



**SEZARYEN OLGULARINDA KULLANILAN  
ANESTEZİ YÖNTEMLERİNİN VERİ MADENCİLİĞİ  
YÖNTEMLERİ KULLANILARAK ANALİZİ**

**Gizem Dilan BOZTAŞ**

**Yüksek Lisans Tezi  
Yönetim Bilişim Sistemleri Anabilim Dalı  
Doç. Dr. Ersin KARAMAN  
2018  
Her Hakkı Saklıdır**

**T.C.  
ATATÜRK ÜNİVERSİTESİ  
SOSYAL BİLİMLER ENSTİTÜSÜ  
YÖNETİM BİLİŞİM SİSTEMLERİ ANABİLİM DALI**

**Gizem Dilan BOZTAŞ**

**SEZARYEN OLGULARINDA KULLANILAN  
ANESTEZİ YÖNTEMLERİNİN VERİ MADENCİLİĞİ  
YÖNTEMLERİ KULLANILARAK ANALİZİ**

**YÜKSEK LİSANS TEZİ**

**TEZ YÖNETİCİSİ  
Doç. Dr. Ersin KARAMAN**

**ERZURUM-2018**



T.C.  
ATATÜRK ÜNİVERSİTESİ  
SOSYAL BİLİMLER ENSTİTÜSÜ  
TEZ BEYAN FORMU



16/07/2018

SOSYAL BİLİMLER ENSTİTÜSÜ MÜDÜRLÜĞÜNE

BİLDİRİM

*Atatürk Üniversitesi Lisansüstü Eğitim ve Öğretim Uygulama Esaslarının ilgili maddelerine* göre hazırlamış olduğum “**SEZARYEN OLGULARINDA KULLANILAN ANESTEZİ YÖNTEMLERİNİN VERİ MADENCİLİĞİ YÖNTEMLERİ KULLANILARAK ANALİZİ**” adlı tezin/raporun tamamen kendi çalışmam olduğunu ve her alıntıya kaynak gösterdiğimi taahhüt eder, tezimin/raporumun kâğıt ve elektronik kopyalarının Atatürk Üniversitesi Sosyal Bilimler Enstitüsü arşivlerinde aşağıda belirttiğim koşullarda saklanmasına izin verdiğimi onaylarım:

*Lisansüstü Eğitim ve Öğretim Uygulama Esaslarının ilgili maddeleri uyarınca gereğinin yapılmasını arz ederim \*.*

- Tezimin/Raporumun tamamı her yerden erişime açılabilir.
- Tezimin/Raporumun makale için **altı ay**, patent için **iki yıl** süreyle erişiminin ertelenmesini istiyorum.

16.07.2018

Gizem Dilan BOZTAŞ

\* LİSANSÜSTÜ TEZLERİN ELEKTRONİK ORTAMDA TOPLANMASI, DÜZENLENMESİ VE ERİŞİME AÇILMASINA İLİŞKİN YÖNERGE

.....  
ÜÇÜNCÜ BÖLÜM

Çeşitli ve Son Hükümler

**Lisansüstü tezlerin erişime açılmasının ertelenmesi MADDE 6– (1)** Lisansüstü teze ilgili patent başvurusu yapılması veya patent alma sürecinin devam etmesi durumunda, tez danışmanının önerisi ve enstitü anabilim dalının uygun görüşü üzerine enstitü veya fakülte yönetim kurulu iki yıl süre ile tezin erişime açılmasının ertelenmesine karar verebilir.

**(2)** Yeni teknik, materyal ve metotların kullanıldığı, henüz makaleye dönüşmemiş veya patent gibi yöntemlerle korunmamış ve internette paylaşılması durumunda 3. şahıslara veya kurumlara haksız kazanç imkanı oluşturabilecek bilgi ve bulguları içeren tezler hakkında tez danışmanının önerisi ve enstitü anabilim dalının uygun görüşü üzerine enstitü veya fakülte yönetim kurulunun gerekçeli kararı ile altı ayı aşmamak üzere tezin erişime açılması engellenebilir.

**Gizlilik dereceli tezler MADDE 7– (1)** Ulusal çıkarları veya güvenliği ilgilendiren, emniyet, istihbarat, savunma ve güvenlik, sağlık vb. konulara ilişkin lisansüstü tezlerle ilgili gizlilik kararı, tezin yapıldığı kurum tarafından verilir. Kurum ve kuruluşlarla yapılan işbirliği protokolü çerçevesinde hazırlanan lisansüstü tezlere ilişkin gizlilik kararı ise, ilgili kurum ve kuruluşun önerisi ile enstitü veya fakültenin uygun görüşü üzerine üniversite yönetim kurulu tarafından verilir. Gizlilik kararı verilen tezler Yükseköğretim Kuruluna bildirilir.

**(2)** Gizlilik kararı verilen tezler gizlilik süresince enstitü veya fakülte tarafından gizlilik kuralları çerçevesinde muhafaza edilir, gizlilik kararının kaldırılması halinde Tez Otomasyon Sistemine yüklenir.



T.C.  
ATATÜRK ÜNİVERSİTESİ  
SOSYAL BİLİMLER ENSTİTÜSÜ



TEZ KABUL TUTANAĞI

SOSYAL BİLİMLER ENSTİTÜSÜ MÜDÜRLÜĞÜNE

Doç. Dr. Ersin KARAMAN danışmanlığında, Gizem Dilan BOZTAŞ tarafından hazırlanan bu çalışma 16 / 07 / 2018 tarihinde aşağıda isimleri yazılı jüri tarafından Yönetim Bilişim Sistemleri Anabilim Dalı'nda Yüksek Lisans Tezi olarak kabul edilmiştir.

**Başkan** : Prof. Dr. Üstün ÖZEN

İmza: 

**Jüri Üyesi** : Prof. Dr. Yılmaz GÖKŞEN

İmza: 

**Jüri Üyesi** : Doç. Dr. Ersin KARAMAN

İmza: 

**Jüri Üyesi** : Dr. Öğretim Üyesi İbrahim Hakkı TÖR

İmza: 

Prof. Dr. Mehmet TÖRENEK

Enstitü Müdürü

## İÇİNDEKİLER

<b>ÖZET</b> .....	<b>III</b>
<b>ABSTRACT</b> .....	<b>IV</b>
<b>KISALTMALAR DİZİNİ</b> .....	<b>V</b>
<b>ŞEKİLLER DİZİNİ</b> .....	<b>VI</b>
<b>TABLolar DİZİNİ</b> .....	<b>VII</b>
<b>ÖNSÖZ</b> .....	<b>IX</b>
<b>GİRİŞ</b> .....	<b>1</b>

## BİRİNCİ BÖLÜM

### LİTERATÜR VE KAVRAMSAL ÇERÇEVE

<b>1.1. VERİ MADENCİLİĞİ NEDİR?</b> .....	<b>3</b>
1.1.1. Veri Madenciliği Uygulama Alanları .....	6
1.1.2. Veri Madenciliği Süreci .....	7
1.1.2.1. Veri Tabanından Bilgi Keşif Süreci (Knowledge Discovery in Databases).....	7
1.1.2.2. Çapraz Endüstri Standart Süreci (Cross Industry Standard Process for Data Mining).....	8
1.1.2.3. Veri Bilimi için Temel Metodoloji (Foundational Methodology for Data Science).....	9
1.1.3. Verilerin Hazırlanması.....	12
<b>1.2. VERİ MADENCİLİĞİ YÖNTEMLERİ</b> .....	<b>16</b>
1.2.1. Sınıflandırma .....	16
1.2.2. Kümeleme Analizi.....	21
1.2.3. Birliktelik Kuralları (İlişkilendirme kuralları).....	24
1.2.3.1. Apriori Algoritması .....	25
<b>1.3. SAĞLIK ALANINDA VERİ MADENCİLİĞİ ÇALIŞMALARI</b> .....	<b>26</b>
<b>1.4. ANESTEZYOLOJİ VE REAMINASYON</b> .....	<b>31</b>
1.4.1. Preoperatif Değerlendirme .....	31
1.4.1.1. ASA (American Society Of Anesthesiologists) Sınıflandırması.....	31
1.4.1.2. Mallampati .....	32
1.4.2. Obstetrik Anestezi .....	33

1.4.2.1. Genel Anestezi.....	35
1.4.2.2. Spinal Anestezi .....	37

## İKİNCİ BÖLÜM YÖNTEM

<b>2.1. VERİ TOPLAMA .....</b>	<b>41</b>
2.1.1. Verinin Anlaşılması.....	41
2.1.2. Veri Hazırlama .....	53
2.1.3. Veri Analizi .....	53

## ÜÇÜNCÜ BÖLÜM BULGULAR

<b>3.1. SINIFLANDIRMA YÖNTEMİ BULGULARI.....</b>	<b>55</b>
<b>3.2. KÜMELEME ANALİZİ İLE İLGİLİ BULGULAR.....</b>	<b>60</b>
<b>3.3 BİRLİKTELİK ANALİZİ İLE İLGİLİ BULGULAR.....</b>	<b>61</b>
<b>SONUÇ VE ÖNERİLER.....</b>	<b>63</b>
<b>TARTIŞMA .....</b>	<b>67</b>
<b>KAYNAKÇA .....</b>	<b>68</b>
<b>EKLER.....</b>	<b>81</b>
<b>ÖZGEÇMİŞ.....</b>	<b>86</b>

## ÖZET

## YÜKSEK LİSANS TEZİ

SEZARYEN OLGULARINDA KULLANILAN ANESTEZİ YÖNTEMLERİNİN  
VERİ MADENCİLİĞİ YÖNTEMLERİ KULLANILARAK ANALİZİ

Gizem Dilan BOZTAŞ

Tez Danışmanı: Doç. Dr. Ersin KARAMAN

2018, 86 sayfa

**Jüri: Doç. Dr. Ersin KARAMAN (Danışman)**  
**Dr. Öğretim Üyesi İbrahim Hakkı TÖR (2. Danışman)**  
**Prof. Dr. Üstün ÖZEN**  
**Prof. Dr. Yılmaz GÖKŞEN**

Birçok alanda olduğu gibi tıbbi verilerden veri madenciliği yöntemlerini kullanarak anlamlı örüntüler çıkarmak ve bu doğrultuda politikalar önermek mümkündür. Bu çalışmada veri madenciliği yöntemleri uygulanarak sezaryen doğum yönteminde belirlenen anestezi türleri analiz edilerek bir örüntü ve karar mekanizması oluşturmak amaçlanmıştır. Bu bağlamda Erzurum ili ve çevresinden elde edilen 300 veri ile sınıflandırma, kümeleme ve birliktelik analizleri yapılmıştır.

Bu çalışmada sınıflandırma analizi için Gini algoritması ve C5.0 algoritması kullanılmıştır. Bu algoritmalar hem uzman görüşüne göre oluşturulan 24 parametrelili veri setinde hem de bilgi edinme ve ki-kare yöntemlerine göre indirgenen 16 parametrelili veri setinde uygulanmıştır. Gini algoritması ile elde edilen karar ağacı karmaşıklık ölçütüne göre budanarak toplamda üç farklı karar ağacı elde edilmiştir. Söz konusu algoritmalar içerisinde C5.0 algoritması % 98,87 ile doğruluk oranı en yüksek karar ağacı olarak belirlenmiştir.

K-prototip algoritması ile yapılan kümeleme analizinde küme sayıları her iki veri setinde de uzman görüşü doğrultusunda 2,3,4 ve 5 olarak belirlenmiştir. 2 ve 3'lü küme ayrımlarında net örüntüler bulunamazken 4 ve 5 ayrımlı kümelerde net örüntülere rastlanmıştır. Birliktelik analizi 3 veri seti üzerinden gerçekleştirilmiş ve Apriori algoritması ile birliktelik kuralları bulunmuştur.

Sonuç olarak, hastanın; yaşı, ameliyata giriş saati, önceki anestezi öyküsü, sezaryen sayısı, anestezi korkusu ve ameliyat öyküsü parametrelerinin sezaryen doğum yönteminde uygulanan anestezi türünü belirlemede etkili olduğu gözlemlenmiştir.

**Anahtar Kelimeler:** Veri madenciliği, Sınıflandırma, Kümeleme, Birliktelik analizi, Sezaryen, Anestezi

**ABSTRACT****MASTER'S THESIS****ANALYSIS OF ANESTHESIA METHODS USED IN CESAREAN SECTION BY  
USING DATA MINING TECHNIQUES****Gizem Dilan BOZTAŞ****Advisor: Assoc. Prof. Dr. Ersin KARAMAN****2018, page: 86****Jury: Assoc. Prof. Dr. Ersin KARAMAN (Advisor)****Assist. Prof. Dr. İbrahim Hakkı TÖR (2. Advisor)****Prof. Dr. Üstün ÖZEN****Prof. Dr. Yılmaz GÖKŞEN**

It is possible to extract meaningful patterns from medical data via data mining techniques to develop policies, as in many other fields. In this study it is aimed to extract pattern and decision mechanism using data mining techniques to analyze the data gathered from the type of anesthesia determined in cesarean birth method. In this context, classification, clustering and association rule analysis were conducted on 300 data obtained from Erzurum province and its surroundings.

In this study, Gini and C5.0 algorithms have been used for classification. These algorithms have been applied both on data set with 24 parameters created according to expert opinion, and data set with 16 parameters which is reduced according to information acquisition and chi-square methods. In total, three different decision trees were obtained after pruning the tree created by Gini algorithms according to confusion measure. According to findings it is found that C5.0 algorithms have the highest performance with 98,87% precision.

Number of cluster were defined as 2,3,4 and 5 according to expert opinion for k-prototype clustering algorithm. Although meaningful patterns for 4 and 5 clusters have been found, there is no significant result for 2 and 3 clusters. Association rules have been found by applying Apriori algorithm on three data set.

In conclusion, it is observed that age of patient, operation time, anesthesia history, number of caesarian, anesthesia phobia and operation history are the important factors in terms of the type of anesthesia.

**Keywords:** Data mining, Classification, Clustering, Association analysis, Cesarean, anesthesia



**KISALTMALAR DİZİNİ**

ASA	: American Society of Anesthesiologists
CS	: Sezaryen
CRISP-DM	: Cross Industry Standard Process for Data Mining
D	: Destek
FMDS	: Foundational Methodology for Data Science
G	: Güven
HGAI	: Hasta Genel Anestezi İstiyor
HSAI	: Hasta Spinal Anestezi İstiyor
HGAK	: Hasta Genel Anesteziden Korkuyor
HS AK	: Hasta Spinal Anesteziden Korkuyor
K	: Kaldıraç
KDD	: Knowledge Discovery in Databases
SDTE	: Spinal Anesteziyi Doktor Tavsiye Etti
TSAU	: Tahliller Spinal Anesteziye Uygun
HGAI	: Hasta Genel Anestezi İstiyor
HSAI	: Hasta Spinal Anestezi İstiyor
HGAK	: Hasta Genel Anesteziden Korkuyor
HS AK	: Hasta Spinal Anesteziden Korkuyor

## ŞEKİLLER DİZİNİ

Şekil 1.1. Veri Madenciliği ve Diğer Disiplinler Arasındaki İlişkiler .....	4
Şekil 1.2. Veri madenciliğinde bilgi keşfi süreci .....	8
Şekil 1.3. CRISP-DM Süreci .....	9
Şekil 1.4. FMDS Süreci .....	10
Şekil 1.5. Mallampati Sınıfları .....	32
Şekil 2.1 Yaş, Boy, Kilo Histogram Grafikleri.....	43
Şekil 3.1. Parametre Seçimi Öncesi Gini Algoritması İle Elde Edilen Karar Ağacı .....	55
Şekil 3.2. Parametre Seçimi Öncesi Gini Algoritması İle Elde Edilen Karar Ağacı Kuralları .....	56
Şekil 3.3. Parametre Seçimi Sonrası Gini Algoritması İle Elde Edilen Karar Ağacı .....	56
Şekil 3.4 Parametre Seçimi Sonrası Gini Algoritması İle Elde Edilen Karar Ağacı Kuralları .....	57
Şekil 3.5. Gini Algoritması İle Elde Edilen Budanmış Karar Ağacı .....	58
Şekil 3.6. Parametre Seçimi Sonrası Gini Algoritması İle Elde Edilen Karar Ağacı Kuralları .....	58
Şekil 3.7. C5.0 Algoritması İle Elde Edilen Karar Ağacı .....	59
Şekil 3.8. C5.0 Algoritması İle Elde Edilen Karar Ağacı Kuralları .....	59
Şekil 3.9. $k=2$ İçin Seçim Öncesi ve Seçim Sonrası Kümeleme Analizi.....	60
Şekil 3.10. $k=3$ için seçim öncesi ve seçim sonrası kümeleme analizi.....	60
Şekil 3.11. $k= 4$ için seçim öncesi ve seçim sonrası kümeleme analizi.....	61
Şekil 3.12. $k= 5$ için seçim öncesi ve seçim sonrası kümeleme analizi.....	61
Şekil 3.13. İlk Veri Seti Kuralları .....	62
Şekil 3.14. İkinci Veri Seti Kuralları .....	62
Şekil 3.15. Üçüncü Veri Seti Kuralları .....	62

## TABLOLAR DİZİNİ

<b>Tablo 1.1.</b> Veri Madenciliği Kullanılan Bazı Alanlar .....	6
<b>Tablo 1.2.</b> KDD, CRISP-DM ve FMDS Arasındaki Uygunluk Karşılaştırması .....	12
<b>Tablo 1.3.</b> Karışıklık Matrisi .....	18
<b>Tablo 1.4.</b> Hiyerarşik ve Bölümlenmeli Kümeleme Yöntemlerinin Genel Özellikleri ..	22
<b>Tablo 1.5.</b> ASA Sınıflandırması .....	32
<b>Tablo 1.6.</b> Mallampati Sınıfl Açıklamaları .....	33
<b>Tablo 1.7.</b> Yıllara Göre Ana Çocuk Sağlığı ve Aile Planlaması Göstergeler .....	34
<b>Tablo 1.8.</b> 2000 Yılında Tüm Sezaryenler 4 Kategoride Toplanmıştır.....	39
<b>Tablo 2.1.</b> Veri Setini Oluşturan Parametrelerin Tanımlamaları .....	42
<b>Tablo 2.2.</b> Örneklem Grubunun Yaş, Boy ve Kilo Parametrelerine Ait Betimsel İstatistik Verileri.....	43
<b>Tablo 2.3.</b> Örneklem Grubunun Yaş Verileri.....	43
<b>Tablo 2.4.</b> Örneklem Grubunun Boy Verileri .....	44
<b>Tablo 2.5.</b> Örneklem Grubunun Kilo Verileri.....	44
<b>Tablo 2.6.</b> Örneklem Grubunun Gebelik Haftası Verileri.....	45
<b>Tablo 2.7.</b> Örneklem Grubunun Sezaryen Doğum Sayısı Verileri.....	45
<b>Tablo 2.8.</b> Örneklem Grubunun Sezaryen Olma Nedeni Verileri.....	45
<b>Tablo 2.9.</b> Örneklem Grubunun Vaka Türü Verileri.....	47
<b>Tablo 2.10.</b> Örneklem Grubunun Açlık Süresi Verileri .....	47
<b>Tablo 2.11.</b> Örneklem Grubunun Anestezi Tercihi Verileri.....	48
<b>Tablo 2.12.</b> Örneklem Grubunun Anestesi Korkusu Verileri .....	48
<b>Tablo 2.13.</b> Örneklem Grubunun Tahlillerinin Spinal Anestezi İçin Uygunluk Verileri .....	49
<b>Tablo 2.14.</b> Örneklem Grubunda Spinal Anestezinin Doktor Tavsiyesi Olma Durumu Verileri .....	49
<b>Tablo 2.15.</b> Örneklem Grubunun Ameliyata Giriş Saati Verileri .....	49
<b>Tablo 2.16.</b> Örneklem Grubunun Önceki Anestezi Türü Geçmiş Verileri.....	50
<b>Tablo 2.17.</b> Örneklem grubunun şimdiki anestezi türü verileri.....	50
<b>Tablo 2.18.</b> Örneklem Grubunun Hastalık Durumu Verileri. ....	50
<b>Tablo 2.19.</b> Örneklem Grubunun Hastalık Verileri.....	51
<b>Tablo 2.20.</b> Örneklem Grubunun İlaç Kullanım Verileri .....	51

<b>Tablo 2.21.</b> Örneklem Grubunun İlaç Verileri .....	51
<b>Tablo 2.22.</b> Örneklem Grubunun Ameliyat Geçmişi İle İlgili Veriler .....	52
<b>Tablo 2.23.</b> Örneklem Grubunun ASA Sınıflandırma Verileri .....	52
<b>Tablo 2.24.</b> Örneklem Grubunun Mallampati Sınıfı İle İlgili Verileri.....	52
<b>Tablo 3.1.</b> Model Performansı Değerlendirme.....	60



## ÖNSÖZ

Bu çalışmanın gerçekleştirilmesinde, her aşamada bilgi ve deneyimlerini benimle paylaşan, kullandığı her kelimenin benim için ayrı bir önemi olan saygı değer danışmanım Doç. Dr. Ersin KARAMAN'a ve yine çalışma sürecinde benden destek ve ilgisini hiçbir zaman esirgemeyen ikinci danışmanım saygı değer hocam Dr. Öğretim Üyesi İbrahim Hakkı TÖR'e teşekkürü bir borç bilirim. Ayrıca tez sürecinde katkılarından dolayı Prof. Dr. Üstün ÖZEN' e ve Prof. Dr. Yılmaz GÖKŞEN'e teşekkürlerimi sunarım.

Çalışmam sırasında bana destek olan Atatürk Üniversitesi İktisadi ve İdari Bilimler Fakültesi Yönetim Bilişim Sistemleri Bölümü doktora öğrencisi sevgili arkadaşım Esra ÖZMEN' e teşekkürü bir borç bilirim.

Hayatta ve çalışmam süresince bana göstermiş oldukları sabır ve hoşgöründen ötürü sevgili kardeşim Baran BOZTAŞ'a, sevgili kuzenim Umut BAYRAK'a ve sevgili teyzelerim Oya BAYRAK KOÇ' a ve Arzu BAYRAK' a teşekkürlerimi sunarım.

Giriştiğim her işte olduğu gibi bu süreçte de her zaman arkamda olan ailem ve arkadaşlarım, Hatice HALİS'e, Rüveyda HALİS'e ve Cezminur İNCESU'ya da teşekkürlerimi sunarım.

Son olarak desteğini her zaman arkamda hissettiğim sevgili annem Nurhayat BAYRAK BOZTAŞ'a ve varlığıyla güç kaynağım olan sevgili babam İbrahim BOZTAŞ'a en içten teşekkürlerimi sunarım.

## GİRİŞ

Günümüz şartlarında bilgi çağında yaşadığımız için bilginin elimizde bulunan en büyük güç olduğu önemli bir gerçekliği oluşturmaktadır. Bu nedenle bilgiyi üretebilen gerek birey, gerek toplum, gerekse firmalar çeşitli birçok avantaja sahip olabilmektedirler. Artık gelişen bilgi teknolojileri sayesinde istenilen birçok alanda veriler kolaylıkla toplanabilmekle beraber bilgiye dönüşmeyen veri bir anlam ifade etmemektedir (Argüden & Erşahin, 2008). Söz konusu durum göz önüne alındığında büyük miktardaki veriden bir anlam çıkarmak için veri madenciliği kullanılmak durumundadır.

Günümüzde veri madenciliğinin uygulandığı alanlarda problemlere ürettiği çözümlerin söz konusu alan için önemli yararlar sağladığı yadsınamaz bir gerçek olmakla birlikte özellikle sağlık alanında oluşan büyük veri yığınları ve daha doğru karar alma gerekliliği veri madenciliği yöntemleri için çok tercih edilen bir uygulama alanı oluşturmaktadır.

Sağlık Bakanlığı ve OECD (İktisadi İşbirliği ve Gelişme Teşkilatı) verilerine göre sezaryen doğum yöntemi Türkiye’de 2002 yılından itibaren hızlı bir artış göstermiş ve ülke dünya sıralamasında 1. sıraya yükselmiştir (Medimagazin, 2017). Bu durum dolayısıyla sezaryen ameliyatlarında anestezi yöntemlerinin daha fazla öneme sahip olmasına neden olmuştur. Günümüzde veri madenciliği yöntemlerinin birçok önemli alanda oldukça başarılı bir şekilde rol oynadığı bilinen bir gerçektir ve bu alanlardan bir tanesi de sağlıktır. Bu çalışma sezaryen doğum yöntemiyle doğum yapan kadınlara en uygun anestezi yöntemini veri madenciliği yöntemleriyle belirlemek amacıyla yapılmıştır.

Çalışma kapsamında Erzurum Nenehatun kadın doğum hastanesinde 2018 yılının bir döneminde sezaryen doğum yöntemi ile doğum yapan 300 hastadan hasta tanıma formu yolu ile elde edilen verilerden bir veri tabanı oluşturulmuştur. Veri tabanında 26 parametre 300 tanede kayıt mevcuttur. Çalışma 3 ana bölümden oluşmaktadır.

Birinci bölümde veri madenciliği alanında bilgi verilerek veri madenciliği süreç ve yöntemleri incelenmiştir. Veri madenciliğinin kullanım alanları ve kullanım alanlarına göre ilgilendiği problemlerle birlikte farklı disiplinlerle olan ilişkisine değinilmiştir. Ayrıca anestezi yöntemleri ile ilgili tıp literatürü de bu bölümde ele alınmıştır. Sağlık

alanında veri madenciliđi uygulamaları ile ilgili daha önce yapılan alıřmalara da yine aynı bölümde değinilmiřtir.

İkinci bölümde veri toplama ve veri analiz yöntemleri ele alınmıřtır. Bu bölümde veri toplama aracı tanıtılmıř ve parametreler anlatılmıřtır. Daha sonra toplanan verilerin tanımlanması ve analiz yöntemleri ile ilgili gerekli detaylara değinilmiřtir.

alıřmanın üçüncü bölümünde ise toplanan verilerin veri madenciliđi yöntemlerinden k-prototip algoritması ile kümelemesi, C5.0 ve Gini algoritması ile sınıflandırılması, Apriori algoritması ile de birliktelik analizi yapılarak iliřki kuralları verilmeye alıřılmıřtır.



## BİRİNCİ BÖLÜM

### LİTERATÜR VE KAVRAMSAL ÇERÇEVE

#### 1.1. VERİ MADENCİLİĞİ NEDİR?

Literatür incelendiğinde çeşitli yaklaşımlarla veri madenciliği tanım ve sürecinin açıklanmaya çalışıldığı gözlemlenebilmektedir. (Balaban & Kartal, 2016). Bu tanımlardan birkaçı aşağıda verilmiştir.

Gartner Group şirketine göre, “*Veri madenciliği depolarda (veri ambarında) saklanan çok büyük boyuttaki verileri inceleyerek anlamlı yeni korelasyonların, örüntülerin ve eğilimlerin keşfedilmesi sürecidir.*” (Larose,2005) (Çataloluk, 2012).

“*Verilerin içerisindeki örüntülerin, ilişkilerin, değişimlerin, düzensizliklerin, kuralların ve istatistiksel olarak önemli olan yapıların keşfedilmesidir*” (Ulucan & Pektekin, 2009) (Alagöz, Öge, & Ortakarpuz, 2014).

Pirinççiler ve Şen’e göre ise veri madenciliği; “*Büyük miktarlardaki verinin otomatik ya da yarı otomatik araçlarla, veri içerisindeki kullanışlı desenleri (model) ortaya çıkarmak için yapılan keşif ve analizdir*” (Pirinççiler & Şen, 2012).

“*Veri madenciliği büyük veri yapılarından değerli bilgilerin çıkartılması süreci/ yöntemleri olarak tanımlanabilir*” (Altunkaynak, Veri Madenciliği Yöntemleri ve R Uygulamaları, 2017).

Savaş ve arkadaşları ise veri madenciliği için “*Veri madenciliği, çok büyük miktarda bilginin depolandığı veri tabanlarından, amacımız doğrultusunda, gelecek ile ilgili tahminler yapmamızı sağlayacak, anlamlı olan veriye ulaşma ve veriyi kullanma işidir.*” tanımını yapmışlardır (Savaş, Topaloğlu, & Yılmaz, 2012).

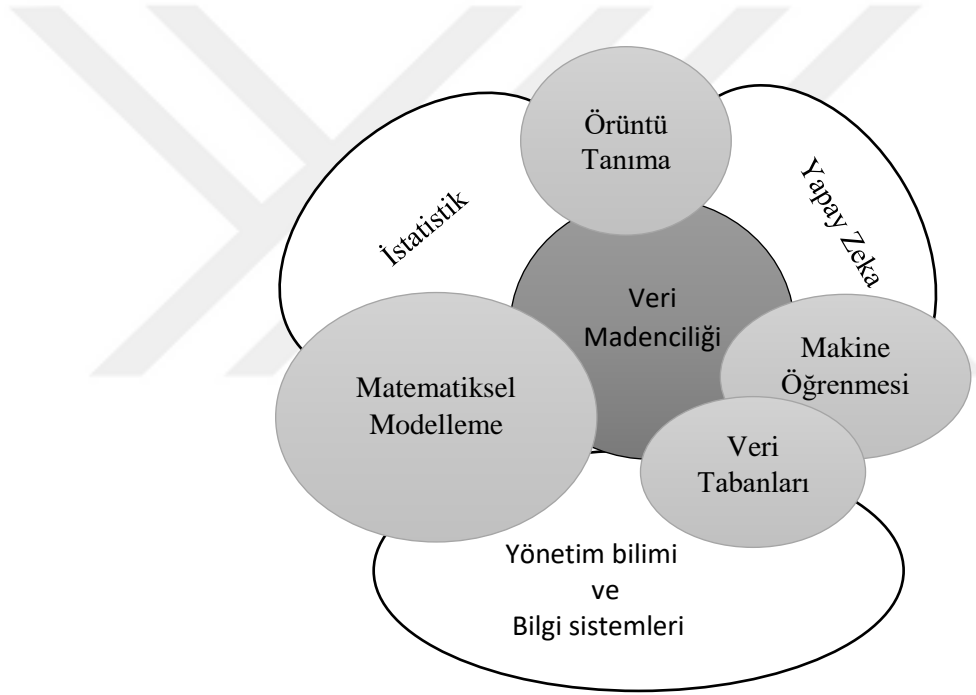
“*Bir hipotezi ispatlamak (yukarıdan aşağıya veri madenciliği) veya kesin istatistiksel korelasyonlar üzerine kurulmuş yeni hipotezler üretmek amacıyla çok büyük veri tabanlarını sorgulama işlemidir*” (Sullivan, 2012).

Ayrıca bilgi keşfi, bilgi madenciliği, makine öğrenmesi vs. (Altunkaynak, 2017) adlarla da anılan veri madenciliğinin mevcut büyük çaptaki düzenlenmiş veri



birikintilerinden çeşitli yöntemlerle anlamlı bilgi elde etme sürecine denk geldiği söylenebilir.

Veri madenciliğinin gelişim süreci incelendiğinde veri madenciliği yöntemlerinin 1980’li yılların sonundan itibaren uygulanmaya başlandığı görülmektedir. 1990’lı yıllara gelindiğinde veri tabanı sayısında beliren artış ile bu veri tabanlarından yararlı bilginin nasıl elde edileceği düşünölmeye başlanmıştır. 2000’li yıllarda veri madenciliği istikrarlı bir gelişim göstererek birçok alanda kullanılmaya başlanmıştır (Savaş, Topaloğlu, & Yılmaz, 2012). Veri madenciliğinin gelişimine farklı birçok disiplinin de katkısı olduğundan veri madenciliği diğer disiplinlerle ilişki içerisinde. Söz konusu ilişki Şekil 1’de şematize edilmiştir.



**Şekil 1.1.** Veri Madenciliği ve Diğer Disiplinler Arasındaki İlişkiler (Turban, Sharda, & Delen, 2011)

Belirtmekte fayda olan noktalardan bir tanesi de dinamik ve her türlü verinin mevcut olduğu veri tabanlarında veri madenciliği yöntemleri ile doğrudan analiz yapılamayacağıdır. Bu nedenle ilk etapta bilginin elde edileceği verilerin hazırlanması gerekmektedir (sonraki bölümlerde verilerin hazırlanması aşamalarına daha detaylı değinilecektir). Ortaya çıkan bu yeni veri tabanı ham veri tabanının bir “alt veri kümesi” niteliğindedir. Üzerinde veri madenciliği yöntemleriyle analizler yapılacak bu “alt veri kümesine” veri ambarı denilmektedir (Altunkaynak, 2017). Fakat bazen büyük veri

ambarları oluşturmak çok uzun zaman alan ve oldukça maliyetli bir işlem olabilir. Böyle bir durumda veri madenciliği yöntemlerini uygulamak için bir veya daha fazla operasyonel veya işlemsel veri tabanından salt okunabilir bir veri tabanı oluşturmak yeterlidir. (Two Crows, 1999).

Ayrıca günümüzde her anlamda gelişen bilgi teknolojileri artık sadece operasyonel düzey için değil yönetim boyutundaki karar mekanizmalarında da kullanılmayı amaçlamaktadır.

Bu nedenle veri ambarı aynı zamanda karar destek sistemlerinin altyapısını oluşturur ve veri ambarı karar destek sürecinde yardımcı olmayacak veriyi içermez (Özkan, 2008).

Veri ambarı yönetimi için konu odaklı, bütünlük, belirli bir dönem ve zamana ait ve geçici olmayan veri topluluğudur tanımı yapılabilir (Özkan, 2008) (Silahtaroglu, 2013). Veri ambarı tanımının içinde geçen kavramlar şu şekilde açıklanabilir;

✓ Konu odaklıdır.

Birbirini ilgilendiren olay ve ya varlık verilerine odaklanması durumudur. Örneğin bir işletmede veri ambarı müşteri, ürün gibi varlıklara ya da satış, sipariş gibi olaylara göre düzenlenmiş olabilir. (Silahtaroglu, 2013)

✓ Bütünlüktür.

Başlıkta anlaşılacağı gibi birden fazla veri tabanının bir araya getirilmesi işlemi olabileceği gibi hazır veya kendimizin oluşturduğu (web sayfaları, Word dosyaları vs.) kaynaklar veri tabanına aktarılarak bütünlüştürülmüş olabilir. (Silahtaroglu, 2013) Öte yandan bazı veriler veri ambarına aktırılırken (ölçü birimlerinin farklılığı, isimlendirme farklılıkları, sayısal değerlerin fiziksel gösteriminde farklılıklar vs.) gerekli alanlarda ki farklılıkların tutarlı hale getirmek için uygun formata göre söz konusu verilere yeniden gerekli dönüştürmenin yapılması gerekir (Özkan, 2008)

✓ Zaman boyutu vardır.

Veri ambarındaki veriler belirli bir zaman çerçevesi içindeki bilgilerdir. Örneğin 5 yıllık ya da 10 yıllık dönemlere ait olabilir (Özkan, 2008).

✓ Sadece okunabilir.

Veri ambarındaki veriler sabittir. Bu demek oluyor ki veri ambarına herhangi bir ekleme, silme veya herhangi bir değiştirme işlemi yapılamaz (Silahtaroglu, 2013).

### 1.1.1. Veri Madenciliği Uygulama Alanları

Veri madenciliğinin faydalarının anlaşılmasıyla kullanım alanı da genişlemiştir. Çok miktarda veri içeren her alanda veri madenciliği kullanılabilir. Tıp, pazarlama, telekomikasyon, bankacılık, eğlence sektörü vb. birçok alan veri madenciliği kullanım alanlarına örnek gösterilebilir. Aşağıdaki veri madenciliği kullanan bazı alanların hangi konular için veri madenciliğine ihtiyaç duydukları gösterilmiştir (Turban, Sharda, & Delen, 2011).

**Tablo 1.1.** Veri Madenciliği Kullanılan Bazı Alanlar

Veri Madenciliği Uygulama Alanı	Uygulama Konu
Pazarlama	<ul style="list-style-type: none"> <li>✓ Müşterilerin elde tutulması ve yeni müşterilerin kazanılması</li> <li>✓ Müşterilerin satın alma alışkanlıklarını belirlenmesi</li> <li>✓ En çok kazanç sağlanan müşterilerin saptanması vb.</li> </ul>
Bankacılık	<ul style="list-style-type: none"> <li>✓ Kredibilite ve risk değerlendirmesi</li> <li>✓ Online banka işlemleri ve kredi kartında yapılan sahtekârlık ve dolandırıcılık tespiti vb.</li> </ul>
Üretim	<ul style="list-style-type: none"> <li>✓ Makine hatalarının önceden tahmini</li> <li>✓ Üretim kapasitesinin optimizasyonu amacıyla üretimdeki normal dışılıkların ve ortaklıkların belirlenmesi</li> <li>✓ Ürün kalitesinin belirlenmesi ve geliştirmesi adına farklı örüntüler keşfetmek vb.</li> </ul>
Perakende ve Lojistik	<ul style="list-style-type: none"> <li>✓ Doğru stokların belirlenmesi için belirli perakende satış noktalarında satışların tahmin edilmesi</li> <li>✓ Ürünler arasındaki bağlantılara göre mağazada ürün yerleşiminin yapılması</li> <li>✓ Çeşitli promosyonların geliştirilmesi</li> <li>✓ Lojistiğin optimize edilmesi ve satışların maksimum düzeye çıkarılması amacıyla farklı ürünlerin tüketim seviyesinin öngörmek vb.</li> </ul>
Aracılık ve Menkul Kıymet Alım Satımı	<ul style="list-style-type: none"> <li>✓ Tahvil fiyatlarının değişim zaman ve miktarını öngörmek</li> <li>✓ Stok değişimlerinin aralığını ve yönünü tahmin etmek</li> <li>✓ Menkul kıymet alım satımında hileli faaliyetleri tespit etmek ve önlemek vb.</li> </ul>
Bilgisayar donanımı ve yazılımı	<ul style="list-style-type: none"> <li>✓ Disket sürücü hatalarını öngörmek</li> <li>✓ İstenmeyen Web içeriklerini ve e-mailleri saptama ve filtrelemek</li> <li>✓ Güvenli olmayan yazılım ürünlerini belirlemek vb.</li> </ul>
Turizm	<ul style="list-style-type: none"> <li>✓ Gelir yönetimi yapmak</li> <li>✓ Talep tahmini ile sınırlı kaynakların doğru yerlere tahsisi</li> <li>✓ En çok kazanç sağlayan müşterileri saptayarak kalıcılıklarını sağlamak vb.</li> </ul>
Tıp	<ul style="list-style-type: none"> <li>✓ Genom biliminde</li> <li>✓ Organ nakli gereken durumlarda donör-organ uyumu tahmininde vb.</li> <li>✓ Çalışmada veri madenciliğinin Tıp alanında kullanımına ayrıntılı olarak değinilmiştir.</li> </ul>

**Tablo 1.1.** (Devamı)

Eğlence	<ul style="list-style-type: none"> <li>✓ İzleyici verilerinin analizinde</li> <li>✓ Yayınlanacak dizi ve filmlerin başarılarını ön görerek yatırım kararları almada</li> <li>✓ Etkinlik ve kaynak planlamada</li> <li>✓ Maksimum gelir için uygun planları geliştirmede vb.</li> </ul>
---------	--

### 1.1.2. Veri Madenciliği Süreci

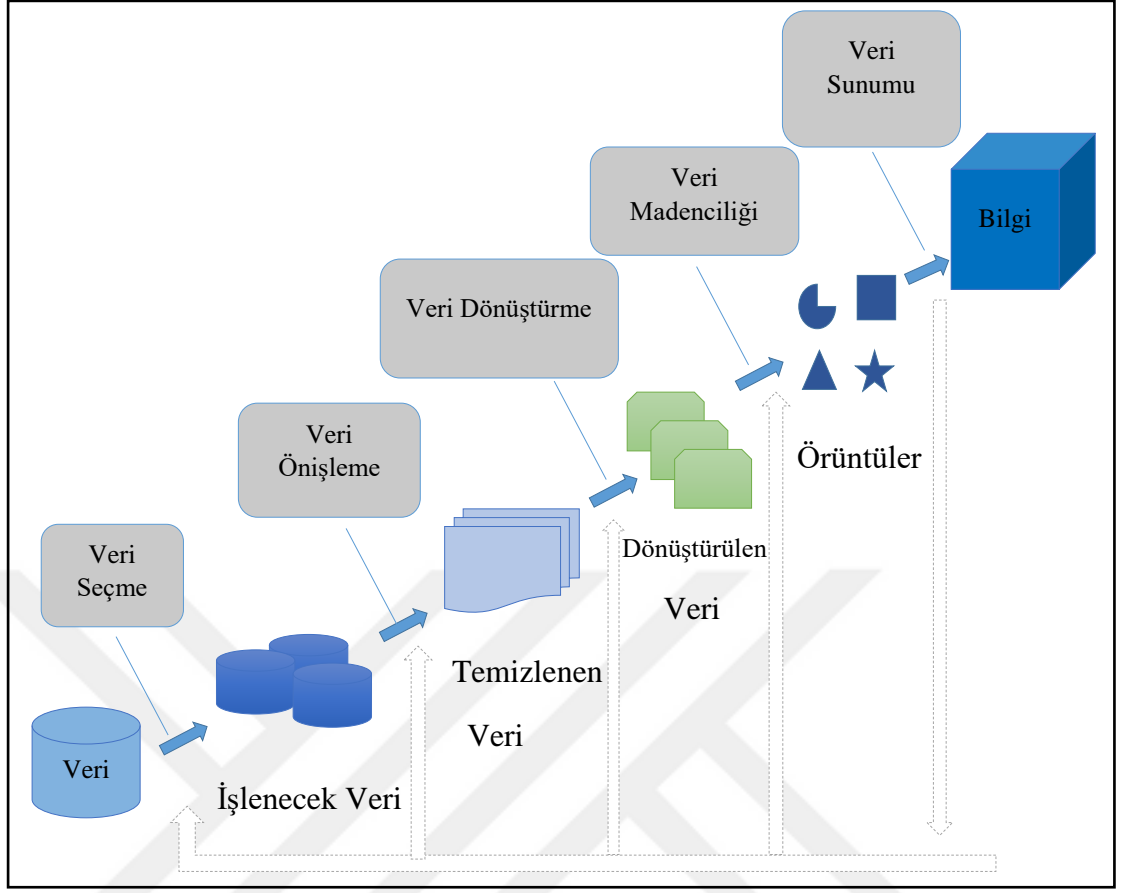
Veriyi değerli kılan olgu bilgiye dönüşmesidir. Bu nedenle bilgi keşfi için veriden bilgiye doğru çıkan basamaklarda KDD, CRISP-DM, SEMMA, FMDS gibi çeşitli süreçler söz konusudur. Bu çalışmada KDD, CRISP-DM ve FMDS süreçlerine değinilecektir.

#### 1.1.2.1. Veri Tabanından Bilgi Keşif Süreci (Knowledge Discovery in Databases)

Knowledge Discovery in Databases (KDD) Fayyad ve arkadaşları tarafından ileriye sürülmüş 5 adımlı bir süreç modelidir (Akpınar, 2014). KDD süreci aynı zamanda birbirleriyle etkileşimli ve yinelenen birçok adımla kullanıcıların farklı farklı kararlar almasını sağlar (Brachman & Anand, 1996). Ayrıca Piatetsky KDD süreci kullanım oranının 2007-2014 yılları arasında %7.3'den %7.5'e yükseldiğini belirtmiştir (Piatetsky, 2014) (Foroughi & Luksch, 2018).

Problemin tanımlı olduğu bir KDD sürecinin 5 adımı şu şekildedir (Fayyad, Shapiro, & Smyth, 1996) (Akpınar, 2014);

- I. Seçim
- II. Ön işleme
- III. Dönüştürme
- IV. Veri madenciliği
- V. Yorumlama

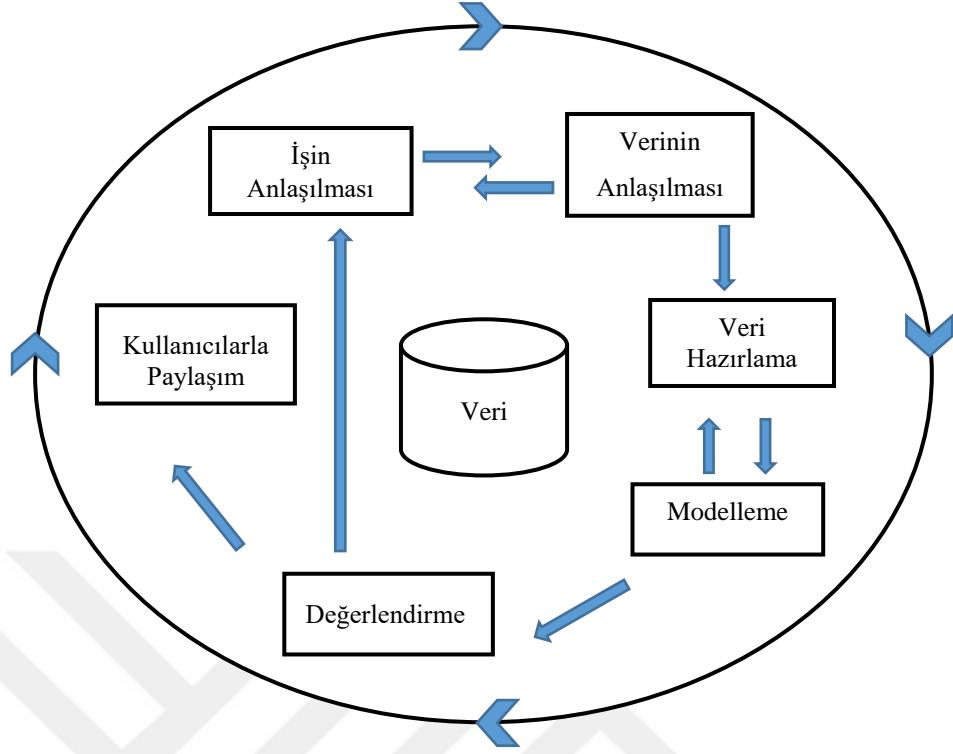


Şekil 1.2. Veri madenciliğinde bilgi keşfi süreci (Fayyad, Shapiro, & Smyth, 1996)

### 1.1.2.2. Çapraz Endüstri Standart Süreci (Cross Industry Standard Process for Data Mining)

Cross Industry Standard Process for Data Mining (CRISP-DM) 1996 yılının sonlarında Daimler Chrysler, SPSS ve NCR tarafından tasarlanmıştır ve 6 adımdan oluşur (CRISP-DM 1.0, 2000). Adımları şunlardır;

- I. İşin anlaşılması
- II. Verinin anlaşılması
- III. Veri hazırlama
- IV. Modelleme
- V. Değerlendirme
- VI. Kullanıcılarla Paylaşım

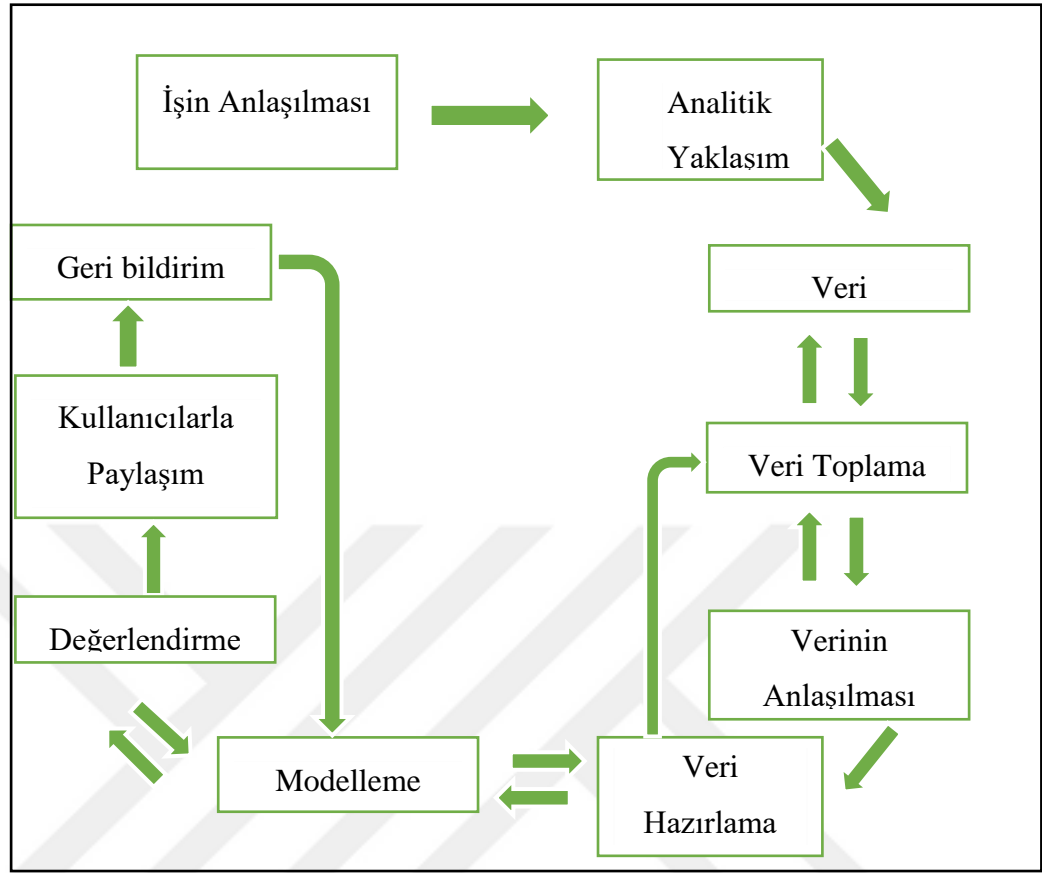


Şekil 1.3. CRISP-DM Süreci (CRISP-DM 1.0, 2000)

### 1.1.2.3. Veri Bilimi için Temel Metodoloji (Foundational Methodology for Data Science)

Veri bilimi için temel metodoloji (FMDS) KDD ve CRISP-DM süreçleriyle benzerliklerine ek olarak veri biliminde çok büyük veri hacimlerinin kullanımı, metin ve görüntü analizi, derin öğrenme, yapay zeka ve dil işleme gibi bir takım yeni uygulamalar sağlar. FMDS 10 adımdan oluşur (Rollins, 2015).

- I. İşin Anlaşılması
- II. Analitik Yaklaşım
- III. Veri Gereksinimi
- IV. Veri Toplama
- V. Verinin Anlaşılması
- VI. Veri Hazırlama
- VII. Modelleme
- VIII. Değerlendirme
- IX. Kullanıcılarla Paylaşım
- X. Geri bildirim



Şekil 1.4. FMDS Süreci

**İşin Anlaşılması:** İlk aşamada konunun amaç ve gereksinimleri belirlenir. Amaçlara ulaşabilmek için bir plan oluşturulur (Akpınar, 2014). Bu aşama en etkili çözümün yapılabilmesi için bir temel oluşturur.

**Analitik Yaklaşım:** Bu aşama konuyu istatistiksel ve makine öğrenme teknikleri bağlamında problemi ifade etmeyi gerektirir. Böylece istenen sonuca ulaşmak için uygun teknikler belirlenir (Rollins, 2015).

**Veri Gereksinimi:** Analitik yaklaşımın seçimi, veri gereksinimlerini belirler; kullanılacak analitik metotlar, alan bilgisi ile yönlendirilen belirli veri içeriği, formatları ve sunumları gerektirir (Rollins,2015).

**Veri Toplama:** Bu aşamada konuyla ilgili ve uygulanabilir olan mevcut veri kaynaklarını (yapılandırılmış, yapılandırılmamış ve yarı yapılandırılmış) belirlemek ve

toplamak gerekmektedir. Gerekirse veri gereksinimlerinin gözden geçirilmesi ve daha fazla veri toplaması gerekebilir (Foroughi & Luksch, 2018).

**Verinin Anlaşılması:** Bu aşama verileri veri içeriğini anlamak, veri kalitesini değerlendirmek ve verilerle ilgili ilk bilgileri keşfetmek gibi amaçları gerçekleştirecek faaliyetleri içerir. Ayrıca bu aşama veri toplama aşamasındaki boşlukları doldurmak için de gerekli olabilir (Rollins, 2015).

**Verinin Hazırlanması:** Veri hazırlama aşaması, modelleme aşamasında kullanılacak olan veri setini oluşturmak için kullanılan tüm etkinlikleri içermektedir. Bunlar, veri temizlemeyi, birden çok kaynaktan veri birleştirmeyi ve verileri daha kullanışlı değişkenlere dönüştürmeyi içerir (Rollins,2015).

**Modelleme:** Modelleme aşaması temel olarak, tahmini veya tanımlayıcı model geliştirme üzerine yoğunlaşmaktadır (Rollins,2015). Modellerde parametreler optimum çözüme ulaşacak şekilde belirlenir (Akpınar, 2014).

**Değerlendirme:** Kullanıcılarla paylaşmadan önce modelin etkinliğinin ve kalitesinin değerlendirildiği aşamadır (Rollins,2015).

**Kullanıcılarla paylaşma:** Elde edilen sonucun son kullanıcıyla paylaşılmasını ifade eden süreçtir. Söz konusu aşama gereksinimler doğrultusunda çok basit olabileceği gibi veri madenciliği sürecinin uygulaması kadar komplike de olabilir (Akpınar, 2014).

**Geri bildirim:** Uygulanan modelden sonuçlar toplayarak, kuruluş modelin performansı hakkında geri bildirim alır ve dağıtım ortamını nasıl etkilediğini gözlemler. Bu geribildirim analiz edilmesi, veri bilimcisinin modeli hassaslaştırmasını, doğruluğunu ve dolayısıyla kullanışlılığını artırmasını sağlar. Genellikle göz ardı edilen aşama, genel sürecin bir parçası olarak ele alındığında önemli ek faydalar sağlayabilir (Rollins,2015).



**Tablo 1.2.** KDD, CRISP-DM ve FMDS Arasındaki Uygunluk Karşılaştırması (Foroughi & Luksch, 2018)

KDD	CRISP-DM	FMDS
-----	İşin Anlaşılması	İşin Anlaşılması
-----	-----	Analitik Yaklaşım
-----	-----	Veri Gereksinimi
Seçim	Verinin Anlaşılması	Veri Toplama
Ön İşleme		Verinin Anlaşılması
Dönüştürme	Veri Hazırlama	Veri Hazırlama
Veri Madenciliği	Modelleme	Modelleme
Yorumlama	Değerlendirme	Değerlendirme
-----	Kullanıcılarla Paylaşım	Kullanıcılarla Paylaşım
-----	-----	Geri Bildirim

İşin anlaşılması ve kullanıcıyla paylaşma gibi iki önemli aşama CRISP-DM ve FMDS süreçlerinde mevcutken KDD sürecinde yer almamaktadır. Ayrıca veri toplama adımına gidilmeden önce uygun istatistiksel veya makine öğrenme tekniklerini tanımak için gerekli olduğu gibi uygun veri toplama stratejisi ve veri kaynaklarını tanımlamak için de oldukça faydalı olabilen analitik yaklaşım aşaması ve yüksek performanslı işlevsellik ve verimli sonuçlara ulaşmak amacıyla sistemi optimize etmek adına çok yararlı olan geri bildirim aşaması da KDD ve CRISP-DM süreçlerinde bulunmamaktadır. Önerdiği veri formatı ve temsilleriyle veri anlama aşamasını daha verimli hale getiren veri gereksinimi aşaması FMDS sürecinde yer almasına rağmen KDD ve CRISP-DM süreçlerinde bulunmamaktadır (Foroughi & Luksch, 2018).

### 1.1.3. Verilerin Hazırlanması

Çalışma için gerekli verilerin toplandıktan sonra yapılacak analiz için uygun hale getirilmesi işlemine veri hazırlanma veya veri ön işleme denir (Balaban & Kartal, 2016). Veri madenciliğinin başarısı ön işleme sonucunda elde edilecek veri kümesinin kalitesiyle doğru orantılıdır (Han & Kamber,2001) (Koçoğlu & Özcan, 2016). Ön işleme süreci temelde verilerin temizlenmesi ve verilerin yeniden yapılandırılması diye ikiye ayrılabilir (Silahtaroglu, 2013).

### 1.1.3.1. Verilerin Temizlenmesi

Veri temizlenmesi kayıp verilerin veya gürültülü verilerin veritabanından temizlenmesi işlemidir. Veri temizlenme kavramının tam olarak anlaşılması için gürültülü veri tanımının bilinmesi gereklidir. Veri setinde bulunan verilerin bazıları yanlış girilmiş veya aşırı uç değerlerde olabilir. Bu durumdaki verilere gürültülü veri denir (Han & Kamber,2001) (Silahtaroglu, 2013).

**Kayıp Veriler:** Kayıp veri sorununu çözmek için kullanılan yöntemler şu şekilde özetlenebilir (Han & Kamber, 2001) (Silahtaroglu, 2013).

- I. Kayıp verileri elle teker teker doldurmak
- II. Tüm kayıp verilere aynı bilgiyi girmek
- III. Kayıp olan verilere tüm verilerin ortalama değerinin verilmesi
- IV. Diğer değişkenlerin yardımı ile kayıp olan verilerin tahmini
  - a. Doğrusal interpolasyon yöntemiyle kayıp verilerin tahmini
  - b. "Maksimum Beklenti" yöntemiyle kayıp verilerin tahmini
  - c. Jackknife yöntemiyle kayıp verilerin tahmini

**Verilerdeki Gürültünün Temizlenmesi:** Yapılan çalışmanın sağlıklı olabilmesi için kayıp veriler gibi gürültülü verilerinde temizlenmesi gereklidir (Tagva & ark, 1994) (Silahtaroglu, 2013). Gürültülü verinin ortadan kaldırılması için yöntemler şu şekilde gösterilebilir:

- I. Kutulama yöntemiyle gürültünün ortadan kaldırılması
- II. Sınırlar yardımıyla düzgünleştirme yapılması ve gürültünün temizlenmesi
- III. Kümeleme yöntemiyle gürültünün temizlenmesi
- IV. Doğrusal regresyon (linear regression) (Enders, 2010) (Çam, 2014).

Gürültülü verilerin düzeltilmesi amacıyla en çok kullanılan ve kolay bir şekilde sonuca ulaştıran yöntemlerin kutulama yöntemi, doğrusal regresyon yöntemi ve kümeleme yöntemi olduğu söylenebilmektedir. (Enders, 2010) (Çam, 2014).

### 1.1.3.2. Verilerin Yeniden Yapılandırılması

**Verilerin Bütünleştirilmesi:** Veri bütünleştirmesinin açıklaması "veri ambarı" bölümünde açıklandığından bu bölümde tekrar edilmemiştir.

**Verilerin Dönüştürülmesi:** Veritabanlarını çoğunlukla sayısal ve sürekli veriler oluşturur. Fakat bazı veri madenciliği algoritmaları sadece kategorik veri değeriyle işlem yaparlar. Bu nedenle gelir, harcama, yaş vs. gibi sürekli verilerden oluşan veri setleri kategorik verilere dönüştürülmelidir (Silahtaroglu, 2013). Dönüştürme işleminde kullanılan bazı yöntemler aşağıda verilmiştir.

- a. Veri Normalizasyonu / Veri Standardizasyonu
- b. Görsel etiketleme Yöntemi
- c. 3-4-5 kuralı

**Veri Normalizasyonu:** Veri setindeki değerlerin aynı değer skalası içerisine alınması işlemine normalizasyon denir (Koçoğlu & Özcan, 2016). Mesafeye dayalı yöntemlerde normalizasyon herhangi bir nitelik alanının diğer nitelik alanları üzerinde dominant karaktere bürünerek sonuçları etkilemesini engellemeye yardımcı olur (Han, Kamber, & Pei,2012). Normalleştirilmiş veriler analize eşit şekilde etki ederler ve birbirleriyle karşılaştırılabilirler. Min- Max Normalizasyonu, Z- score Normalizasyonu, Ondalık ölçekleme ile Normalizasyon, Box-cox normalizasyonu en çok kullanılan veri normalleştirme tekniklerindedir (Koçoğlu & Özcan, 2016).

**Verilerin İndirgenmesi:** Veri madenciliği yöntemleri bakımından veri setinin büyüklüğü önemli olmakla birlikte bazı uygulamalar için kullanılan veri setlerinde çok sayıda parametre ve değişkenin varlığı analist için süreci yönetmeyi zorlaştırmaktadır. Bu tür durumlarda parametre ve değişken sayısının optimum seviyeye çekilmesi gerekir (Turban, Sharda, & Delen, 2011). Parametre ve değişken sayısının azaltılması işlemine veri indirgeme denir. Daha sağlıklı sonuçların elde edilmesi için ve kullanılan algoritmanın gerektirmesiyle bazı veriler birleştirilerek tek bir veri gibi işleme alınabilirler bu durum indirgeme işlemine önem kazandırır. Birleştirme işlemi temel bileşenler analizi ve dalga analizi ile yapılabilir. (Silahtaroglu, 2013). Veri indirgeme yapmanın birçok çeşidi vardır (Gezer, 2016);

- a. Veri birleştirme veya veri küpü
- b. Boyut indirgeme
- c. Veri sıkıştırma
- d. Kesikli hale getirme

Parametre seçimi işleminde kullanılan algoritmalar filtreleme modeli, sarmal modeli ve gömülü modeli olmak üzere 3 ana başlık altında incelenmektedir (Saeys, Inza, & Larranaga, 2007).

Filtre modeli algoritmalar, parametre seçiminde istatistiksel varsayımlardan yola çıkarak parametrelerin hedef özniteliğe erişim katkılarını belirleyip her bir parametre için bir skor döndürerek çalışırlar. Kolerasyon-bazlı parametre seçme (CFS), bilgi kazanımı (IG), ortak bilgi, Ki-kare, ReliefF ve F-skor algoritmaları filtre modeli parametre seçme algoritmaları olarak bilinirler (Gümüştü, Aydilek, & Taşaltın, 2016).

**Bilgi Kazanımı Yöntemi:** Entropiye dayalı yöntemlerden biri olan bilgi kazanımı yöntemi hedef özniteliğe ait en fazla bilgiyi içeren parametreleri belirlemek için her bir parametre için aşağıdaki denklem yardımıyla hesaplanır (Yazıcı, et al., 2015)

D: Veri seti

n: Belirlenmek istenen parametre sayısı

X: Bilgi kazanımı hesaplanmak istenen parametre

E(D): Veri setinin X üzerinden bölünmeden önceki entropisi

E(D<sub>i</sub>):i alt bölümünün X üzerinden bölünme olduktan sonraki entropisi

p(D<sub>i</sub>):i alt bölümünün X üzerinden bölünme olduktan sonraki olasılığı

$$\boxed{\text{Bilgi Kazanımı}(D, X) = E(D) - \sum_{k=1}^n p(D_k)E(D_k)} \quad \text{Denklem 1}$$

**Ki-kare Yöntemi:** Ki-kare yöntemi en fazla kullanılan filtre modeli algoritmalarından biridir. Ki-kare her bir değer için sınıf içi bağımlılığını ölçer. Bir özniteliğin ki-kare değerinin sifıra eşit olması o özniteliğin sınıftan bağımsız olduğu anlamına gelir. Ki-kare değeri aşağıdaki denklem yardımıyla hesaplanır (Yazıcı, et al., 2015).

k: Veri kümesindeki sınıf sayısı

A<sub>ij</sub>: Gözlenen frekans değeri (i satır, j sütün)

E<sub>ij</sub>: A<sub>ij</sub>'nin beklenen (teorik) frekans değeridir

R<sub>i</sub>:i'inci aralıktaki veri sayısı

C<sub>j</sub>:j'inci sınıftaki gözlemlerin sayısı

N:Sınıflardaki gözlem sayısı

$$X^2 = \sum_{i=1}^2 \sum_{j=1}^k \frac{(A_{ij}-E_{ij})^2}{E_{ij}}$$

Denklem 2

$$E_{ij} = \frac{(R_j * C_j)}{N}$$

Denklem 3

## 1.2. VERİ MADENCİLİĞİ YÖNTEMLERİ

Veri madenciliği temelde 2 işleve sahiptir. Bu işlevler tahminlemeye dayalı ve tanımlamaya dayalı işlevlerdir. Tahminlemeye dayalı işlevlerde amaç mevcut veriler kullanılarak bir tahmin modeli oluşturmak yani öngörü yapabilmektir. Tanımlamaya dayalı modellerde ise amaç isminden de anlaşılacağı gibi tahmin etmek değildir. Tanımlamaya dayalı modeller mevcut verileri gözlemleyerek veriler arasındaki örüntüleri tespit etmeyi ve benzer örüntülere sahip farklı veri kümelerinin özelliklerini tanımlamayı amaçlar (Altun, 2017). Tahminlemeye dayalı modeller denetimli veya danışmalı öğrenme kapsamına girerlerken tanımlamaya dayalı modeller denetimsiz veya danışmansız öğrenme kapsamında değerlendirilir (Argüden & Erşahin, 2008).

Tahminlemeye dayalı model yöntemlerinden bazıları şunlardır;

- 1- Sınıflandırma
- 2- Regresyon

Tanımlamaya dayalı model yöntemlerinin bazıları şunlardır;

- 1- Kümeleme
- 2- Birliktelik Kuralları
- 3- Ardışık Örüntüler

### 1.2.1. Sınıflandırma

Sınıflandırma yöntemi için “bağımsız değişken değerleri belli iken bağımlı değişkenin değerini/düzeyini tahmin etme işlemidir” tanımı yapılabilir (Zaki & JR, 2014) (Altunkaynak, 2017). Sınıflandırma veri madenciliği yöntemleri arasında en çok uygulaması olan yöntemlerden bir tanesidir. Uygulama alanları arasında hastalık tanıları, dolandırıcılık tespiti, pazarlama, kalite kontrol işlemleri vs. sayılmaktadır. Sınıflandırma için birçok algoritma söz konusudur. Bunlardan bazıları aşağıda verilmiştir (Silahtaroglu, 2013) (Altunkaynak, 2017);

- a) İstatistiğe dayalı yöntemler
  - Bayesyen sınıflandırma
  - CHAID
- b) Mesafeye dayalı algoritmalar
  - En yakın komşu
  - En küçük mesafe sınıflandırıcısı
- c) Karar Ağaçları
  - CART
  - ID3
  - C 4.5
  - Sprint
- d) Genetik algoritmalar
- e) Yapay sinir ağları
- f) Kural temelli yöntemler
  - ZeroR Yöntemi
  - OneR yöntemi

Sınıflandırma verilerin eğitimi ve modelin test edilmesine dayanan iki adımlı bir süreç şeklinde çalışır. İlk adımda eğitim verilerine bir algoritma uygulanarak bir model oluşturularak ikinci adımda oluşan modelin test verileri kullanılarak başarısı belirlenir (Emel & Taşkın, 2005).

Sınıflandırma sürecinin ilk aşamasında bahsedilen eğitim ve test veri setinin belirlenmesinde çeşitli yöntemler söz konusu olsa da Balaban ve Kartal'ın belirttiği en çok kullanılan üç yöntem şu şekilde sıralanabilir; (Balaban & Kartal, 2016)

- 1- Hold-out: Örneklerin rastgele seçimine dayanan bir yöntem olmakla beraber ve araştırmacılar tarafından sıklıkla kullanılır. Kullanılan algoritmanın daha fazla örnek görmesi ve çıkarımda bulunması sınıflandırma açısından daha sağlıklı olacağından eğitim veri setinin daha büyük olması tercih edilir. (Balaban & Kartal, 2016) Genelde analiz için verilerin 2/3 'ü eğitim verisi olarak 1/3'ü ise test verisi olarak kullanılır fakat farklı oranlarda ayrılmalarda yapılabilir. (Öğüdücü)
- 2- Çapraz Geçerleme

### 3- Tabakalı Örnekleme

İkinci aşamada bahsedilen model performansının değerlendirilmesi doğru algoritmayı seçmek bakımından da önemlidir. Model performansının ölçülebilmesi için çeşitli teknikler bulunmaktadır. Basit geçerlilik testi, karışıklık matrisi, K-kere çapraz doğrulama, Leave-One-Out yöntemi, bootstrapping yöntemi, Jackknifing yöntemi, ROC eğrisi bu tekniklerden bazılarıdır (Fakı, 2015).

**Karışıklık matrisi:** Sınıflandırma model performans değerlendirmelerinde sıklıkla kullanılan yöntemlerden biri olan karışıklık matrisi hata matrisi olarak da bilinir. Modelin başarısı verilerin doğru veya yanlış sınıflandırılmasıyla ilgi olduğundan modelin performansını belirleyebilmek için hata matrisi üzerinden bazı performans ölçümleri yapılır (Coşkun & Baykal, 2011). Birçok ölçüm çeşidi olmasına karşın doğruluk, hata oranı, kesinlik, duyarlılık, özgünlük ve F- ölçütü kullanılan temel ölçümlerdir (Selçukcan Erol, 2016).

**Tablo 1.3.** Karışıklık Matrisi

		Gerçek Durum	
		Doğru (+)	Yanlış(-)
Tahmin Durumu	Doğru(+)	Gerçek Pozitif (a)	Yanlış Pozitif (b)
	Yanlış(-)	Yanlış Negatif (c)	Gerçek Negatif (d)

Temel ölçümlerin formülleri aşağıda belirtilmiştir (Altunkaynak, 2017).

Doğruluk: En çok kullanılan ve en basit ölçüttür.

$$\text{Doğruluk} = \frac{a+d}{a+b+c+d}$$

Hata oranı: Doğruluğu 1'e tamamlayan değerdir. Yani yanlış sınıfa atanan verilerin toplamının toplam veri sayısına oranıdır.

$$\text{Hata oranı} = 1 - \text{doğruluk} \Rightarrow \text{hata oranı} = \frac{c+b}{a+b+c+d}$$

Kesinlik (pozitif kestirim değeri)

$$\text{Kesinlik} = a / a+b$$

Duyarlılık (doğru pozitif oranı)

$$\text{Duyarlılık} = a/a+c$$

Kesinlik ve duyarlılık ölçümleri sadece olumlu gerçeklik ve öngörülere odaklandıklarından modelin olumsuz durumlarda işleyişi hakkında bilgi vermezler.

Bu durum söz konusu iki değişkenin harmonik ortalaması olan F ölçümü için de geçerlidir (Powers, 2011) .

$$\text{Özgüllük} = d/d+b$$

$$F = 2 * \text{duyarlılık} * \text{kesinlik} / \text{duyarlılık} + \text{kesinlik}$$

### 1.2.1.1. Karar Ağaçları

Karar ağaçları sınıflandırma yöntemleri içinde en çok kullanılan algoritmalarıdır. Bu durumun nedenleri arasında karar ağaçlarının daha düşük maliyetli olması, yorumlanması ve anlaşılabilirliğinin kolay olması, veri tabanlarıyla entegrasyonunun rahatlığı, güvenilirlik düzeyinin yüksek olması vs. etmenler sayılabilir (Çalış, Kayapınar, & Çetinyokuş, 2014).

Karar ağaçları iki adımla oluşurlar. Birinci adımda ağacın kurulumu yapılırken ikinci adımda sınıflandırma işlemi yapılır (Altunkaynak, 2017). Karar ağaçları, doğada bulunan ağaçların yapısında olup kök, dal ve yapraklardan oluşur. Çalışma prensibi olarak kökten yapraklara doğru bir yol izlenir bu nedenle karar ağaçlarında tümden gelim söz konusudur (Akpınar, 2014).

Karar ağacı algoritmaları mümkün olduğu kadarıyla küçük ve az derinlikli ağaçlar oluşturarak genelleştirme hatalarını minimuma indirmeyi amaçlarlar (Onan, 2015). Etkili bir karar ağacı oluşturmak için seçilen algoritma sonucu etkilemesi bakımından önemlidir. Çünkü farklı ağaç yapıları farklı sınıflandırmalar oluşturur (Silahtaroglu, 2013). Bu nedenle algoritmalar arasında farklılık oluşturan temel özellikleri bilmek doğru algoritmayı seçmek için önemlidir. Söz konusu özellikler şöyledir (Akpınar, 2014);

**Algoritmanın kullandığı ölçü skalası:** Kullanılan skala kategorik veya sürekli olabilir (Akpınar, 2014).



**Ortaya çıkan yeni düğüm sayısı:** Her dallanmadan sonra ortaya çıkan düğüm sayısı algoritmaya göre ikili, üçlü veya daha fazla olabilir (Akpınar, 2014). Belirtmek gerekir ki ikili olmayan ağaçlar veriler nominal olduğunda anlamlıdır (Rutkowski, Jaworski, Pietruczuk, & Duda, 2014).

**En iyi bölen özneliğin seçilmesi için kullanılacak yöntemler:** Karar ağacı oluşturmada önemli bir nokta da parametre seçimidir (Rutkowski, Jaworski, Pietruczuk, & Duda, 2014). Ölçü skalasına göre uygun yöntemler kullanılır. Bunlardan bazıları şunlardır; kategorik veriler için entropi, gini, sınıflandırma hatası endeksleri, twoing veya ordered twoing (sadece ordinal değişkenler için) kullanılırken sürekli değişkenler için en küçük kareler sapması kullanılır. (Akpınar, 2014)

**Budama süreci:** Aşırı öğrenmenin gerçekleştiği durumlarda meydana gelen etkileri minimuma indirerek daha sağlıklı bir karar ağacı oluşturmak amacıyla gereksiz dalların ortadan kaldırılması işlemidir. Maliyet-karmaşıklık budama, en düşük hata budama yöntemi, azaltılmış hata budaması, kötümser hata budaması, genetik algoritma kullanarak budama (Gümüşçü, Taşaltın, & Aydilek, "C4.5 Karar Ağaçlarında Genetik Algoritma İle Budama", 2016), ön budama yöntemi (Kavzoğlu & Çölkesen, 2010) gibi birçok yöntemin yanı sıra Gümüşçü ve arkadaşları Genetik Algoritma ile Son Budama (GASB) metodu adıyla yeni bir budama yöntemi önermişlerdir (Gümüşçü, Taşaltın, & Aydilek, 2016).

#### 1.2.1.1.1. C 5.0 Algoritması

C5.0 algoritması C4.5 algoritmasının uzantısı olması nedeniyle benzer bir şekilde C4.5 algoritmasının kurallarını takip eder (Pandya & Pandya, 2015). Verimlilik ve hafıza bakımından C4.5 algoritmasından daha iyidir. C 5.0 algoritması maksimum bilgi kazancı sağlayan nitelikten bölünme temelinde çalışır ve büyük veri kümelerine uygulanır (Patil, Lathi, & Chitre, 2012). Bu özelliklere ek olarak C5.0 algoritması gürültülü ve eksik veriler hakkında bilgi vermekle beraber aşırı uyum ve hata budama problemini de çözmektedir (Pandya & Pandya, 2015).

#### 1.2.1.1.2. Gini Algoritması

Gini algoritması CART algoritmalarından olduğundan ikili ağaç (binary tree) yapısına sahiptir (Altunkaynak, 2017). Bölünmenin ilk olarak başlayacağı niteliği

belirlemek için gini indeksinden faydalanılır. Gini indeks değerinin minimum olduğu nitelik bölünmenin başlayacağı nitelik olarak kabul edilir (Adak & Yurtay, 2013). Gini indeksi niteliklerin zayıflıklarını belirler (Mather, 1987) (Atasever, 2011). Burada budama işlemi karmaşıklık ölçüsüne dayanır (Emel & Taşkın, 2005). Her bir nitelik için gini indeksi hesaplanırken ilk etapta sağ ve sol gini indeks değerleri hesaplanması gerekir. Sağ ve sol gini indeks değerleri aşağıdaki gibi hesaplanır.

k: Sınıfların sayısı

T: Bir düğümdeki örnek sayısı

T<sub>sol</sub>: Sol koldaki örneklerin sayısı

T<sub>sağ</sub>: Sağ koldaki örneklerin sayısı

L<sub>i</sub>: Sol kolda i kategorisindeki örneklerin sayısı

R<sub>i</sub>: Sağ kolda i kategorisindeki örneklerin sayısı

$$Gini_{sol} = 1 - \sum_{i=1}^k \left[ \frac{L_i}{|T_{sol}|} \right]^2$$

Denklem 4

$$Gini_{sağ} = 1 - \sum_{i=1}^k \left[ \frac{R_i}{|T_{sağ}|} \right]^2$$

Denklem 5

Sağ ve sol gini indeks değerleri hesaplandıktan sonra gini indeks değeri şu formülle hesaplanmaktadır.

$$Gini_j = \frac{1}{n} (|T_{sol}| Gini_{sol} |T_{sağ}| Gini_{sağ})$$

Denklem 6

### 1.2.2. Kümeleme Analizi

Kümeleme veri setinde bulunan verilerin benzerliklerine göre gruplandırılması işlemidir. Kümeleme işleminde amaç aynı küme içinde bulunan verilerin birbirleriyle olabildiğince benzer diğer kümedeki verilerle de olabildiğince farklı bir şekilde kümelenecek analist için bilgileri daha anlaşılır kılmaktır (Jipkate & Gohokar, 2012).

Genel olarak kümeleme algoritmaları hiyerarşik ve bölünmeli olmak üzere ikiye ayrılabilirken literatürde birçok ayırım mevcuttur. Hiyerarşik kümeleme yöntemleri kullanıldığında kümeler yukardan aşağıya (bölünür kümeleme algoritmaları) veya tersi şeklinde aşağıdan yukarıya (toplaşım kümeleme algoritmaları) olarak aşamalı bir şekilde

oluşturulurken bölümlenmeli yöntemlerde küme sayısı hakkında bir ön fikir söz konusudur (Taşkın & Emel, 2010). Ayrıca bölümlenmeli yöntemler tek seviyeli kümeleme yaparken hiyerarşik yöntemler iç içe bir kümeleme yapısını kullanırlar (Jain, Murty, & Flynn, 1999) (Sarıman, 2011).

**Tablo 1.4.** Hiyerarşik ve Bölümlenmeli Kümeleme Yöntemlerinin Genel Özellikleri (Han, Kamber, & Pei, 2012).

<b>Hiyerarşik Kümeleme Yöntemleri</b>	<b>Bölümlenmeli Yöntemler</b>
<ul style="list-style-type: none"> <li>❖ Kümeleme, hiyerarşik bir ayrıştırımadır (çok seviyeli)</li> <li>❖ Hatalı birleştirmeleri veya bölmeleri düzeltemez</li> <li>❖ Mikro kümeleme veya "eklenmemiş mekanizmalar" nesnesi gibi diğer teknikleri de içerebilir.</li> </ul>	<ul style="list-style-type: none"> <li>❖ Karşılıklı olarak küresel şekilli kümeler bulunur</li> <li>❖ Uzaklık tabanlıdır</li> <li>❖ Küme merkezini temsil etmek için ortalama veya medoid (vb.) kullanabilir</li> <li>❖ Küçük ve orta büyüklükteki veri setleri için etkilidir</li> </ul>

Berkhin'in çalışmasında söz konusu ayrımlar şu şekilde gösterilmiştir; (Berkhin)

- Hiyerarşik Kümeleme Yöntemleri
  - Toplaşım Kümeleme Algoritmaları
  - Bölünür Kümeleme Algoritmaları
- Bölümlenmeli Yöntemler
  - Yer Değiştiren Algoritmalar
  - Olasılıksal Algoritmalar
  - K-Medoid Yöntemler
  - K-Means Yöntemler
  - Yoğunluğa Dayalı Algoritmalar
- Grid temelli yöntemler
- Kategorik verinin yinelenmesine dayalı yöntemler
- Kısıtlara dayanan yöntemler
- Makine öğrenmesi alanında kullanılan yöntemler

Ayrıca Akpınar(2014)'ın belirttiğine göre kümeleme algoritmaları hard ve soft olarak da ayrılabilir (Akpınar, 2014). Hard (sert) kümeleme mantığında her veri tek bir kümeye ait olabilirken soft (yumuşak) kümelemede ise veriler farklı düzeylerde birden çok kümenin üyesi olabilirler. Soft (yumuşak) kümeleme veriyi tek bir kümeye ait olamaya itmediğinden hard(sert) kümelemeye göre daha sağlıklı kümeleme olanağı sunmaktadır (Cebeci & Yıldız,2015). Ayrıca belirtilmelidir ki kümeleme algoritmalarının büyük çoğunluğu hard kümeleme amaçlıdır (Akpınar, 2014).

### 1.2.2.1. K-prototypes

Zamanla veri setlerinin heterojenleşmesi sonucu veriyi analiz etmek daha da karmaşık bir sorun haline gelmiştir. Verilerin tamamen kategorik veya numerik olamaması durumunda (hibrid veri seti) geleneksel yöntemleri doğrudan kullanmak uygun olmadığından veriler üzerindeki sınırlılığı kaldırmak amacıyla verilerin bir ön işleminden geçmesi genellikle gereklidir (Kacem, N'cir, & Nadia, 2015). Verilerin sınırlılıkları kategorik verilerde basit eşleştirme mesafesini kullanarak veya modlara göre küme ortalamalarının yerleri değiştirilerek kaldırılabilir (Huang Z., 1998) (Wang, Franco, Pugh, & Ross, 2016).

Bununla beraber hibrid veri tiplerini kümelemek için bazı kümeleme yöntemleri önerilmiştir. 1997 'de Huang (Huang, 1997) tarafından önerilen K- prototip (K-Prototype) algoritması en iyi bilinen hibrid veri kümeleme yöntemlerinden bir tanesidir (Ji, et al., 2015). K-prototip algoritması hibrid veri tiplerini kümelemek için k-ortalamar ve k-modes algoritmalarını birleştirir (Huang, 1997). K-prptotip algoritmasının kümeleme süreci k-modes yaklaşımını kulanmasının dışında k- ortalamar algoritmasına benzerdir. Söz konusu algoritmda k-ortalamar algoritması ile aynı uygulama süreci kullandığından k-ortalamar algoritmasının verimliliği korunur (Huang, 1998). K-prototipler algoritması, k-ortalamar algoritması gibi aşağıdaki adımları içerir (Huang, 1997);

1. Veri kümesindeki kümeleri temsil etmek için k başlangıç merkezi (Prototip) seçilir.
2. Veri kümesindeki her bir nesne en yakın prototipi içeren kümeye atanır.

3. Nesnelerin hepsi atandıktan sonra küme prototipleri yeniden hesaplanır ve her bir nesne yeni merkezlere göre yeniden atanır.
4. Bütün nesnelere bitene kadar 3. Adım tekrarlanır.

### 1.2.3. Birliktelik Kuralları (İlişkilendirme kuralları)

Birliktelik kuralları, veri tabanında mevcut olan parametreler arasındaki ilişkileri saptamak için kullanılan etkili bir algoritmadır (Agrawal, Imielinski, & Swami, 1993). Ayrıca bir birliktelik kuralı, veri tabanındaki spesifik durumların senkronize bir şekilde meydana gelmeleriyle bağlantılı bir olasılık ifadesidir ve genelden özele bir arama yöntemi kullanır. Makine öğrenimi literatüründe birçok farklı kural bulma algoritması mevcutsa da, birliktelik kuralı algoritmaları, çok büyük veri kümelerinde nispeten verimli bir şekilde çalışmak üzere özel olarak tasarlanmıştır (Hand, Mannila, & Smyth, 2001). Oldukça önemli bir veri madenciliği tekniği olan birliktelik kuralları denetimsiz öğrenme sistemlerinin belki de en yaygın yerel model keşif şekli olabilmekle birlikte veriler arasında farkındalığı zor olan bağlantıları saptar (Kantardzic, 2011).

Genel olarak birliktelik kuralları iki aşamalı bir süreç şeklinde düşünülebilir. İlk olarak sık kullanılan öğeler bulunur daha sonra sık kullanılan öğelerden ilişkilendirme kuralları oluşturulur. Sık kullanılan öğelerden kasıt analist tarafından belirtilen asgâri düzeyde minimum destek değerini sağlayan öğelerdir. Bunlarla beraber birliktelik kuralları algoritmalarının genel performansı birinci adımda belirlenir (Han & Kamber, 2006).

Bir birliktelik kuralı  $A \rightarrow B$  şekline gösterilir. Bu ifade ile A'nın (öncül) meydana gelmesi durumunda B'nin (sonuç) de meydana gelmesi durumu anlatılmaktadır (Agrawal, Imielinski, & Swami, 1993). Yani B'nin A'ya bağımlılığı söz konusudur.

Bir kuralın etkisini belirlemeye yardımcı olmak için güven ve destek parametreleri kullanılabilir. Destek değeri A ve B nesnelere bütünü veri tabanında birlikte yer alma ihtimallerini verirken güven değeri ise A'nın kapsadığı durumların B'yi de kapsama yüzdesidir (Karahana Adalı, 2016). Güven değeri  $P(B|A)$  şeklinde, destek değeri ise  $P(A \cup B)$  şeklinde bir olasılık tahmini olarak düşünülebilir (Han & Kamber, 2006). Analiz sonucunda yüksek destek ve güven değerine sahip kurallar güçlü kurallar olarak

adlandırılırlar (Agrawal, Imielinski, & Swami, 1993). Destek ve güven değerleri aşağıda belirtilen denklemler yardımıyla hesaplanır.

$$Destek(A \rightarrow B) = \frac{n(AUB)}{n(N)} \quad \text{Denklem 7}$$

n(AUB): A ve B'nin beraber bulunduğu durumların sayısı  
n(N): toplam durum sayısı

$$Güven(A \rightarrow B) = \frac{n(AUB)}{n(A)} \quad \text{Denklem 8}$$

n(AUB): A ve B'nin beraber bulunduğu durumların sayısı  
n(A): X'i kapsayan durum sayısı

Birliktelik kurallarında veri bilimcisi destek ve güven değerleri için minimum bir eşik değeri belirler (Han & Kamber, 2006). Genellikle destek değeri 0.30 olarak alınırken güven değeri 0.50 veya üzerinde bir değer alınır (Altunkaynak, 2017).

Kaldıraç değeri, A ve B'nin istatistiksel olarak bağımsız olması durumunda veri setinde ne kadar ihtimalle beraber bulduklarını gösteren değer olarak tanımlanabilir. Kaldıraç değeri kuralın güvenilirliği hakkında bilgi verdiği için, kaldıraç değerinin 1'den büyüklüğüyle ilişkinin güvenilirliği arasında bir doğru orantının varlığı söz konusudur.

Güven değerinin destek değerine oranı ile ifade edilen kaldıraç değeri aşağıdaki denklem yardımıyla hesaplanır (Karahan Adalı, 2016).

$$Kaldıraç(A \rightarrow B) = \frac{Güven(A \rightarrow B)}{Destek(A \rightarrow B)} \quad \text{Denklem 9}$$

Bir kuralın destek değerinin yüksekliği kuralın yinelenme sıklığıyla doğru orantılıyken güven değerinin yüksekliği kuralın istisnai durum sayısı ile ters orantılıdır (Plasse, 2005). Ayrıca destek ve güven değerleri yüksek olan kurallara güçlü kurallar denilmektedir (Agrawal, Imielinski, & Swami, 1993).

### 1.2.3.1. Apriori Algoritması

Apriori algoritması, birliktelik kuralları çıkarmak amacıyla bilinirlik ve kullanım yaygınlığı bakımından en üst seviyede olan birliktelik kuralı algoritmasıdır (Silahtaroglu, 2013). Söz konusu algoritma iteratif temele dayanmaktadır (Han & Kamber, 2006) ve veri tabanında sık tekrarlanan veri kümelerini bulmak için veri tabanını birçok defa

taramaktadır (Sever & Oğuz, 2003). Apriori algoritması sık tekrarlanan veri kümesinin alt kümelerinin de sık tekrarlanması esasına dayanır (Tan, Steinbach, & Kumar, 2005). Apriori Algoritmasının adımları aşağıdaki gibi sıralanabilir (Karahan Adalı, 2016).

1. Minimum destek ve minimum güven değerleri atanır
2. Her seçenek için destek değeri hesaplanır
3. Minimum destek değer eşliğinin altında kalan seçenekler elimine edilir
4. Meydana gelen tekli birliktelikler dikkate alınarak ikili birliktelikler oluşturulur
5. Minimum destek değerinden düşük olan seçenek kümeleri çıkartılır
6. Üçlü birlikler oluşturulur
7. Üçlü birlikteliklerden minimum destek değerini aşamayanlar devre dışı bırakılır
8. Üçlü birlikteliklerden birliktelik kuralları çıkarılır

### 1.3. SAĞLIK ALANINDA VERİ MADENCİLİĞİ ÇALIŞMALARI

Literatürde bu alanda çeşitli yöntemler kullanılarak yapılan farklı çalışmalar mevcuttur. Bu çalışmalardan bir kaçına değinilmesi hem konunun önemini kavranması hem de çalışmanın alt yapısını oluşturan uygulamanın daha iyi anlaşılabilmesi bakımından önemlidir.

Danacı ve arkadaşları Irvine California Üniversitesi veri madenciliği havuzundan aldıkları 569 hastanın meme altı doku örneklerini C4.5 sınıflandırma algoritması ile sınıflandırarak hastalık tahmini yapmayı amaçlamışlardır. Yapılan sınıflandırma sonucunda %97,4359 doğruluk oranı ile hastalık tanısı konulabilmiştir (Danacı, Çelik, & Akkaya, 2010).

Yapılan çalışmada beyin ve damar hastalıklarını önleme ve tedavi programından 493 adet geçerli numune örneği alınarak karar ağacı, Bayesyen sınıflandırma ve geri beslemeli sinir ağı olmak üzere 3 farklı yöntem uygulanmıştır. Uygulanan yöntemler duyarlılık ve doğruluk bazında karşılaştırılıp optimum yöntemin %99.48 duyarlılık ve %99.59 doğruluk oranıyla karar ağacı algoritması olduğu belirlenmiştir. Ayrıca söz konusu hastalığın tanısında etkili olan 8 önemli etken ve 16 tane tanı sınıflandırma kuralı çıkmıştır (Yeh, Cheng, & Chen, 2011).

Xie ve Wang dermatoloji veri setini kullanarak hastalık teşhisi yapmak amacıyla “yeni bir hibrid özellik seçimi yöntemi olan destek vektör makineleri (SVM) temelli bir tanı modeli” oluşturmuşlardır. Bu tanı modeli ile %98.61 oranında doğruluk değeri elde edilmiştir (Xie & Wang, 2011).

Yıldız ve arkadaşları meme kanseri gibi önemli bir rahatsızlığın erkenden fark edilmesi amacıyla hastalıkta dominant karakterde olan genlerin saptanması için “veri füzyonu ve genetik algoritma tabanlı yeni bir nitelik seçme metodu” önererek sonuçta tespit edilen 10 genin sınıflandırma doğruluk oranının %94,65 olduğunu saptanmışlardır (Yıldız, Tez, Bilge, Akcayol, & Güler, 2012).

Çataloluk tarafından gerçekleştirilen çalışmada dermatolojide bulunan erythematous squamous hastalıklarının tanısına yardım amacıyla bir karar destek sistemi tasarımı hedeflenmiştir. Kullanılan veri seti ilk etapta 366 kayıttan oluşsa da veri ön işleme işlemleri sayesinde 358 kayıta indirilerek analizler bu kayıtlar üzerinden gerçekleştirilmiştir. Bu tasarım için veri madenciliği yöntemlerinden k-en yakın komşu algoritması (kNN) ile k-means algoritması kullanılarak hekimlere doğru tanı için yardımcı olacak bir sistem geliştirilmiştir (Çataloluk, 2012).

Veri madenciliği yöntemleri ile tasarlanan bir tıbbi karar destek sistemi için sınıflandırma tahmin modeli ve hibrid tahmin modeli ile iki farklı model Metastatik kolorektal kanser veri seti ve diyabet hastalığı veri seti olmak üzere iki ayrı veri seti üzerinden geliştirilmiştir. Sınıflandırma algoritması olarak Destek Vektör Makineleri, Naive Bayes, Karar Ağaçları, Yapay Sinir Ağları, Çok Katmanlı Algılayıcı, Lojistik Regresyon algoritmaları kullanılmış olup Metastatik kolorektal kanser veri setinde sınıflandırma tahmin modelinde Destek Vektör Makineleri en başarılı algoritma olurken hibrid tahmin modelinde ise karar ağaçları ve yapay sinir ağları en başarılı algoritmalar olmuşlardır. Diyabet veri setinde ise en başarılı algoritma Çok Katmanlı Algılayıcı algoritması iken en başarısız algoritma karar ağaçları algoritmasıdır (Pala, 2013).

Elmas’ın yaptığı tez çalışmasında 153 kalp krizi vakasında kan değerlerinde oluşan ortak değişimler saptanarak kalp krizinin ön sinyallerinin tespit edilmesi amaçlanmıştır. Bu amaç doğrultusunda birliktelik kurallarından Apriori ve Gri algoritmaları kullanılmış olup sonuçta Apriori algoritması 5000’den fazla kural oluştururken Gri algoritması 2000 tane kural oluşturularak kural bazında Apriori algoritmasının gerisinde kalmıştır. Fakat her



iki algoritmanın da ürettiği en anlamlı ve en geçerli kurallar, hasta verileri üzerinde denendiğinde kalp krizi vakasını Apriori algoritması %72, Gri algoritması ise %68 oranla tespit etmiştir. Tespit bazında değerlendirildiğinde her iki algoritma birbirlerine paralel bir başarı göstermiştir (Elmas, 2014).

Çam'ın yaptığı çalışma Sivas ilinde 2011 yılında Cumhuriyet Üniversitesi Hastanesi'ne gelen 18-65 yaş aralığında olan hastaların verilerine kümeleme analizi yöntemlerinden olan K-Ortalamlar ve Yoğunluk tabanlı kümeleme algoritması yöntemlerini uygulayarak hastaların yaşlarının kümelere göre farklılık gösterdiğini ve de genç hastaların daha farklı teşhislerle ileri yaştaki hastaların ise daha az çeşitli hastalıklarla hastaneye başvurduklarını ortaya çıkarmıştır (Çam, 2014).

Yapılan bu çalışma 418 küçük hücreli dışı akciğer kanseri (KHDAK) hastanın geçmiş verileri üzerinden iki aşamalı olarak tamamlanmıştır. Çalışmanın ilk aşamasında Bayesyen, Karar Ağaçları, Yapay Sinir Ağları gibi farklı sınıflandırma yöntemleriyle WEKA programında mevcut olan veri için uygun sınıflandırma algoritmaları kullanılarak sınıflandırma işlemi gerçekleştirilmiştir. %81.69 doğruluk oranıyla en doğru sınıflandırmayı Naive Bayes sınıflandırma algoritmasının gerçekleştirdiği görülmüştür. Çalışmanın ikinci aşamasında ise maliyete duyarlı meta öğrenme yöntemleri ile birinci aşamada kullanılan maliyete duyarsız sınıflama algoritmalarını hiçbir değişiklik yapmadan maliyete duyarlı hale getirilip sınıflama işlemi yenilenmiştir. Maliyete duyarlı sınıflandırmada ise sonuç olarak bayes. NaiveBayes ve trees.NBTree algoritmalarının en düşük maliyet ve en yüksek doğruluk oranı ile sınıflandırmayı gerçekleştirdiği belirlenmiştir (Kayışoğlu, 2014).

Topaloğlu ve Sur'un yapmış oldukları çalışmada sarılık tanısı konulmuş 300 hastanın verileri üzerinde C5.0 ve J48 algoritmalarıyla karar ağaçları oluşturulmuştur. Oluşturulan karar ağaçları "*en sağlıklı budama ile 16 hastalığa %100 hatasız ulaşmıştır*". (Topaloğlu & Sur, 2015).

Senthilkumar ve Paulraj 'ın düşük doğum ağırlığı için risk faktörlerini belirlemek amacıyla yaptığı çalışmada farklı veri madenciliği yöntemleri kullanılarak düşük doğum ağırlığını etkileyen başlıca parametrelerin annenin ağırlığı, annenin yaşı, gebeliğin ilk üç ayında yapılan hekim ziyaretlerinin sayısı ve önceden yapılan erken doğum sayısı olduğu tespit edilmiştir (Senthilkumar & Paulraj, 2015)

Demircioğlu ve Bilge'nin yumurtalık kanseri gen veri kümesinde inceleme yapabilmek için optimum gen sayısını belirlemek amacıyla yaptıkları çalışmada yumurtalık kanseri gen veri kümesi içerisinde 253 tane örnekle beraber 15154 tane de gen mevcuttur. Veri setini sınıflandırmak için k en yakın komşu (kNN) ve destek vektör makineleri (SVM) algoritmaları uygulanmış olup veri setinin %40'ı eğitim, % 60'ı test verisi olarak rastgele belirlenmiştir. Sonuç olarak mevcut veri kümesi için yüzlerce hatta binlerce genle çalışmak yerine 100 gende inceleme yapılması yeterli bulunmuştur. (Demircioğlu & Bilge, 2015)

Erkuş'un çalışmasında 604 tane kayıt üzerinden cinsiyet, yaş, beden kitle indeksi, sigara kullanımı, diyabet, HDL, LDL, HGB, BUN, WBC, PLT, Ürik Asit ve PDW parametrelerine HNB, AODE, LBR, WAODE, Classification Via Regression, Dagging, LMT, Simple Logistic, RBFNetwork, Decision Table algoritmaları olmak üzere 10 farklı sınıflandırma algoritması kullanılarak KVH (Kardiyovasküler hastalık) teşhisi koymak amaçlanmıştır. Yapılan analizler sonucunda yaklaşık olarak %84,8 doğruluk oranıyla HNB algoritması mevcut algoritmalar arasında teşhis koymak için en başarılı algoritma olmuştur (Erkuş, 2015).

Anemi hastalarının hastalık tipini belirlemek amacıyla yapılan çalışmada 323 kişilik veri setinde 221 kişi farklı anemi çeşitlerinden tanı konulan hastalardan seçilirken 102 kişi ise hematolojik açıdan sağlıklı kişilerden seçilmiştir. Seçilen kişilerin tam kan sayımı test değerleri üzerinden Yapay Sinir Ağları, Karar Ağaçları, K-En Yakın Komşu ve Bayesyen Sınıflandırma yöntemleriyle sınıflandırma yapılmıştır. Yapılan sınıflandırma sonucunda %76,77 ile doğruluk oranı en fazla olan sınıflandırma yöntemi yapay sinir ağları olmuştur (Fakı, 2015).

Şatır ve arkadaşlarının glokom hastalığının teşhisi amacıyla yapılmış 168 kişilik veri setine ID3, C4.5, CART algoritmaları ile yapay sinir ağları uygulanmıştır. Çalışma 5 nitelik ile 2'den10'a kadar küme sayısı kullanılarak ulaşılan sonuçta C4.5 algoritması 6'lı küme üzerinde % 93.45 ile en yüksek başarı oranına sahip olan karar ağacı olurken bu başarı oranı yapay sinir ağlarında ise 4 doğrulama sayısında %91.67+/- %2.66'dır. (Şatır, Azboy, Aydın, Arslan, & Hacıfendioğlu, 2016).

Veri madenciliğinin uygulandığı başka bir çalışmada Rubio-Escudero ve arkadaşlarının 2571 hastanın veri seti üzerine k-means algoritması uygulayarak "laktoz

*absorpsiyonu üzerine hidrojen üretiminin yeni modelleri*”nin tanımlandığı çalışmadır. (Rubio-Escudero, et al., 2017).

Konjenital kalp kusurlarının öngörülmesi (KKH) için modeller üretmek amacıyla yapılan çalışmada 33831 vaka için veri madenciliği sınıflandırma yöntemlerinden rastgele orman, lojistik regresyon ve destek vektör makinaları algoritmaları kullanılmıştır. Kullanılan yöntemlerin performanslarını değerlendirmek için doğru pozitif oran, doğru negatif oran, doğruluk, ağırlıklı ACC, G ortalaması ve eğrilerin altındaki alan metrikleri kullanılmıştır. Destek vektör makinaları doğru pozitif oran, doğruluk, ağırlıklı ACC ve G ortalaması metriklerinde en iyi sonucu göstererek en iyi performansa sahip sınıflandırma yöntemi olarak belirlenmiştir (Luo, et al., 2017).

Abdar ve arkadaşlarının çalışmasında 583 kişilik UCI karaciğer hastalığı veri setinde C5.0 ve CHAID algoritmaları kullanılarak analiz yapılmıştır. CHAID algoritmasının doğruluk oranı % 65 iken C5.0 algoritmasının %93.75’lik doğruluk oranıyla en iyi performansa sahip olduğu belirlenmiştir. Ayrıca kadınların erkeklere oranla daha fazla karaciğer hastalığına yakalanma riski taşıdığı sonucuna da ulaşılmıştır (Abdar, Zomorodi Moghadam, Das, & Ting, 2017).

Özdemir ve Kayhan’ın nöroaksiyel blokların başarısızlık oranlarının ve nedensellik ilişkilerininin saptanması amacı ile 1998-2008 yılları arasında, 18 yaş ve üzeri hastalara cerrahi amaçla uygulanan 6966 nöroaksiyel blok verisi üzerine Chi-Square, Student-T ve Mann-Whitney U testleri kullanılarak anlamlı başarısızlık etkeni olarak bulunan parametrelere lojistik regresyon analizi uygulanarak bağımsız risk faktörleri belirlenmiştir. Başarısızlık oranları; hastaların %10,69’unda nöroaksiyel blok uygulanmış olup, tüm bloklarda başarısızlık hızı %5,4; spinal anestezi (SA)’de %3,9, epidural anestezi (EA)’de %10,9, kombine spinal epidural (KSE) blokta %6,4 olarak saptanırken; Bağımsız risk etkenleri ise paramediyan yaklaşım, periferik damar hastalığı, periferik damar hastalığı, epidural blok , cerrahi girişim süresi, uzman deneyimi, kronik obstrüktif akciğer rahatsızlığı, nörolojik rahatsızlık ve vücut ağırlığı olarak belirlenmiştir (Özdemir & Kayhan, 2011).

Kararmaz ve arkadaşlarının spinal anestezi uygulanması gereken durumlarda hipotansiyon ile ilişkili faktörleri belirlemek amacıyla lojistik regresyon uygulana 95 hasta verisi ile yapılan çalışmada, amnion kesesinin perfore olması, sezaryenin acil olması,

preeklamsi varlığı, spinal anestezinin oturur konumda uygulanmış olması ve duyu bloğun yüksekliği hipotansiyon ile ilişkili faktörler olarak belirlendi (Kararmaz, Kaya, Turhanoglu, & Özyılmaz, 2003).

Turan ve arkadaşlarının yaptığı çalışmada spinal anestezide başarısızlık oranları ve başarısızlığa yol açan nedenlerin açığa çıkarılması hedeflenmiştir. Çalışma 1499 hasta verisi üzerine lojistik regresyon yapılarak, başarısızlık oranı %6,5 olarak belirlenmiştir. Ayrıca iğne tipi, iğne çapı, hasta pozisyonu, lokal anestezi dozunu, uygulayıcının tecrübesi başarısızlığı etkileyen faktörler olarak saptanmıştır (Turan, Bombacı, Yılmaz, & Ömür, 2017).

## **1.4. ANESTEZYOLOJİ VE REAMİNASYON**

### **1.4.1. Preoperatif Değerlendirme**

#### **1.4.1.1. ASA (American Society Of Anesthesiologists) Sınıflandırması**


Hastaların preoperatif olarak değerlendirilerek sınıflandırıldığı ve buna göre anestezi yaklaşımın ve monitorizasyon yöntemlerinin belirlenmesinde yararlı olduğu kabul edilen bir değerlendirme sistemidir (İstanbul Üniversitesi İstanbul Tıp fakültesi, 2015). Tablo 1.4'de ASA sınıflandırması açıklanmaktadır.

**Tablo 1.5.** ASA Sınıflandırması (Türk Anesteziyoloji ve Reanimasyon Derneği, 2015)

<b>ASA 1</b>	Normal, sistemik bir bozukluğa neden olmayan cerrahi patoloji dışında bir hastalık veya sistemik sorunu olmayan sağlıklı bir kişi.
<b>ASA 2</b>	Cerrahi girişim gerektiren nedene veya başka bir hastalığa (hafif derecede anemi, kronik bronşit, hipertansiyon, amfizem, şişmanlık, diyabet gibi) bağlı hafif bir sistemik bozukluğu olan kişi.
<b>ASA 3</b>	Aktivitesini sınırlayan, ancak güçsüz bırakmayan hastalığı (hipovolemi, latent kalp yetmezliği, geçirilmiş miyokard infarktüsü, ileri diyabet, sınırlı akciğer fonksiyonu gibi) olan kişi.
<b>ASA 4</b>	Gücünü tamamen yitirmesine neden olup hayatına sürekli bir tehdit oluşturan bir hastalığı (şok, dekompanse kalp veya solunum sistemi hastalığı, böbrek, karaciğer yetmezliği gibi) olan kişi.
<b>ASA 5</b>	Ameliyat olsa da olmasa da 24 saatten fazla yaşaması beklenmeyen, son ümit olarak cerrahi girişim yapılan ölüm halindeki kişi.
<b>ASA 6</b>	Yukarıdaki 5 gruba daha sonra bu grup eklenmiştir. Bu gruba da organ alınmaya uygun, beyin ölümü gelişmiş hastalar girmektedir.
Acil cerrahi girişim gerektiğinde hastanın sınıflama numarasından sonra "E" harfi eklenmektedir. ASA IE gibi.	

#### 1.4.1.2. Mallampati

Zor entübasyon açısından öngörü sağlamak amacıyla yararlanılan yöntemlerden biridir. Şekil 1.5’de hastanın hangi ağız yapısında hangi mallampati sınıflandırmasına gireceği gösterilirken, Tablo 1.5’de sınıf açıklamaları gösterilmiştir.

**Şekil 1.5.** Mallampati Sınıfları (Özcan, 2009).

**Tablo 1.6.** Mallampati Sınıfl Açıklamaları (Kayhan, "Entübasyon güçlüğü, tanımı, nedenleri, sınıflandırılması, önceden belirlenmesi", 1998).

<b>Mallampati testine göre;</b>	
<b>Sınıf I</b>	Uvula, yumuşak damak, tonsil yatağı, ön ve arka plikalar rahatlıkla görülüyor;
<b>Sınıf II</b>	Uvula ve yumuşak damak görülüyor;
<b>Sınıf III</b>	Yumuşak damak ve uvula tabanı görülüyor;
<b>Sınıf IV</b>	Uvula dil kökü tarafından tamamen kapatılmış, farenks duvarı görülüyor

#### 1.4.2. Obstetrik Anestezi

Rejyonel anestezi doğum anesteziinde yaygın olarak kullanılan ve anesteziyolojinin memnun edici bir alt dalıdır (Tulunay & Cuhruk, 2008). Vajinal doğum eyleminin güvenli bir şekilde tamamlanamayacağı durumlarda yani anne ve/veya bebek için artan morbidite ve mortalite riski olduğu durumlarda sezaryen uygulanmaktadır (T.C. Sağlık Bakanlığı Ana Çocuk Sağlığı ve Aile Planlaması Genel Müdürlüğü, 2010). Dünya Sağlık Örgütü sezaryen oranının % 15 ile sınırlı kalmasını önemesine rağmen, sezaryen uygulamasının zamanla daha güvenli bir hale gelmesi ile birlikte sezaryen miktarı dikkat çekici bir şekilde artmaktadır (Önderoğlu, Karamürsel, & Taşkiran, 2005) (Konakçı & Kılıç, 2004). Birçok ülkede olduğu gibi ülkemizde de sezaryen oranı, bu hedefin üzerindedir. Sezaryen ile doğum hızı, Sağlık Bakanlığının 2017 yılında yayınlanan istatistik verilerine göre son 15 yılda büyük ölçüde (% 21'den %53,1'e) yükselmiştir (OECD, 2018). Bu yüzden sezaryen dünyada en sık yapılan cerrahi girişimlerden biri olmuştur (Souza, et al., 2016). Özellikle orta ve yüksek gelirli ülkelerde olmak üzere dünya genelinde sezaryen doğum sıklığı hızla artmaktadır (Betrán, et al., 2016).

Sezaryen oranlarında ki bu artışın sebepleri: anestezi ve operasyon yöntemlerinde ilerlemeler, fetusun durumunu değerlendirmek için kullanılan doppler, NST, biyofizik profil vb. teknolojik ilerlemelerin hızla gelişmesi, anne ve bebek mortalitesini azaltma çabası, kadınların daha ileri yaşta evlenmelerine bağlı olarak ileri yaşta gebe kalmaları ve az sayıda çocuk sahibi olmak istemeleri, infertilite sorunları nedeniyle uygulanan yardımcı üreme tekniklerinin gelişmesi (IVF, ICSI) ile "riskli gebelik" ve "kıymetli bebek" kavramlarının kullanılmaya başlanması, doğum analjesinin yetersizliği ve ekonomik nedenler oluşturmaktadır (Özgünen & Evrücke, Sezaryen, 2001). Sağlık

çalışanları arasında sezaryen uygulaması tıbbi endikasyon olmaksızın çok tercih edilen yöntem haline gelmekte. Ayrıca birçok kadın hamileliğinin başlamasıyla sezaryen ile doğumu daha çok tercih etmektedir (Pickett, 2002).

Sezaryen anestezisinin önemini şu şekilde ifade edebiliriz: sezaryen dışı normal bir cerrahi işlem esnasında uygulanan anestezide sadece bir kişinin güvenliği ve optimal koşullar sağlanmaya çalışılırken; sezaryende annenin fetusun da güvenliği sağlanmak zorundadır (Erdem, Özgen, & Coşkun, 1996).

Hem genel hem de rejyonel anestezi teknikleri sezaryen anestezisinde kullanılmaktadır. Hastanın isteği, bilincinin açık olması, aspirasyon riski taşımaması, yeni doğanda solunum depresyonu yapmaması, uterus atonisine yol açmaması gibi avantajları nedeniyle son yıllarda rejyonel anestezi daha çok tercih edilmektedir. Anestezi seçimi elektif şartlar altında tüm risk ve yararlarla birlikte annenin seçimi de dikkate alınmalıdır (Erdine, 1993) (Yegül, 1996) (Santos, Bravemen, & Finster, 2006). Tablo 1.7'de sezaryen doğum ile ilgili yıllara göre istatistiki bilgiler gösterilmektedir.

**Tablo 1.7.** Yıllara Göre Ana Çocuk Sağlığı ve Aile Planlaması Göstergeler (Sağlık İstatistikleri Yıllığı 2016, 2017).

<b>Türkiye</b>	<b>2002</b>	<b>2012</b>	<b>2013</b>	<b>2014</b>	<b>2015</b>	<b>2016</b>
Sağlık Kuruluşlarında Gerçekleşen Doğum Oranı (%)	75	97	98	98	99	98
Sezaryen Doğumların Tüm Doğumlar İçindeki Payı (%)	21,0	48,0	50,4	51,1	53,1	53,1

Sezaryen için anestezi seçiminde operasyonun aciliyeti, endikasyonu, hasta ve cerrahın tercihleri ve anesteziğin yeteneğine bağlı olarak değişir (Batislam, 2008) (Şahin & Owen, 2006) .

Bu nedenlerden dolayı anestezi uygularken gebenin rahatını, güvenliğini sağlayan en uygun obstetrik anestezi ve ek olarak annede oluşan her türlü değişikliklerden etkilenen fetus için de en güvenilir ve en az zararlı olduğuna inanılan bir yöntem seçilmelidir (Birnbach & Browne, 2010) (Toker, et al., 2003) (Purtuloğlu, et al., 2008).

Genel ve rejyonel olmak üzere başlıca iki anestezi yöntemi sezaryen ameliyatlarında uygulanabilir. İki yöntemin de avantaj ve dezavantajları bulunmaktadır. Anestezist, optimal anesteziyi oluşturmak için, gebede ki fizyolojik değişiklikleri, fetus ve yeni doğanda anestezi ajanlarının direkt, indirekt etkilerini, anestezi tekniklerinin risklerini ve yararlarını, özellikle obstetrik komplikasyonları bilmelidir. Bu durumlarda obstetrik anestezisinin önem derecesini yükseltmektedir. Anestezinin seçimi hastanın isteğine, obstetrik gereksinimine ve anestezistin deneyimine bağlıdır (Batislam, 2008) (Birnbach & Browne, 2010) (Kayhan, Klinik Anestezi, 2004).

Bunlarla beraber anestezi seçiminde elektif şartlar altında tüm risk ve yararlarla birlikte annenin tercihi de gözünde bulundurulmalıdır (Santos, Bravemen, & Finster, 2006).

#### **1.4.2.1. Genel Anestezi**

Günümüzde, çok acil durumlarda, rejyonel yöntemler için bir kontrendikasyon durumu mevcutsa veya rejyonel girişim başarısız olduğunda genel anestezi uygulanmaktadır (Şahin, 2010) (Santos, Bravemen, & Finster, 2006).

Genel anestezi kontrendikasyon olmayan durumda hastanın rejyonel anesteziyi reddetmesinin yanında, indüksiyonun hızlı ve güvenilir olması, umbilikal kord prolapsusu, plasenta previa kanaması veya uterusun akut inversiyonu gibi anne ve fetusun tehlike içinde olduğu çok acil durumlarda üstünlük sağlar (Kayhan, Klinik Anestezi, 2004) (Erdem, Özgen, & Coşkun, 1996).

Genel anestezi rejyonel anestezinin aksine daha az hipotansiyon riski, kardiovasküler stabilitenin daha iyi sağlanması, hava yolu ve ventilasyonunun daha iyi kontrolü nedeniyle de avantajlı sayılabilir (Batislam, 2008) (Purtuloğlu, et al., 2008) (Okumuş, et al., 2009).

Obstetrik anestezide mortalitesinin en önemli nedenleri arasında mide içeriğinin aspirasyonu gösterilebilir (Kayhan, Klinik Anestezi, 2004).

Tüm hastalar indüksiyondan 30-45 dakika önce aspirasyon pnömonisine karşı 30 ml 0.3 M sodyum sitrat profilaksisi almalıdır. Histamin 2 reseptör blokerleri (H<sub>2</sub>), simetidin, ranitidin indüksiyondan en az 1-2 saat önce oral ya da 45-60 dakika önce



intravenöz veya intramüsküler yapılmalıdır; elektif sezaryen yapılacak yüksek riskli hastalarda da ayrıca operasyondan önceki gece ve operasyon sabahı 40 mg omeprazol yüksek oranda etkilidir. Hava yolu sekresyonlarını azaltmak için küçük doz (0,1mg) glikopirolatla premedikasyon düşünülmelidir. Antiemetik olarak metoklopramid intravenöz verilebilir. Pozitif basınçlı ventilasyondan kaçınılmalı, krikoid bası (Sellick manevrası) eşliğinde, hızlı endotrakeal entübasyon yapılmalı ve laringeal koruyucu refleksler tam olarak geldiğinde ve hasta tamamen uyandığında ekstübe edilmelidir. Anesteziyle ilişkili maternal mortalitenin en önemli nedenlerinden bir başkası da zor ventilasyon, başarısız ya da zor entübasyondur (Batislam, 2008) (Birnbach & Browne, 2010) (Kayhan, Klinik Anestezi, 2004).

Zor ventilasyon ve zor entübasyonun önceden tahmini başarısız entübasyon riskini azaltabilmektedir. Boyun, mandibula, dişlerin ve orofarinksin muayenesi karşılaşılabilecek problemleri önceden saptamaya yardımcı olur. Hava yolu ödemi, dişlerin tam olması ve kısa boyunlu hastalarda büyük göğüslerin laringoskop sapının hareketini kısıtlaması nedeniyle gebelerde, gebe olmayan cerrahi hastalara göre zor entübasyon insidansı artabilir. Genellikle ventilasyonu en az deprese etmesi beklenen ajan olduğundan sevofluran seçilmektedir. Hastanın ventile edilememesinde acil krikotrotomi ve trakeostomi gerekebilir (Batislam, 2008).

Hasta masaya alındıktan sonra, aortakaval basıya bağlı hipotansiyonu önlemek için ameliyat masası 15 derece sola devriye edilebilir veya gebenin sağ kalçasının altına küçük bir yastık yerleştirilebilir. Genel anesteziye başlamadan önce geniş bir venöz yol ile dekstroz içermeyen dengeli tuz solüsyonu (ringer laktat/serum fizyolojik) başlanır; elektrokardiyogram (EKG), kan basıncı, puls oksimetri, BİS, kapnograf monitorizasyonu yapılır. İndüksiyondan önce yüze uygun iyi bir maskeyle en az 3 dakika % 100 oksijen uygulanır ya da gebenin % 100 oksijen ile 4 kez maksimum derin soluk alması istenir (Günaydın, 2012).

Genel anestezi indüksiyonu ile çıkım arasındaki süre fetusun anesteziye maruz kalmasını ve geçici hipotoniye minime indirmek için, 10 dakika veya daha az olmalıdır (Şahin, 2010). Doğumun indüksiyondan sonra 10 dakika içerisinde gerçekleşmesi durumunda İntravenöz (IV) ajanların dozu kısıtlanmakta ve fetal depresyon klinik olarak önemsiz bir hâl almaktadır (Batislam, 2008) (Şahin, 2010) (Kayhan, Klinik Anestezi,

2004). Bu sürenin 10 dakikayı geçmesi durumunda ise fetal dokularda Nitroz oksit ( $N_2O$ ) doyar, yeni doğanda hafif bir depresyon ve yeterli oksijenasyon yapılmazsa diffüzyon hipoksisi gelişebilir (Kayhan, 2004).

Hızlı anestezi indüksiyonu için tiyopental 4-5 mg/kg, kas gevşetici olarak süksinilkolin 1,0-1,5 mg/kg kullanılır. Süksinil kolin kontrendike ise 0,6 mg/kg rokuronyum alternatif olabilir. Hipotansif hastalarda tiyopental yerine ketamin 1,0-1,5 mg/kg tercih edilmelidir. Endotrakeal tüp yerleştirilinceye kadar krikoid bası uygulanmalı (Sellick manevrası) ve iç çapı 6,0-7,0 mm olan kafalı tüp ile entübasyon yapıp kaf şişirildikten sonra trakeada olduğu doğrulanmalıdır (15,16). Bebek doğana kadar anestezi % 50 oksijen ve % 50 nitroz oksit içinde 0,5 MAK volatil anestezik ile sürdürülür. Kordon klempe edilince uterus toparlanıncaya kadar  $N_2O+O_2$  ve İV anestezikler, opioidler ve kas gevşeticiler ile devam edilir. Volatil anesteziklerin düşük konsantrasyonda neonatal depresyona neden olmadığı, kan kaybını artırmadığı bilinmekle beraber anneye bilinç kaybı yapacak kadar inhalasyon anesteziği verilmesi, annenin uyanık kalması veya olayların farkında olmasının doğurduğu streten daha zararlı değildir. % 50  $O_2$ +% 50  $N_2O$  ile birlikte, isofluran % 0,75, sevofluran % 1 veya desfluran % 3 konsantrasyonda uygulanması idame için kullanılabilir. Bu dozlar bilinci kaldırmaya yetmektedir (Batislam, 2008) (Birnbach & Browne, 2010) (Kayhan, 2004).

Bebeğin doğumundan sonra uterusun kontrakte olmasını sağlamak için, hızla gitmekte olan sıvılara oksitosin eklenmelidir. Cerrahi girişimin sonuna doğru mide içeriği orogastrik bir tüple aspire edilerek, rezidüel nöromusküler blok ekstübasyondan önce antagonize edilmektedir. Uyanık ekstübasyon kriterleri sağlandığında anne ekstübe edilir (Günaydın, 2012) (Şahin, 2010).

#### **1.4.2.2. Spinal Anestezi**

Rejyonel Anestezi yöntemlerinden olan spinal anestezinin etki mekanizması şu şekilde işlemektedir; lokal anestezik BOS içine veya epidural aralığa enjekte edilmektedir. Spinal anestezi subaraknoid aralıktaki sinir kökleri tutulmaktadır. Nöroaksiyel blokajın esas etki yerinin sinir kökü olduğu belirtilmiştir. Spinal anestezi için lokal anesteziğin direk BOS'a enjeksiyonu göreceli olarak düşük doz ve hacimde, lokal anestezikle yoğun motor ve duyuşsal blok oluşmasına neden olmaktadır. Nöroaksiyel

bloklar, ağırlı uyarıların iletiminin engellenmesi ve iskelet kas tonusunun ortadan kaldırılması ile ideal operasyon koşullarını sağlarmaktadırlar (Ateş, 2008).

Aşağıda spinal anestezinin endikasyonları, kontrendikasyonları, avantajları, dezavantajları ve komplikasyonları hakkında bilgi verilmektedir (Ateş, 2008) (Brown, 2010) (Yılmazlar, 2012) (Göğüş, 2010).

### **Spinal anestezinin avantajları**

- Anestezinin hızlı başlaması
- Basitliği
- Güvenilirliği (Başarısızlık oranı %2.8 civarında)
- Depresan medikasyona fetusun minimal maruz kalması
- Hasta uyanık, aspirasyon tehlikesi minimal
- Annenin doğuma iştirakine izin verir
- Epidural anesteziden daha az ürperti
- Epidural anestezide göre daha yoğun ve daha güvenilir sakral sinir bloğu

### **Spinal anestezinin Dezavantajları**

- Daha fazla hipotansiyon riski (Diğer anestezi tekniklerine göre)
- Operasyon anında daha fazla bulantı-kusma
- Postdural delinmeye bağlı baş ağrısı olasılığı
- Sınırlı etki süresi

### **Spinal Anestezinin Komplikasyonlar**

- İdrar retansiyonu
- Yüksek blok
- Total spinal anestezi
- Kardiyak arrest
- Anterior spinal arter sendromu
- Horner sendromu
- Travma (Sırt ağrısı, Dural ponksiyon kaçağı-Postdural ponksiyon baş ağrısı, Diplopi, Tinnitus)
- Nöral hasar

- Kanama
- İnflamasyon
- Enfeksiyon(Menenjit)

**Acil Sezaryenlerde Anestezi:** Anestezi seçimi sadece anne ve bebeğin durumuna bağlı olmamakla beraber operasyonun aciliyeti ile de ilişkilidir. Planlı sezaryenler haricindeki sezaryenler daha önceden acil olarak sınıflandırılrsa da, sonraları acil sezaryenler “stabil, acil ve çok acil” olarak 3 gruba ayrılmıştır (Harris, 1990) (Keçik, Alkış, Yörükoğlu, & Alanoğlu, 2012);

**Tablo 1.8.** 2000 Yılında Tüm Sezaryenler 4 Kategoride Toplanmıştır (Keçik, Alkış, Yörükoğlu, & Alanoğlu, 2012).

		<b>Operasyon Kararı Alınması Sırasında</b>
<b>Kategori 1</b>	<b>Çok Acil</b>	Anne yada bebek için acil tehdit oluşturan durumlar (fetal bradikardi, kordon sarkması, uterus rüptürü, fetal pH<7)
<b>Kategori 2</b>	<b>Acil</b>	Anne yada bebek için acil tehdit oluşturan, acilen hayatı tehdit etmeyen (doğum öncesi kanama, doğumun ilerlemesi)
<b>Kategori 3</b>	<b>Stabil</b>	Erken doğum gerektiren fakat anne yada bebek için acil tehdit oluşturmayan (sezaryen planlanmış ama erken doğum gereken durumlar)
<b>Kategori 4</b>	<b>Elektif</b>	Anne ve cerrahi ekibin hazırlanacak kadar zamanı var (tüm planlı elektif sezaryenler)

Söz konusu 4 kategori şu şekilde açıklanabilir (Lucas, et al., 2000) (Keçik, Alkış, Yörükoğlu, & Alanoğlu, 2012);

**Kategori 4:** Bu sınıflandırmaya göre tüm planlı elektif vakaları içerir

**Kategori 3:** Erken doğum gerektiren fakat anne yada bebek için acil tehdit oluşturmayan durumlardır. Kronik uteroplasental yetmezlik bu gruba girer.

**Kategori 2:** Anne yada bebek için acilen hayatı tehdit etmeyen fakat tehlike oluşturan, durumlar. Fetal distress mevcut değilken kordon sarkması, değişken fetal taşikardi, doğum öncesi kanama, doğumun ilerlemesi, aktif genital herpes, erken membran rüptürü, ilerlemeyen eylem bu grubun içerisinde.

**Kategori 1:** Anne yada bebek için acil tehdit oluşturan durumlardır. Maternal masif hemoraji, fetal distres(fetal bradikardi), kordon sarkması, uterus rüptürü, fetal pH<7 gibi durumlar bu kategoridedir.

Kategori 1'e giren çok acil hastalarda genellikle genel anestezi tercih edilmektedir. Acil sezaryenlerde sezaryen kararından doğuma, anestezi indüksiyonundan doğuma, uterus insizyonundan doğuma kadar geçen süreler için hâla tartışmalar yapılmaktadır. Perinatal bakım klavuzuna göre sezaryen kararından doğuma kadar geçen sürenin 30 dakikayı geçmemesi önerilirken, plesenta previa, uterus rüptürü gibi obstetrik hemorajilerde, kordon sarkması gibi maternal ya/yada fetal mortalite ve/veya morbiditeyi azaltmak adına mümkün olduğunca hızlı bir şekilde hareket edilmesi önerilmektedir. Anestezi indüksiyonundan doğuma kadar geçen süre normal şartlarda 4-7 dakika arasında değişebilirken, bu süre 8 dakikanın üzerinde olduğunda neonatal asidozda artış ve 1.dakika APGAR skorlarında bir düşüş gözlenmektedir. Bunun yanında anestezi indüksiyonundan doğuma kadar geçen süreden ziyade uterus insizyonundan doğuma kadar geçen süre 3 dakikadan fazla olduğu durumlarda APGAR skorlarında bir düşüş meydana gelmektedir (MacKenzie & Cooke, 2002) (Keçik, Alkış, Yörükoğlu, & Alanoğlu, 2012).

Sezaryen kararı alındıktan sonra 10 dakika içerisinde hastanın operasyona alınması, sezaryen kararından doğuma kadar geçen sürenin 30 dakika olması ihtimalini büyük oranda artırmaktadır. Birçok deneyimli anestezist spinal anestezi yapmanın genel anestezi vermek kadar hızlı olduğunu iddia etsede spinal anestezi yapılan acil gebelerin cerrahiye başlama süreleri (27.6 dakika) genel anestezi yapılan acil gebelerden (15.4 dakika) anlamlı olarak uzun bulunmuştur (McCahon & Catling, 2003) (Keçik, Alkış, Yörükoğlu, & Alanoğlu, 2012).

Elektif sezaryenler için uygun bir seçim olan spinal anestezi özellikle Kategori 2 acil sezaryenler içinde uygun kabul edilmektedir. Fakat Kategori 2'ye spinal anestezi uygulamadan önce fetal distresin sebebinin erken plasenta ayrılmasına bağlı gelişen hipovolemi nedenli olmadığından emin olmak gerekmektedir. Ayrıca spinal anestezi hızlı uygulanmalı ve hipotansiyondan kaçınılmalıdır (Lawrence, 2009) (Keçik, Alkış, Yörükoğlu, & Alanoğlu, 2012).

## İKİNCİ BÖLÜM

### YÖNTEM

#### 2.1. VERİ TOPLAMA

Erzurum Nenehatun kadın doğum hastanesinde 2018 yılının bir döneminde sezaryen doğum yöntemi ile doğum yapan 300 katılımcı için EK 2’de gösterilen Atatürk Üniversitesi Tıp Fakültesi Etik Kurulu’nun yazılı onayı alınarak EK 1’deki hasta tanıma formu ile bir veri seti oluşturulmuştur.

##### 2.1.1. Verinin Anlaşılması

Veri setini oluşturan 300 katılımcının 239 tanesine spinal anestezi yapılırken, 61 tanesine genel anestezi yapılmıştır.

Veri seti, hastaların demografik parametreleri(yaş, boy, kilo), katılımcıların gebelikleri ile ilgili parametreleri ( gebelik sayısı, gebelik haftası, sezaryen doğum sayısı), katılımcının sezaryen durumu ile ilgili parametreleri (sezaryen nedeni, vaka türü, açlık süresi, önceki anestezi türü, mevcut anestezi türü, ameliyata giriş saati), katılımcının sağlık değerlendirmesi ile ilgili parametreleri (yandaş hastalık öyküsü, hastalık, ilaç öyküsü, ilaç, tahlillerin spinal aneztesiye uygunluğu, spinal anestezinin doktor tavsiyesi olması, önceki ameliyat, ASA, Mallampati), katılımcının anestezi tercihi ile ilgili parametreleri ( hastanın genel anestezi tercihi, hastanın spinal anestezi tercihi, hastanın genel anestezi korkusu, hastanın spinal anestezi korkusu). Tablo 2.1’de parametrelerin tanımlamaları verilmiştir.

**Tablo 2.1.** Veri Setini Oluşturan Parametrelerin Tanımlamaları


<b>Parametre İsmi</b>	<b>Açıklaması</b>
<b>Hastanın Demografik Verileri</b>	
Yaş	
Boy	
Kilo	
<b>Hastanın Gebelik Bilgileri İle İlgili Veriler</b>	
Gebelik Haftası	
Sezaryen Doğum Sayısı	
<b>Hastanın Sezaryen Durumu İle İlgili Veriler</b>	
Sezaryen Nedeni	
Vaka Türü	Katılımcının sağlık durumunun ciddiyeti
Açlık Süresi	
Önceki Anestezi Türü	
Şimdiki Anestezi Türü	
Ameliyata Giriş	Katılımcının ameliyata giriş saati
<b>Hastanın Sağlık Değerlendirmesi İle İlgili Parametreler</b>	
Yandaş Hastalık Öyküsü (Ek hastalık)	Katılımcının herhangi bir hastalığı var mı?
Hastalık	Katılımcının herhangi bir hastalığı olması durumunda hangi hastalığının olduğu
İlaç Öyküsü	Katılımcının herhangi bir ilaç kullanıyor mu?
İlaç	Katılımcının ilaç kullanması durumunda hangi ilacı kullandığı
Tahliller Spinal Aneztesiye Uygun Mu?	
Spinal Anesteziyi Doktor mu Tavsiye Etti?	
Ameliyat Öyküsü	
ASA	Katılımcıların preoperatif olarak sınıflandırılması
Mallampati	
<b>Hastanın Anestezi Tercihi İle İlgili Parametreler</b>	
Hastanın Genel Anestezi Tercihi	
Hasta Spinal Anestezi Tercihi	
Hasta Genel Anesteziden Korkuyor	
Hasta Spinal Anesteziden Korkuyor	

Parametreler ile ilgili istatistiki bilgiler aşağıda belirtilmiştir.

**Tablo 2.2.** Örneklem Grubunun Yaş, Boy ve Kilo Parametrelerine Ait Betimsel İstatistik Verileri

Parametre	$\bar{X}$	Mod	Min.	Max.	N
Yaş	28,71	27	17	44	300
Boy	1,60	1,60	1,40	1,75	300
Kilo	78.07	75	54	113	300

Veri setindeki yaş, boy ve kilo parametrelerine ait betimsel istatistik değerleri yukarıdaki Tablo 2.2 gösterilmiştir. Tablo 2.2 incelendiğinde örneklem grubunu oluşturan 300 katılımcı için yaş niteliğinin ortalaması 28,71 olarak, mod değeri 27 olarak, en küçük yaş değeri 17 olarak, en büyük yaş değeri ise 44 olarak tespit edilirken boy niteliğinin ortalaması 1,60 cm olarak, mod değeri 1,60 cm olarak, en kısa boy oranı 1,40 cm olarak, en uzun boy oranı 1,75 cm olarak tespit edilmiştir. Kilo niteliğinin ise ortalaması 78.8 kg olarak, mod değeri 75 kg olarak, en düşük kilo değeri 54 kg olarak, en yüksek kilo değeri 113 olarak tespit edilmiştir. Şekil 2.1 yaş, boy ve kilo parametrelerine ait histogram grafikleri gösterilmiştir.

**Şekil 2.1** Yaş, Boy, Kilo Histogram Grafikleri

Çalışma kapsamında araştırmaya katılanların yaş verileri ile bilgiler Tablo 2.3'te gösterilmiştir.

**Tablo 2.3.** Örneklem Grubunun Yaş Verileri

Yaş Grupları	N	%
15-20	20	6.7
20-25	73	24.3
25-30	95	31.7
30-35	71	23.7
35-40	33	11
40-45	8	2.7



Tablo 2.3 incelendiğinde 300 hastadan oluşan örneklem aralığında, 15-20 yaş aralığında 20 hasta, 20-25 yaş aralığında 73 hasta, 25-30 yaş aralığı 95 hasta, 30-35 yaş aralığı 71 hasta, 35-40 yaş aralığı 33 hasta ve 40-45 yaş aralığı 8 hasta mevcuttur. Söz konusu yaş aralıklarının %6,7'sini 15-20 yaş aralığı, %24,3'ünü 20-25 yaş aralığı, %31,7'sini 25-30 yaş aralığı, %23,7'sini 30-35 yaş aralığı, %11'ini 35-40 yaş grubu ve %2,7'sini ise 40-45 yaş aralığında ki hastalar oluşturmaktadır.

**Tablo 2.4.** Örneklem Grubunun Boy Verileri

Boy Grupları	N	%
1,40-1,45	4	1.3
1,45-1,50	31	10.3
1,50-1,55	53	17.7
1,55-1,60	86	28.7
1,60-1,65	82	27.3
1,65-1,70	37	12.3
1,70-1,75	7	2.3

Tablo 2.4 incelendiğinde Çalışma kapsamında bulunan 300 katılımcıdan 4 tanesi 1,40-1,45 boy aralığında, 31 tanesi 1,45-1,50 boy aralığında, 53 tanesi 1,50-1,55 boy aralığında, 86 tanesi 1,55-1,60 boy aralığında, 82 tanesi 1,60-1,65 boy aralığında, 37 tanesi 1,65-1,70 boy aralığında ve 8 tanesi de 1,70-1,75 boy aralığında yer almaktadır. Boy aralıklarının % 1,3'ünü 1,40-1,45 boy aralığı, % 10,3'ünü 1,45-1,50 boy aralığı, %17,7'sini 1,50-1,55 boy aralığı, % 28,7'sini 1,55-1,60 boy aralığı, % 27,3'ünü 1,60-1,65 boy aralığı, %12,3'ünü 1,65-1,70 boy aralığı, %2,3'ünü ise 1,70-1,75 boy aralığı oluşturmaktadır.

**Tablo 2.5.** Örneklem Grubunun Kilo Verileri.

Kilo grupları	N	%
55-65	44	14.7
65-75	93	31
75-85	92	30.7
85-95	47	15.7
95-105	19	6.3
105-115	5	1.7

Tablo 2.5 incelendiğinde Çalışma kapsamında bulunan 300 katılımcıdan 44 tanesi 55-65 kilo aralığında, 93 tanesi 65-75 kilo aralığında, 92 tanesi 75-85 kilo aralığında, 47 tanesi 85-95 kilo aralığında, 19 tanesi 95-105 kilo aralığında, 5 tanesi ise 105-115 kilo aralığında yer almaktadır. Kilo aralıklarının % 14,7'sini 55-65 kilo aralığı, % 31'ini 65-75 kilo aralığı, %30.7'sini 75-85 kilo aralığı, % 15.7,7'sini 85-95 kilo aralığı, %6.3'ünü 95-105 kilo aralığı, %1.7'sini ise 105-115 kilo aralığı oluşturmaktadır.

**Tablo 2.6** Örneklem Grubunun Gebelik Haftası Verileri.

Gebelik Haftası Grubu	N	%
25-30	13	4.3
30-35	28	9.3
35-40	246	82
40-45	13	4.3

Tablo 2.6 incelendiğinde çalışma kapsamında bulunan 300 katılımcıdan 13 tanesi (%4.3) 25-30 hafta arasında gebelik sürecinde, 28 tanesi (%9.3) 30-35 hafta arasında gebelik sürecinde, 246 tanesi (%82) 35-40 hafta arasında gebelik sürecinde, 13 tanesi (%4.3) ise 40-45 haftalık gebelik süreci içerisinde yer almaktadır.

**Tablo 2.7.** Örneklem Grubunun Sezaryen Doğum Sayısı Verileri.

Sezaryen Sayısı Grubu	N	%
0-1	221	73.7
1-2	70	23.3
2-3	9	3

Tablo 2.7 incelendiğinde çalışma kapsamında bulunan 300 katılımcıdan 221 tanesinin (%73,7) 0-1 defa aralığında sezaryen doğum yapmış olduğu, 70 (%23.3) tanesinin 1-2 defa aralığında sezaryen doğum yapmış olduğu, 9 (%3) tanesinin ise 2-3 defa aralığında sezaryen doğum yapmış olduğu tespit edilmiştir.

**Tablo 2.8.** Örneklem Grubunun Sezaryen Olma Nedeni Verileri.

<b>Sezaryen Olma Nedeni</b>	<b>N</b>	<b>%</b>
Geçirilmiş Sezaryen	115	38.3
Mükerrer Sezaryen	62	20.7
Fetal Distres	35	11.7
Dekolman Plasenta	7	2.3
Plasenta Previa	1	0.3
Preeklampsi	5	1.7
Çoğul Gebelik	6	2
Malprezentasyon	12	4
İlerlemeyen Gebelik	7	2.3
CPD	29	9.7
NRNST	7	2.3
Ex Fetüs	2	0.7
İYGR	2	0.7
EMR	6	2
Oligohidramnios	2	0.7
Kıymetli Gebelik	2	0.7

Tablo 2.8 incelendiğinde çalışma kapsamında bulunan 300 katılımcıdan 115 tanesinin (%38,3) sezaryen olma nedeni geçirilmiş sezaryen olarak, 62 tanesinin (%20,7) sezaryen olma nedeni Mükerrer sezaryen olarak, 35 tanesinin (%11,7) sezaryen olma nedeni Fetal Distres olarak, 7 tanesinin (% 2,3) sezaryen olma nedeni Dekolman Plasenta olarak, 1 tanesinin (%0,3) sezaryen olma nedeni Plasenta Previa olarak, 5 tanesinin (%1,7) tanesinin sezaryen olma nedeni Preeklampsi olarak, 6 tanesinin (%2) sezaryen olma nedeni Çoğul Gebelik olarak, 12 tanesinin (%4) sezaryen olma nedeni Malprezentasyon olarak, 7 tanesinin (%2,3) sezaryen olma nedeni İlerlemeyen Gebelik olarak, 29 tanesinin (%9,7) sezaryen olma nedeni CPD olarak, 7 tanesinin (%2,3) sezaryen olma nedeni NRNST olarak, 2 tanesinin (%0,7) sezaryen olma nedeni Ex Fetüs olarak, 2 tanesinin (%0,7) sezaryen olma nedeni İYGR olarak, 6 tanesinin (%2) sezaryen olma nedeni EMR olarak, 2'şer tanesinin (%0,7) sezaryen olma nedeni ise Oligohidramnios ve Kıymetli Gebelik olarak saptanmıştır.

**Tablo 2.9.** Örneklem Grubunun Vaka Türü Verileri

Vaka Türü	N	%
Çok Acil	42	14
Acil	28	9.3
Stabil	31	10.3
Elektif	199	66.3

Tablo 2.9 incelendiğinde çalışma kapsamında bulunan 300 katılımcıdan 42 tanesinin (%14) çok acil kategorisinde olduğu, 28 tanesinin (%9,3) tanesinin acil kategorisinde olduğu, 31 tanesinin (%10,3) stabil kategorisinde olduğu, 199 tanesinin (%66,3) ise elektif kategorisinde olduğu tespit edilmiştir.

**Tablo 2.10.** Örneklem Grubunun Açlık Süresi Verileri

Açlık Süresi Grupları	N	%
0-6	88	29.3
6-12	179	59.7
12-18	29	9.7
18-24	4	1.3

Tablo 2.10. incelendiğinde çalışma kapsamında bulunan 300 katılımcının saat bazında açlık süresi veri dağılımı incelendiğinde 88 tanesinin (%29,3) 0-6 aralığı grubunda, 179 tanesinin (%59,7) 6-12 aralığı grubunda, 29 tanesinin (%9,7) 12-18 aralığı grubunda, 4 tanesinin ise (%1,3) 18-24 aralığı grubunda olduğu görülmüştür.

**Tablo 2.11.** Örneklem Grubunun Anestezi Tercihi Verileri

<b>Hastanın Aneztesi Tercihi</b>		<b>Cevaplar</b>		
		<b>Evet</b>	<b>Hayır</b>	<b>Yanıtsız</b>
Spinal	N	125	147	28
	%	41.7	49	9.3
Genel	N	134	138	28
	%	44.7	46	9.3

Tablo 2.11. incelendiğinde örneklem grubuna yöneltilen spinal aneztesi tercihi sorusuna 125 kişinin (%41,7) evet cevabı, 147 kişinin (%49) hayır cevabı verdiği belirlenmiştir. Ayrıca genel aneztesi tercihi sorusuna 134 kişinin (%44.7) evet cevabı, 138 kişinin (%46) hayır cevabı verdiği belirlenmiştir. 28 kişiye (%9.3) ise durumlarının aciliyeti dolayısıyla aneztesi tercihi sorusunun sorulması uygun bulunmamıştır.

**Tablo 2.12.** Örneklem Grubunun Aneztesi Korkusu Verileri

<b>Hastanın Aneztesi Korkusu</b>		<b>Cevaplar</b>		
		<b>Evet</b>	<b>Hayır</b>	<b>Yanıtsız</b>
Spinal	N	200	72	28
	%	66.7	24	9.3
Genel	N	75	197	28
	%	25	65.7	9.3

Tablo 2.12 incelendiğinde örneklem grubuna yöneltilen spinal aneztesi korkusu sorusuna 200 kişinin (%66,7) evet cevabı, 72 kişinin (%24) ise hayır cevabı verdiği belirlenmiştir. Ayrıca genel anestezi korkusu sorusuna 75 kişinin (%25) evet cevabı, 197 kişinin (%65,7) ise hayır cevabı verdiği belirlenmiştir. 28 kişiye (%9.3) ise durumlarının aciliyeti dolayısıyla anestezi korkusu sorusunun sorulması uygun bulunmamıştır.

**Tablo 2.13.** Örneklem Grubunun Tahlillerinin Spinal Anestezi İçin Uygunluk Verileri

<b>Tahlillerin Spinal Anesteziye Uygunluğu</b>	<b>N</b>	<b>%</b>
Hayır	12	4.0
Evet	260	86.7
Yanıtsız	28	9.3

Tablo 2.13 incelendiğinde örneklem grubundaki 12 kişinin (%4) tahlil sonuçlarının spinal anestezi için uygun olmadığı fakat 260 kişinin (% 86,7) tahlil sonuçlarının spinal anesteziye uygun olduğu belirlenmiştir. 28 kişiye (%9,3) ise durumlarının aciliyetleri dolayısıyla tahlil yapılması uygun bulunmamıştır.

**Tablo 2.14.** Örneklem Grubunda Spinal Anestezinin Doktor Tavsiyesi Olma Durumu Verileri

<b>Spinal Anestezinin Doktor Tavsiyesi Olması</b>	<b>N</b>	<b>%</b>
Hayır	106	35.3
Evet	166	55.3
Yanıtsız	28	9.3

Tablo 2.14 incelendiğinde örneklem grubundaki 300 katılımcıdan 106 kişi (%35,3) için spinal anestezi doktor tavsiyesi olmadığı, 166 kişi (%55,3) için ise spinal anestezinin doktor tavsiyesi olduğu belirlenmiştir. 28 kişiye (%9,3) ise durumlarının aciliyetlerinden dolayı doktor tavsiyesi verilememiştir.

**Tablo 2.15.** Örneklem Grubunun Ameliyata Giriş Saati Verileri

<b>Ameliyata Giriş Saati</b>	<b>N</b>	<b>%</b>
00:00-06:00	20	7
06:00-12:00	126	42
12:00-18:00	96	32
18:00-23:59	58	19

Tablo 2.15 incelendiğinde örneklem grubundaki 300 katılımcıdan 20 kişinin (%7) 00:00-00:06 arasında ameliyata girdiği, 126 kişinin (%42) 06:00-12:00 arasında ameliyata girdiği, 96 kişinin (%32) 12:00-18:00 arasında ameliyata girdiği, 58 kişinin (%19) ise 18:00-23:59 arasında ameliyata girdiği saptanmıştır.

**Tablo 2.16.** Örneklem Grubunun Önceki Anestezi Türü Geçmiş Verileri

<b>Önceki Anestezi Türü</b>	<b>N</b>	<b>%</b>
Anestezi Geçmiş Yok	120	40
Genel Anestezi	72	24
Spinal Anestezi	108	36

Tablo 2.16 incelendiğinde örneklem grubundaki 300 katılımcıdan 120 tanesinin (%40) daha önce anestezi geçmişinin olmadığı, 72 tanesinin (%24) daha önce genel anestezi geçirdiği, 108 tanesinin (%36) ise spinal anestezi geçirdiği belirlenmiştir.

**Tablo 2.17.** Örneklem grubunun şimdiki anestezi türü verileri.

<b>Şimdiki Anestezi Türü</b>	<b>N</b>	<b>%</b>
Genel Anestezi	62	20.7
Spinal Anestezi	238	79.3

Tablo 2.17. incelendiğinde örneklem grubundaki 300 katılımcının 62 tanesinin (%20,7) mevcut anestezi türü genel anesteziyken 238 tanesinin (%79,3) mevcut anestezi türünün spinal anestezi olduğu belirlenmiştir.

**Tablo 2.18.** Örneklem Grubunun Hastalık Durumu Verileri.

<b>Hastalık durumu</b>	<b>N</b>	<b>%</b>
Farklı bir hastalık durumu yok	263	87.7
Farklı bir hastalık durumu var	37	12.3

Tablo 2.18 incelendiğinde örneklem grubundaki 300 katılımcının 263 tanesinde (%87,7) herhangi bir hastalık tespit edilememişken, 37 tanesinde (%12,3) ise hastalık durumu varlığı tespit edilmiştir.

**Tablo 2.19.** Örneklem Grubunun Hastalık Verileri

Hastalık	N	%
HT	9	3
DM	4	1.3
Guatr	13	4.3
Astım	2	0.7
Üsye	4	1.3
Diğer	5	1.7

Tablo 2.19 incelendiğinde hastalık durumunun tespit edilen 37 katılımcının 9 tanesinde (%3) HT rahatsızlığı, 4 tanesinde (%1,3) DM rahatsızlığı, 13 tanesinde (%4,3) Guatr rahatsızlığı, 2 tanesinde (%0,7) Astım rahatsızlığı, 4 tanesinde (%1,3) Üsye rahatsızlığı, 5 tanesinde (%1,7) ise diğer rahatsızlıklardan biri tespit edilmiştir.

**Tablo 2.20.** Örneklem Grubunun İlaç Kullanım Verileri

İlaç Kullanımı	N	%
İlaç kullanımı yok	279	93
İlaç kullanımı var	21	7

Tablo 2.20 incelendiğinde örneklem grubundaki 300 katılımcının 279 tanesi (%93) herhangi bir ilaç kullanmazken, 21 tanesinin (%7,0) ise ilaç kullandığı belirlenmiştir.

**Tablo 2.21.** Örneklem Grubunun İlaç Verileri

İlaç	N	%
Antihipertasnif	7	2.3
Aspirin	2	0.7
Clexane	1	0.3
Diğer	11	3.7



Tablo 2.21 incelendiğinde ilaç kullandığı tespit edilen 21 katılımcının 7 tanesinin (%2,3) Antihipertansif, 2 tanesinin (%0,7) Aspirin, 1 tanesinin (%0,3) Clexane, 11 tanesinin (%3,7) ise diğer ilaçları kullandıkları tespit edilmiştir.

**Tablo 2.22.** Örneklem Grubunun Ameliyat Geçmişi İle İlgili Veriler

<b>Ameliyat Geçmişi Öyküsü</b>	<b>N</b>	<b>%</b>
Ameliyat Geçmişi Yok	116	38.7
Sezaryen	178	59.3
Diğer	6	2

Tablo 2.22 incelendiğinde örneklem grubundaki 300 katılımcıdan 116 tanesinin (%38,7) daha önce herhangi bir ameliyat geçmişinin olmadığı, 178 tanesinin (%59,9) daha önce sezaryen geçirdiği, 6 tanesinin (%2) ise diğer ameliyatlardan geçirdiği saptanmıştır.

**Tablo 2.23.** Örneklem Grubunun ASA Sınıflandırma Verileri

<b>ASA</b>	<b>N</b>	<b>%</b>
1	8	2.7
2	288	96
3	4	1.3

Tablo 2.23 incelendiğinde örneklem grubundaki 300 katılımcıdan 8 tanesinin (%2,7) ASA-1 sınıfında, 288 tanesinin (%96) ASA-2 sınıfında, 4 tanesinin (%1,3) ise ASA-3 sınıfında yer aldığı belirlenmiştir.

**Tablo 2.24.** Örneklem Grubunun Mallampati Sınıfı İle İlgili Verileri

<b>Mallampati</b>	<b>N</b>	<b>%</b>
1	72	24
2	223	74.3
3	5	1.7

Tablo 2.24 incelendiğinde örneklem grubundaki 300 katılımcıdan 72 tanesinin (%24) Mallampati skoru 1, 223 tanesinin (%74,3) Mallampati skoru 2, 5 tanesinin (%1,7) ise Mallampati skorunun 3 olduğu belirlenmiştir.

### 2.1.2. Veri Hazırlama

Daha önce Microsoft Excel’de toplanmış olan 24 parametrelili 300 adet veri R yazılımının read.csv fonksiyonunun yardımı ile R programına aktarılmıştır. Mevcut 24 parametre filtreleme yöntemlerinden olan Bilgi Kazanımı (Information Gain) ve Ki-Kare (Chi-Squared) metotları ile parametre seçimi yapılarak parametre sayısı 16’ya indirgenmiştir.

Veri setlerine uygulanacak sınıflandırma metodu için hold out yöntemi ile %80 eğitim verisi, %20 ise test verisi olarak ayrılmıştır.

Birliktelik analizi yöntemi için üç adet veri seti üzerinde çalışılmıştır. İlk veri seti SDTE, TSAU, hastanın anestezi tercihi parametreleri ve vaka türü “4” (elektif) olan hastalar dahil edilmeyerek, ikinci veri seti SDTE, TSAU, hastanın anestezi tercihi parametreleri ve vaka türü “4” (elektif) olan hastalar dahil edilerek oluşturulurken üçüncü veri setinde ise SDTE, TSAU, hastanın anestezi tercihi parametreleri dahilken, vaka türü “4” (elektif) olan hastalar dahil edilmemiştir.

Aynı zamanda veri seti kategorik ve nümerik değerlerden oluştuğundan birliktelik analizi uygulanabilmesi için nümerik veriler ayrıklaştırılmıştır.

### 2.1.3. Veri Analizi

Çalışmada veri analizi genel anlamda 2 aşamalı olarak ve R programı ile tamamlanmıştır. Kısaca R’a değinilecek olursa R, GPL’ye sahip (General Public License), istatistiki yazılım geliştirme ve veri analizinde kullanılan açık kaynak kodlu, kullanımı kolay ve görselleştirme açısından oldukça zengin bir programlama dilidir.

İlk aşamada veri seti üzerinde parametre seçimi yapılmadan, ikinci aşamada ise Ki-kare ve Bilgi Kazanımı metotlarıyla seçilen parametreler ile oluşturulan veri seti üzerinde veri madenciliği yöntemleri uygulanmıştır.

Aslında bir saflık ölçütü olan Gini indeksi, literatürde bulunan çalışmalar örneğın Selçukcan Erol'un tiroid sınıfını ön görebilmek amacıyla yaptığı çalışma ve Adak ve Yurtay'ın “*Gini Algoritmasını Kullanarak Karar Ağacı Oluşturmayı Sağlayan Bir Yazılımın Geliştirilmesi*” çalışması doğrultusunda algoritma olarak kabul edilen Gini algoritması ile C5.0 algoritması kullanılarak sınıflandırma yapılmıştır. Ayrıca performans deęişikliğini gözlemlemek amacıyla Gini algoritması ile oluşturulan karar ağacı karmaşıklık ölçüsüne göre budanmıştır. Sınıflandırma için kullanılan modellerin performansları karışılık matrisi yardımıyla doğruluk ölçütüne göre karşılaştırılmıştır.

Her iki aşamada da veri seti üzerinde ilk olarak uzman görüşü doğrultusunda küme sayısı 2, 3, 4 ve 5 şeklinde belirlenerek kümeleme analizi gerçekleştirilmiştir. Kümeleme analizi yapılırken veri setinin hem nümerik hem de kategorik olmasından dolayı K-prototip algoritması uygulanmıştır.

Son olarak anestezi türü koşulu belirtilerek ilk ve üçüncü veri setinde destek deęeri 0.1, güven deęeri ise 0.3 ile kısıtlanırken, ikinci veri setinde ise destek deęeri 0.3, güven deęeri ise 0.5 ile kısıtlanarak kullanımı yaygın olan Apriori algoritması kullanılarak birliktelik analizi yöntemi uygulanmıştır.

Eđitim, BMI, normal doğum sayısı parametreleriyle de aynı analizler yapılmış olsa da en yüksek performanslı sonuçlar çalışmada belirtilen parametreler üzerinden gerçekleştirilen analizler sonucunda elde edilmiştir.

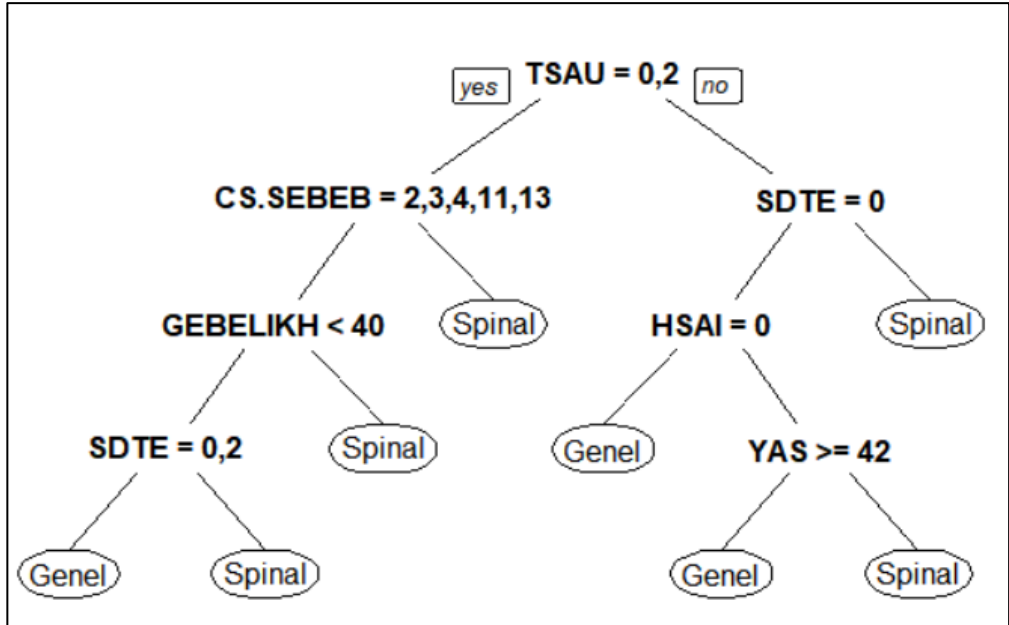
## ÜÇÜNCÜ BÖLÜM

### BULGULAR

#### 3.1. SINIFLANDIRMA YÖNTEMİ BULGULARI

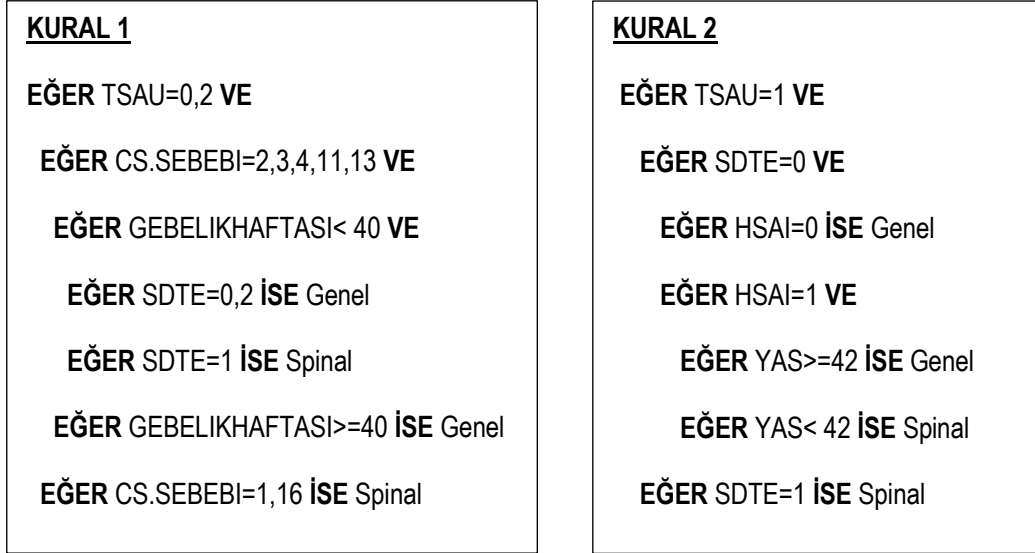
Parametre seçimi için kullanılan Bilgi Kazanımı ve Ki-kare metotları ile aynı parametrelerin seçildiği görülmüştür. Seçilen parametreler ağırlık sıralamasına göre; SDTE, HGAI, HSAI, TSAU, HGAK, HSAK, CS.SEBEBI, VAKA.TURU, GRUP.SAAT, ACLIK.SURESI, ONCEKLANESTEZI.TURU, ONCEKLANELIYAT, CS.SAYISI, MALLAMPATI, KILO şeklindedir.

Parametre seçimi öncesinde ve sonrasında oluşturulan veri setleri ile yapılan sınıflandırma analizinde elde edilen Gini algoritmasından elde edilen budanmış karar ağaçlarının ve C5.0 algoritmasından elde edilen karar ağaçlarının her iki veri seti içinde aynı yapıda olduğu görülmüştür. Fakat parametre seçimi öncesi ve sonrasında Gini algoritması ile elde edilen karar ağaçlarında farklılık tespit edilmiştir. Aşağıda elde edilen karar ağaçları hakkında bilgi verilmiştir.

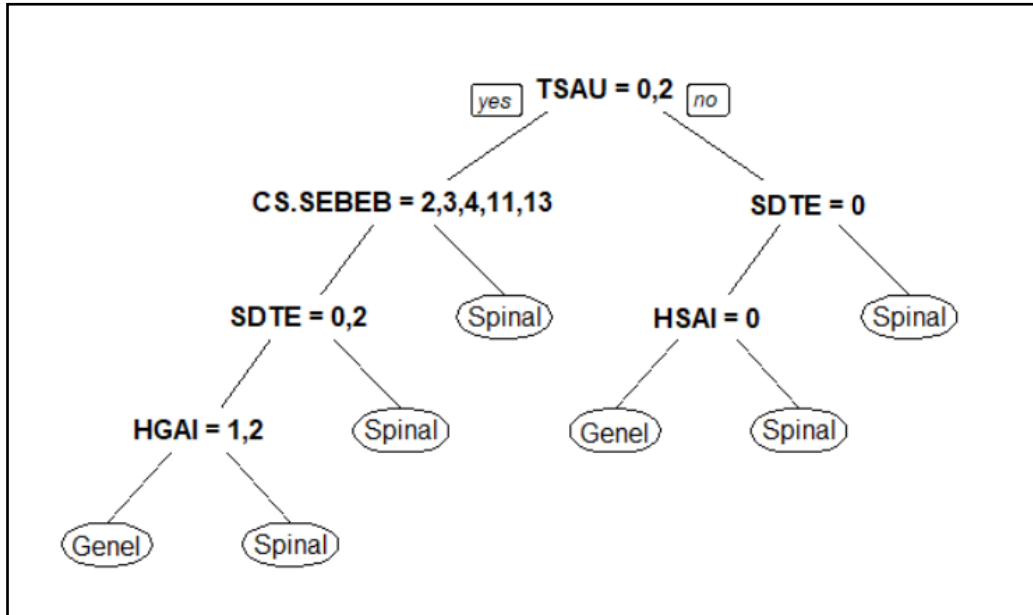


Şekil 3.1. Parametre Seçimi Öncesi Gini Algoritması İle Elde Edilen Karar Ağacı

Şekil 3.1 incelendiğinde ayrımın TSAU özneliği ile başladığı görülmektedir. İkinci düzeyde dallanma CS.SEBEB ve SDTE parametreleri ile, üçüncü düzeyde dallanma GEBELİK HAFTASI ve HSAI parametreleri ile, dördüncü düzeyde dallanma ise SDTE ve YAS parametreleri ile sağlanmıştır. Karar ağacından elde edilen kurallar ise şu şekilde ifade edilebilir;

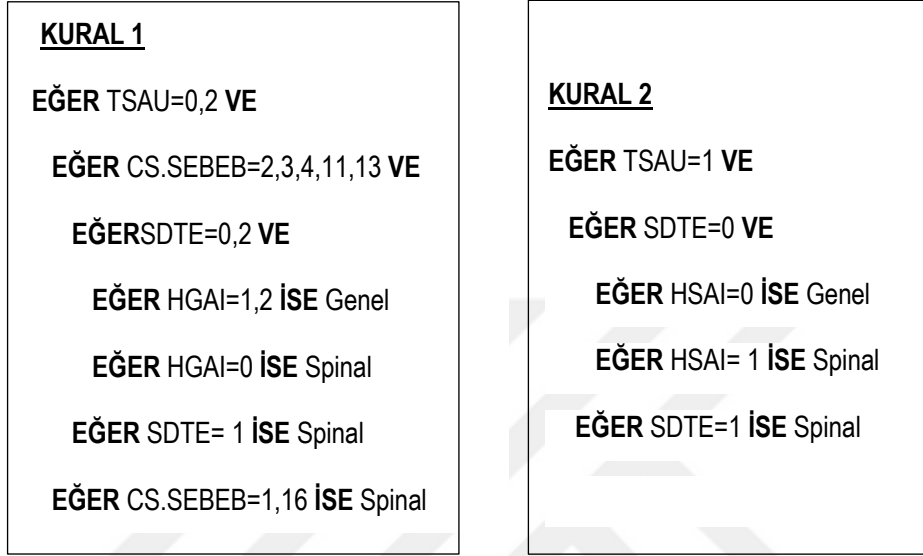


Şekil 3.2. Parametre Seçimi Öncesi Gini Algoritması İle Elde Edilen Karar Ağacı Kuralları



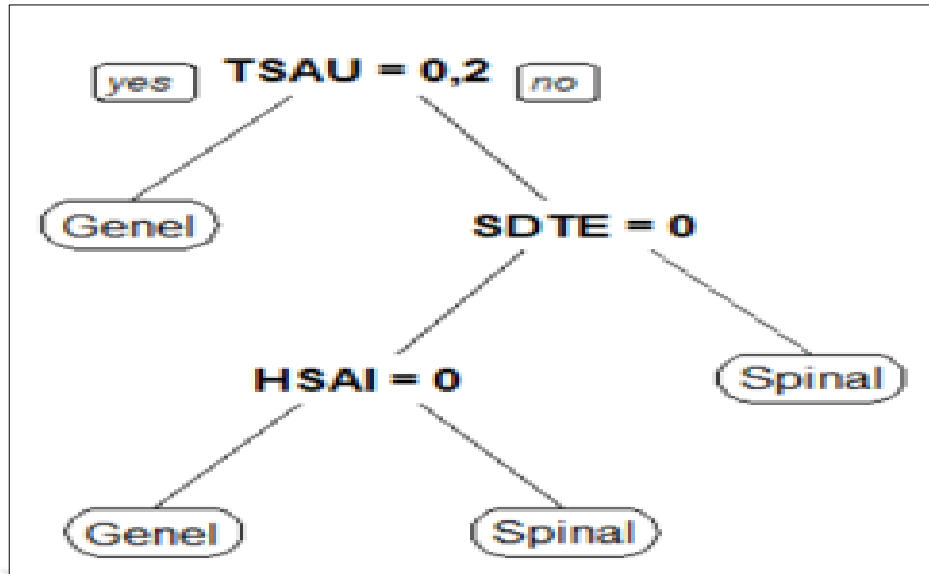
Şekil 3.3. Parametre Seçimi Sonrası Gini Algoritması İle Elde Edilen Karar Ağacı

Şekil 3.3 incelendiğinde ayrımın TSAU özniteliği ile başladığı görülmektedir. İkinci düzeyde dallanma CS.SEBEB ve SDTE parametreleri ile, üçüncü düzeyde dallanma SDTE ve HSAI parametreleri ile, dördüncü düzeyde dallanma ise HGAI özniteliği ile sağlanmıştır. Karar ağacından elde edilen kurallar ise şu şekilde ifade edilebilir.



**Şekil 3.4** Parametre Seçimi Sonrası Gini Algoritması İle Elde Edilen Karar Ağacı Kuralları

Şekil 3.4 bulunan kurallar incelendiğinde e göre TSAU değerinin “0” olması tahlillerin spinal anestezi için uygun olmadığını “2” olması ise hastanın acil durumundan dolayı tahlillerin değerlendirilememesini ifade etmektedir. CS.SEBEBI’nin “2,3,4,11,13” olması sırasıyla Mükerrer CS, Fetal Distres, Dekolman Plasenta, CPD ve Ex Fetüs olması durumunu ifade ederken “1ve”16 olması ise sırasıyla Geçirilmiş CS ve Oligohidramnios olmasını ifade etmektedir. SDTE değerinin “0” olması spinal anesteziyi doktorun tavsiye etmediğini, “2” olması hastanın acil durumundan dolayı doktorun tavsiyede bulunmadığını “1” olması ise doktorun spinal anesteziyi tavsiye ettiğini ifade etmektedir. HGAI değerinin “1” olması hastanın genel anestezi istediğini, “2” olması hastanın aciliyetinden dolayı tercihinin sorulamamasını ifade ederken “0” olması ise hastanın genel anesteziyi istemediğini ifade etmektedir.



**Şekil 3.5.** Gini Algoritması İle Elde Edilen Budanmış Karar Ağacı

Şekil 3.5 incelendiğinde ayrımın TSAU özneliği ile başladığı görülmektedir. İkinci düzeyde dallanma SDTE özneliği ile, üçüncü düzeyde dallanma ise HSAI özneliği ile sağlanmıştır. Karar ağacından elde edilen kurallar ise şu şekilde ifade edilebilir;

**KURAL 1**

**EĞER TSAU=0,2 İSE Genel**

**KURAL 2**

**EĞER TSAU=1 VE**

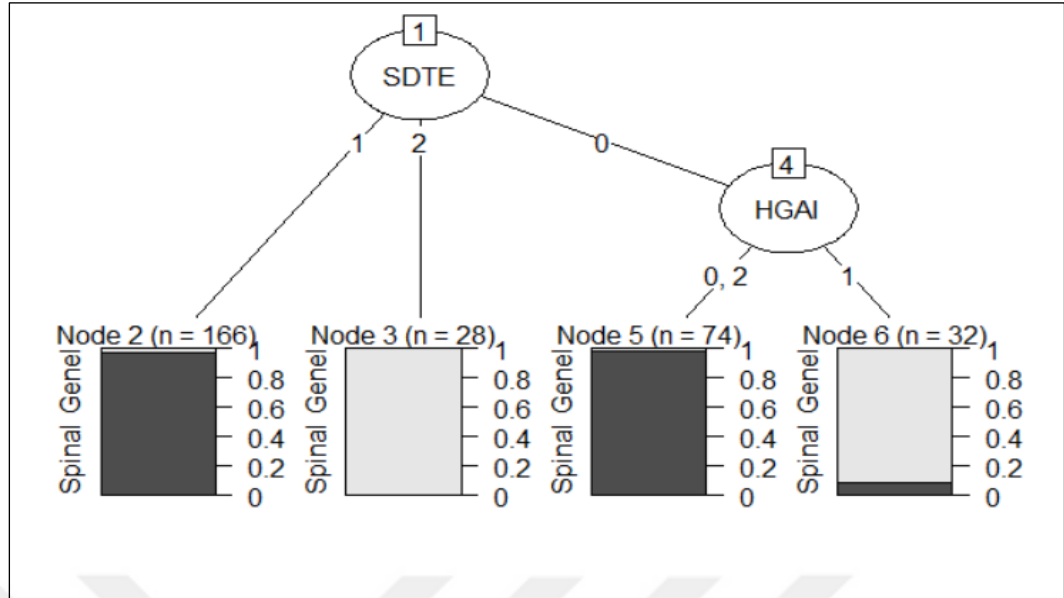
**EĞER SDTE=0 VE**

**EĞER HSAI=0 İSE Genel**

**EĞER HSAI=1 İSE Spinal**

**EĞER SDTE=1 İSE Spinal**

**Şekil 3.6.** Parametre Seçimi Sonrası Gini Algoritması İle Elde Edilen Karar Ağacı Kuralları



Şekil 3.7. C5.0 Algoritması İle Elde Edilen Karar Ağacı

Şekil 3.7 incelendiğinde ayrımın SDTE özneliği ile başladığı görülmektedir. İkinci düzeyde dallanma HGAI özneliği ile sağlanmıştır. Karar ağacından elde edilen kurallar ise şu şekilde ifade edilebilir;

**KURAL 1**

EĞER SDTE=1 İSE Spinal

**KURAL 2**

EĞER SDTE=2 İSE Genel

**KURAL 3**

EĞER SDTE=0 VE

EĞER HGAI=0,2 İSE Spinal

EĞER HGAI=1 İSE Genel

Şekil 3.8. C5.0 Algoritması İle Elde Edilen Karar Ağacı Kuralları



**Tablo 3.1.** Model Performansı Değerlendirme

	Gini Algoritması	Budanmış Gini Algoritması	C5.0 Algoritması
Doğruluk Değeri	0.966101694915254	0.949152542372881	0.98876404494382


Tablo 3.1 İncelendiğinde Gini algoritması ile elde edilmiş karar ağaçlarının doğruluk ölçütüne göre performans değeri her iki veri seti içinde eşit olduğu saptanmıştır. Ayrıca Gni algoritması ile elde edilen karar ağaçlarının, Gini algoritması ile elde edilen budanmış karar ağacının ve C5.0 algoritması ile elde edilmiş karar ağacının doğruluk ölçütüne göre performans değerlendirmeleri sırasıyla % 96,61, %94,91 ve %98,87 olarak saptanmıştır.

### 3.2. KÜMELEME ANALİZİ İLE İLGİLİ BULGULAR


Parametre seçiminden önce ve sonra yapılan kümeleme analizi hakkında bilgi vermek amacıyla elde edilen histogramlar aşağıda gösterilmiştir.

Parametre seçim öncesi kümeler


Parametre seçimi sonrası kümeler



**Şekil 3.9.** k=2 için Seçim Öncesi ve Seçim Sonrası Kümeleme Analizi




**Şekil 3.10.** k=3 için seçim öncesi ve seçim sonrası kümeleme analizi.



**Şekil 3.11.** k= 4 için seçim öncesi ve seçim sonrası kümeleme analizi.

Şekil 3.11 incelendiğinde seçim öncesinde yapılan kümeleme analizinde 4.kümede bulunan hastaların, seçim sonrası yapılan kümeleme analizinde ise 2.kümede bulunan hastaların tamamının genel anesteziyi gerektirecek özellikler, diğer hastaların ise çoğunlukla spinal anesteziyi gerektirecek özellikler taşıdığı tespit edilmiştir.



**Şekil 3.12.** k= 5 için seçim öncesi ve seçim sonrası kümeleme analizi

Şekil 3.12 incelendiğinde seçim öncesi yapılan kümeleme analizinde 3.kümede bulunan hastaların tamamının, 4. Kümedeki hastaların ise tamamına yakınının genel anesteziyi gerektirecek özellikler taşıdığı tespit edilmiştir. Ayrıca seçim sonrası kümeleme analizinde de 1.kümede bulunan hastaların tamamının genel anesteziyi gerektirecek özellikler taşıdığı saptanmıştır.

### 3.3 BİRLİKTELİK ANALİZİ İLE İLGİLİ BULGULAR

Her üç veri setinden de elde edilen kurallardan uzman görüşü doğrultusunda farklı sayılabilecek olanlar aşağıda belirtilmiştir. Şekil 3.13'de ilk veri setinden elde edilen farklı sayılabilecek kurallar, Şekil 3.14'de ikinci veri setinden elde edilen önemli

sayılabilecek kurallar gösterilirken Şekil 3.15’de üçüncü veri setinden elde edilen farklı sayılabilecek kurallar gösterilmiştir.

	D	G	K
[5] {CS.SAYISI=0,ONCEKI.AMELİYAT.TURU=0}→{SIMDIKI.ANESTEZI.TURU= SPINAL}	0.15	0.56	2.86

**Şekil 3.13.** İlk Veri Seti Kuralları.

Şekil 3.13 incelendiğinde elde edilen kuralın destek değerinin % 15, güven değerinin % 56 kaldırmaç değerinin ise 2.86 olarak bulunduğu belirlenmiştir.

	D	G	K
[14]{VAKA.TURU=4,HS AK=1,ONCEKI.AMELİYAT=1}→{SIMDIKI.ANESTEZI.TURU= SPINAL}	0.36	0.94	1.19
[18] {TSAU=1,HS AK=1,ONCEKI.AMELİYAT=1}→{SIMDIKI.ANESTEZI.TURU= SPINAL}	0.39	0.93	1.18
[33] { grup_saat=2} → {SIMDIKI.ANESTEZI.TURU= SPINAL}	0.38	0.90	1.14

**Şekil 3.14.** İkinci Veri Seti Kuralları

Şekil 3.14 incelendiğinde elde edilen kurallardan 14. kuralın destek değeri % 36, güven değeri % 94, kaldırmaç değeri 1.19 olarak, 18.kuralın destek değeri % 39, güven değeri % 93, kaldırmaç değeri 1.18 olarak, 33.kuralın destek değeri %38, güven değeri %90, kaldırmaç değeri ise 1.14 olarak belirlenmiştir.

	D	G	K
[7]{HSAI=0}→{SIMDIKI.ANESTEZI.TURU= SPINAL}	0.11	0.76	3.68
[12] {ONCEKI.ANESTEZI.TURU=0}→{SIMDIKI.ANESTEZI.TURU= SPINAL}	0.16	0.57	2.79

**Şekil 3.15.** Üçüncü Veri Seti Kuralları

Şekil 3.15 incelendiğinde elde edilen kurallardan 7. kuralın destek değeri % 11, güven değeri % 76, kaldırmaç değeri 3.68 olarak, 12.kuralın ise destek değeri % 16, güven değeri % 57, kaldırmaç değeri ise 2.79 olarak belirlenmiştir.

## SONUÇ VE ÖNERİLER

Bu çalışmada, veri madenciliği yöntemleri yardımıyla, sezaryen olgularında karar verilmiş anestezi türünü analiz ederek bir örüntü ve karar mekanizması oluşturmak amaçlanmıştır.

Parametre seçiminde, hem Bilgi kazanımı hem de Ki-kare parametre seçimi yöntemlerinde SDTE özniteliği ilk sırada yer almaktadır. Bu durum hastanın sağlıklı bir doğum geçirmesi açısından doktor tavsiyesi ile hareket etmesinin ne kadar önemli olduğunun bir kanıtıdır.

Çalışmada her iki veri setinden elde edilen karar ağaçları karşılaştırıldığında C5.0 algoritmasının % 98,87 ile en yüksek doğruluk oranına sahip olduğu görülmüştür. Bu karar ağacına göre spinal anestezinin doktor tavsiyesi olması ve hastanın genel anestezi isteyip istememesi anestezi türünün belirlenmesinde oldukça önemli bir rol oynamaktadır. Gini algoritması ile elde edilen karar ağaçlarına göre ise parametre seçiminden önce tahlillerin spinal anesteziye uygunluk durumu sezaryen sebebi, spinal anestezinin doktor tavsiyesi olup olmama durumu, gebelik haftası, hastanın spinal anesteziyi isteyip istememesi durumu ve hastanın yaşı anestezi türünü belirleyen etkenler olarak saptanırken, parametre seçimi sonrası ise yine tahlillerin spinal anesteziye uygunluk durumu sezaryen sebebi, spinal anestezinin doktor tavsiyesi olup olmama durumu ve bunlara ek olarak hastanın genel anestezi isteyip istememesi durumu anestezi türünü belirleyen etkenler olarak saptanmıştır. Gini algoritması ile elde edilen karar ağacının budanmasıyla oluşan karar ağacında ise tahlillerin spinal anesteziye uygun olup olmaması durumu, spinal anestezinin doktor tavsiyesi olup olmama durumu ve hastanın spinal anestezi isteyip istememesi durumu anestezi türünü belirleyen etkenler olarak saptanmıştır. Böylelikle mevcut karar ağaçlarının incelenmesi ile anestezi türünün belirlenmesinde hastanın tahlil dönütlerinin, doktor tavsiyesinin; hastanın, anestezi tercihlerinin, sezaryen sebebinin, gebelik haftasının ve yaşının rol aldığı saptanmıştır. Ancak karar ağaçlarının doğruluk oranlarına bakıldığında parametrelerden, gebelik haftasının ve yaş özniteliğinin sayılan diğer parametreler kadar hedef parametre üzerinde etkili olamadığı sonucuna ulaşılmıştır. Çıkan sonuç, anestezi uzmanlarının tıbbi nedenler konusunda dikkatli olmalarının yanında hastaların anestezi konusunda bilinçlendirilmesinin de önemine vurgu yapmaktadır.

Çalışmada yapılan kümeleme analizinde veri seti, parametre seçimi öncesi ve sonrasında 2 ve 3 kümeye ayrıldığında anestezi türü ile ilgili bariz bir örüntü saptanamamıştır. Fakat veri seti her iki aşamada da 4 ve 5 kümeye ayrıldığında net örüntüler olduğu keşfedilmiştir.

Parametre seçimi öncesi veri seti 4 kümeye ayrıldığında 4.kümede, 5 kümeye ayrıldığında ise 3.kümede, parametre seçimi sonrası ise 4 kümeye ayrıldığında 2.kümede, 5 kümeye ayrıldığında ise 1.kümede bulunan hastaların büyük çoğunluğunun; 55-80 kilo aralığında, açlık sürelerinin 5-12 saat aralığında değiştiği, ameliyata 00:00-06:00 arasında girdikleri saptanırken, ayrıca yine büyük çoğunluğun daha önce herhangi bir ameliyat geçirmediği, herhangi bir anestezi almadığı, vaka türlerinin çok acil olduğu, sezaryen sebeplerinin “3” (Fetal Distres) ve “4” (Dekolman Plasenta) olduğu, mallampati sınıflarının ise 2 olduğu karakteristiklerini taşıdıkları, bu karakteristiklere ek olarak parametre seçiminden önce yapılan kümeleme analizinde 4 kümeye ayrıldığında 4.kümede, 5 kümeye ayrıldığında ise 3.kümede bulunan hastaların büyük çoğunluğunun; 20-40 yaş aralığında, 1.55-1.70 boy aralığında, 35-40 hafta gebelik haftası içinde buldukları, yandaş bir hastalıklarının bulunmadığı ve herhangi bir ilaç kullanmadıkları, ASA sınıflarının ise 2 olduğu ortak karakteristiklerini taşıdıkları sonucuna ulaşılmıştır.

Ayrıca çalışmanın sınıflandırma yöntemi sonucunda anestezi türünü belirlemede etkili olduğu düşünülen yaş özniteliğinin alan uzmanı tarafından karar sürecinde etkili olmadığı belirtilmiştir. Bu ifadenin nedeni yaş niteliğinin zaten biyokimya testlerinin de içinde olmasından kaynaklanabilir.

Birliktelik analizi sonucunda elde edilen kurallar veri setleri dahilinde incelendiğinde ilk veri setinde bulunan 5.kurala göre; CS sayısı 0 önceki anestezi türü “0”( anestezi öyküsü yok) olan hastaların %56’sının şimdiki anestezi türünün spinal olduğu anlaşılmıştır. % 15 ihtimalle bu üçlünün bütün operasyonlarda birlikte oldukları söylenebilir. Ayrıca kaldırma oranının 1’den büyük olması kuralın tahmin olarak kullanılabileceğini söylemektedir. Alan uzmanı ise özellikle stabil hastalarda bir müddet beklenebilirliğin ve acil ile beraber stabil hasta grubunda yine açlık süresinin uygun olmaması ve gebelik haftasının küçük olmasının kuralın oluşumunda etkili olabileceğini belirtmiştir.

İkinci veri setinde bulunan 14. kurala göre; vaka türü “4”(elektif), hastanın spinal anesteziye korktuğu ve önceki ameliyatı “1” (sezaryen) olan hastaların %94’ünün şimdiki anestezi türünün spinal olduğu anlaşılmıştır. % 36 ihtimalle bu dördlünün bütün operasyonlarda birlikte oldukları söylenebilirken kaldırma değerinden dolayı kuralın tahmin olarak kullanılabilmesi söylenebilir. Alan uzmanına danışıldığında ise gebelik haftası süresinin küçüklüğü, daha önce geçirdiği sezaryen sayısına bağlı olarak karın içindeki yapışıklığın yoğunluğundan ötürü bebeğin çıkış süresi gecikeceğinden genel anestezi yapılması durumunda bebeğin anesteziye etkilenmemesi için doktorun hastayı spinal anesteziye ikna etmesi durumunda kuralın oluşabileceği anlaşılmaktadır.

18.kurala göre; tahlilleri spinal anesteziye uygun, spinal anesteziye korkan ve önceki ameliyatı “1” (sezaryen) olan hastaların % 93’ünün şimdiki anestezi türünün spinal olduğu anlaşılmaktadır. %39 ihtimalle bu dördlünün bütün operasyonlarda birlikte oldukları söylenebilirken kaldırma değerine bakıldığında kuralın tahmin olarak kullanılabilmesi söylenebilir. Alan uzmanına danışıldığında şimdiki sezaryen nedeninin geçirilmiş veya mükerrer CS olabileceği, SDTE ve açlık süresinin 8 saatin altında olmasının kuralın oluşumunda etkili olabileceği belirtilmiştir.

Üçüncü veri seti incelendiğinde ise 7.kurala göre; spinal anestezi istemeyen hastaların %76’sının şimdiki anestezi türünün spinal anestezi olduğu anlaşılmaktadır. %11 ihtimalle bu ikilinin bütün operasyonlarda bir arada bulunduğu ve kaldırma değerine göre ise kuralın tahminlerde kullanılabilmesi söylenebilir. Kuralın ortaya çıkmasında açlık süresinin uygunsuzluğu, obezite ve gebelik haftasının küçüklüğü nedeniyle doktorun spinal anesteziyi uygun görmesi ve bunu hastaya tavsiye etmesinin etkili olabileceği alan uzmanı tarafından belirtilmiştir.

12. kurala göre ise; önceki anestezi türü “0” (anestezi öyküsü yok) olan hastaların % 57’sinin şimdiki anestezi türünün spinal anestezi olduğu anlaşılmaktadır. % 16 ihtimalle bu ikilinin bütün operasyonlarda bir arada bulunduğu ve kaldırma değerine bakılarak kuralın tahminlerde kullanılabilmesi söylenebilir. Ayrıca 33.kurala göre; ameliyata giriş saati 06:00-12:00 arasında olan hastaların % 90’nının Şimdiki anestezi türünün spinal olduğu, % 38 ihtimalle söz konusu ikilinin bütün operasyonlarda bir arada bulunduğu ve kaldırma değerine bakılarak kuralın tahminlerde kullanılabilmesi saptanmıştır. Alan uzmanı ise, hastaların çok acil ve acil olduğunda vakanın

bekletilememesine ve stabil yada elektif olması durumunda ise açlık süresinin 8 saatin altında olmasına, gebelik haftasının küçük olmasına (< 35 hafta) ve anestezi deneyimine bağlı olarak mevcut kuralların oluşabileceğini belirtmektedir.

Yukarıda bahsi geçen sonuçlar doğrultusunda öncelikle hastaların bilinç düzeylerinin artırılması amacıyla infografikler, broşürler veya bilgilendirme toplantıları vb. uygulamalarla hastaların anestezi türleri konusunda doğru bir şekilde bilgilendirilmesi önerilmektedir.

Veri sayısı artırılarak analizlerin yapay zekâ teknikleriyle yapılması önerilmektedir.

Hastanın ameliyat öncesi bilgilendirme noktasında hasta verilerinin kullanılması da öneriler arasındadır.

## TARTIŞMA

Her ne kadar daha önce anestezi türü ile ilgili veri madenciliği çalışması olmasa da tıp literatürüne girmiş veri madenciliği çalışmalarına bakıldığında Topaloğlu ve Sur'un, Abdar ve arkadaşlarının ve de Şatır ve arkadaşlarının yapmış oldukları çalışmalarda oluşturulan karar ağaçlarının başarı performanslarına yakın hatta daha yüksek değerler elde edildiğinden dolayı yukarıda belirtilen karar ağaçlarının anestezi uzmanları tarafından kullanılabilmesi görülmektedir.

Ayrıca çalışma içerisinde kullanılan parametrelerden farklı olarak alerji test sonuçları, Elektrokardiyografi sonuçları, kan sayımı ve anestezi uzmanlarının belirleyeceği farklı parametrelerle yöntemlerin tekrarlanması oluşturulan karar ağaçlarında değişimlere yol açabilir.

Verilerin sadece Erzurum ve çevresindeki hastalardan elde edilmesi yaş, boy, kilo, sezaryen sayısı, anestezi tercihleri gibi parametreleri sınırlandırdığından veri toplama çerçevesi genişletilerek analizler yinelenmelidir.

Çalışmadaki öneriler bunların daha fazla veriyle tekrar edilmesi ya da anestezi türünün, doğum dışında diğer operasyonlar da dikkate alınarak yeniden analiz edilmesinin tıp bilişimi alanına katkı sağlayacağı düşünülmektedir.

Çalışmanın bulgularının, gelecekte yapılacak kadın doğum alanında kullanılacak anestezi türü konulu çalışmalara da bir temel oluşturabileceği düşünülmektedir. Ayrıca doğumlarda kullanılan anestezi türlerine karar verirken başka parametreleri de göz önünde bulundurma bağlamında yol gösterici olabilir.



## KAYNAKÇA

- Abdar, M., Zomorodi Moghadam, M., Das, R., & Ting, I.-H. (2017). "Performance Analysis of Classification Algorithms on Early Detection of Liver Disease". *Expert Systems with Applications*, 239-251.
- Adak, M. F., & Yurtay, N. (2013). "Gini Algoritmasını Kullanarak Karar Ağacı Oluşturmayı Sağlayan Bir Yazılımın Geliştirilmesi". *Bilişim Teknolojileri Dergisi*, 6(3).
- Agrawal, R., Imielinski, T., & Swami, A. (1993). Mining Association Rules between Sets of Items in Large Databases. *Proceedings of the 1993 ACM SIGMOD international conference on Management of data (ACMSIGMOD '93)*, (s. 207--216).
- Akpınar, H. (2014). *Data*. İstanbul: Papatya Yayıncılık.
- Alagöz, A., Öge, S., & Ortakarpuz, M. (2014). "Bir Kurumsal Zekâ Teknolojisi Olarak Veri Madenciliği İle Muhasebe Bilgi Sistemi İlişkisi". *Selçuk Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 1-21.
- Altun, M. (2017). *Veri Madenciliği ve Uygulama Alanları*. Antalya: Akdeniz Üniversitesi.
- Altunkaynak, B. (2017). *Veri Madenciliği Yöntemleri ve R Uygulamaları*. Ankara: Seçkin Yayıncılık.
- Argüden, Y., & Erşahin, B. (2008). *Veri Madenciliği*. İstanbul: ARGE Danışmanlık.
- Arttıran İğde, F. (2004). Sezaryen Sonrası Normal Vajinal Doğum. *Sürekli Tıp Eğitimi Dergisi*, 13(4), 137-140.
- Atasever, Ü. H. (2011). Uydu Görüntülerinin Sınıflandırılmasında Hızlandırma (Boosting), Destek Vektör Makineleri, Rastgele Orman (Random Forest) Ve Regresyon Ağaçları Yöntemlerinin Kullanılması. (*Yüksek Lisans Tezi*). Kayseri: Erciyes Üniversitesi Fen Bilimleri Enstitüsü.
- Ateş, Y. (2008). "Spinal, Epidural ve Kaudal Bloklar". M. Tulunay, & H. Cuhruk içinde, *Klinik Anesteziyoloji* (s. 289 - 324). Ankara: Güneş Tıp Kitabevleri.

- Balaban, M., & Kartal, E. (2016). "Veri Madenciliği Süreci ve Futbol Maç Sonuçlarının Öngörülmesine İlişkin Bir Uygulama". M. E. Balaban, & E. Kartal içinde, *R ile Veri Madenciliği Uygulamaları* (s. 2). İstanbul: Çağlayan Kitabevi.
- Batislam, Y. (2008). "Obstetrik Anestezi". M. Tulunay, & H. Cuhruk içinde, *Klinik Anesteziyoloji* (s. 890-922). Ankara: Güneş Tıp Kitabevleri.
- Berkhin, P. (tarih yok). *Survey of Clustering Data Mining Techniques*. Ocak 26, 2018 tarihinde <https://www.cc.gatech.edu/~isbell/reading/papers/berkhin02survey.pdf> adresinden alındı
- Betrán, A. P., Ye, J., Moller, A.-B., Zhang, J., Gülmezoglu, A. M., & Torloni, M. R. (2016). "The Increasing Trend in Caesarean Section Rates: Global, Regional and National Estimates: 1990-2014". *PLoS ONE*, *11*(2). <https://doi.org/10.1371/journal.pone.0148343> adresinden alınmıştır
- Birnback, J. D., & Browne, M. I. (2010). Anesthesia for Obstetrics. R. D. Miller içinde, *Miller's Anesthesia* (s. 2203-2236). Churchill Livingstone Elsevier.
- Brachman, R. J., & Anand, T. (1996). The Process of Knowledge Discovery in Databases. U. M. Fayyad içinde, *Advances in Knowledge Discovery and Data Mining* (s. 37-57).
- Brown, D. L. (2010). "Spinal, Epidural and Caudal Anesthesia". R. Miller içinde, *Miller's Anesthesia* (s. 1611 - 1639). Philadelphia: Churchill Livingstone Elsevier.
- Coşkun, C., & Baykal, A. (2011). "Veri Madenciliğinde Sınıflandırma Algoritmalarının Bir Örnek Üzerinde Karşılaştırılması". *XIII. Akademik Bilişim Konferansı Bildirileri* (s. 51-57). Malatya: İnönü Üniversitesi.
- CRISP-DM 1.0. (2000). *Step-by-step data mining guide*. Registered by SPSS Inc.
- Cunningham, F. G., Gant, N. F., & Leveno, K. J. (2001). "Cesarean section and postpartum hysterectomy". *Williams Obstetrics* (21 b., s. 537-565). içinde McGraw-Hill.
- Cunningham, F., Leveno, K., Bloom, S., Spong, C., Dashe, J., & Hoffman, B. (2014). "Cesarean section and postpartum hysterectomy". *Williams Obstetrics* (s. 587-588). içinde New York: McGraw-Hill Education.

- Çalış, A., Kayapınar, S., & Çetinyokuş, T. (2014). "Veri Madenciliğinde Karar Ağacı Algoritmaları ile Bilgisayar ve İnternet Güvenliği Üzerine Bir Uygulama". *Endüstri Mühendisliği Dergisi*, 2-19.
- Çam, S. (2014). *Veri Madenciliğinde Kümeleme Analizi ve Sağlık Sektöründe Bir Uygulaması*. (Yüksek Lisans Tezi). Sivas: Cumhuriyet Üniversitesi Sosyal Bilimler Enstitüsü.
- Çataloluk, H. (2012). *Gerçek Tıbbi Veriler Üzerinde Veri Madenciliği Yöntemlerini Kullanarak Hastalık Teşhisi*. (Yüksek Lisans Tezi). Bilecik: Bilecik Üniversitesi Fen Bilimleri Enstitüsü.
- Danacı, M., Çelik, M., & Akkaya, A. E. (2010). "Veri Madenciliği Yöntemleri Kullanılarak Meme Kanseri Hücrelerinin Tahmin ve Teşhisi". *Akıllı Sistemlerde Yenilikler ve Uygulama Sempozyumu*, (s. 9-12). Kayseri.
- Demircioğlu, H. Z., & Bilge, H. Ş. (2015). "Yumurtalık Kanseri Veri Kümesindeki Gen İfadelerinin Veri Madenciliği ile Analizi". *Marmara Fen Bilimleri Dergisi*, 125-134.
- Duman, Z. (2006). *Sağlık Çalışanlarının Normal Doğum Ve Sezaryen İle ilgili Düşünceleri* (Yayınlanmış Yüksek Lisans Tezi). Afyonkarahisar: Afyon Kocatepe Üniversitesi Sağlık Bilimleri Enstitüsü.
- Elmas, F. (2014). *Kalp Krizi Riskinin Bir Veri Madenciliği Uygulaması İle Analizi*. (Yüksek Lisans Tezi). Muğla: Muğla Sıtkı Kocaman Üniversitesi Fen Bilimleri Enstitüsü.
- Emel, G. G., & Taşkın, Ç. (2005). "Veri Madenciliğinde Karar Ağaçları ve Bir Satış Analizi Uygulaması". *Eskişehir Osmangazi Üniversitesi Sosyal Bilimler Dergisi*, 6(2), 221-236.
- Enders, C. K. (2010). *Applied Missing Data Analysis*. London, United Kingdom: The Guilford Press.
- Erdem, M. K., Özgen, S., & Coşkun, F. (1996). "Obstetrik Anestezi ve Analjezi". H. A. Kişinçi içinde, *Temel Kadın Hastalıkları ve Doğum Bilgisi* (s. 173-186). Ankara: Melisa Matbaacılık.

- Erdem, M., Özgen, S., & Coşkun, F. (1996). "Obstetrik Anestezi ve Analjezi". H. A. Kınışçı, & G. E içinde, *Temel Kadın Hastalıkları ve Doğum Bilgisi* (s. 86-173). Ankara: Melisa Matbaacılık.
- Erdine, S. (1993). *Sinir Blokları*. İstanbul: Emre Matbaacılık.
- Erkuş, S. (2015). *Veri Madenciliği Yöntemleri İle Kardiyovasküler Hastalık Tahmini Yapılması*. (Yüksek Lisans Tezi). İstanbul: Bahçeşehir Üniversitesi Fen Bilimleri Enstitüsü.
- Ezberci, M., Zencirci, B., Öksüz, H., & Güven, A. (2005). "Sezaryenlerde genel ve epidural anestezinin bebek stres hormonları, kan gazları ve Apgar skoru üzerine olan etkilerinin karşılaştırılması". *Türk Jinekoloji ve Obstetrik Derneği Dergisi*, 284 - 289.
- Fakı, B. M. (2015). *Veri Madenciliği Yöntemlerini Kullanarak Anemi Sınıflandırılmasına Yönelik Bir Uygulama*. (Yüksek Lisans Tezi). İstanbul: İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü.
- Fayyad, U., Shapiro, G., & Smyth, P. (1996). "From Data Mining to Knowledge Discovery in Databases". *AI Magazine*, 17(3), 37-54.
- Foroughi, F., & Luksch, P. (2018, Mart 12). *Data Science Methodology for Cybersecurity Projects*. Cornell University Library: <https://arxiv.org/abs/1803.04219> adresinden alınmıştır
- Gezer, M. (2016). "Veri Madenciliğinde Verinin Ön İşlenmesi". M. Balaban, & E. Kartal içinde, *R ile Veri Madenciliği Uygulamaları* (s. 157-158). İstanbul: Çağlayan Kitabevi.
- Göğüş, Y. (2010). "Spinal ve Epidural Anestezi". A. N. Tüzüner F içinde, *Anestezi Yoğun Bakım Ağrı* (s. 545- 561). Ankara: MN Medikal ve Nobel Kitapları.
- Gümüşçü, A., Aydilek, b. B., & Taşaltın, R. (2016). "Mikro-dizilim Veri Sınıflandırmasında Öznitelik Seçme Algoritmalarının Karşılaştırılması". *Harran Üniversitesi Mühendislik Dergisi*, 1-7.

- Gümüřçü, A., Tařaltın, R., & Aydilek, İ. B. (2016). "C4.5 Karar Aęaęlarında Genetik Algoritma İle Budama". *Dicle Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 5(2), 77-80.
- Günaydın, B. ( 2012). "Obstetrik ve Jinekolojik Anestezi. Y. Keçik, N. Alkış, D. Yörükoęlu, & Z. Alanoęlu içinde, *Temel Anestezi* (s. 549 - 569). Ankara: Güneř Tıp Kitabevleri.
- Han, J., & Kamber, M. (2006). *Data Mining: Concepts and Techniques* (Cilt Second Edition). Morgan Kaufmann.
- Hand, D., Mannila, H., & Smyth, P. (2001). *Principles of Data Mining [Elektronik Sürüm]*. England: The MIT Press.
- Harris, A. P. (1990). "Emergency Cesarean Section". M. C. Rogers içinde, *Current Practice In Anesthesiology* (s. 355-361). Toronto: B.C Decker.
- Huang, Z. (1997). "Clustering large data sets with mixed numeric and categorical values"., (s. 21-34). Singapore.
- Huang, Z. (1998). "Extensions to the k-means algorithm for clustering large data sets with categorical values". *Data mining and knowledge discovery*, 2(3), 283–304.
- İstanbul Üniversitesi İstanbul Tıp fakültesi. (2015). *ASA Sınıflandırması*. <http://istanbultip.istanbul.edu.tr/asa-american-society-of-anesthesiologists-siniflandirmasi/#> adresinden alınmıştır
- Jain, A. K., Murty, M. N., & Flynn, P. J. (1999). "Data Clustering:A Review". *ACM Computing Surveys*, 3(31).
- Ji, J., Pang, W., Zheng, Y., Wang, Z., Ma, Z., & Zhang, L. (2015). "A Novel Cluster Center Initialization Method for the k-prototypes algorithms using centrality and distance". *Applied Mathematics & Information Sciences*, 9(6), 2933-2942.
- Jipkate, B. R., & Gohokar, V. V. (2012). "A Comparative Analysis of Fuzzy C-Means Clustering and K Means Clustering Algorithms". *International Journal Of Computational Engineering Research*, 2(3), 737-739.

- Kacem, M. A., n'cir, C.-e. B., & Nadia, E. (2015). "Parallel K-prototypes for Clustering Big Data". *Conference: International Conference Computational Collective Intelligence-ICCCI 2015*, 7, s. 628-636. Madrid, Spain.
- Kantardzic, M. (2011). *Data Mining: Concepts, Models, Methods, and Algorithms* (Cilt Second Edition). USA: John Wiley & Sons.
- Karahan Adalı, G. (2016). "Birliktelik Kuralları ile Veri Madenciliğinde Bir Pazarlama Uygulaması Gerçekleştirilmesi". M. E. Balaban içinde, *R ile Veri Madenciliği Uygulamaları* (s. 222-223). İstanbul: Çağlayan Kitabevi.
- Kararmaz, A., Kaya, S., Turhanoğlu, S., & Özyılmaz, M. (2003). "Sezaryen İçin Spinal Anestezi Uygulanan Olgularda Hipotansiyon İle İlişkili Faktörler". *Dicle Tıp Dergisi*, 30(1-4), 61-65.
- Kavzoğlu, T., & Çölkesen, İ. (2010). "Karar Ağaçları İle Uydu Görüntülerinin Sınıflandırılması: Kocaeli Örneği". *Harita Teknolojileri Elektronik Dergisi*, 2(1), 36-45.
- Kayhan, Z. (1998). "Entübasyon güçlüğü, tanımı, nedenleri, sınıflandırılması, önceden belirlenmesi". *Anestezi Dergisi*, 6(3), 91-96.
- Kayhan, Z. (2004). *Klinik Anestezi*. Ankara: Logos Yayıncılık.
- Kayısoğlu, B. (2014). *Maliyete Duyarlı Veri Madenciliği Yöntemleri İle Akciğer Kanseri Sınıflandırılması*. (Yüksek Lisans Tezi). Kayseri: Erciyes Üniversitesi Fen Bilimleri Enstitüsü.
- Keçik, Y., Alkış, N., Yörükoğlu, D., & Alanoğlu, Z. (2012). *Temel Anestezi*.
- Kocamanoğlu, İ. S., Sarıhasan, B., Şener, B., Tür, A., Şahinoğlu, H., & Sunter, T. (2005). "Sezaryen uygulamalarında uygulanan anestezi yöntemleri ve komplikasyonları: 3552 olgunun retrospektifdeğerlendirilmesi". *Türkiye Klinikleri Journal of Medical Sciences*, 25(6), 810 - 816.
- Koçoğlu, F. Ö., & Özcan, T. (2016). "Veri Madenciliğinde Kümeleme Algoritmaları ile Müşteri Segmantasyonu". M. E. Balaban, & E. Kartal içinde, *R ile Veri Madenciliği Uygulamaları* (s. 193). İstanbul: Çağlayan Kitabevi.

- Konakçı, S., & Kılıç, B. (2004). "İzmir'de sezaryen sıklığı ve buna etki eden faktörler". *T Klin Jinekoloj Obst*, 14(2), 88-95.
- Lawrence, T. C. (2009). "Chestnut's Obstetric Anesthesia: Principles And Practice". D. H. Chestnut, L. C. Tseng, L. S. Polley, & C. A. Wong içinde, *Anesthesia for Cesarean Delivery* (s. 521-575). Philadelphia: Elsevier Mosby.
- Lellan, K. M. (2004). "Postoperative pain: Strategy for improving patient experiences". *Journal of Advanced Nursing*, 46(2), 179-185.
- Lucas, D. N., Yentis, S. M., Kinsella, S. M., Holdcroft, A., May, A. E., Wee, M., & Robinson, P. N. (2000). "Urgency of caesarean section: a new classification". *Journal of the Royal Society of Medicine*, 93(7), 346-350.
- Luo, Y., Li, Z., Guo, H., Cao, H., Song, C., Guo, X., & Zhang, Y. (2017). "Predicting Congenital Heart Defects: A Comparison of Three Data Mining Methods". *PLoS ONE*, 12(5). e0177811. <https://doi.org/10.1371/journal.pone.0177811> adresinden alınmıştır
- MacKenzie, I. Z., & Cooke, I. (2002). "What is a reasonable time from decision to delivery by caesarean section? Evidence from 415 deliveries". *BJOG: An International Journal of Obstetrics & Gynaecology*, 109(2), 498-504.
- Marie Plasse, N. N.-K. (2005). "Utilisation conjointe des regles d'association et de la classification de variables". *Journées Françaises de Statistiques*.
- Mather, P. M. (1987). *Computer Processing Of Remote-Sensed Images*. John Wiley & Sons.
- McCahon, R. A., & Catling, S. (2003). "Time required for surgical readiness in emergency caesarean section: spinal compared with general anaesthesia". *International journal of obstetric anaesthesia*, 12(3), 178-182.
- Medimagazin. (2017, 3). *Sezaryende dünya birincisi Türkiye'nin istatistikleri!* 12 2017 tarihinde alındı
- OECD. (2018). *Caesarean sections*. <https://data.oecd.org/healthcare/caesarean-sections.htm> adresinden alınmıştır

- Okumuş, N., Önal, E. E., Türkyılmaz, C., Demirci, S., Koç, E., Atalay, Y., . . . Günaydın, B. (2009). "Doğum Şekli Ve Anneye Uygulanan Anestezi Tipinin Postnatal Erken Dönemde Yeni Doğanlarda Görülen Tartı Kaybına Etkileri". *Türkiye Çocuk Hastalıkları Dergisi*, 3(1), 31-40.
- Onan, A. (2015). "Şirket İflaslarının Tahmin Edilmesinde Karar Ağacı Algoritmalarının Karşılaştırmalı Başarım Analizi". *Bilişim Teknolojileri Dergisi*, 8(1), 9-18.
- Öğüdücü, Ş. G. (tarih yok). Veri Madenciliği Farklı Sınıflandırma Yöntemleri. Ocak 2018 tarihinde <http://web.itu.edu.tr/~sgunduz/courses/verimaden/slides/d4.pdf> adresinden alındı
- Önderoğlu, L., Karamürsel, B., & Taşkıran, Ç. (2005). *Obstetrik Operasyonlar*. Ankara: Güneş Kitabevi.
- Özcan, S. (2009). *Endotrakeal Entübasyon Yöntemlerine Hemodinamik Yanıtların Karşılaştırılması*. (Uzmanlık Tezi). Aydın: Adnan Menderes Üniversitesi Tıp Fakültesi Anesteziyoloji Ve Reanimasyon Anabilim Dalı.
- Özdemir, H., & Kayhan, Z. (2011). "Nöroaksiyel Bloklarda Başarısızlıklar ve Nedenleri". *Türk Anest Rean Der Dergisi*, 39(4), 198-206.
- Özgünen, T., & Evrücke, C. (2001). *Sezaryen*. İstanbul: Nobel Tıp Kitapevleri.
- Özgünen, T., & Evrücke, C. (2001). "Sezaryen". S. Beksaç içinde, *Obstetrik Maternal Fetal Tıp Perinatoloji* (s. 1322-1328). İstanbul: Nobel Tıp Kitapevleri.
- Özkan, Y. (2008). *Veri Madenciliği Yöntemleri*. İstanbul: Papatya Yayıncılık.
- Öztürk, E., But, A., Gülhaş, N., Begeç, Z., Doğan, Z., Yapıcı, E., & Ersoy, Ö. M. (2006). "Sezaryende bupivakain ve ropivakainin hemodinami üzerine etkileri". *Türk Anest Rean Der Dergisi*, 34(6), 355 - 360.
- Pala, T. (2013). *Tıbbi Karar Destek Sisteminin Veri Madenciliği Yöntemleriyle Gerçekleştirilmesi*. (Yüksek Lisans Tezi). İstanbul: Marmara Üniversitesi Fen Bilimleri Enstitüsü.
- Pandya, R., & Pandya, J. (2015). "C5.0 Algorithm to Improved Decision Tree with Feature Selection and Reduced Error Pruning". *International Journal of Computer Applications*, 117(16), 19-21.



- Patil, N., Lathi, R., & Chitre, V. (2012). "Comparison of C5.0 & CART Classification algorithms using pruning technique". *International Journal of Engineering Research & Technology*, 1(4), 1-5.
- Piatetsky, G. (2014). "CRISP-DM, still the top methodology for analytics, data mining, or data science projects". *KDD News*.
- Pickett, J. (2002). "History of Obstetric Analgesia and Anesthesia". R. Collis, F. Plaat, & J. Urquhart içinde, *Text Book of Obstetric Anesthesia* (s. 1 – 21). London: Greenwich Medical Media.
- Pirinççiler, E. C., & Şen, A. (2012). "Süreç İyileştirme Çalışmalarında Veri Madenciliği Yaklaşımının Kullanılması Üzerine Bir Çalışma". *Muğla Sıtkı Koçman Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 58- 77.
- Powers, M. W. (2011). "Evaluation: From "Precision, Recall and F-Measure to ROC, Informedness, Markedness & Correlation". *Journal of Machine Learning Technologies*, 2(1), 37-63.
- Purtuloğlu, T. P., Özkan, S., Teksöz, E., Dere, K., Pen, H., Yen, T., & Dağlı, G. (2008). "Elektif sezaryen uygulanan olgularda genel ve spinal anestezinin maternal ve fetal etkilerinin karşılaştırılması". *Gülhane Tıp Dergisi*, 50, 91-97.
- Rollins, J. B. (2015). *Foundational Methodology for Data Science*. IBM: <https://www-01.ibm.com/common/ssi/cgi-bin/ssialias?htmlfid=IMW14824USEN> adresinden alınmıştır
- Rubio-Escudero, C., Valverde-Fernandez, J., Nepomuceno-Chamorro, I., Pontes-Balanza, B., Hernandez-Mendoza, Y., & Rodríguez-Herrera, A. (2017). "Data Mining Techniques Applied to Hydrogen Lactose Breath Test". *PLoS ONE*, 12(1). e0170385. <https://doi.org/10.1371/journal.pone.0170385> adresinden alınmıştır
- Rutkowski, L., Jaworski, M., Pietruczuk, L., & Duda, P. (2014). "Gauss Yaklaşımına Dayalı Veri Akımlarının Madenciliği İçin Karar Ağaçları". *IEEE Transactions on Knowledge and Data Engineering*, 26(1), 108-119.
- Saeyns, Y., Inza, I., & Larranaga, P. (2007). "A review of feature selection techniques in bioinformatics". *bioinformatics*, 23(19), 2507-2517.

- Sağlık İstatistikleri Yıllığı 2016*. (2017, Aralık). T.C. Sağlık Bakanlığı: <https://dosyasb.saglik.gov.tr/Eklenti/13183,sy2016turkcepdf.pdf?0> adresinden alınmıştır
- Santos, A., Bravemen, F. R., & Finster, F. (2006). "Obstetric Anesteheasia". P. G. Barash, B. F. Cullen, & R. K. Stoelting içinde, *Clinical Anesthesia* (s. 1152-1180). Lippincott Williams ve Wilkins.
- Sarıman, G. (2011). "Veri Madenciliğinde Kümeleme Teknikleri Üzerine Bir Çalışma:K-Means ve K-Medoids Kümeleme Algoritmalarının Karşılaştırılması". *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 15(3), 192-202.
- Savaş, S., Topaloğlu, N., & Yılmaz, M. (2012). "Veri Madenciliği ve Türkiye'deki Uygulama Örnekleri". *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi*, 1-23.
- Selçukcan Erol, Ç. (2016). "Sağlık Bilimlerinde R ile Veri Madenciliği". M. E. Balaban, & E. Kartal içinde, *R ile Veri Madenciliği Uygulamaları* (s. 26). İstanbul: Çağlayan Kitabevi.
- Senthilkumar, D., & Paulraj, S. (2015). "Prediction of Low Birth Weight Infants and Its Risk Factors Using Data Mining Techniques". *Proceedings of the 2015 International Conference on Industrial Engineering and Operations Management*. Dubai: United Arab Emirates.
- Sever, H., & Oğuz, B. (2003). "Veri Tabanlarında Bilgi Keşfine Formel Bir Yaklaşım Kısım I: Eşleştirme Sorguları ve Algoritmalar". *Bilgi Dünyası*, 3(2), 173-204.
- Silahtaroglu, G. (2013). *Veri Madenciliği*. İstanbul: Papatya Yayıncılık.
- Souza, J., Betran, A., Dumont, A., Mucio, B. D., GibbsPickens, C., & Deneux-tharoux, C. (2016). "A globalreferenceforcaesarean sectionrates (C-Model): a multicountrycross-sectionalstudy". *BJOG*, 123(3), 427-436.
- Sullivan, R. (2012). *Introduction to Data Mining for the Life Sciences*. Cincinnati, OH, USA: Springer.
- Şahin, Ş. (2010). "Obstetrik Anestezi ve Analjezi". F. Tüzüner, N. Alkış, İ. Aşık, & A. A. Yılmaz içinde, *Anestezi Yoğun Bakım Ağrı* (s. 973-993). Ankara: MN Medikal & Nobel.

- Şahin, Ş., & Owen, M. (2002). "Türkiye’de ve dünyada obstetrik analjezi ve anestezi". *Türk Anest Rean Cem Mecmuası*, 30, 52-59.
- Şahin, Ş., & Owen, M. D. (2006). *Ağrısız Doğum ve Sezaryende Anestezi*. Nobel&Güneş Tıp Kitabevleri.
- Şatır, E., Azboy, F., Aydın, A., Arslan, H., & Haciefendioğlu, Ş. (2016). "Veri İndirgeme ve Sınıflandırma Teknikleri ile Glokom Hastalığı Teşhisi". *El-Cezerî Fen ve Mühendislik Dergisi*, 3(3), 485-497.
- T.C. Sağlık Bakanlığı Ana Çocuk Sağlığı ve Aile Planlaması Genel Müdürlüğü. (2010). *Doğum ve Sezaryen Eylemi Yönetim Rehberi*. Ankara: Damla Matbaacılık.
- Tagva, K., & ark, v. (1994). "The Effects of Noisy Data on Text Retrieval". *journal of the American Society for Information Science*, 45(1), 134-135.
- Tan, P.-N., Steinbach, M., & Kumar, V. (2005). *Introduction to Data Mining*. Pearson .
- Taşkın, Ç., & Emel, G. G. (2010). "Veri Madenciliğinde Kümeleme Yaklaşımları ve Kohonen Ağları İle Perakendecilik Sektöründe Bir Uygulama". *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 15(3), 395-409.
- Toker, K., Yılmaz, A., Gürkan, A., Baykara, N., Canatay, H., Özdamar, D., & Yıldız, Ş. T. (2003). "Sezaryen Ameliyatlarında Anestezi Uygulaması, 5 Yıllık Retrospektif Değerlendirme". *Türk Anest Rean Cem Mecmuası*, 31, 26-30.
- Topaloğlu, M., & Sur, H. (2015). "Sarılık Semptomlarında Yanlış Teşhisi Azaltmak İçin Karar Ağacı Uygulaması". *Nobel Medicus*, 11(3), 64-73.
- Tulunay, M., & Cuhruk, H. (2008). *Batıslam Y. Obstetrik Anestezi*. 890-922: Güneş Tıp Kitabevleri.
- Turan, A. Z., Bombacı, E., Yılmaz, M., & Ömür, Y. (2017). "Spinal Anestezide Blok Başarısını Etkileyen Faktörler". *Türkiye Klinikleri Journal of Anesthesiology Reanimation*, 15(1), 9-14.
- Turban, E., Sharda, R., & Delen, D. (2011). *Decision Support and Business Intelligence Systems*. New Jersey: Pearson Education Inc.

- Türk Anesteziyoloji ve Reanimasyon Derneği (2015). Anestezi uygulama kılavuzları. *Preoperatif değerlendirme*. <https://www.tard.org.tr/assets/kilavuz/preoperatifdegerlendirme.pdf> adresinden alınmıştır
- Two Crows. (1999). *Introduction to Data Mining and Knowledge Discovery* (Cilt Third Edition). Two Crows Corporation.
- Ulucan, Ö., & Pektekin, P. (2009). "Muhasebe Yolsuzluklarının Tespitinde Adli Muhasebecinin Rolü ve Veri Madenciliği Tekniklerinin Kullanılması". *Muhasebe Bilim Dünyası Dergisi*, 4.
- Wang, F., Franco, H., Pugh, J., & Ross, R. (2016). "Empirical Comparative Analysis of 1-of-K Coding and K-Prototypes in Categorical Clustering". *Irish Conference on Artificial Intelligence and Cognitive Science (AICS 2016)*. University College Dublin.
- Xie, J., & Wang, C. (2011). "Using Support Vector Machines with A Novel Hybrid Feature Selection Method for Diagnosis of Erythemato-Squamous Diseases". *Expert Systems with Applications*, 5(38), 5809-5815.
- Yazıcı, B., Yaşlı, F., Gürleyik, H. Y., Turgut, U. O., Aktas, M. S., & Kalıpsız, O. (2015). "Veri Madenciliğinde Özellik Seçim Tekniklerinin Bankacılık Verisine Uygulanması Üzerine Araştırma ve Karşılaştırmalı Uygulama". *In Proceedings of the 9th Turkish National Software Engineering Symposium,(UYMS 2015)*. Yasar University, Izmir, Turkey.
- Yegül, İ. (1996, Aralık 5-8). "Obstetride Rejyonel Analjezi ve Anestezi". *VI. Uludağ Kış Sempozyumu,5-8 Aralık*, (s. 80-85). Bursa.
- Yeh, D.-Y., Cheng, C.-H., & Chen, Y.-W. (2011). "A Predictive Model for Cerebrovascular Disease Using Data Mining". *Expert Systems with Applications*, 38(7), 8970-8977.
- Yıldız, O., Tez, M., Bilge, H., Akcayol, M., & Güler, İ. (2012). "Meme Kanseri Sınıflandırması İçin Veri Füzyonu ve Genetik Algoritma Tabanlı Gen Seçimi". *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 27(3), 659-668.

Yılmazlar, A. (2012). "Spinal, Epidural ve Kaudal Anestezi". Y. Keçik, N. Alkış, D. Yörükoğlu, & Z. Alanoğlu içinde, *Temel Anestezi* (s. 797 - 820). Ankara: Güneş Tıp Kitabevleri.

Zaki, M. J., & JR, W. M. (2014). *Data Mining and Analysis: Fundamental Concepts and Algorithms*. New York: Cambridge University Press.



## EKLER

## EK 1. HASTA TANIMA FORMU

ŞİMDİKİ ANESTEZİ TÜRÜ:	GENEL( )	SPİNAL( )
YAŞ	BOY	KİLO
GEBELİK HAFTASI( )	CS SAYISI ( )	AÇLIK SÜRESİ..... CS SEBEBİ ( )
ÖNCEKİ ANESTEZİ TÜRÜ ( )		
HASTA SPİNAL ANESTEZİ İSTİYORMU	EVET( )	HAYIR( )
HASTA GENEL ANESTEZİDEN KORKUYOR	EVET( )	HAYIR( )
TAHLİLLERİ SPİNAL ANESTEZİYE UYGUN	EVET( )	HAYIR( )
SPİNALİ DOKTOR TAVSİYE ETTİ	EVET( )	HAYIR( )
HASTA GENEL ANESTEZİ İSTİYOR	EVET( )	HAYIR( )
HASTA SPİNAL ANESTEZİDEN KORKUYOR	EVET( )	HAYIR( )
ACİL VAKA ( )	ELEKTİF VAKA( )	
Yandaş Hastalık Öyküsü (Ek hastalık)	EVET( )	HAYIR( )
Ek hastalık:	HT..... DM..... Guatr.....	Astım..... ÜSYE..... DİĞER.....
İlaç kullanımı	EVET( )	HAYIR( )
İlaç kullanımı(NE ALMIŞ):	Anti hipertansif..... Aspirin.....	Ağrı kesici..... Clexane.....
(kaçık)	Diğer.....	
ÖNCEKİ AMELİYATLARI (ne olmuş)		
AMELİYAT GİRİŞ SAATİ		
ASA ( )	MALLAMPATİ ( )	

## EK 2. ETİK KURUL KARARI

ATATÜRK ÜNİVERSİTESİ TIP FAKÜLTESİ KLİNİK ARAŞTIRMALAR ETİK KURULU	
<b>HAKEM DEĞERLENDİRME FORMU</b>	
2014   Araştırma No:	
Araştırmanın adı:	"Sezaryen olgularında uygulanan anestezi yöntemlerinin veri madenciliği yöntemleri kullanılarak analizi"
Araştırmanın adı çalışma içeriği ile uyumlu mu?	Evet <input checked="" type="checkbox"/> Hayır <input type="checkbox"/>
Araştırmanın destekleyicisi var mı?	Evet <input checked="" type="checkbox"/> Hayır <input type="checkbox"/>
Bütçe formu doldurulmuş mu?	Evet <input checked="" type="checkbox"/> Hayır <input type="checkbox"/>
Bütçe ile ilgili varsa eleştirileriniz	
<b>ARAŞTIRMADAKİ GÖNÜLLÜ POPÜLASYONU</b>	
Sayı olarak	Yeterli <input checked="" type="checkbox"/> Yetersiz <input type="checkbox"/>
Çalışmanın içeriğine	Uygun <input checked="" type="checkbox"/> Uygun değil <input type="checkbox"/>
Gönüllü bilgilendirme formu	Uygun <input checked="" type="checkbox"/> Uygun değil <input type="checkbox"/>
Yetersizse Önerileriniz	
<b>BAŞVURUDA YER ALAN KLİNİK ARAŞTIRMA MERKEZLERİ/ARAŞTIRMACILAR</b>	
Katılımcılar çalışmanın kapsamına uygundur	Evet <input checked="" type="checkbox"/> Hayır <input type="checkbox"/>
Çalışma kapsamına katılmasının uygun olduğunu düşündüğünüz birimler konusunda önerileriniz...	
<b>Araştırmada uygulanacak yaklaşım ve yöntemleri</b>	
GİRİŞ VE AMAÇ	Yeterli <input checked="" type="checkbox"/> Yetersiz <input type="checkbox"/>
MATERYAL VE METOD	Yeterli <input checked="" type="checkbox"/> Yetersiz <input type="checkbox"/>
KAYNAKLAR	Yeterli <input checked="" type="checkbox"/> Yetersiz <input type="checkbox"/>
Yetersizse Önerileriniz	
<b>ARAŞTIRMANIN TASARIMI İLE İLGİLİ GÖRÜŞLER</b>	



ATATÜRK ÜNİVERSİTESİ TIP  
FAKÜLTESİ KLİNİK ARAŞTIRMALAR  
ETİK KURULU



## KARAR

ETİK KURULU BİLGİLERİ	ETİK KURULUN ADI	Atatürk Üniversitesi Tıp Fakültesi Klinik Araştırmalar Etik Kurulu
	AÇIK ADRESİ	Atatürk Üniversitesi Tıp Fakültesi Dekanlığı
	TELEFON	+90 442 234 65 11
	FAKS	+90 442 236 09 68
	E-POSTA	anatipetikkurul@gmail.com
SORUMLU ARAŞTIRMACI UNVANI/ADISOYADI	Güzem Dilan BOZTAŞ	
ARAŞTIRMACININ AÇIK ADI	Sezaryen Olgularında Uygulanan Anestezi Yöntemlerinin Veri Madenciliği Yöntemleri Kullanılarak Analizi	
KARAR BİLGİLERİ	Toplantı Sayısı: 2 Karar No: 46	Tarih: 15.02.2018
	Yukarıda bilgileri verilen başvuru dosyası ile ilgili belgeler araştırmanın/çalışmanın gerekece, amaç, yaklaşım ve yöntemleri dikkate alınarak incelenmiş ve çalışmanın bilginin/kredisi taraflardan faydalanması kapsamında ile yapılmasında bilimsel ve etik açıdan sakınca olmadığına oy birliği ile karar verildi. Klinik Araştırmalar Hakkında Yönetmelik kapsamında yer alan araştırmalar/çalışmalar için Türkiye İlaç ve Tıbbi Cihaz Kurumu'ndan izin alınması gerekmektedir. Araştırmacıya çalışmalarında başarılar dileriz.	

Prof.Dr.Zeynep ÇAKIR  
Etik Kurul Başkanı

Prof.Dr.M.Hamidullah UYANIK  
Üye

Prof.Dr.Zekai HALICI  
Üye

Prof.Mustafa GÜL  
Üye

Doç.Dr.Anılla ÇAYIR  
Üye

Doç.Dr.İlker İNCE  
Üye

Yrd.Doç.Dr.Zahide KOŞAN  
Üye

Emrah MİLETLİOĞLU  
Üye





ATATÜRK ÜNİVERSİTESİ TIP  
FAKÜLTESİ KLİNİK ARAŞTIRMALAR  
ETİK KURULU



Bölümü : Dekanlık  
Servisi : Klinik Araştırmalar Etik Kurulu  
Sayı : B.30.2.ATA.0.01.00/64  
Konu : Etik Kurul Kararı

15.02.2018

Sayın: Gizem Dilan BOZTAŞ  
Sosyal Bilimleri Enstitüsü  
Yüksek Lisans Öğrencisi

Değerlendirilmek üzere Klinik Araştırmalar Etik Kurulu'na başvuruda bulunduğunuz "Sezaryen Olgularında Uygulanan Anestezi Yöntemlerinin Veri Madenciliği Yöntemleri Kullanılarak Analizi" isimli bilimsel tez çalışmasına ait Kurul Kararı ekte sunulmuştur.

Klinik Araştırmalar Hakkında Yönetmelik kapsamında yer alan araştırmalar/çalışmalar için Türkiye İlaç ve Tıbbi Cihaz Kurumu'ndan izin alınması gerekmektedir.

Bilgilerinizi ve gereğini rica ederim.

Prof.Dr.Zeynep ÇAKIR  
Etik Kurul Başkanı

Eki :  
1 Adet Etik Kurul Kararı

## EK 3. APRIORİ ALGORİTMASI İLE ELDE EDİLEN BİRLİKTELİK KURALLARI

### İlk veri setinden elde edilen birliktelik kuralları

	lhs	rhs	support	confidence	lift	count
[1]	{VAKA. TURU=1}	=> {SIMDIKI. ANESTEZI. TURU=Gene}}	0.1033333	0.7380952	5.272109	31
[2]	{ONCEKI. AMELIYAT=0}	=> {SIMDIKI. ANESTEZI. TURU=Gene}}	0.1233333	0.4868421	3.477444	37
[3]	{ONCEKI. ANESTEZI. TURU=0}	=> {SIMDIKI. ANESTEZI. TURU=Gene}}	0.1233333	0.4457831	3.184165	37
[4]	{CS. SAYISI=0}	=> {SIMDIKI. ANESTEZI. TURU=Gene}}	0.1200000	0.4390244	3.135889	36
[5]	{CS. SAYISI=0, ONCEKI. ANESTEZI. TURU=0}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.1500000	0.5625000	2.860169	45
[6]	{CS. SAYISI=0}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.1533333	0.5609756	2.852418	46
[7]	{DOGUM. S.=0}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.1166667	0.5555556	2.824859	35
[8]	{ONCEKI. ANESTEZI. TURU=0}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.1533333	0.5542169	2.818052	46
[9]	{ONCEKI. AMELIYAT=0}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.1300000	0.5131579	2.609277	39

### İkinci veri setinden elde edilen birliktelik kuralları

	lhs	rhs	support	confidence	lift	count
[1]	{VAKA. TURU=4, HSAI=1}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.3200000	1.0000000	1.260504	96
[2]	{VAKA. TURU=4, HGAI=0}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.3266667	1.0000000	1.260504	98
[3]	{HSAI=1, TSAU=1}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.4000000	0.9917355	1.250087	120
[4]	{VAKA. TURU=4, SDTE=1}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.3833333	0.9913793	1.249638	115
[5]	{HSAI=1, HGAI=0}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.3700000	0.9910714	1.249250	111
[6]	{HGAI=0}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.4533333	0.9855072	1.242236	136
[7]	{HSAI=1}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.4100000	0.9840000	1.240336	123
[8]	{SDTE=1, ONCEKI. AMELIYAT=1}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.3333333	0.9803922	1.235788	100
[9]	{HSAK=1, grup_saat=2}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.3066667	0.9787234	1.233685	92
[10]	{SDTE=1}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.5400000	0.9759036	1.230131	162
[11]	{VAKA. TURU=4, TSAU=1, grup_saat=2}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.3033333	0.9578947	1.207430	91
[12]	{TSAU=1, grup_saat=2}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.3766667	0.9576271	1.207093	113
[13]	{VAKA. TURU=4, grup_saat=2}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.3066667	0.9484536	1.195530	92
[14]	{VAKA. TURU=4, HSAK=1, ONCEKI. AMELIYAT=1}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.3600000	0.9473684	1.194162	108
[15]	{VAKA. TURU=4, TSAU=1, HSAK=1}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.4366667	0.9424460	1.187957	131
[16]	{HGAK=0, grup_saat=2}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.3233333	0.9417476	1.187077	97
[17]	{CS. SEBEBI=1}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.3600000	0.9391304	1.183778	108
[18]	{TSAU=1, HSAK=1, ONCEKI. AMELIYAT=1}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.3933333	0.9365079	1.180472	118
[19]	{HSAK=1, ONCEKI. AMELIYAT=1}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.4000000	0.9302326	1.172562	120
[20]	{CS. SAYISI=1, ONCEKI. AMELIYAT=1}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.3100000	0.9300000	1.172269	93
[21]	{VAKA. TURU=4, HSAK=1}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.4400000	0.9295775	1.171736	132
[22]	{CS. SAYISI=1, TSAU=1}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.3233333	0.9238095	1.164466	97
[23]	{TSAU=1, HSAK=1}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.5966667	0.9226804	1.163043	179
[24]	{TSAU=1, ONCEKI. ANESTEZI. TURU=2}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.3166667	0.9223301	1.162601	95
[25]	{CS. SAYISI=1, VAKA. TURU=4}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.3000000	0.9183673	1.157606	90
[26]	{CS. SAYISI=1}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.3300000	0.9166667	1.155462	99
[27]	{VAKA. TURU=4, TSAU=1, ONCEKI. AMELIYAT=1}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.4700000	0.9155844	1.154098	141
[28]	{TSAU=1, ONCEKI. AMELIYAT=1}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.5166667	0.9117647	1.149283	155
[29]	{VAKA. TURU=4, TSAU=1}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.5766667	0.9105263	1.147722	173
[30]	{ONCEKI. ANESTEZI. TURU=2}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.3266667	0.9074074	1.143791	98
[31]	{VAKA. TURU=4, ONCEKI. AMELIYAT=1}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.4766667	0.9050633	1.140836	143
[32]	{HSAK=1}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.6033333	0.9050000	1.140756	181
[33]	{grup_saat=2}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.3800000	0.9047619	1.140456	114
[34]	{TSAU=1}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.7766667	0.8961538	1.129606	233
[35]	{ONCEKI. AMELIYAT=1}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.5300000	0.8932584	1.125956	159
[36]	{VAKA. TURU=4}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.5866667	0.8844221	1.114818	176

### Üçüncü veri setinden elde edilen kurallar

	lhs	rhs	support	confidence	lift	count
[1]	{HGAI=0}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.1266667	0.9500000	4.596774	38
[2]	{SDTE=1, ONCEKI. ANESTEZI. TURU=0}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.1233333	0.9487179	4.590571	37
[3]	{CS. SAYISI=0, SDTE=1}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.1200000	0.9473684	4.584041	36
[4]	{SDTE=1, ONCEKI. AMELIYAT=0}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.1066667	0.9411765	4.554080	32
[5]	{SDTE=1}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.1566667	0.9400000	4.548387	47
[6]	{TSAU=1}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.2000000	0.8571429	4.147465	60
[7]	{HSAI=0}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.1166667	0.7608696	3.681627	35
[8]	{CS. SAYISI=0, ONCEKI. AMELIYAT=0}	=> {SIMDIKI. ANESTEZI. TURU=Gene}}	0.1133333	0.4657534	3.582719	34
[9]	{ONCEKI. AMELIYAT=0}	=> {SIMDIKI. ANESTEZI. TURU=Gene}}	0.1166667	0.4605263	3.542510	35
[10]	{CS. SAYISI=0}	=> {SIMDIKI. ANESTEZI. TURU=Gene}}	0.1166667	0.4268293	3.283302	35
[11]	{ONCEKI. ANESTEZI. TURU=0}	=> {SIMDIKI. ANESTEZI. TURU=Gene}}	0.1166667	0.4216867	3.243744	35
[12]	{ONCEKI. ANESTEZI. TURU=0}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.1600000	0.5783133	2.798290	48
[13]	{CS. SAYISI=0}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.1566667	0.5731707	2.773407	47
[14]	{DOGUM. S.=0}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.1200000	0.5714286	2.764977	36
[15]	{ONCEKI. AMELIYAT=0}	=> {SIMDIKI. ANESTEZI. TURU=Spinal}}	0.1366667	0.5394737	2.610357	41

## ÖZGEÇMİŞ

<b>Kişisel Bilgiler</b>	
Adı Soyadı	Gizem Dilan BOZTAŞ
Doğum Yeri ve Tarihi	Kağızman – 03.01.1993
<b>Eğitim Durumu</b>	
Lisans Öğrenimi	Atatürk Üniversitesi İktisadi ve İdari Bilimler Fakültesi Yönetim Bilişim Sistemleri (2012-2016) Atatürk Üniversitesi Açıköğretim Fakültesi Sosyoloji (2013- )
Y. Lisans Öğrenimi	Atatürk Üniversitesi Sosyal Bilimler Enstitüsü Yönetim Bilişim Sistemleri Anabilim Dalı
Bildiği Yabancı Diller	İngilizce
<b>İş Deneyimi</b>	
Çalıştığı Kurumlar	Atatürk Üniversitesi Açıköğretim Fakültesi (2014-2016)
<b>İletişim</b>	
E-Posta Adresi	gizem.boztas@hotmail.com
<b>Tarih</b>	16.07.2018