$$Error = 0.5 \cdot \sum_1^h (r_i - y_i)^2 \quad (45)$$

Hata değişmeyen ya da ihmal edilebilir bir aralıkta değişen olmalıdır.

Temel fonksiyolar gibi, k-means clusters için uygulanan logistic regression:

1.0E-8 ridge parametresi ile logistic regression

Katsayılar...

Class		Class	
Variable	dipper	Variable	dipper
=====		=====	
pCluster_0_0	2.8135	pCluster_0_0	16.6688
pCluster_0_1	2.3645	pCluster_0_1	10.6382
pCluster_1_0	-9.1571	pCluster_1_0	0.0001
pCluster_1_1	-2.1639	pCluster_1_1	0.1149
Intercept	-0.8931		
Odds Ratios...			

Tablo V. 32 Deney – 5 Gerçek ve Tahmin Karşılaştırma Tablosu

Denek	Gerçek	Tahmin	Hata	Olasılık
1	dipper	dipper		0.753
2	nondipper	dipper	+	0.955
3	dipper	dipper		0.828
4	nondipper	nondipper		0.989
5	nondipper	nondipper		0.938
6	nondipper	nondipper		0.936
7	dipper	dipper		0.608
8	dipper	dipper		0.823
9	dipper	dipper		0.958
10	nondipper	nondipper		0.636
11	dipper	dipper		0.826
12	dipper	dipper		0.847
13	nondipper	dipper	+	0.958
14	dipper	dipper		0.958
15	nondipper	nondipper		0.93
16	nondipper	nondipper		0.988
17	nondipper	nondipper		0.847
18	dipper	dipper		0.957
19	nondipper	nondipper		0.972

Denekleri Doğru Sınıflandırma	17	%89.4737
Denekleri Yanlış Sınıflandırma	2	%10.5263
Kappa istatistik	0.7912	(15)
Ortalama Mutlak Hata	0.2168	(16)
Ortalama Karesel Hatanın Karekökü	0.3505	(17)
Bağıl mutlak hata	%42.8396	(18)
Bağıl Karesel Hatanın Karakökü	%67.5318	(19)

Tablo V. 33 Deney – 5 Sonuç Değerlendirmesi

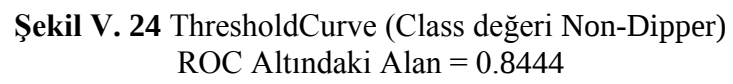
	TP Oranı	FP Oranı	ROC Alanı	Class
	0.8	0	0.844	Non-Dipper
	1	0.2	0.844	Dipper
Ağırlıklı Ort.	0.895	0.095	0.844	

Tablo V. 34 Deney – 5 Hata Matrisi

Hata Matrisi		
a	b	sınıflandırma
8	2	a = Non-Dipper
0	9	b = Dipper
Doğruluk % =		$\frac{(9+8)}{(9+0+2+8)} = 89.4737$

$$\begin{aligned}
 \text{Duyarlılık} &= ((\text{TP}) / (\text{TP}+\text{FN})) & (20) \\
 &= ((8 / (8+2)) \\
 &= 0.80 \\
 &= \%80
 \end{aligned}$$

$$\begin{aligned}
 \text{Özgüllük} &= (\text{TN} / (\text{TN}+\text{FP})) & (21) \\
 &= (9 / (9+0)) \\
 &= 1.00 \\
 &= \%100
 \end{aligned}$$



V.2.4.6 Deney-6

Deney Grubu Profili : İkinci Denek Grubu

Uygulanan Yöntem : Karar Ağaçları

Algoritma : J48

Model Tasarım Süresi: 0 seconds

Nitelik Sayısı : 2


Tablo V. 35 Deney – 6 Nitelik Sayısı

Demografik veriler	Laboratuar tetkikleri	Otonomik Testler	Cihaz ölçümleri				
			EKG	EKO	Holter		
Cinsiyet	A1C	V1	S V1	SWth	dt sis		
Yaş	AKS	V2	R V5	PWth	dt dias		
Boy	Kreatinin	Vm		LVEDD	nt sis		
Kilo	malb	DSD		LVESD	nt dias		
BELC	LDL	AKH		ME	24h sis		
BSA	ABI	OrH		MA	24h dias		
BMI		HDKBF		MDT	mask HT		
		PH		AoIVRT	%sisD		
		SH		LVM	%diasD		
		Ewing		LVMI			
				EF			
				LA			
				Ao			
						Genel Toplam	
7	2	9	0	12	6	36	2. denek grubu
0	0	2	0	0	0	2	İndirgenik Durum

*Turuncu ile belirtilen veriler 2.denek grubu için hiç ölçülenmemiştir.

Tablo V. 36 Deney – 6 Gerçek ve Tahmin Karşılaştırma Tablosu

Denek	Gerçek	Tahmin	Hata	Olasılık
1	nondipper	nondipper		1
2	dipper	dipper		0.833
3	nondipper	nondipper		1
4	nondipper	nondipper		1
5	dipper	dipper		0.833
6	dipper	dipper		0.833
7	dipper	dipper		0.833
8	dipper	dipper		0.833



Şekil V. 25 Deney- 6 Karar Ağacı Modeli

Denekleri Doğru Sınıflandırma	8	%100	
Denekleri Yanlış Sınıflandırma	0	% 0	
Kappa istatistik	1		(15)
Ortalama Mutlak Hata	0.1042		(16)
Ortalama Karesel Hatanın Karekökü	0.1318		(17)
Bağıl mutlak hata	%23.4375		(18)
Bağıl Karesel Hatanın Karakökü	%26.6838		(19)

Tablo V. 37 Deney – 6 Sonuç Değerlendirmesi


	TP Oranı	FP Oranı	ROC Alanı	Class
	1	0	1	Non-Dipper
	1	0	1	Dipper
Ağırlıklı Ort.	1	0	1	

Tablo V. 38 Deney – 6 Hata Matrisi

Hata Matrisi		
a	b	sınıflandırma
3	0	a = Non-Dipper
0	5	b = Dipper
Doğruluk % =		(5+3)/(5+0+0+3) = 100

$$\begin{aligned}
 \text{Sensitivity (Duyarlılık)} &= ((\text{TP}) / (\text{TP}+\text{FN})) & (20) \\
 &= ((3 / (3+0)) \\
 &= 1.00 \\
 &= \%100
 \end{aligned}$$

$$\begin{aligned}
 \text{Özgüllük} &= (\text{TN} / (\text{TN}+\text{FP})) & (21) \\
 &= (5 / (5+0)) \\
 &= 1.00 \\
 &= \%100
 \end{aligned}$$



Şekil V. 26 ThresholdCurve (Class değeri Non-Dipper) ROC Altındaki Alan = 1

V.2.4.7 Deney-7

Deney Grubu Profili:	İkinci Denek Grubu
Uygulanan Yöntem:	Yapay Sinir Ağları
Algoritma:	RBF Network
Model Tasarım Süresi:	0.01 seconds
Nitelik Sayısı:	2 (Tablo V.35)

Tablo V. 39 Deney-7 Gerçek ve Tahmin Karşılaştırma Tablosu

Denek	Gerçek	Tahmin	Hata	Olasılık
1	nondipper	nondipper		1
2	dipper	dipper		0.8
3	nondipper	nondipper		0.642
4	nondipper	nondipper		1
5	dipper	dipper		1
6	dipper	dipper		0.8
7	dipper	dipper		0.8
8	dipper	dipper		0.633

Temel fonksiyolar gibi, k-means clusters için uygulanan logistic regression:

1.0E-8 ridge parametresi ile logistic regression

Katsayılar...

Variable	Class nondipper	Variable	Class nondipper
=====		=====	
pCluster_0_0	3.2512	pCluster_0_0	25.8222
pCluster_0_1	12.2659	pCluster_0_1	212331.0786
pCluster_1_0	-7.139	pCluster_1_0	0.0008
pCluster_1_1	-3.7184	pCluster_1_1	0.0243
Intercept	1.2073		
Odds Ratios...			

Denekleri Doğru Sınıflandırma	8	%100	
Denekleri Yanlış Sınıflandırma	0	%0	
Kappa istatistik	1		(15)
Ortalama Mutlak Hata	0.1655		(16)
Ortalama Karesel Hatanın Karekökü	0.2187		(17)
Bağıl mutlak hata	%37.246		(18)
Bağıl Karesel Hatanın Karakökü	%44.284		(19)

Tablo V. 40 Deney – 7 Sonuç Değerlendirmesi

	TP Oranı	FP Oranı	ROC Alanı	Class
	1	0	1	Non-Dipper
	1	0	1	Dipper
Ağırlıklı Ort.	1	0	1	

Tablo V. 41 Deney – 7 Hata Matrisi

Hata Matrisi		
a	b	sınıflandırma
3	0	a = Non-Dipper
0	5	b = Dipper
Doğruluk % =		(5+3)/(5+0+0+3) = 100

$$\text{Duyarlılık} = (\text{TP} / (\text{TP} + \text{FN})) \quad (20)$$

$$= (3 / (3 + 0))$$

$$= 1.00$$

$$= \%100$$

$$\text{Özgüllük} = (\text{TN} / (\text{TN} + \text{FP})) \quad (21)$$

$$= (5 / (5 + 0))$$

$$= 1.00$$

$$= \%100$$




Şekil V. 27 ThresholdCurve (Class değeri Non-Dipper) ROC Altındaki Alan = 1

V.2.4.8 Deney-8

Deney Grubu Profili : İkinci Denek Grubu
Uygulanan Yöntem : Yapay Sinir Ağları
Algoritma : MLP
Model Tasarım Süresi : 0.04 seconds
Nitelik Sayısı : 2 (Tablo V.35)

Tablo V. 42 Deney-8 Gerçek ve Tahmin Karşılaştırma Tablosu

Denek	Gerçek	Tahmin	Hata	Olasılık
1	nondipper	nondipper		0.954
2	dipper	dipper		0.886
3	nondipper	nondipper		0.815
4	nondipper	nondipper		0.954
5	dipper	dipper		0.886
6	dipper	dipper		0.886
7	dipper	dipper		0.886
8	dipper	dipper		0.84



Şekil V. 28 Deney-8 MLP Modeli Şeması

Bu deneyde MLP modeli için;

gizli katman sayısı: 2

λ : 0.3

$\emptyset$: 0.2

epoch : 500

Tablo V. 43 Deney-8 MLP Modeli

		Sigmoid Node2	Sigmoid Node3
Nitelikler	Threshold	4.74	4.97
	OrH	3.03	3.21
	Ewing	-4.77	-5.11
Class dipper	Threshold	-3.14	-3.51
Sigmoid Node 0	4.32		
Class nondipper	Threshold	3.14	3.52
Sigmoid Node 1	-4.32		

Denekleri Doğru Sınıflandırma	8	%100
Denekleri Yanlış Sınıflandırma	0	%0
Kappa istatistik	1	(15)
Ortalama Mutlak Hata	0.1117	(16)
Ortalama Karesel Hatanın Karekökü	0.1205	(17)
Bağıl mutlak hata	%25.1226	(18)
Bağıl Karesel Hatanın Karakökü	%24.4131	(19)

Tablo V. 44 Deney – 8 Sonuç Değerlendirmesi


	TP Oranı	FP Oranı	ROC Alanı	Class
	1	0	1	Non-Dipper
	1	0	1	Dipper
Ağırlıklı Ort.	1	0	1	

Tablo V. 45 Deney – 8 Hata Matrisi

Hata Matrisi		
a	b	sınıflandırma
3	0	a = Non-Dipper
0	5	b = Dipper
Doğruluk % = $(5+3)/(5+0+0+3) = 100$		

$$\begin{aligned}\text{Duyarlılık} &= (TP / (TP+FN)) \\ &= (3 / (3+0)) \\ &= 1.00 \\ &= \%100\end{aligned}\tag{20}$$

$$\begin{aligned}\text{Özgüllük} &= (TN / (TN+FP)) \\ &= (5 / (5+0)) \\ &= 1.00 \\ &= \%100\end{aligned}\tag{21}$$




Şekil V. 29 ThresholdCurve (Class değeri Non-Dipper) ROC Altındaki Alan = 1

V.2.4.9 Deney-9

Deney Grubu Profili	: Birinci Denek Grubu
Uygulanan Yöntem	: Karar Ağaçları, Bayes, Yapay Sinir Ağları
Algoritma	: J48, NaiveBayes, MLP, RBF
İşlem	: 10-kat çapraz doğrulama (10-fold cross validation)
	Model Tasarım Başarısı Karşılaştırma


K- kat çapraz doğrulama tekniğinde, veri kümesi rastgele şekilde k sayıdaki eşit büyüklükte kümeler halinde bölünmektedir. Herbir sınıflandırıcının eğitimi ve testi k kez gerçekleştirilmektedir ve her seferinde bir k kümesi test için kullanılırken, ayrılan diğer k-1 kümeleri de eğitim için kullanılmaktadır. 4- kat çapraz doğrulama işleyişi örnek olarak Şekil V.30'da aşamalarıyla gösterilmiştir.



a) Veri Setinin 4'e Eşit Bölünmesi

b) 1. Çapraz Doğrulama

c) 2. Çapraz Doğrulama



d) 3. Çapraz Doğrulama

e) 4. Çapraz Doğrulama

f) 4-Kat Çapraz Doğrulama Sonucu

Şekil V. 30 4- Kat Çapraz Doğrulama İşleyişi [164]

Tablo V. 46 Birinci Denek Grubu için 10- kat çapraz doğrulama (10-fold cross validation) Model Tasarım Başarısı Karşılaştırma

Nitelikler	Algoritmalar											
	J48			NaiveBayes			MLP			RBF		
	Doğruluk	Duyarlılık	Özgüllük	Doğruluk	Duyarlılık	Özgüllük	Doğruluk	Duyarlılık	Özgüllük	Doğruluk	Duyarlılık	Özgüllük
Table V.14 (9 adet)	%64.29	%54	%72	%60.71	%67	%56	%62.5	%54	%69	%60.71	%46	%72
Table V.26 (13 adet)	%58.92	%58	%59	%71.42	%71	%72	%53.57	%50	%56	%62.5	%58	%66

V.2.4.10 Deney-10

Deney Grubu Profili : İkinci Denek Grubu

Uygulanan Yöntem : Karar Ağaçları, Bayes Yapay Sinir Ağları

Algoritma : J48, Naive Bayes, MLP, RBF

İşlem : 10-kat çapraz doğrulama (10-fold cross validation)

Model Tasarım Başarısı Karşılaştırma

Tablo V. 47 İkinci Denek Grubu için 10 – kat çapraz doğrulama (10-fold cross validation) Model Tasarım Başarısı Karşılaştırma

Nitelikler	Algoritmalar											
	J48			Naive Bayes			MLP			RBF		
	Doğruluk	Duyarlılık	Özgüllük	Doğruluk	Duyarlılık	Özgüllük	Doğruluk	Duyarlılık	Özgüllük	Doğruluk	Duyarlılık	Özgüllük
Table V.35 (2 adet)	%75	%71	%76	%79.16	%71	%82	%87.5	%71	%94	%83.33	%71	%88

BÖLÜM VI

SONUÇ VE ÖNERİLER

- 100 civarında deney yapılmış; ancak içlerinden 10 adet deneye tezde yer verilmiştir.
- Bu çalışma konusunun yeni ve özgün olması çalışmayı değerli kılmakta, bundan sonra yapılacak çalışmalara kaynak teşkil edeceği öngörülmektedir.

Bu çalışma ile;

- Akıllı sağlık programı tasarlanmıştır. Kullanıcı dostu grafik arayüz sayesinde tıp doktorlarının hasta verilerini daha kolay depolayabilme ve erişebilmelerine olanak tanınmıştır.
- Marmara Üniversitesi Hastanesi hasta profilini belirlemeye yönelik kullanılabilir, elektronik veritabanı oluşturulmaya bu çalışma kapsamında başlanmış ve toplam 94 hasta verisi şimdilik yüklenmiştir.
- Birinci denek grubu diyabetik ve normotansif hastalardan oluşturulmuştur.
- İkinci denek grubu nondiyabetik ve hipertansif hastalardan oluşturulmuştur.
- Veri madenciliği sınıflandırma ve öngörü yaklaşımı için karar ağaçları, bayes, yapay sinir ağları yöntemlerine ait algoritmalar ile deneyler yapılmıştır. Çalışmanın ilk aşamasında algoritmalar sınanmış ve %62 ile J48 karar ağacı algoritmasının en iyi sonuç vereceği öngörülmüştür.
- Birinci denek grubu için oluşturulan model ikinci denek grubu üzerinde başarılı olmadığından her iki grup için ayrı model oluşturulma gereksinimi ortaya çıkmıştır.
- Birinci denek grubu için; demografik nitelikler (7), laboratuvar tetkiki (6), otonomik testler (10), EKG ve EKO ölçümleri ile elde edilen nitelikler (15) ve Holter cihazı ölçümlerinden (9) elde edilen toplam 47 adet niteliğe ait veriler ile tıp doktorları nondipper/dipper sınıflamasını yapmaktadırlar. Holter cihazı verileri olmadan RBF ağı ve MLP ile oluşturulan modellerde nitelik sayısı toplam 13'e düşürülmüştür. Doğruluk oranı %89.47'dir.

- İkinci denek grubu için 36 nitelik sayısı, Holter cihazı verileri olmadan toplam 2'ye düşürülmüş ve uygulanan tüm algoritmalar ile %100 Doğruluk oranı elde edilmiştir.
- Özellikle non-diyabetik hipertansif hasta profiline sahip ikinci denek grubu için elde sonuçlarda ortostotik hipotansiyon ile Ewing skor niteliklerinin önem kazandığı ortaya çıkmıştır. Bu da diyabetli kişilerde zaten bozuk olan bu değerlerin, diyabet hastası olmayan kişilerde anormallik göstermesinin non-dipper özelliğe işaret ettiği anlamına gelmektedir.
- 10- Kat çapraz doğrulama deney sonuçları, denek sayısı arttığında %100 olan başarıların biraz düşebileceğini ve halk içinde normal dağılım olan %10'a yakın non-dipper oranını verebileceğini ön görmemizi sağlamaktadır.

VI.1 ÇALIŞMANIN DEĞERLENDİRİLMESİ

Bu tez çalışması; hasta yaşam kalitesine, maliyetlere ve disiplinlerarası alana olan katkıları bakımından üç farklı kategoride değerlendirilmeye çalışılmıştır. Sonuçları itibariyle bu tez çalışması, tıbbi olarak nondipper/dipper sınıflaması için holter cihazı verileri gerekmebileceğini, hasta yaşam kalitesi ve maliyetler açısından ortaya çıkan olumsuzluklara çözüm sunulabileceğini göstermiştir.

VI.1.1 Hasta Açısından

- Hastanın Holter cihazını taktırmak amacıyla, randevu almak için çaba sarf etmesi,
- Cihazı taktırmak ve söktürmek için en az iki kez hastaneye gidip gelmesi (nadir durumlarda cihaz ölçüm almadığında ya da yanlışlık olduğu düşünüldüğünde sayı artabilir)
- Non-invazif yöntem olmasına rağmen üzerinde tüm gün bir cihaz taşımak durumunda kalması,
- Bu cihaz ile banyo alma, giyinip-soyunma vb. aktiviteleri yerine getirememesi ya da zorlanması,
- Cihazın özellikle gece yarım saatte bir ölçüm alması sırasında verdiği rahatsızlıktan dolayı hastanın uykusunun bölünmesi ya da kalitesinin düşmesi,
- Kendini mental ve ruhsal olarak sıkıntıda hissetmesi,
- Bunlarla birlikte hastanın ruhsal ve mental olarak hissettiği rahatsızlıktan ötürü sağlıklı veri kaydı yapılamaması olasılığının önüne geçilmesi.

Sayılan tüm bu olumsuzlukların ortadan kaldırılmasıyla hastanın yaşam kalitesi yükseltilmiş olacaktır.

VI.1.2 Maliyet Açısından

- Hastanın randevu almak için telefon etmesi ya da hastaneye gelip gitmelerinden kaynaklanan zaman ve finansal maliyetler,
- Hastane tarafından bu cihazın takibi, takılıp-sökülmesi ve verilerin bilgisayara aktarılması işlemleri için personel istihdamı, (işgücü, zaman ve finansal maliyetler)

- Görevli kişinin bu işi öğrenmesini sağlamak amacıyla verilen eğitim için ayrılan zaman ve eğitim maliyeti,
- Holter cihazı ve yazılımı için gereken maliyet,
- Aynı zaman diliminde çok sayıdaki hastaya hizmet verebilmek için cihaz sayısının arttırılması ile ortaya çıkan maliyet,
- Hastanın kendisi tarafından ya da özel/devlet sağlık güvencesi ile karşılanmak üzere, bu işlemin ortaya çıkardığı maliyet.

Bu maliyetlerin mümkün olduğunca enaza indirilmesi, hatta ortadan kaldırılabilmesinden birinci derecede sağlık kurum ve kuruluşları fayda sağlayacaklardır. Sağlık harcamalarının büyüklüğü özellikle gelişmekte olan ülkemiz ekonomisi açısından büyük yük teşkil etmektedir. Dolaylı olarak bu maliyetlerdeki azalış ülke ekonomisine de katkı sağlayacaktır.

VI.1.3 Tıp ve Bilişim Alanında Disiplinler Arası Yapılan Çalışmalar Açısından

- Tıp ve bilişim teknolojileri alanında üniversitemiz bünyesinde yapılmış ve literatüre kazandırılmış bir çalışmadır.
- Özellikle disiplinlerarası çalışmada; zaman, mekan, çalışmaya istekli kişilerin buluşturulması ve ortak bir dilin oluşturulması gibi ortaya çıkan zorluklar aşılmıştır.
- MÜ. Tıp Fakültesi İç Hastalıkları ABD. Ateroskleroz Ünitesi bünyesinde kullanılmak üzere elektronik veritabanı oluşturulması için Akıllı Sağlık Programı adında yazılım geliştirilmiştir.
- Hastalara ait elektronik veritabanı oluşturulmaya başlanmıştır.
- Tıbbi açıdan özellikle non-dipper/dipper özelliğinin teşhisinde Holter cihazı ölçümleri ile elde edilen verilerin önemi ortaya konmuştur.
- Veri madenciliği çalışmaları sonucu ortaya konan modeller ve başarı yüzdeleri ile Holter cihazı verileri olmadan da bu teşhisin konulabileceği ile ilgili çalışma sonuçları ortaya konmuş ve bu konuda yapılacak yeni çalışmalara kaynak teşkil etmesi öngörülmüştür.
- Birinci gruba uygulanan modelin ikinci grup üzerinde kullanılamayacağı sonucuna varılmış ve her iki denek grubundaki hasta profilleri için ayrı modeller ortaya konmuştur.

- Özellikle non-diyabetik hipertansif hasta profiline sahip ikinci denek grubu için elde sonuçlarda cinsiyet ve özellikle ortostatik hipotansiyon ile Ewing skor niteliklerinin önem kazandığı ortaya çıkmıştır. Bu da diyabetli kişilerde zaten bozuk olan bu değerlerin, diyabet hastası olmayan kişilerde anormallik göstermesinin non-dipper özelliğe işaret ettiği anlamına gelmektedir.

VI.2 TIP UZMANININ DEĞERLENDİRMESİ [165]

Marmara Üniversitesi Tıp Fakültesi İç Hastalıkları ABD. Öğretim üyesi, Hipertansiyon ve Ateroskleroz Eğitim, Uygulama ve Araştırma Merkezi Müdür Yardımcısı Sayın Prof.Dr. Ali Serdar Fak Bey ile bu tez çalışması sırasında 2009 - 2011 yılları arasında görüşmeler yapılmış ve değerli katkıları ile bu çalışma gerçekleştirilmiştir.

“Hangi parametre / neden “non-dipper” durumu ile ilişkili olabilir?” sorusu ve bu yöntemin klinik uygulamalara olası katkıları hakkındaki yorumları aşağıda sunulmuştur.

- **CİNSİYET:** Hipertansif hastalarda dipper/ non-dipper özelliğın cinsiyet ile ilişkisi bulunmamaktadır. Ancak premenopozal kadınlarda “non-dipper” özelliğın daha az olduđu; diğeryandan postmenopozal dönemde olup hormon tedavisi almakta olan kadınlarda “non-dipper” paternin düzelebileceğı bilinmektedir. Bu nedenle kadın ve erkekler arasındaki olası farklılık ancak bu açıdan tartışılabilir.

- **ORTOSTATİK HİPOTANSİYON:** Ortostatik hipotansiyon özellikle diyabetik hastalarda otonomik disfonksiyon bulgusudur. Hipertansif hastalarda varlığı da, baroreseptör işlev bozukluğuna işaret edebilir. Bu nedenle hipertansiyonun daha şiddetli ve hipertansif hedef organ hasarının daha fazla olduđu hastalarda (özellikle ileri yaş hastalarda) ortostatik hipotansiyon beklenebilir. Benzer olarak “non-dipper” hipertansif hastalarda hipertansif hedef organ hasarı daha fazla olduğundan ortostatik hipotansiyon varlığı “non-dipper” özellikle yine bulgulardan birisi veya belki de belirteç olabilir.

- **LVH (sol ventrikül hipertrofisi) veya LVM artışı:** Sol ventrikül hipertrofisi (LVM artışı) hipertansif hastalarda en sık karşılaşılan hedef organ hasarlarından birisidir. LVH varlığı EKG ve ekokardiyografi incelemeleriyle kolayca anlaşılabilir. LVH varlığı uzun dönemde artmış kardiyovasküler ve toplam morbidite ve mortalite için önemli ve bağımsız bir bulgudur. En sık hedef organ hasarlarından olan LVH’

nin (veya LVM deki artışın) bu nedenle “non-dipper” özellikle birlikte olması beklenen bir durumdur. Çünkü yine “non-dipper” hastalarda hedef organ hasarının daha fazla olduğu bilindiğinden, “non-dipper” hipertansif hastalarda LVH gelişmesi daha olasıdır. Klinik uygulamada da hipertansif hastaların tedavi planları yapılırken LVH varlığı aranır ve varlığına veya yokluğuna göre farklı tedaviler düzenlenir. Bu nedenle LVH tanısının, non-diper” özelliğın saptanacağı modellerde bulunması; EKG ve EKO yaygın ve kolay tetkikler olduğu için hem uygulama açısından pratiklik getirebilir; hem de hastaların tedavilerinin daha uygun şekilde planlanmasına katkıda bulunabilir.

- **EWING SKORU:** Ewing skoru, otonomik disfonksiyon varlığını belirlemek için kullanılan bir puanlama sistemidir. Yapılan otonomik testlerdeki anormal bulgu varlığına göre Ewing skoru yüksektir ve yüksek skorlar otonomik bozukluk varlığına işaret eder. Otonomik disfonksiyonun hipertansif hastalarda hipertansiyonun süresi ve şiddetiyle paralel olarak daha sık bulunduğu bildirilmiştir. Bu nedenle “non-dipper” özelliğın otonomik disfonksiyonu olan hastalarda daha sık olması veya başka bir deyişle otonomik disfonksiyonu olan hastalarda “non-dipper” özelliğın bulunması beklenir. Otonomik disfonksiyon testleri zaman alıcı olsa da, kısa sürede tamamlanabilir ve “non-dipper” özelliğın tanınmasında yardımcı olabilir.

- **SWth (Sol ventrikül septal duvar kalınlığı):** Hipertansif hastalarda septal duvar kalınlığı sol ventrikül hipertrofisinin ölçütlerinden birisidir. Hipertansif hastanın ekokardiyografik incelemesinde sol ventrikül septal duvarın ve arka duvarın kalınlığının artmış olduğu hallerde sol ventrikül hipertrofisi tanısı konabilmektedir. Bu durumda “non-dipper” hastalarda sol ventrikül hipertrofisinin daha sık olduğu bilgisinden hareketle septal veya arka duvarın kalınlaştığı haller, daha fazla hedef organ hasarına ve “non-dipper” özelliğın işaret edebilir.

- **ME (Mitral doluş E dalgası hızı; m/sn):** Hipertansif hastalarda sol ventrikül hipertrofisi ile birlikte sıklıkla diyastolik disfonksiyon gözlenir. Diyastolik disfonksiyon çoğu zaman sol ventrikül hipertrofisinden önce geliştiğı bilinmektedir. Bugün için diyastolik fonksiyon bozukluğının en doğru saptanması konusunda belirsizlikler mevcut olsa da; günlük uygulamada sıklıkla mitral doluşun özelliklerine bakarak karar verilebilmektedir. Mitral doluş E dalgasının çok hızlı olması veya tersine A dalgasından daha düşük hızda olması (E/A ve A dalgalarının hızına ve birbiriyle olan ilişkisine bakılarak anlaşılabilir. Diyastolik disfonksiyon da

hipertansif hedef organ hasarı zemininde geliştiğinden Mitral doluş bozukluklarının “non-dipper” özellikle ilişkili olması olasıdır.

- **MDT (mitral kapak diyastolik deselerasyon zamanı; ms):** MDT deki bozukluk da sol ventrikülde anormal hemodinamik zemini işaret eder ve diyastolik disfonksiyonla ilişkilidir. Diyastolik disfonksiyon da hipertansif hedef organ hasarı zemininde geliştiğinden Mitral doluş bozukluklarının “non-dipper” özellikle ilişkili olması olasıdır.

- **AoIVRT (aortik izovolumik relaksasyon zamanı; ms):** AoIVRT sol ventrikül diyastolik bozukluklarında ve bazı kapak hastalıklarında uzamaktadır. Özellikle diyastolik fonksiyon bozukluğunda AoIVRT'nın uzadığı bilindiğinden, benzer olarak hipertansif bir hastada “non-dipper” özelliğe işaret edebilir.

- **Bu Yöntemin Klinik Uygulamada Olası Yararları:** Bugün için klinik uygulama hipertansif (yüksek tansiyonu olan) veya normotansif (kan basıncı normal olan) bir hastanın dipper veya non-dipper olduğu ancak 24 saatlik kan basıncı kaydıyla anlaşılabilir. Kan basıncı “non-dipper” özellikte olan bir kişide özellikle kalp-damar hastalıkları riskinin ve uzun vadede bu hastalıklardan ölüm riskinin “dipper” olanlara göre daha yüksek olduğu bilinmektedir. Özellikle şeker hastalığı (diyabetes mellitus) olan veya önceden kalp krizi geçirmiş olan veya kalp yetersizliği olan kişilerde “non-dipper” kan basıncı özelliği önemli bir risktir. Bu nedenle kan basıncının tedavisinde hastanın “dipper” veya “non-dipper” olduğunun bilinmesi önem taşımaktadır; önümüzdeki yıllarda kan basıncı tedavilerinin bu duruma şekilleneceği beklenmektedir.

Kan basıncının bu özelliğinin saptanmasında 24 saat Holter kan basıncı kaydı, bugün için altın standart olsa da bu yöntemin bazı zorlukları bulunmaktadır ve 24 saatlik bir kan basıncı ölçümü ve kaydı hastalar için günlük yaşam kalitesini azaltabilecek bir uygulamadır.

Öncelikle cihazın hastanede / muayenehanede takılması ve 24 saat sonra hastanın cihazı teslim etmek üzere tekrar aynı mekana gelmesini gerektirmektedir. Bu başlı başına bir maliyettir.

Her ne kadar cihazın varlığı ve kan basıncı ölçümleri günlük aktivitelerini tümünden engellememekteyse de hastalar için ek bir zahmet oluşturmaktadır. En önemlisi cihazın gece hastanın uyku sırasında aktif olup kan basıncını ölçmesi bazı hastalarda uyku bölünmelerine, strese sebep olabilmektedir. Bu durum kan basıncında gerçek olmayan bir artışa neden olabilmektedir.

Kan basıncının 24 saatlik paterninin akıllı sistem yoluyla tahmin edilmesi bu zorlukları ortadan kaldıracıdır. Hipertansif bir hastaya zaten rutin olarak yapılmakta olan bazı tetkiklerle ve ayrıca bunlara eklenebilecek birkaç tetkikler “dipper / non-dipper” durumu tahmin edilebileceği çalışmamızda gösterilmiştir.

EKG, ekokardiyografi, rutin idrar tetkiki, mikroalbuminüri testleri hipertansif hastalarda zaten klinik uygulamada istenen testlerdir. Çalışmamızda otonomik testlerin verileri de kullanılmıştır; otonomik testler bugün için rutin klinik uygulamada yapılmamaktadır. Ancak hastanın hastaneye / muayenehaneye geldiği bir sırada tek bir oturumda tamamlanabilen ve sonucu hemen alınan basit testlerdir. Hastanın demografik bilgileriyle birlikte rutin testlerin ve tek bir oturumda tamamlanabilen bu otonomik testlerin sonuçları akıllı sistemde değerlendirilerek “dipper / non-dipper” durumun tahmin edilmesinde kullanılabilir. Çalışmamızın sonuçları bu verilerle ve akıllı sistem kullanılarak “dipper / non-dipper” durumun önemli bir doğruluk payıyla ve duyarlılıkla tahmin edilebileceğini göstermektedir.

- Çalışmanın kısıtlılıkları: Çalışmamızın bazı kısıtlılıkları bulunmaktadır. Elbette çalışma sonuçlarının daha çok sayıda hastayı içeren başka çalışmalarla desteklenmesinde yarar vardır. Diğer yandan hipertansif hastaların (ikinci denek grubu) bir kısmı kan basıncı kontrolü / tedavisi için çeşitli ilaçlar kullanmaktaydı. Bu ilaçların özellikle otonomik testler üzerine olası etkileri mevcut olabilir. Benzer olarak ilaç etkisinden arındırılmış deneklerde çalışmanın tekrarlanması yeni bilgiler ve yeni sonuçlar ortaya koyabilir.

VI.3 ÖNERİLER

- Bu çalışmanın sürdürülebilirliği yüksektir. Denek sayısının her iki grup içinde çoğaltılması ve böylece deneylerin devamı sağlanarak modellerin güvenilirliğinin artırılması,
- Bu çalışmanın sürdürülebilirliğinin sağlanması ve kayıtların Weka tarafından anında işlenebilir hale getirilerek web tabanlı veri madenciliği (web data mining) çalışması yapılması,

- Bulanık mantık yaklaşımı ile verilerin nominal tanımlanması ve bu şekilde model oluşturularak özellikle birinci denek grubu profilindeki denekler üzerinde çalışılması,
- İlaç etkisinden arındırılmış deneklerde çalışmanın tekrarlanması yeni bilgiler ve yeni sonuçlar ortaya koyabileceği için böyle bir denek grubu ile modellerin test edilmesi,
- Veri madenciliğinde tekrarlı olarak kullanılabilecek bir model ortaya konduğu gibi artan ya da yenilenen verilerle tekrarlanması gereken bir çalışmada ortaya çıkabilmektedir. Bu tez çalışması şu an için tekrarlanması gereken bir çalışma olup, kesin model oluşturulduğunda programın exe haline getirilmesi,
- Her bir niteliğin azalıp çoğalmasının, sonuca olan etkilerinin denek bazında incelenmesi için çalışmaların bu konuda sürdürülmesi önerilmektedir.

KAYNAKÇA

- [1] Fak AS.; Okucu M.; Tezcan H.; Bodur G.; Oktay A.: “The Effects of Amlodipine on Left Ventricular Mass and Diastolic Function in Concentric and Eccentric Left Ventricular Hypertrophy.”, J Cardiovasc Pharmacol Ther. **1996**:95-100.
- [2] Giles TD.: “Circadian rhythm of blood pressure and the relation to cardiovascular events.”, J Hypertens Suppl. **2006** Apr, 24(2):S11-6
- [3] Cabezas-Cerrato J.; Hermida R.C.; Cabezas-Agricola J.M.; Ayala D.E.: “Cardiac Autonomic Neuropathy, Estimated Cardiovascular Risk and Circadian Blood Pressure Pattern in Diabetes Mellitus.”, Chronobiol Int. **2009** Jul, 26(5):942-57
- [4] The Seventh Report of the Joint National Committee on Prevention, Detection, Evaluation, and Treatment of High Blood Pressure, August, **2004**.
- [5] Filho V. D.; Chaves Hilton de C. Jr.;Valença M. J.S.; Campello de Souza F.M.: “A Constructive Neural Network for Detecting Left Venticular Hypertrophy”, Proceedings of the Fifth International Conference on Hybrid Intelligent Systems, IEEE-**2005**
- [6] Giardiana M.; Azuaje F.; McCullagh P.; Harper R.: “A Supervised Learning Approach to Predicting Coronary Heart Disease Complications in Type 2 Diabetes Mellitus Patients”, Sixth Symposium on Bioinformatics and Bioengineering, IEEE-**2006**
- [7] Zheng, J.; Jiang Y.; Yan H.: “Committee Machines with Ensembles of Multilayer Perceptron for the Support of Diagnosis of Heart Diseases”, International Conference on Communications, Circuits and Systems Proceedings, Guilin, 25-28 June **2006**: 2046 – 2050.
- [8] Polat K., Güneş S.: “A hybrid approach to medical decision support systems: Combining feature selection, fuzzy weighted pre-processing and AIRS”, Computer Methods and Programs in Biomedicine, **2007**, 88(2): 164-174.
- [9] Polat K.; Güneş S.: “An Expert System Approach Based on Principal Component Analysis and Adaptive Neuro-Fuzzy Inference System to Diagnosis of Diabetes Disease”, **2007**
- [10] Polat K.; Şahan S.; Güneş S.: “Automatic detection of heart disease using an artificial immune recognition system (AIRS) with fuzzy resource allocation mechanism and k-nn (nearest neighbour) based weighting preprocessing”, Expert Systems with Applications, **2007**, 32(2): 625-631.
- [11] Tsipouras M. G.; Exarchos T. P.; Fotiadis D. I.; Kotsia A. P.;Vakalis K. V.; Naka K. K.; Michalis L. K.: “Automated Diagnosis of Coronary Artery Disease Based on Data

- Mining and Fuzzy Modeling”, IEEE Transactions on Information Technology in Biomedicine, July **2008**,12(4): 447-458
- [12] Latifoğlu F.; Polat K.; Kara S.; Güneş S.: “Medical diagnosis of atherosclerosis from Carotid Artery Doppler Signals using principal component analysis (PCA), k-NN based weighting pre-processing and Artificial Immune Recognition System (AIRS)”, Journal of Biomedical Informatics, **2008**, 41(1): 15-23.
- [13] Hatemi H.: “Diabetes Mellitus Tarihçesi.” Aktuel Tıp Dergisi. Kasım **1996**, 7: 497-499.
- [14] Bağrıaçık N.: “Dibetes Mellitus Tanımı, Tarihçesi, Sınıflaması ve Sıklığı” İ.Ü. Cerrahpaşa Tıp Fakültesi Sürekli Tıp Eğitim Sempozyumu, 18-19 Aralık **1997**: 9-18.
- [15] Dobson M.: “Nature of the urine in diabetes”, Medical Observations and Inquiries **1776**, 5: 298–310
- [16] Dr. Ertürk T.: “Diyabetik Hasta ve Bakıcısının Öğrenim Düzeylerinin, Diyabetik Ayak Yarası Üzerine Etkisi”, Genel Cerrahi Uzmanlık Tezi, İstanbul-**2005**
- [17] Savona Ventura C.: “The History of Diabetes Mellitus a Maltese Perspective”, Malta-**2002**
- [18] http://www.medicinenet.com/type_2_diabetes_pictures_slideshow/article.htm
Erişim Tarihi: 16.05.**2011**
- [19] http://www.medicinenet.com/diabetes_mellitus/article.htm
Erişim Tarihi: 16.05.**2011** MedicineNet Inc.1996-2011
- [20] Report of a WHO Consultation,” Definition, Diagnosis and Classification of Diabetes Mellitus and its Complications”, WHO/NCD/NCS/99.2 Original: English Distr.: General,**1999**
- [21] Durna Z.: Diyabetin Sınıflandırılması ve Tanı Kriterleri , Ed. S. Erdoğan, Diyabet Hemşireliği,Yüce Reklam, Yayın, Dağıtım AŞ, İstanbul, **2002**:11-19.
- [22] Altuntaş Y.: Diabetes mellitus’un tanımı, tanısı ve sınıflaması. Her yönüyle diabetes mellitus, Nobel tıp kitabevi 2inci baskı, İstanbul, **2001**:51-58
- [23] <http://www.turkdiab.org/> Erişim Tarihi: 15.05.**2011**
- [24] Dr. Türker H.: “Hipertansif ve Normotansif Tip 2 Diyabet Hastalarında İnsülin Direncinin Karşılaştırılması”, Uzmanlık Tezi, İstanbul- **2006**
- [25] Gavin III J. R; Alberti K. G. M. M.; Davidson M. B.; DeFronzo R. A.: “Report of the Expert Committee on the Diagnosis and Classification of Diabetes Mellitus”, Diabetes Care, Research Library, Jul **1997**, 20 (7):1183-1197
- [26] Arslan M.: “Diabetes Mellitusta Tanı ve Sınıflandırma”, İç Hastalıkları, 2. Baskı, Ankara: Güneş Kitabevi **2003**: 2279–2291.
- [27] Dr. Morgül G.: “Tip 2 Diyabetes Mellitus Hastalarında Serum Lipoprotein Düzeyleri”, Uzmanlık Tezi, Adana - **2008**

- [28] Dr. Çeliker T.: “60 Yaş ve üstü Geriatrik Hastalarda Tip II Diabetes Mellitus ve Depresyon İlişkisi”, Uzmanlık Tezi, İstanbul-**2007**
- [29] Satman İ.: “Diabetes Mellitus’un Epidemiyolojisi”,Yenigün M., Altuntaş Y. (eds), Her Yönüyle Diabetes Mellitus, 2. Baskı, Nobel Tıp Yayınevi İstanbul **2001**:69-84, ISBN: 9754200521
- [30] World Health Organization, Department of No Communicable Disease Surveillance: Definition, Diagnosis and Classification of Diabetes Mellitus and Its Complications, Report of a WHO Consultation, WHO Publ., Geneva, **1999**
- [31] The Expert Committee on the Diagnosis and Classification of Diabetes Mellitus: Report on the Expert Committee on the Diagnosis and Classification of Diabetes Mellitus. Diabetes Care, 26(1), **2003**:5-19
- [32] American Diabetes Association, “Diagnosis and Classification of Diabetes Mellitus”, Diabetes Care, 33(1), January **2010**:62-69
- [33] Dr. Bozkurt B. O.: “Haseki Eğitim Ve Araştırma Hastanesi İç Hastalıkları Nefroloji Polikliniğinde Takip Edilen Aşık Nefropatili Tip 2 Diyabetik Hastalarda Renal Prognozun Göstergeleri”, Uzmanlık Tezi, İstanbul **2007**
- [34] American Diabetes Association, “Diagnosis and Classification of Diabetes Mellitus”, Diabetes Care, 33(1), January **2010**: 62-69
- [35] http://www.aeczane.com/index.php?option=com_content&view=article&id=635:diyabetin-kronik-komplikasyonu&catid=126:diyabet-rehberi&Itemid=132
Erişim Tarihi: 16.05.2011
- [36] National Diabetes data group, Classification and diagnosis of Diabetes mellitus and categories of glucose tolerance, Diabetes. **1999**, 28: 1039-57
- [37] http://www.medicinenet.com/heart_disease_pictures_slideshow/article.htm
Erişim Tarihi: 16.05.2011
- [38] Wild S.; Roglic G.; Green A.; Sicree R.; King H.: “Global Prevalence of Diabetes: Estimates for the year 2000 and projection for 2030”, Diabetes Care **2004**, 27: 1047-1053.
- [39] Satman İ.: Epidemiology Study. Population-based study of diabetes and related risk characteristics of Turkey, Results of the Turkish Diabetes Care **2002**, 25: 1551–1556.
- [40] King H.; Aubert R.E.; Herman W.H.: “Global burden of diabetes, 1995–2025.” Diabetes Care **1998**, 21: 1414–1431.
- [41] King H.; Rewers M.: “Global estimates for prevalence of diabetes mellitus and impaired glucose tolerance in adults: the WHO AdHoc Diabetes Reporting Group”, Diabetes Care **1993**, 16: 157–177.

- [42] Amos A.F.; McVarty D.J.; Zimmet P.: “The rising global burden of diabetes and its complications: Estimates and projections to the year 2010”, *Diabetic Med* **1997**, 14:7-55
- [43] Zimmet P.; Dowse G.; Finch C.; King H.: “The epidemiology and natural history of NIDDM– lessons from South Pacific.”, *Diabetes Metabo. Rev.* **1990**, 6: 91-124.
- [44] Dr. Topsever P.: “Sorularla Diabet-1”, *Aile Hekimliği Aktüel Bilimsel Tıp Dergisi* **2006**, 1(2): 80-84.
- [45] Satman İ.; Şengül A.M.; Uygur S.; Salman S.; Baştar İ.; Sargın M.; Tütüncü Y.; Karşıdağ K.; Dinççağ N.; The TURDEP group, *Diabetologia*, **2000**, 11:1.
- [46] Satman İ.; Yılmaz T.; The Turdep Group: “Population-Based Study Of Diabetes and Risk Characteristics in Turkey Results of The Turkish Diabetes Epidemiology Study (Turdep)”, *Diabetes Care*, September **2002**, 25(9): 1551- 1556
- [47] Onat A.; Hergenç G.; Uyarel H.; Günay C.; Özhan H.: “Prevalence, Incidence, Predictors and Outcome of Type 2 Diabetes in Turkey”, *Anadolu Kardiyoloji Dergisi*, Aralık **2006**, 6(2): 314 -321.
- [48] Dr. Ceyhan C.: “Hipertansiyonun Tanımı ve Sınıflandırılması”, *Hipertansiyon Eğitim Kursu, X. Ege Hipertansiyon Haftası*, 29-30 Mayıs **2008**
- [49] <http://www.baskent.edu.tr/~bmeweb/20493780.htm> Gök M, Erişim Tarihi:09.08.2011
- [50] Gager Leslie T.: *Hypertension*, Baltimore, The Williams & Wilkins Company, **1930**
- [51] Çeviren Çataloluk G.: *Hipertansiyon Tarihi*, Kuantum P.A.P, Nadir Kitap, **2003**, İstanbul
- [52] Dr. Akdağ İ.: “Hipertansiyon Hasta Bilgilendirme El Kitabı”, <http://www20.uludag.edu.tr/~akdagi/hastalarima.htm> Erişim Tarihi: 07.02.2011
- [53] Prof. Dr. Akpolat T.: *İçimizdeki Düşman Hipertansiyon*, Doğan Kitapçılık **2001**, ISBN:9756719613
- [54] Guidelines Committee: 2003 European Society of Hypertension-European Society of Cardiology guidelines for the management of arterial hypertension, *J Hypertens.* **2003**, 21: 1011-53.
- [55] Dr. Sağlam K.: “Hipertansiyon Fizyopatolojisi”, *Askeri Tıp Fakültesi 3.Sınıf Ders Notu*, <http://www.gata.edu.tr/dahilibilimler/ichastaliklari/files/dersler/73.pdf> Erişim Tarihi:5.5.2011
- [56] Dr.Ünalacak M.: “Hipertansiyon: Kronik Komplikasyonları”, *I. Ulusal Atah Kongresi, Panel 4, İstanbul - 26-28 Mart* **2010**
www.sunummerkezi.org/?s=37352B395A5C362227 Erişim Tarihi:29.04.2011
- [57] www.kalpveyasam.com Erişim Tarihi: 6.6.2011

- [58] Kearney P.M.; Whelton M.; Reynolds K.; Muntner P.; Whelton P.K., He J.: “Global burden of hypertension: analysis of worldwide data”, *The Lancet*, **2005**, 365(9455): 217 - 223, doi:10.1016/S0140-6736(05)17741-1
- [59] Prof. Dr. Karatan O.; Prof. Dr. Turgan Ç.; Prof. Dr. Sindel Ş.; Prof. Dr. Erbay B.; Prof. Dr. Hasanoğlu E.; Prof. Dr. Çağlar Ş.; Doç. Dr. Altun B.; Doç. Dr. Arıcı M.; Doç. Dr. Nergizoğlu G.; Doç. Dr. Derici Ü.: “Türk Hipertansiyon Prevalans Çalışması”, *Türk Hipertansiyon ve Böbrek Hastalıkları Derneği, 5. Ulusal Hipertansiyon ve Böbrek Kongresi*, 21-25 Mayıs **2003**, www.turkhipertansiyon.org Erişim tarihi: 29.04.2011
- [60] Leitão CB.; Canani LH.; Silveiro SP.: “Jorge Luiz Gross Serviço de Endocrinologia Ambulatory Blood Pressure Monitoring and Type 2 Diabetes Mellitus”, review article do Hospital de Clinicas de Porte Alegre - Porto Alegre, RS – Brazil, *Arq Bras Cardiol* **2007**, 88(2): 315 – 321
- [61] Bilgin, D.: “Masked with and without hypertension, hypertensive organ damage in patients with Type 2 Diabetes Mellitus”, PhD Thesis, Marmara University, İstanbul – **2010**
- [62] <http://www.tkd.org.tr/pages.asp?pg=406> Erişim Tarihi: 26. 04. **2011**
- [63] Guilbert J.J.: *World Health Report 2002: Reducing risks, promoting healthy life. Educ Health (Abingdon)*, **2003**, 16: 230.
- [64] Hernandez-Hernandez R.; Armas-Padilla MC.; Velasco M.; Carvajal A.R.; de Hernandez M.J.A.; Guerrero-Pajuelo J.; Pacheco B.: “Effects Of Amlodipin and Enalapril on Platelet Function in Patients With Mild to Moderate Hypertension.”, *Int J Clin Pharmacol Ther.*, **1999**, 37: 323-31.
- [65] Nadar S.; Blann A.D.; Lip G.Y.: “ Platelet Morphology and Plasma Indices of Platelet Activation in Essential Hypertension: Effects of Amlodipine-Based Antihypertensive Therapy.”, *Ann Med.* **2004**, 36: 552-7.
- [66] Yamanishi J.; Sano H.; Saito K.; Furuta Y.; Fukuzaki H.: “Plasma Concentrations of Platelet n Specific Proteins in Different Stages of Essential Hypertension: Interactions Between Platelet Aggregation, Blood Lipids and Age.”, *Thromb Haemost.* **1985**, 54: 539-43.
- [67] Chobanian A.V.; Bakris G.L.; Black H.R.; Cushman W.C.; Gren L.A.; Izzo J.L. Jr.; Jones D.W.; Materson B.J.; Oparil S.; Wright J.T. Jr.; Rochella E.J.: “Seventh Report of The Joint National Committee on Prevention, Detection, Evaluation and Treatment of High Blood Pressure.”, *Hypertension*, **2003**, 42: 1206-52.
- [68] Doç. Dr. Tuzcu A.: *Diyabet Yazokulu*, 11-13 Haziran **2010**, Van, <http://www.diyabetokulu.org/?s=2C5E575858265F3F20> Erişim Tarihi: 06.05.2011

- [69] Christopher PA.: Diastolic heart function. In: Murphy JG, Lloyd MA (eds), Mayo Clinic Cardiology Concise Textbook (third ed.) Mayo Clinic Scientific Pres., **2008**:1087-8.
- [70] Guidelines Committee: **2003** European Society of Hypertension-European Society of Cardiology guidelines for the management of arterial hypertension., J Hypertens. **2003**, 21: 1011-53.
- [71] WHO Library Cataloguing in Publication Data, Prevention of Cardiovascular Diseases: Pocket Guidelines for Assessment and Management of Cardiovascular Risk:(WHO/ISH cardiovascular risk prediction charts for the European Region), Geneva **2007**, ISBN:978 92 4 154727 7
- [72] WHO Library Cataloguing in Publication Data, Prevention of Cardiovascular Diseases: Guidelines for Assessment and Management of Total Cardiovascular Risk, **2007**, ISBN: 978 92 4 154717 8
- [73] Tjugen T.B.; Halvorsen S.; Bjørnerheim R.; Kjeldsen S.E.: "The role of statins in patients with arterial hypertension", Arch Med Sci **2007**, 3(4A): 97-S101
- [74] WHO, ISH Writing Group, "2003 WHO/ISH statement on Management of Hypertension", Journal of Hypertension **2003**, 21(11), Lippincott Williams & Wilkins, DOI: 10.1097/01.hjh.0000084751.37215.d2
- [75] Dr. Taşkan H.: "Hipertansiyon Tanısı Nasıl Konulmalıdır", 11.Ulusal Hipertansiyon ve Böbrek Hastalıkları Kongresi, 13-17 Mayıs **2009** Antalya.
- [76] Tzamou V.; Vyssoulis G.; Karpanou E.; Kyvelou S.M.; Gialernios T.; Stefanadis C.: "Serum Phosphate in White Coat Hypertensive Patients: Focus On Dipping Status and Metabolic Syndrome", Journal of Hypertension ,28, e-Supplement A, June **2010**
- [77] Nagy V. (MD.): "Ambuláns vérnyomás-monitorozás - Ambulatory Blood Pressure Monitoring", Orv. Hetil., **2010**, 44:1823–1833.
- [78] Cuspidia C.; Horio T.; Meania S.; Lonatib L.; Fusia V.; Valerioa C.; Salaa C.; Magnaghib G.; Maisaidic M.; Zanchettib A.: "Short-term Reproducibility of a Non-Dipping Pattern in Type 2 Diabetic Hypertensive Patients", Journal of Hypertension **2006**, 24:647-653
- [79] <http://www.halls.md/body-surface-area/refs.htm> Erişim Tarihi: 5.7.**2011**
- [80] Kurt İ.: "Glukozile Hemoglobin(HbA1c) Ölçümü Ve Diabetes Mellitusun Uzun Dönem Glisemik Kontrolünde Kullanılması", Gülhane Tıp Dergisi, **2003**, 45 (4): 387-395, ISSN 1302-0471
- [81] Prof.Dr. Dökmeci İ.; Yrd.Doç.Dr.Dökmeci H.: Türkçe ve Yabancı Tıp Terimleri Sözlüğü, Nobel Tıp Kitapevleri-**2010**:580
- [82] <http://www.ankaradiyabet.org.tr/d8.aspx> Erişim Tarihi: 10.04.**2011**

- [83] http://www.aeczane.com/index.php?option=com_content&view=article&id=635:diyabetin-kronik-komplikasyonu&catid=126:diyabet-rehberi&Itemid=132
Eriřim Tarihi:15.05.**2011**
- [84] [http://tip.sdu.edu.tr/akademikyapi/dersnotlar/KalpDamar/Yrd_Doc_Dr_ilker_Kiris/Periferik_Arter_HASTALIKLARI_\(Aortoiliak%20TIKAYICI%20HASTALIK\).pdf](http://tip.sdu.edu.tr/akademikyapi/dersnotlar/KalpDamar/Yrd_Doc_Dr_ilker_Kiris/Periferik_Arter_HASTALIKLARI_(Aortoiliak%20TIKAYICI%20HASTALIK).pdf)
Eriřim Tarihi: 20.02.**2011**
- [85] <http://www.cidpusa.org/ABI%20PAD.htm> Eriřim Tarihi: 03.03.**2011**
- [86] Dr. AKALIN S., www.phd.org.tr/14kongresunum/29ekim/3.ppt
Eriřim Tarihi:12.03.**2011**
- [87] Dr. Akıl E.: “Akut Serebrovasküler Hastalıklarda Otonom Sinir Sisteminin Kalp Hızı Deęiřkenlięi ve Katekolamin Düzeyleri ile Deęerlendirilmesi”, Uzmanlık Tezi, Dicle Üniversitesi Tıp Fakóltesi Nöroloji Anabilim Dalı, Diyarbakır -**2008**.
- [88] Çelen Y. Z.; Önderiřik İ.; Okan V.; Özbay E.; Zincirkeser S.: “Kardiyovasküler Otonomik Nöropatili Diabetes Mellitus Olgularında Sol Ventrikül Fonksiyonlarının İncelenmesi”, Van Tıp Dergisi, Ekim **1999**,6(4).
- [89] Deyneli O.; Ersöz H.O.; Yavuz D.; Fak A.S.; Akalin S.: “QT dispersion in type 2 diabetic patients with altered diurnal blood pressure rhythm.”, Diabetes Obes Metab., Mar **2005**,7(2):136-43.
- [90] <http://yayanakhyar.wordpress.com/2010/07/30/elektrokardiogram-ekg/>
Eriřim Tarihi: 24.02.**2011**
- [91] Sahn D.J.; DeMaria A.; Kisslo J.; Weyman A.: “Recommendations regarding quantitation in M-Mode echocardiography: Results of a survey of echocardiographic measurements.”, Circulation, **1978**, 54: 1072-1084.
- [92] Devereux R.B.; Reichek N.: “Echocardiographic determination of left ventricular mass in man. Anatomic validation of the method.”, Circulation, **1977**, 55(4):613-618.
- [93] Ganau A.; Devereux R.B.; Roman M.J.; Giovanni S.; Pickering T.; Saba P.S.; Vargiu P.; Simongini I.; Laragh J.: “Patterns of left ventricular hypertrophy and geometric remodeling in essential hypertension.”, J Am Coll Cardiol **1992**, 19: 1550-1558.
- [94] Prof.Dr. Akdeniz F.: Olasılık ve İstatistik Kitabı, Nobel Yayınevi, 16. Baskı, 2011
- [95] Vahaplar, A.; İnceoglu, M.M.; “Veri Madencilięi ve Elektronik Ticaret”, Türkiye’de İnternet Konferansları-VII. Elektronik Poster Bildiri, **2001**.
- [96] Han J.; Kamber M.: Data Mining : Concepts and Techniques, Academic Press, **2001**:5
- [97] Çakır Ö.: “Veri Madencilięinde Sınıflandırma Yöntemlerinin Karşılaştırılması: Bankacılık Müsteri Veri Tabanı Üzerinde Bir Uygulama”, Doktora Tezi, Marmara Üniversitesi Sosyal Bilimler Enstitüsü İřletme Anabilim Dalı Sayısal Yöntemler Bilim Dalı, İstanbul **2008**

- [98] Two Crows Co., “Introduction to Data Mining and Knowledge Discovery”, Introduction to Data Mining and Knowledge Discovery, Third Edition, **2005**: 4-5 ISBN: 1-892095-02-5.
- [99] Data Distilleries, Introduction to Data Mining - Discover Hidden Value in Your Databases, Amsterdam, The Netherlands, **1999**:7-9.
- [100] Telcioğlu M.B.: “Veri Madenciliğinde Genetik Programlama Temelli Yeni Bir Sınıflandırma Yaklaşımı ve Uygulaması”, YL Tezi, Erciyes Üniversitesi Fen Bilimleri Enstitüsü, Kayseri **2007**.
- [101] Kamrani, A.; Rong, W.; Gonzalez, R.: “A Genetic Algorithm Methodology For Data Mining And Intelligent Knowledge Acquisition”, Computers & Industrial Engineering, **2001**,40: 361-377.
- [102] Flawley W.J.; Piatetsky-Shapiro G.; Matheus C.J.: “Knowledge Discovery in Databases : An Overview”, AI Magazine, **1992**, 13(3):57-70.
- [103] Fayyad U. M.; Piatetsky-Shapiro G.; Smyth P.: “From data mining to knowledge discovery: an overview”, In Fayyad, U. M., Piatetsky-Shapiro, G., Smyth, P., and Uthurusamy, R., editors, Advances in Knowledge Discovery and Data Mining, AAAI Press / MIT Press, Menlo Park, CA., (**1996c**): 1-34.
- [104] Hand D.J.: Data mining: statistics and more?, The American Statistician, May **1998**, 52(2):112-118.
- [105] Berry M.J.A.; Linoff G.S.: Mastering Data Mining : The Art and Science of CRM, John Wiley & Sons, **2000**:7
- [106] Han J.; Kamber M.: a.g.e., **2001**:7
- [107] Swift R.: Accelerating Customer Relationship, Prentice Hall PTR, **2001**:93
- [108] Giudici P.: Applied Data Mining: Statistical Methods for Business and Industry, John Wiley & Sons, **2003**:2
- [109] Dr. Borne; UMUC Dataminig Lecture 2, 2005,
<http://www.slideshare.net/butest/lecture-2-3860196> Erişim Tarihi:7.5.2011
- [110] Lovell M.C.: “Data Mining”, The Review of Economics and Statistics, **1983**, 65(1): 1-12.
- [111] The Second International Conference On Knowledge Discovery & Data Mining Call For Papers Portland, Oregon , Sponsored by The American Association for Artificial Intelligence , August 2 – 4, **1996**.
- [112] <http://www.aaai.org/Conferences/KDD/1996/kdd96call.pdf>,
Erişim Tarihi: 28.8.2011
- [113] Journal of Data Mining and Knowledge Discovery, Springer US, **1997**,1, ISSN: 1384-5810 (print version)

- [114] Shearer C.: “The CRISP-DM Model: The New Blueprint for Data Mining”, Journal of Data Warehousing, **2000**, 5(4): 13-22.
- [115] <http://www.slideshare.net/Tommy96/crispdm-an-introduction>
Erişim Tarihi: 28.8.2011
- [116] <http://www.yorku.ca/lbianchi/nats1700/lecture14.html>
Erişim Tarihi: 2.4.2011
- [117] Fayyad U. M.; Piatetsky-Shapiro G.; Smyth P.: “From data mining to knowledge discovery: an overview”, In Fayyad U. M., Piatetsky-Shapiro G.; Smyth P.; Uthurusamy R.; editors, Advances in Knowledge Discovery and Data Mining, AAAI Press / MIT Press, Menlo Park, CA., **1996**: 1-34.
- [118] Aydoğan K. E.: “Veri Madenciliğinde Sınıflandırma Problemleri için Evrimsel Algoritma Tabanlı Yeni Bir Yaklaşım: Rough-Mep Algoritması”, Doktora Tezi, Endüstri Mühendisliği Gazi Üniversitesi FBE., Ocak **2008**
- [119] Almuallim H.; Dietterich T. G.: “Learning with many irrelevant features.”, Proceedings of the Ninth National Conference on Artificial Intelligence (AAAI-91) Anaheim, CA: AAAI Press.,**1991**:547-552.
- [120] J.R. Quinlan: Induction of Decision Trees, Machine Learning, **1986**: 81-106
- [121] Witten H. I.; Frank E.; Hall A. M: Data mining: practical machine learning tools and techniques.—2nd ed., Elsevier Inc., **2005**, ISBN 0-12-088407-0
- [122] Yıldırım P.; Uludağ M.; Görür A.: “Hastane Bilgi Sistemlerinde Veri Madenciliği”, Akademik Bilişim 2008, Çanakkale Onsekiz Mart Üniversitesi, Çanakkale, 30 Ocak - 01 Şubat **2007**
- [123] ŞEKER Ş. E.: Gözetimli Öğrenme (Supervised Learning)
<http://www.bilgisayarkavramlari.com/2008/10/27/gozetimli-ogrenme-supervised-learning/> Erişim Tarihi:12.10.2011
- [124] Muir T.: “Key Principles of Data Mining” An Introduction to Marketing Analytics, 23rd June **2010**.
- [125] Golemati S.; Mougiakakou S.; Stoitsis J.; Valavanis I.; Nikita K.: Clinical Decision Support Systems, Idea Group Inc., **2005**, 14:255.
- [126] Nammuni K.; Pickering C.; Modgil S.; Montgomery A.; Hammond P.; Wyatt J.C.; Altman D.G.; Dunlop R.; Potts H.: Design-a-trial: A rule-based decision support system for clinical trial design , Knowledge-Based Systems, Publisher: Elsevier Science Bv, **2004**, 17(2-4):121-129
- [127] Saad M. K.: CLIPS: Expert System Shell College of IT – CS Dept., <http://www.slideshare.net/mksaad/introduction-to-clips-expert-system-presentation>
Erişim Tarihi: 20.09.2011
- [128] <http://msdn.microsoft.com/en-us/sync/bb821992> Erişim Tarihi: 16.09.2011

- [129] Sitar-Taut D.A.; Sitar-Taut A.V.: “Overview on How Data Mining Tools May Support Cardiovascular Prediction”, *Journal of Applied Computer Science & Mathematics*, Suceava, **2010**, 8 (4).
- [130] Witten H. I.; Frank E.; Hall A. M.: *Data mining: practical machine learning tools and techniques*.—3rd ed., Elsevier Inc., **2011**, ISBN 978-0-12-374856-0
- [131] <http://www.cs.waikato.ac.nz/ml/weka/> Erişim Tarihi: 01.04. **2011**.
- [132] Sitar-Taut V. A.; Zdrengea D.; Pop D.; Sitar-Taut. A.D.: “Using machine learning algorithms in cardiovascular disease risk evaluation”, *Journal of Applied Computer Science & Mathematics*, **2009**5(3):29- 32.
- [133] SITAR-TĂUT D.A.; SITAR-TĂUT A.V.: Overview on How Data Mining Tools May Support Cardiovascular Disease Prediction, *Journal of Applied Computer Science & Mathematics*, Suceava, **2010**,8 (4)
- [134] Safavian R.; Landgrebe D.: “A survey of Decision Tree Classifier Methodology”, *IEEE Transactions on Systems, Man and Cybernetics*, May/June **1991**21(3): 660-674.
- [135] Pooja A. P.; Jayanth J.; Dr. Shivaprakash K.: “Classification of RS data using Decision Tree Approach”, *International Journal of Computer Applications* June **2011**, 23(3): 0975 – 8887
- [136] Li J.; Fu A. W.; Fahey P.: “Efficient discovery of risk patterns in medical data.” *Artificial Intelligence in Medicine*, **2009**,45: 77—89
- [137] Kononenko I.: “Machine learning for medical diagnosis: history, state of the art and perspective.”, *Artificial Intelligence in Medicine* **2001**,1:89—109.
- [138] Zhou Z.; Jiang Y.: “Medical diagnosis with C4.5 rule preceded by artificial neural network ensemble.”, *IEEE Transactions on Information Technology in Biomedicine* **2003**,1:37—42.
- [139] Ordonez C.: “Comparing association rules and decision trees for disease prediction.” In: Xiong L, Xia Y, editors. *Proceedings of the international workshop on healthcare information and knowledge management*, New York: ACM, **2006**: 17—24.
- [140] Gaga L.; Moustakis V.; Vlachakis Y.; Charissis G.: “ID+: Enhancing Medical Knowledge Acquisition with Machine Learning”, *Applied Artificial Intelligence*, Taylor & Francis, **1996**,10:79- 94.
- [141] Quinlan J.R.: *Induction of Decision Trees*, *Machine Learning*, **1986**: 81-106
- [142] Hewett R.; Leuchner J.; Mooney S. D.; Klein T.E.: “Analysis of mutations in the colia1 gene with secondorder rule induction”, *International Journal of Pattern Recognition and Artificial Intelligence*, World Scientific Publishing Company, **2003**, 17(5):721-740
- [143] Quinlan J.R.: *C4.5: Programs for Machine Learning*, Morgan Kaufmann Publishers, San Mateo, CA,**1993**

- [144] Mazid M. M.; Shawkat A. B. M. A.; Tickle K. S.: Improved C4.5 Algorithm For Rule Based Classification, Recent Advances In Artificial Intelligence, Knowledge Engineering And Data Bases, ISBN: 978-960-474-154-0 Artificial Intelligence Series, Wseas Press, **2010**.
- [145] Mollazade K.; Ahmadi H.; Omid M.; Alimardani R.; “An Intelligent Combined Method Based on Power”, International Journal of Intelligent Technology, Spectral Density, Decision Trees and Fuzzy Logic for Hydraulic Pumps Fault Diagnosis, **2008**, 3(4): 251-263.
- [146] Hu J.; Mojsilovic A.: “High-utility pattern mining: a method for discovery of high-utility item sets.”, Pattern Recognition, **2007**, 11:3317—24.
- [147] Doğan Y.: “A Data Mining Based Target Classification for Tactical Underwater Sensor Networks”, Master Thesis, Turkish Naval Academy, Naval Sciences and Engineering Institute, Department of Computer Engineering, **2004**, Istanbul
- [148] Brennan P.; Silman A.: “Statistical methods for assessing observer variability in clinical measures.”, BMJ., Jun **1992**, 6,304(6840):1491-4.
- [149] Demir Y. K.; Gerçek H.: “Flexible methods of calculating the transport type selection”, itüdergisi/d mühendislik, December **2006** 5(6): 61-73.
- [150] Ekici O.: “Bayesyen Regresyon ve WinBugs ile Bir Uygulama”, Yüksek Lisans Tezi, İstanbul Ün. SBE. Ekonometri ABD., İstanbul **2005**.
- [151] Aha D.W.; Kibler D.; Albert M.K.: “Instance-Based Learning Algorithms.”, Machine Learning, **1991**, 6(1):37–66.
- [152] Zheng Z.; Webb G.I.: “Lazy Learning of Bayesian Rules, Machine Learning”, Kluwer Academic Publishers, **2000**, 41:53–87.
- [153] Hudairy H.: “Data Mining and Decision Making Support In The Governmental Sector”, Master Thesis, Louisville University, **2004**.
- [154] <http://www.statsoft.com/textbook/naive-bayes-classifier/> Erişim tarihi: 7.11.2011
- [155] Kayaalp K.: “Asenkron Motorlarda Veri Madenciliği İle Hata Tespiti”, Yüksek Lisans Tezi, T.C. Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü, Isparta – **2007**.
- [156] Tang, T.; Chi, L.; “Predicting multilateral trade credit risks: comparisons of Logit and Fuzzy Logic models using ROC curve analysis.”, Expert Syst. Appl., **2005**: 547-556 Erişim Tarihi: 8.11.2011
- [157] Öztemel E.; “Yapay Sinir Ağları”, Papatya Yayıncılık, İstanbul- **2003**
- [158] Şen A.: “Elektrik Alan Şiddetlerinin Ölçümü ve Coğrafi Bilgi Sistemi Ortamında Yapay Sinir Ağları ile Analizi”, Yüksek Lisans Tezi, YTÜ. FBE., İstanbul **2007**

- [159] Dr. Takçı H.; “İlk Yapay Sinir Ağları”, ders notu.
http://htakci.sucati.org/YSA/index_dosyalar/bolum-2.pdf Erişim Tarihi:7.11.2011
- [160] Türkoğlu F.: “Melez Yaklaşımlarla Türkçe Dökümanlarda Yazar Tanıma”, YTÜ.FBE., Yüksek lisans Tezi, İstanbul **2006**
- [161] Çamcı F.: “Yapay Sinir Ağları Kullanılarak İzostatik Kafes Sistem Analizi”, Yüksek Lisans Tezi, Afyon Kocatepe Ün., Fatih Çamcı, FBE., İnşaat Müh., **2006**
- [162] Alpaydın, E.; Introduction to Machine Learning, MIT Press, **2004**.
- [163] Başkeleş B.: “Software Effort Estimation Using Machine Learning Methods”, Master Thesis, Boğaziçi Un., İstanbul- **2006**.
- [164] Gupta R.: Lecture No :3, AU-KBC Research Centre, MIT Campus, Anna University, **2008**.
- [165] Prof.Dr. Fak A.S., Marmara Üniversitesi Tıp Fak. İç Hastalıkları ABD. Öğretim üyesi, Hipertansiyon ve Ateroskleroz Eğitim, Uygulama ve Araştırma Merkezi Müdür Yardımcısı, **2009 -2011** yılları görüşmeler.

EKLER

ÇALIŞMADA KULLANILAN TIBBİ TERİMLER SÖZLÜĞÜ

DIABETES MELLITUS: Diabētēs terimi “sifon” + mellitus tatlı kelimelerinin birleşiminden oluşmuş, vücudun şeker yakmasında ortaya çıkan bozukluğun neden olduğu ve halk arasında yaygın biçimde şeker hastalığı olarak bilinen bir hastalıktır.

DIPPER: Sağlıklı bireylerde gündüz KB ortalama değerine göre, gece uykusu sırasında ortalama KB değeri %10 ve üzeri şeklinde düşüş göstermesi durumuna denilmektedir.

ENTROPİ: En kaba tanımla bir sistemin düzensizliğinin ölçüsüdür.

ETİYOLOJİK: Neden bilimsel, hastalığın nedeni ile ilişkili olan anlamı taşır.

ETİYOLOJİK FAKTÖRLER: Hastalığın oluşumuna katkıda bulunan risk faktörleridir.

ETİYOLOJİK TANI: Etiyolojiye ek olarak, hastalığın oluşumu ve gelişimini de içeren tanı.

FENOTİPİK: Bir canlı organizmanın genetik ve doğal çevre tarafından belirlenen dış görünüş özelliğidir.

INSIDANS: Belirli bir süre içerisinde yeni ortaya çıkan hastalık olgularının sayısının aynı süre içerisinde risk altında bulunan nüfusa oranıdır.

İNSÜLİN: Glukozun hücreye girmek için ihtiyaç duyduğu maddedir.

İNVAZİF: Girişimsel yani kapalı olan damarları açmak, sten takmak vb. tedavilerde iğne ile yapılan işlem biçimidir.

KARDİOVASKÜLER SİSTEM: Tüm dokulara oksijen ve metabolizma etkinlikleri için gerekli maddelerin ulaştırılması ve hücre metabolizması artıklarının dokulardan uzaklaştırılması görevini yerine getiren, içinde kan ve lenfin dolaştığı anatomik yapıların bütününe dolaşım sistemi yani kardiyovasküler sistem denir.

KAROTİS: Boyun arteridir.

KETOSİDOZ: Hiperglisemi hali ortaya çıktığında kandaki şeker insülin yetersizliği nedeniyle hücre içine giremez ve bu durumda şeker alamayan hücreler enerji elde etmek için yağ yakmaya başlarlar. Böylece ketonların ortaya çıkmasına ve kanda bu cisimlerin artarak idrara da geçmesine ve idrarda aseton çıkmasına neden olan bu duruma denir. Her yaşta diyabetli hastada görülebilen tehlikeli durumdur.

MORBIDİTE: Bir toplulukta herhangi bir hastalık için görülme sıklığı, yani hastalığa sahip kişilerin sağlıklı kişilere oranıdır.

MORTALİTE: Belirli bir nüfus topluluğunun gözlem altında tutularak oluşturulan yaşama ve ölüm istatistiklerine göre elde edilen sonuçlardan, her bir yaşta bir yıl içerisinde kaç kişinin hayatta kalacağını, kaç kişinin öleceğinin öngörüldüğü tablolarıdır.

NON-DIPPER: Bireylerde fizyolojik durumun bozularak gece uykusu esnasında ortalama KB değerinin hiç düşmemesi ya da %10'un altında düşmesi ise "Non-Dipper Paterni" olarak adlandırılmaktadır.

NON-İNVAZİF: Girişimsel olmayan yani vücuda herhangi bir şekilde iğne vb. bir araç ile girişimde bulunulmama biçimidir.

PREVALANS: Belirli bir nüfusta, belirli bir zaman dilimi içerisinde, çalışma kapsamında yer alan, belirli bir hastalık veya hastalıklara sahip kişilerin oranıdır.
Prevalans = Hastalık süresi x İnsidans

SENSITIVITY: Duyarlılık, testin hasta olanların hepsini doğru yani hasta olarak tanımlayabildiğinin göstergesidir.

SPECIFICITY: Özgüllük, testin sağlıklı insanların hepsini doğru tanımlayabildiğinin bir göstergesidir.

ÖZGEÇMİŞ

Adı Soyadı: Zehra Aysun ALTIKARDEŞ

Öğrenim Durumu:

- | | |
|------|---|
| 1993 | Marmara Üniversitesi Teknik Eğitim Fakültesi
Elektrik ve Elektronik Eğitimi Böl. Elektronik İşleri Öğretmenliği |
| 2001 | Marmara Üniversitesi Fen Bilimleri Enstitüsü
Elektronik - Bilgisayar Eğitimi ABD. Elektronik–Haberleşme Eğt.
Prog. “Lojik Devreler Dersinin İnternet Tabanlı Simülatörlü Eğitimi”
Doç.Dr. Yılmaz Çamurcu |

Projelerde Yaptığı Görevler:

- “ EDUMEC- E-Learning Education and Innovative Remote Laboratory for Mechatronics”, AB Leonardo da Vinci Yenilik Transferi Projesi, Proje No: 2011-1-TR1-LEO05-28030 Proje Contact Person ve Araştırmacı 2011-..
- “RFID ile Elde Edilen Yaşamsal İşaretlerin Uzman Sistem Yardımıyla Değerlendirilmesi” Proje Numarası: 2008 FEN-C-DRP-110908-0225, Araştırmacı
- “GUNT Proses Eğitim Setinin İnternet Tabanlı Kontrolü Laboratuvarı Uygulaması” Proje Numarası: 2005 FENYLS 201205042 Onay Tarihi: 2007, Araştırmacı
- "Teknik Bilimler Meslek Yüksekokulu Uzaktan Eğitim Pilot Projesi"
Proje Numarası: 2003 EĞT.031/020103 Onay Tarihi: 2006, Araştırmacı
- "İznik Gölü Balıkçılarının Sosyo-Ekonomik Durumu"
Proje Numarası: 2001 SOC-103/131200 Onay Tarihi: 2004, Araştırmacı

Bilimsel Kuruluşlara Üyelikler: Türkiye Bilişim Derneği

Ödüller:

- MÜ. Teknik Bilimler Meslek Yüksekokul’unda ki başarılı çalışmalarından dolayı plaket ile ödüllendirildi, 2004
- "I.Ulusal Meslek Yüksekokulları Sempozyumu" düzenlenmesine katkılarının dolay plaket ve teşekkür belgesi verildi, 2001

ESERLER

Uluslararası bilimsel toplantılarda sunulan ve bildiri kitabında basılan 8 adet bildiri, ulusal hakemli dergide yayınlanan 1 makalesi ve ulusal bilimsel toplantılarda sunulan ve bildiri kitaplarında basılan 4 adet bildirisi ve bulunmaktadır.