



**VERİ MADENCİLİĞİ İLE KÜTÜPHANE KULLANIMI VE DERS
BAŞARISI ARASINDAKİ İLİŞKİNİN İNCELENMESİ**

Şükran ARMUTLU

Yüksek Lisans Tezi

Danışman: Dr. Öğr. Üyesi Gülten DEMİRAL

Uşak

Kasım, 2018

**VERİ MADENCİLİĞİ İLE KÜTÜPHANE KULLANIMI VE DERS
BAŞARISI ARASINDAKİ İLİŞKİNİN İNCELENMESİ**

Şükran ARMUTLU

YÜKSEK LİSANS TEZİ

İşletme Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Gülten DEMİRAL

Uşak

Uşak Üniversitesi Sosyal Bilimler Enstitüsü

Kasım, 2018

ÖZET

VERİ MADENCİLİĞİ İLE KÜTÜPHANE KULLANIMI VE DERS BAŞARISI ARASINDAKİ İLİŞKİNİN İNCELENMESİ

Şükran ARMUTLU

İşletme Ana Bilim Dalı

Uşak Üniversitesi Sosyal Bilimler Enstitüsü, Kasım, 2018

Danışman Dr. Öğr. Üyesi Gülten DEMİRAL

Bilişim teknolojilerinde yaşanan olağanüstü gelişmeler birçok sektörde veriyi üretme, toplama ve depolama oranlarını arttırmaktadır. Anlık olarak depolanabilen yüksek hacimli veriler analiz edilmediği sürece anlam ifade etmemekte ve veri yığımına dönüşmektedir. Öte yandan verinin doğru yöntemlerle analiz edilmesi sonucunda karar vericiler için kullanışlı bilgiler elde edilmektedir. Ancak veriyi klasik yöntemlerle analiz etmek ayrıntılı ve yararlı sonuçlara ulaşılabilmesi için yetersiz kalmaktadır. Bu aşamada mevcut veri kaynaklarını kullanışlı, anlaşılır hale getirme, yararlı bilgiye dönüştürme ve ham veri içerisinde potansiyel bilgileri elde etmede veri madenciliği yaygın olarak kullanılan yöntemlerden biridir.

Bu çalışmada, Uşak Üniversitesi İktisadi ve İdari Bilimler Fakültesi (İİBF) İşletme bölümü öğrencilerinin, Uşak Üniversitesi Merkez Kütüphanesinden ödünç almış oldukları zorunlu ders içerikli kitaplar ile zorunlu dersler arasındaki başarı ilişkisi, veri madenciliği tanımlayıcı modellerinden birliktelik analizi kullanılarak incelenmiştir. Birliktelik analizi, açık kaynak kodlu WEKA veri madenciliği yazılımı ile uygulanmıştır. Analiz WEKA yazılımı içerisinde mevcut olan ve yaygın olarak kullanılan Apriori algoritması ile gerçekleştirilmiştir.

Analiz’de 17 adet zorunlu ders üzerine odaklanılmıştır. Analiz sonucunda ders harf notu, ders başarı durumu ve kitap kullanımına ait çeşitli birliktelik kuralları elde edilmiştir. Böylelikle öğrencilerin ödünç almış olduğu zorunlu ders içerikli kitaplar ile dersten geçme – kalma durumu ve harf notu arasındaki ilişkiler yüzdelerle değerlerle ortaya konulmuştur. Ayrıca birliktelik kuralları sonucunda 17 adet dersin tamamında kitap ödünç alımı ile dersten geçme durumu arasında ilişki tespit edilmiştir.

Anahtar Kelimeler: *Veri madenciliği, Birliktelik Kuralları, Apriori Algoritması, WEKA.*

ABSTRACT

THE ANALYSIS OF THE RELATIONSHIP BETWEEN LIBRARY USE AND COURSE ACHIEVEMENT THROUGH DATA MINING

Şükran ARMUTLU

Social Sciences Department

Uşak University Social Sciences Institute, Nov, 2018

Advisor: Dr. Gülten DEMİRAL

Extraordinary developments in information technologies increase the rate of data production, collection and storage in many sectors. That high volume of data, which can be stored instantaneously, does not make sense unless it is analyzed and transformed into a pile of data. On the other hand, by analyzing the data with the right methods, useful information can be obtained for decision makers. However, analyzing data manually in classical ways is insufficient to achieve detailed and useful results. In this sense, data mining is one of the most widely used method for making available data sources usable, understandable, transforming them into useful information and finally, obtaining potential information from raw data.

In this study, the relationship between (Uşak University Faculty of Economics and Administrative Sciences) students' borrowed books about their must courses from Central Library of Uşak Univeristy and their success in the must courses were investigated through association analysis, which is one of descriptive data mining techniques. The association analysis was performed via open source WEKA data mining software. The analysis was carried out with the Apriori algorithm, which is widely used technique as found in WEKA.

In this analysis it was focused on 17 must courses. As a result of the analysis, various association rules for course letter note, course achievement status and book

use were obtained. In this way, the relationship between the students' borrowed books about must courses and the status of passing or failing the course along with the course grade are presented as percentage values. In addition, as a result of the association rules, a relation was found between the borrowing book and the status of passing the course in all 17 courses.

Keywords: *Data Mining, Association Rules, Apriori Algorithm, WEKA.*





UŞAK ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
 Tezli Yüksek Lisans Jüri ve Enstitü Onayı

JÜRİ VE ENSTİTÜ ONAYI

İşletme Ana Bilim Dalı Tezli Yüksek Lisans Programı 164005015 No'lu öğrencisi Şükran ARMUTLU'nun 'Veri Madenciliği İle Kütüphane Kullanımı ve Ders Başarısı Arasındaki İlişkinin İncelenmesi' adlı tezi 16 / 11 / 2018 tarihinde, aşağıdaki jüri tarafından Uşak Üniversitesi Lisansüstü Eğitim Öğretim ve Sınav Yönetmeliğinin ilgili maddeleri uyarınca, Yüksek Lisans tezi olarak değerlendirilerek kabul edilmiştir.

Jüri	Adı Soyadı	İmza
Danışman	: Dr. Öğr. Üyesi Gülten DEMİRAL	
Üye	: Dr. Öğr. Üyesi Ozan ÇATIR	
Üye	: Dr. Öğr. Üyesi Utku KÖSE	
Üye	:	

Enstitü Müdürü

ÖNSÖZ

Tez çalışmamın planlanmasında, araştırılmasında ve yürütülmesinde bana yardımcı olan ve tez yazımı boyunca engin bilgilerini benden esirgemeyerek çalışmayı bilimsel temeller ışığında şekillendiren sayın danışmamım Dr. Öğr. Üyesi Gülten DEMİRAL'a, çalışma konumu seçmemde ışık tutan Öğr. Gör. Ahmet DEMİR'e, lisansüstü eğitimim boyunca beni destekleyen Doç. Dr. Musatafa SOBA'ya, yöntem bilgisi ile aydınlatan Dr. Öğr. Üyesi Utku KÖSE ve Dr. Öğr. Üyesi Ozan ÇATIR'a teşekkürlerimi sunarım.

Benden hiçbir zaman desteğini esirgemeyerek cesaretlendiren canım eşim HASAN'a, bana yürekten güvenen fedakâr anneme ve tez yazımı boyunca elinden gelen her yöntemle beni teşvik eden güzel kızım ÖYKÜ'ye sevgilerimle.

Bu çalışmamı kızım Öykü'ye atfediyorum.

Şükran ARMUTLU

UŞAK, 2018

ÖZGEÇMİŞ

Kişisel Bilgiler:

Adı Soyadı: Şükran ARMUTLU

Doğum Yeri ve Tarihi: Bilecik – 26.01.1982

Lisans Öğrenimi: Anadolu Üniversitesi, İşletme Fakültesi, İşletme Bölümü

Yüksek Lisans Öğrenimi: Uşak Üniversitesi, İşletme Anabilim Dalı

Bildiği Yabancı Diller: İngilizce

İş Denevimi:

Çalıştığı Kurum: E-Yaz yazılım (2006)

Çalıştığı Kurum: ASD Web Tasarım (2006-2010)

Makale / Bildiri

Kütüphane Veri Tabanında Veri Madenciliği: Uşak Üniversitesi Örneği. Bartın Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi.

İletişim:

sukranarmutlu@gmail.com

İÇİNDEKİLER

ÖZET.....	iii
ABSTRACT	V
JÜRİ VE ENSTİTÜ ONAYI.....	vii
ÖNSÖZ.....	viii
ÖZGEÇMİŞ.....	ix
TABLolar LİSTESİ.....	xiv
ŞEKİLLER LİSTESİ.....	xv
KISALTMALAR	xvi
GİRİŞ	1
1. BÖLÜM VERİ MADENCİLİĞİ.....	3
1.1. Veri.....	3
1.2. Veri Tabanı.....	3
1.3. Veri Tabanı Yönetim Sistemleri (VTYS)	4
1.4. Veri Madenciliğinin Tanımı	4
1.5. Veri Madenciliğinin Tarihçesi.....	6
1.6. Veri Madenciliğinin Günümüzdeki Durumu	8
1.7. Veri Madenciliğinin Geleceği	8
1.8. Veri Madenciliğinin Önemi.....	10
1.9. Veri Madenciliğinde Kullanılan Yazılımlar	11
1.9.1. WEKA.....	12
1.9.2. RapidMiner	13

1.9.3.	R	13
1.9.4.	Orange	14
1.9.5.	KNIME.....	14
1.9.6.	IBM SPSS Modeler (SPSS Clementine).....	15
1.9.7.	SAS Enterprise Miner	15
1.9.8.	MS SQL Server Analysis Services	16
1.10.	Veri Madenciliği'nin Farklı Disiplinlerle İlişkisi.....	16
1.11.	Veri Madenciliğinin Uygulama Alanları.....	17
1.11.1.	Eğitim Sektörü	18
1.11.2.	Kütüphanecilik	19
1.11.3.	Bankacılık ve Finans	20
1.11.4.	Sigortacılık	21
1.11.5.	Ticaret ve Pazarlama	21
1.11.6.	Sağlık	22
1.11.7.	Diğer Sektörler	22
2.	BÖLÜM AMPİRİK LİTERATÜR	24
2.1.	Ulusal Çalışmalar	24
2.2.	Uluslararası Çalışmalar	26
3.	BÖLÜM VERİ TABANINDA BİLGİ KEŞFİ SÜRECİ VE VERİ MADENCİLİĞİ YÖNTEMLERİ.....	28
3.1.	Problemin Tanımlanması	29
3.2.	Veri Seçme	29
3.3.	Veri Ön İşleme	29
3.3.1.	Veri Birleştirme.....	30
3.3.2.	Veri Temizleme.....	31
3.3.3.	Veri Dönüştürme (Uyumlaştırma)	31
3.3.4.	Veri İndirgeme (Azaltma).....	32
3.4.	Veri Madenciliği Aşaması.....	32
3.5.	Değerlendirme	34

3.6.	Bilgi Sunumu.....	34
3.7.	Veri Madenciliği Yöntemleri	34
3.7.1.	Sınıflama ve Regresyon	35
3.7.1.1.	Karar Ağaçları	36
3.7.1.2.	Yapay Sinir Ağları.....	37
3.7.1.3.	Destek Vektör Makineleri	38
3.7.1.4.	Bayes Sınıflandırıcılar	39
3.7.1.5.	K-en Yakın Komşu.....	40
3.7.1.6.	Lojistik Regresyon	40
3.7.2.	Zaman Serileri Analizi	41
3.7.3.	Kümeleme	42
3.7.3.1.	K-Means	43
3.7.3.2.	K-Medoids.....	44
3.7.3.3.	Bulanık C-Ortalamalar	44
3.7.3.4.	Kohonen Ağları	45
3.7.3.5.	Hiyerarşik Kümeleme.....	46
3.7.4.	Birliktelik Kuralları ve Ardışık Zamanlı Örüntüler	48
3.7.4.1.	Apriori Algoritması	49
4.	BÖLÜM VERİ MADENCİLİĞİ İLE KÜTÜPHANE KULLANIMI VE DERS BAŞARISI ARASINDAKİ İLİŞKİNİN İNCELENMESİ.....	51
4.1.	Araştırmanın Amacı ve Önemi.....	51
4.2.	Araştırmanın Kapsamı ve Sınırlılıkları	51
4.3.	Araştırma Yöntemi	53
4.4.	Uygulama Süreci	54
4.4.1.	Problemin Tanımlanması	54
4.4.2.	Veri Seçimi.....	55
4.4.3.	Veri Ön İşleme	56
4.4.4.	Veri Seti	59
4.5.	Araştırmanın Bulguları ve Yorumları	62
4.5.1.	Genel İşletme I Dersine Ait Birliktelik Kuralları.....	64

4.5.2.	Genel İşletme II Dersine Ait Birliktelik Kuralları	65
4.5.3.	İktisada Giriş Dersine Ait Birliktelik Kuralları.....	66
4.5.4.	Genel Muhasebe I Dersine Ait Birliktelik Kuralları	67
4.5.5.	Genel Muhasebe II Dersine Ait Birliktelik Kuralları.....	68
4.5.6.	Makro İktisat Dersine Ait Birliktelik Kuralları.....	69
4.5.7.	İşletme Yönetimi Dersine Ait Birliktelik Kuralları	70
4.5.8.	Davranış Bilimleri Dersine Ait Birliktelik Kuralları	71
4.5.9.	Pazarlama İlkeleri Dersine Ait Birliktelik Kuralları	72
4.5.10.	Sosyal Bilim. Araş. Yön. Dersine Ait Birliktelik Kuralları	73
4.5.11.	Örgütsel Davranış Dersine Ait Birliktelik Kuralları	74
4.5.12.	İnsan Kaynakları Dersine Ait Birliktelik Kuralları.....	75
4.5.13.	Stratejik Yön. ve İşletme Politikası Dersine Ait Birliktelik Kuralları .	76
4.5.14.	Maliyet Muhasebesi Dersine Ait Birliktelik Kuralları.....	78
4.5.15.	Finansal Yönetim I Dersine Ait Birliktelik Kuralları	79
4.5.16.	Mali Tablolar Analizi Dersine Ait Birliktelik Kuralları	81
4.5.17.	Muhasebe Uygulamaları Dersine Ait Birliktelik Kuralları.....	82
5.	BÖLÜM SONUÇ VE ÖNERİLER	83
EKLER.....	88
EK 1:	Yayın Etiği Kurulu Kararları	88
EK 2:	LC Sınıflama Sistemi	89
EK 3:	Analize Giren Kitaplar Listesi	90
KAYNAKÇA	92

TABLOLAR LİSTESİ

Tablo 4.1. Zorunlu Ders Toplamları ve Analize Tabi Tutulan Dersler.....	52
Tablo 4.2. Analize ait örnek veri satırı	58
Tablo 4.3. Ders harf notları ve geçme/kalma durumlarının yüzdeler dağılımı.	61
Tablo 4.4. Genel İşletme I Dersine Ait Birliktelik Kuralları	64
Tablo 4.5. Genel İşletme II Dersine Ait Birliktelik Kuralları	65
Tablo 4.6. İktisada Giriş I Dersine Ait Birliktelik Kuralları	66
Tablo 4.7. Genel Muhasebe I Dersine Ait Birliktelik Kuralları	67
Tablo 4.8. Genel Muhasebe II Dersine Ait Birliktelik Kuralları.....	68
Tablo 4.9. Makro İktisat Dersine Ait Birliktelik Kuralları.....	69
Tablo 4.10. İşletme Yönetimi Dersine Ait Birliktelik Kuralları	70
Tablo 4.11. Davranış Bilimleri Dersine Ait Birliktelik Kuralları	71
Tablo 4.12. Pazarlama İlkeleri Dersine Ait Birliktelik Kuralları	72
Tablo 4.13. Sosyal Bilim. Araş. Yön. Dersine Ait Birliktelik Kuralları	73
Tablo 4.14. Örgütsel Davranış Dersine Ait Birliktelik Kuralları	74
Tablo 4.15. İnsan Kaynakları Yönetimi Dersine Ait Birliktelik Kuralları.....	75
Tablo 4.16. Stratejik Yön. ve İşletme Politikası Dersine Ait Birliktelik Kuralları ...	76
Tablo 4.17. Maliyet Muhasebesi Dersine Ait Birliktelik Kuralları.....	78
Tablo 4.18. Finansal Yönetim I Dersine Ait Birliktelik Kuralları	79
Tablo 4.19. Mali Tablolar Analizi Dersine Ait Birliktelik Kuralları	81
Tablo 4.20. Muhasebe Uygulamaları Dersine Ait Birliktelik Kuralları	82

ŞEKİLLER LİSTESİ

Şekil 1.1. Veri madenciliği tarihsel gelişim süreci	7
Şekil 1.2. WEKA programı ara yüzü	12
Şekil 1.3. Veri madenciliğinin diğer disiplinler ile ilişkisi	17
Şekil 3.1. Veri tabanında bilgi keşfi süreci	28
Şekil 3.2. Üç sınıftan oluşan örnek karar ağacı yapısı.....	36
Şekil 3.3. Yapay sinir ağları genel yapısı	38
Şekil 3.4. Birleştirici ve ayırıcı hiyerarşik kümeleme.....	47
Şekil 4.1. Örnek arff dosyası.....	59
Şekil 4.2. Ödünç alınan kitapların LC sınıflama sistemine göre dağılımı	60
Şekil 4.3. H Serisi Kitapların Alt Kümelere Dağılımı	60
Şekil 4.4. Apriori algoritması genel ayarlarına ait ekran görüntüsü	63

KISALTMALAR

TDK	Türk Dil Kurumu
VTYS	Veri Tabanı Yönetim Sistemleri
MS	Microsoft
SQL	Structured Query Language
WEKA	Waikato Environment for Knowledge Analysis
KNIME	Konstanz Information Miner
OLAP	Online Analytical Processing
ÖYS	Öğrenci Yerleştirme Sınavı
İ.Ö.	İkinci Öğretim
Y.L.	Yüksek Lisans
İİBF	İktisadi İdari Bilimler Fakültesi
KDH	Kendini Düzenleyen Haritalama
AGNES	Agglomerative Nesting
DIANA	Divisive Analysis
T.C.	Türkiye Cumhuriyeti
OBS	Öğrenci Bilgi Sistemi
XML	Extensible Markup Language
ARFF	Attribute Relation File Format
CSV	Comma-Separated Variables
LC	Library of Congress
CHAID	Chi Squared Automatic Interaction Detector
QUEST	Quick Unbiased Efficient Statistical Tree
CART	Classification and Regression Tree
IBM	International Business Machines
EVM	Eğitimsel Veri Madenciliği
CRISP-DM	Cross Industry Standard Process Model for Data Mining

GİRİŞ

Günümüz bilişim teknolojilerindeki gelişmeler birçok sektörde verinin anlık olarak veri tabanlarında kolayca depolanmasına olanak tanımaktadır. Eğitimden sağlığa, pazarlamadan ekonomiye kadar birçok alanda depolanan veriler zaman içinde artmakta ve birer veri yığınına dönüşmektedir. Veri tabanlarında depolanan veri yığınları analiz edilmediği sürece bir anlam ifade etmemekte, ayrıca bu verilerin manüel olarak analiz edilmesi oldukça zahmetli ve zaman alıcı bir iş haline gelmektedir. Bu duruma çözüm olarak veri madenciliği kavramı ortaya çıkmış ve zamanla çeşitli veri madenciliği teknikleri geliştirilmiştir.

Veri içerisinde bulunan anlamlı bağlantı ve kuralları elde etmek için büyük ölçekli veriyi güçlü tekniklerle irdeleyen veri madenciliği, akademik alanda ve birçok sektörde yoğun ilgi gören bir veri analiz tekniğidir (Albayrak, 2017). Geleneksel veri analiz yöntemleri ile gelişmiş algoritmaları harmanlayan veri madenciliği (Ceylan vd., 2017), veriyi analiz ederken kullanıcılara farklı algoritmalar kullanma imkânı tanır. Veri madenciliği istatistik, yapay zekâ, makine öğrenmesi vb. alanlarla işbirliği içindedir. Böylelikle veriden gizli, anlamlı, kullanışlı, değerli bilgiler ve ilişkiler elde edilebilir.

Bu çalışmada, İİBF İşletme bölümü öğrencilerinin 2007 - 2018 yılları arasındaki güz ve bahar akademik dönemlerinde kütüphaneden ödünç almış oldukları zorunlu ders içerikli kitaplar ile yine 2007 – 2018 yılları arasındaki güz ve bahar akademik dönemlerindeki zorunlu derslerden almış oldukları harf notları ve başarı durumları arasındaki ilişki analiz edilmiştir. Analiz veri madenciliğinin tanımlayıcı yöntemlerinden biri olan birliktelik analizine ait Apriori algoritması ile gerçekleştirilmiştir.

Analiz için kullanılan yazılım açık kaynak kodlu bir yazılım olan WEKA veri madenciliği yazılımıdır. Analiz sonucunda ders içerikli kitap kullanımı ve ders başarısına ait birliktelik kuralları elde edilmiştir. Bu sayede eğitim ve kütüphane alanında hizmet veren uzmanlara karar verme aşamasında alacakları kararların

kalitesini arttırmaya yardımcı bilgiler sunulmuştur. Literatürde kütüphane kullanımı ve öğrenci notlarının analiz edildiği çok az çalışma bulunmaktadır. Bu yönüyle çalışmanın literatüre katkı sağlayacağı düşünülmektedir. Ayrıca çalışma kütüphane ve öğrenci notlarını tek bir platformda analiz edecek bir otomasyon sisteminin oluşturulabilmesi açısından örnek niteliğindedir.

Çalışmanın birinci bölümünde veri, veri tabanı, veri tabanı yönetim sistemleri ve veri madenciliği genel tanımları yapılmıştır. Veri madenciliğinin gelişimi, günümüzdeki durumu, gelecek öngörüsü ve önemi üzerinde durulmuştur. Ayrıca Veri madenciliğinde kullanılan yazılımlar, veri madenciliğinin farklı disiplinlerle olan ilişkisi ve veri madenciliği uygulama alanları hakkında genel bilgilere değinilmiştir.

Çalışmanın ikinci bölümünde veri madenciliği yazılımlarından biri olan WEKA'nın Apriori algortiması ve diğer algoritmaları ile gerçekleştirilmiş ulusal ve uluslar arası veri madenciliği çalışmalarına ait ampirik literatüre yer verilmiştir.

Çalışmanın üçüncü bölümünde ise veri tabanından bilgi keşfi süreçleri olan problemin tanımlanması, veri seçme, veri ön işleme ve veri madenciliği aşaması hakkında açıklayıcı bilgiler bulunmaktadır. Ayrıca veri madenciliği yöntemlerinden olan tanımlayıcı ve tahmin edici yöntemlere ait bilgiler ve bu yöntemlerin işleyişleri hakkında genel bilgilere değinilmiştir.

Çalışmanın dördüncü bölümünde araştırmanın amacı, önemi, kapsamı, sınırlılıkları, yöntemi, süreci, çalışmada kullanılan veri seti hakkında bilgiler verilmiştir ve veriyi ön işleme aşamaları üzerinde durulmuştur. Ayrıca zorunlu derslere ait birliktelik kurallı analizi sonucunda elde edilen kurallar, kurallara ait açıklamalar ve yorumları bulunmaktadır.

Çalışmanın son bölümünde ise sonuçlar tartışılmıştır ve gelecek çalışmalar için önerilere değinilmiştir.

1. BÖLÜM VERİ MADENCİLİĞİ

Bu bölümde veri, veri tabanı, veri tabanı yönetim sistemleri ve geniş çerçevede veri madenciliği tanımlanmaktadır.

1.1. Veri

Veri, veri madenciliğinin temel yapı taşıdır. Veri olmadan veri madenciliği yapılamaz bu sebeple veriyi tanımlamak önemlidir.

TDK (2018) veriyi "bir araştırmanın, bir tartışmanın, bir muhakemenin temeli olan ana öge, sonuç çıkarmak, çıkarsama yapmak, ya da bir incelemeyi sürdürmek için gerekli olaylara, ilişkilere ve sayısal ham bilgilere verilen ad" olarak tanımlamıştır.

Veri bilginin ham maddesi, bilgiyi oluşturan en küçük parça, enformasyon oluşumundaki yapıtaşdır (Atlı, 2014, s.632).

Genel anlamda veri bağımsız ve soyut gerçeklerin, ölçümlerin, sembol ve sayısal karakterlerin bir dizisidir. Veri işlenmeden tek başına bir anlam ifade etmez. Bir verinin anlamlandırılması için analiz edilerek yorumlanması gerekir (Yılmaz, 2013, s.243). Veri madenciliğinin ana ögesi olan verinin analiz edilebilmesi için ise bilişim teknolojileri vasıtasıyla kayıt altına alınması önemlidir.

1.2. Veri Tabanı

En genel tanımıyla veri tabanı, kullanım amacına uygun olarak depolanmış veri topluluğudur (Vural ve Sağiroğlu, 2010, s.73). Birbiri ile ilişkili verinin tutulduğu, kullanım amacına uygun biçimde düzenlenmiş veri topluluğunun fiziksel ve mantıksal olarak tanımının olduğu depolardır. Bilişim ortamlarındaki formlardan gelen veri geçicidir. Mevcut sayfa kapatıldığı zaman veride kayıp olur, bu sebeple veriyi ileride kullanabilmek için kayıt altına almak gerekir. Bir dosyaya veya belgeye yapılan kayıtlara okuma, arama, güncelleme, silme vb. işlemlerinin yapılması oldukça zor ve kullanışsızdır. Veri tabanları verilerin belli bir düzende kayıt edildiği

depolardır. Veri tabanına yapılan kayıtların yönetilmesi (sorgulama, silme, güncelleme vb.) dosyalama sistemine göre daha kolaydır.

1.3. Veri Tabanı Yönetim Sistemleri (VTYS)

Bir veri tabanına veri eklenebilir veya silinebilir. Bu tip işlemlerin yapılması için VTYS'ye ihtiyaç vardır. VTYS'leri veri tabanını yaratmak, tanımlamak, kullanmak, değiştirmek vb. işlemlerin yapılması amacıyla hazırlanmış yazılımlardır. Yeni bir veritabanı oluşturmak, geliştirmek, düzenlemek, bakımını yapmak gibi karmaşık işlemlerin yapıldığı yazılımlar VTYS olarak adlandırılmaktadır (Vural ve Sağıroğlu, 2010, s.73).

En bilinen VTYS yazılımları (Kaplan vd., 2017; Abrar ve Wahyudi, 2016; Yağcı vd., 2015; Deperlioğlu ve Sarpkaya, 2009):

- MS (Microsoft) SQL Server,
- My SQL,
- Oracle,
- Access'dir.

Veri madenciliğinin gerçekleştirilebilmesi için verinin kayıt altına alınması gerekir. Bu noktada VTYS yazılımları önemlidir. VTYS ile belli bir düzene göre kayıt altına alınan veriler, veri madenciliği uygulamasının en temel ögesi olan veriyi kayıt altına alır.

1.4. Veri Madenciliğinin Tanımı

Veri madenciliğinin günümüzde pek çok tanımı yapılmaktadır. Genel anlamda düzensiz biçimde depolanan büyük ölçekli ham verinin analiz edilerek, bu veriden değerli örüntülerin ve anlamlı ilişkisel bilgilerin ortaya çıkartılması biçiminde tanımlamak mümkündür.

Veri madenciliğinin literatürde bulunan bazı tanımları aşağıdaki gibidir:

Alfonso vd. (2017) veri madenciliğini; ‘geniş veri kümelerinin altında yatan bilgi yapısını ortaya çıkartmak için karmaşık veri analiz araçlarını kullanan ve büyük miktardaki veriden bilgiye ulaşmak için bir dizi hesaplama teknik ve yöntemler kümesini içinde barındıran bir veri analiz tekniğidir’ biçiminde tanımlamıştır.

Roiger (2017)'ye göre veri madenciliği, ‘verideki ilginç kalıpları bulma veya gelecekte oluşabilecek durumları tahmin etme işlemi’dir.

Moslehi vd. (2017) ise veri madenciliğini; ‘veri tabanları kullanılarak depolanan büyük miktardaki verinin istatistik, yapay zekâ, makine öğrenimi ve veri görselleştirme gibi analiz teknikleri vasıtasıyla veri içerisinde açık olmayan; ancak kullanışlı bilgileri bulma işi, işletmelerin gelecekte kullanmaları ve öngörülerde bulunmalarını sağlamak için veri içerisinde bulunan gizli ilişkileri ortaya çıkartma veya kazma işlemidir’ biçiminde tanımlamışlardır.

Zahedi ve Zare-Mirakabad (2014) göre ise veri madenciliği ‘veri tabanlarında örtük olarak var olan bilgilerin ortaya çıkarılması, yani veri öbekleri içerisinde bulunan ilişki ve örüntüleri keşfetmek için veriyi inceleme ve analiz etme süreci’dir.

Argüden ve Erşahin (2008) veri madenciliğini; ‘doğru kararlar alabilmek için büyük miktardaki karmaşık veri yığınları arasından faydalı olabilecek, anlamlı ve uygulanabilir bilgileri bulmak’ olarak tanımlamışlardır.

Veri madenciliği büyük veri öbekleri içerisinde anlamlı ve kullanılabilir bilgileri açığa çıkartmak için, modern teknolojinin, istatistiksel ve matematiksel tekniklerini kullanma işlemidir (Tozak vd., 2017, s.139).

Bir diğer tanıma göre veri madenciliği, yığın halindeki ham veriler içerisinde bulunan örüntüleri tespit etmek, veriler arasındaki ilişkileri araştırmak ve işlevsel bilgiye dönüştürmek için kullanılan veri işleme tekniğidir (Bircan ve Çam, 2016, s.86).

Başka bir tanıma göre ise veri madenciliği, hacimsel olarak büyük veri yığınları arasından bilgisayar programları aracılığıyla akıllı algoritmalar kullanarak,

gelecekle ilgili tahminler yapılmasında etkili olan ilişkilerin keşfedilmesidir (Santur vd., 2016, s.141).

Veri toplama ve depolama teknolojilerindeki gelişmeler, kurumların büyük miktarlarda veri depolamasına olanak tanımıştır. Fakat bu depolanan veri çok büyük miktarlarda olduğu için anlamlı bilgilerin elde edilmesi zordur. Geleneksel veri analiz teknikleri büyük miktardaki veriyi çözümlenmekte yetersizdir. Veri madenciliği bu soruna çözüm üreten bir tekniktir. Veri madenciliği geleneksel veri analiz teknikleri ile geliştirilmiş algoritmaları birleştiren bir teknolojidir (Ceylan vd., 2017, s.477).

Bu tanımlardan da anlaşıldığı gibi depolanan veri tek başına bir anlam ifade etmemektedir. Elde bulunan veriyi analiz ederek gelecekte ortaya çıkabilecek gizli bir bilgiyi tahmin etmek veya veri içinde var olan ancak henüz bilinmeyen bir durumu ortaya koymak veri madenciliği teknikleri ile mümkün olmaktadır. Bu sebeple veri madenciliği uygulamaları kurumların karar merkezleri açısından önemlidir.

1.5. Veri Madenciliğinin Tarihçesi

İlk bilgisayarlar 1950'li yıllarda sayım için kullanılmıştır. 1960'lı (Liao vd. 2012, s.11303) yıllara gelindiğinde ise veri tabanı ve depolama olgusu teknoloji dünyasında yer edinmiştir. 60'lı yılların sonunda ise bilim insanları basit öğrenmeli bilgisayarları geliştirmeye başlamıştır (Savaş vd., 2012, s.4).

1970'lerde uygulanmaya başlanan ilişkisel veri tabanı yönetim sistemleri uzmanlara, basit kurallara dayanan uzman sistemler ve basit kurallı makine öğrenimi geliştirmelerine zemin hazırlamıştır.

1980'li yıllarda veri tabanı yönetim sistemlerindeki artan kullanım oranları büyük miktarda veri depolanmasına olanak tanımıştır; ancak oluşan bu ham veriyi yorumlama alanındaki yetersizlikler, verinin nasıl yararlı kullanılabileceği problemini ortaya çıkartmıştır. Bu bağlamda 1980'li yılların sonuna kadar verinin nasıl

toplanacağı ve depolanacağı ile ilgilenilirken 1990'lı yıllardan itibaren veri analizi önem kazanmıştır (Ertuğrul vd., 2013, s.97).

90'lı yıllarda ise veri hacmi üzerine akademik çalışmalar yapılmaya, veri madenciliği ve makine öğrenimi algoritmaları geliştirilmeye başlanmıştır (Amato vd., 2018, s.287). 1989 yılında Piatetsky-Shapiro tarafından ilk kez gerçekleştirilen veri tabanından bilgi keşfi çalışma grubu toplantısında 'Veri tabanından bilgi keşfi' kavramı kullanılmıştır. 1991 yılında veri madenciliği ile ilgili temel tanım ve kavramlar ortaya çıkmıştır. Veri madenciliği terimi ilk kez; istatistikçiler, veri tabanı araştırmacıları, bilgi sistem yöneticileri ve işletme toplulukları tarafından kullanılmıştır. Bu alanda hızlanan sürecin akabinde 1992 yılında ilk veri madenciliği yazılımı gerçekleştirilmiştir (Alagöz vd., 2014, s.3; Albayrak ve Yılmaz, 2009, s.32; Savaş vd., 2012, s.5).

2000'li yıllara gelindiğinde ise veri madenciliği gelişimi süreklilik arz etmiştir ve birçok alanda da kullanılmaya başlanmıştır. Kullanım sonucunda elde edilen faydalar bu alana olan ilgiyi arttırmıştır.

Bu bölümde anlatılan veri madenciliğinin tarihsel gelişim süreci Şekil 1.1.'de görsel olarak özetlenmektedir.

1950'ler	• İlk Bilgisayarların Geliştirilmesi (Sayım İçin)
1960'lar	• Basit Öğrenmeli Bilgisayarların Geliştirilmesi • Veri Tabanları ve Verilerin Depolaması
1970'ler	• İlişkisel Veri Tabanı Yönetim Sistemleri • Basit Kurallı Makine Öğrenimi
1980'ler	• Artan Veri Tabanı Yığınları • Verilerden Nasıl Yararlanılacağı Probleminin Ortaya Çıkması
1990'lar	• Veri Madenciliği Kavramının Ortaya Çıkması • İlk Veri Madenciliği Yazılımlarının Uygulanması
2000'ler	• Veri Madenciliğine Artan İlgi ve Kullanım Alanlarındaki Yaygınlaşma

Şekil 1.1. Veri madenciliği tarihsel gelişim süreci

1.6. Veri Madenciliğinin Günümüzdeki Durumu

Veri madenciliği kavramı, onlarca yıl öncesinde ortaya çıkmış olmasına karşın kullanımı - her işlemin dijital cihazlar ile kayıt edilebildiği - son yıllarda yaygınlaşmıştır (Silahtaroglu ve Ergül, 2016, s.103-104). Günümüzde dünya üzerinde oluşan veri miktarının her geçen gün arttığı görülmektedir. Bilişim teknolojilerindeki gelişim ve teknolojik cihazların bellek kapasitelerindeki artış daha çok veriyi saklamaya olanak tanımaktadır. Bu sebeple artan verinin analiz edilerek işlenmesi karar merkezleri için önemli hale gelmiştir (Albayrak, 2017, s.751-752). Veriler yalnızca belli bir amaç doğrultusunda işlenirse anlamlıdır. Bu amaç doğrultusunda günümüzde en çok kabul gören yöntem veri madenciliğidir (Çeşmeli vd., 2015, s.37). Veri madenciliği, veri tabanlarında depolanan veriden, yararlı ve aralarında ilişki olabilecek veriyi keşfederek, bu verinin anlaşılır ve kullanılabilir bilgilere dönüştürülmesine olanak tanıyan yöntemler topluluğudur. Veri madenciliği veri yığını analizinde en önemli yöntemlerden bir tanesidir (Doğan ve Arslan Tekin, 2016, s.26)

Veri madenciliği günümüzde hızlı gelişen ve önemi git gide artan bir yöntemdir (Yılmaz ve Şeker, 2016, s.10) ve birçok farklı alanda başarı ile kullanılmaktadır (Can vd., 2012, s.3). Bu kullanım alanları çeşitlilik göstermektedir. Pazarlama, finans, üretim, bankacılık, sağlık, müşteri ilişkileri, eğitim vb. gibi birçok alanda uygulanabilir olması dolayısıyla veri madenciliği, veri tabanı araştırma ve kullanıcılarının dikkatini son dönemlerde daha çok çekmektedir (Çalış ve Baynal, 2016, s.18). Bu sebeple veri analizi için geliştirilen veri madenciliği programlarının sayısı da günden güne artış göstermektedir (Doğan, 2017, s.77).

1.7. Veri Madenciliğinin Geleceği

Veri madenciliği yeni ve gelecek vaat eden bir teknolojidir. Dünya üzerindeki veri miktarları her yıl daha da büyümektedir. Yakın geçmişte terabayte ile ölçülen bir verinin büyük miktarda bir veri olduğu düşünülürken artık günümüzde petabyte boyutlu bir verinin daha büyük olduğu kabul edilmektedir. Ancak bunun da ötesinde

exebayte ve zetabyte veri ölçü birimleri göz önünde bulundurulmaya başlanmıştır (Doğan, 2014, s.6).

Sosyal medyanın yaygınlaşması ve insanların mobil cihazlar sayesinde dijital dünyaya daha çok dâhil olması, büyük miktarda verinin dijital olarak depolanmasını sağlamıştır. Kullandığımız birçok mobil uygulama vasıtasıyla depolanan bu veri, dinlediğimiz müzikten sevdiğimiz restorana, aldığımız ayakkabıdan gittiğimiz şehirlere kadar birçok konuyu içerebilmektedir. Bu verilerin kayıt altına alınması, gelişen mobil uygulamalar ve hızlanan internet teknolojisi sayesinde çok kolaylaşmıştır ve bu verilerin daha da artacağı ön görülmektedir.

Amerika birleşik devletlerinde 'IDC Analyze the Future' tarafından yapılan dijital evren çalışmalarına göre dünya üzerindeki verilerin, 2012-2020 yılları arasında 898 exebayttan 6,6 zetabayta çıkacağı veya her yıl verinin %25'ten fazla büyüyeceği öngörülmektedir. Yani bu durum verinin her 3 yılda bir 2'ye katlanacağı anlamına gelmektedir (Gantz vd, 2012, s.1).

Dünya çapında toplanan bu veri, veri yığınlarına dönüşerek 'büyük veri' (big data) kavramını oluşturmakta ve veri madenciliği sürecini etkilemektedir. Büyük veri, tipik veritabanı yazılım araçlarının yakalama, depolama, yönetme ve analiz etme yeteneğinin ötesinde olan (Brown vd., 2011, s.1), analiz ve görselleştirilmesinin güç olduğu, çok karmaşık yapıya sahip (Sağiroğlu ve Sinanç, 2013, s.42) veri kümelerini ifade eder. Son yıllarda, öğrenme ortamları tarafından (facebook, Youtube, Twitter, cep telefonu konum verileri vb.) üretilen veriler akabinde büyük veri teknolojilerine ve bunları ele alacak araçlara duyulan gereksinimi arttırmaya başlamıştır (Sin ve Muthu, 2015, s.1035). Bu verilerin anlamlı ve kullanılabilir veri haline getirilmesi için veri madenciliğinin çeşitli yöntemleri kullanılmakta ve böylelikle 'büyük veri madenciliği' kavramı oluşmaktadır.

Büyük veri madenciliği, büyük veri kümelerinden veya veri akışlarından yararlı bilgiler çıkarma yeteneğidir. Bu tür verilerin hacim, değişkenlik ve hızından dolayı yeni madencilik teknikleri ise gerekli olmaktadır (Fan ve Bifet, 2013, s.1). Bu

durum ortaya koymaktadır ki veri toplama ve veri depolama teknolojilerinin gelişmesiyle yeni veri madenciliği teknik ve kavramlarının oluşması kaçınılmazdır. Ayrıca gelecekte oluşması ön görülen veri büyüklükleri ve verinin toplanma hızları düşünüldüğünde; birçok kaynaktan depolanan ve dinamik olarak çoğalan heterojen verinin analizi için günümüzde kullanılan veri madenciliği tekniklerinin yetersiz kalacağı, daha hızlı ve akıllı algoritmaların geliştirilmesi gerekliliği öngörülebilir.

1.8. Veri Madenciliğinin Önemi

İçinde bulunulan bilişim çağı sayesinde veri toplama araçlarında ve veri depolama teknolojilerinde olağan üstü gelişmeler yaşanmaktadır. Bu gelişim daha fazla ve detaylı veri toplanmasına olanak tanımaktadır. Günümüzde sağlık, finans, eğitim, lojistik, bankacılık, endüstri, haberleşme, ticaret, tıp, kütüphanecilik vb. birçok alanda bilişim teknolojileri yaygın biçimde kullanılmakta ve bu alanlarla ilgili kayıtlar veri tabanlarında depolanmaktadır. Ancak depolanan bu veriler birer veri yığınına dönüşmekle birlikte, bu verilerde dezenformasyon (bilgiyi çarpıtma) ve bilgi kirliliği yüksek olabilmektedir. Teknolojinin sürekli olarak ilerlediği ve kendini yenilediği bilişim çağında doğru bilgiye ulaşmak önemlidir; ancak dezenformasyon ve bilgi kirliliği doğru bilgiye ulaşmayı zorlaştırmaktadır.

Veri bilginin ham halidir ve bir verinin bilgiye dönüşmesi için işlenerek (toplama, birleştirme, temizleme, dönüştürme, analiz, yorumlama vb.) anlamlandırılması gerekir. Kurumlar veriyi etkin biçimde işleyerek yönettikleri zaman, dezenformasyondan uzak, kaliteli bilgiye ulaşım doğru kararlar alabilirler (Dinçerden, 2017, s.137).

Veri tabanlarındaki veri artışı, bilgi ve bilgiyi akıllıca kullanan teknolojilerin geliştirilmesi ihtiyacını doğurmuştur. Bu nedenle, veri madenciliği giderek daha önemli bir araştırma alanı haline gelmiştir (Liao vd., 2012, s.11303).

Ayrıca çeşitli alanlarda bilgi teknolojilerinin kullanımı yeni veri biçimleri (video, ses kaydı, resim, belge gibi) ortaya çıkarmıştır ve çeşitli türde büyük miktarda veri depolanmasına olanak tanımıştır. Farklı alanlardan toplanan veriyi

kullanarak daha iyi ve doğru karar vermek amacıyla bilgi çıkarımı yapılması gereklidir. Veri madenciliğinin temel işlevi, veri kalıplarını keşfetmek ve örüntüler çıkartmak için çeşitli yöntem ve algoritmaları uygulamaktır. Veri madenciliği karar vermede yardımcı gizli kalıpları ve ilişkileri keşfetmek adına veri yığınlarını inceler (Ahmed ve Elaraby, 2014, s.43-44). Çünkü büyük miktardaki veriyi manüel olarak işlemek veri fazlalığı, çeşitliliği ve kirliliği nedeniyle neredeyse imkânsızdır. Klasik istatistiksel yöntemler büyük veri kümelerini işlemede yetersiz kalabilmektedir. Bu nedenle büyük ölçekli veri kümelerini işleyebilmek için daha özel yöntemler gerekir. Klasik yöntemlerin aksine veri madenciliği araştırmacıya veri yığınlarını analiz etmede kolaylık sağlar (Alan, 2012, s.165).

Veri madenciliği araştırmacılara veri kalıplarını keşfetmek için daha akıllı ve çeşitli veri işleme algoritmaları sunmaktadır (Dangare ve Apte, 2012, s.44). Verileri bilgiye dönüştürürken hangi algoritmaların kullanılacağı önemlidir. Araştırma amacına uygun olarak toplanan verilerin yine araştırma amacına uygun tekniklerle analiz edilmesi gerekir. Klasik istatistiksel yöntemlerde analiz teknikleri sınırlı sayıda olmasına karşın veri madenciliğinin kullandığı teknikler çeşitlilik göstermektedir.

1.9. Veri Madenciliğinde Kullanılan Yazılımlar

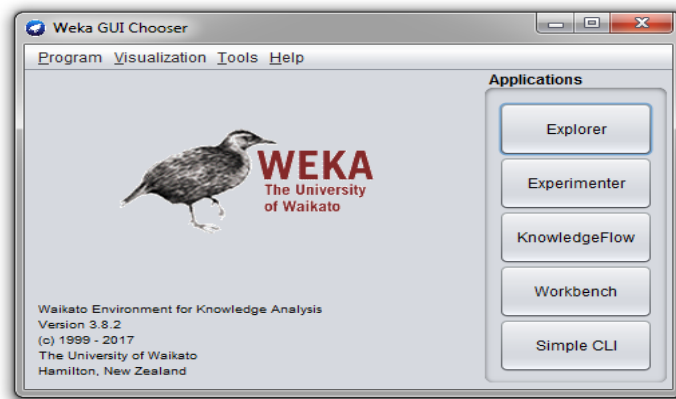
Veri madenciliği algoritmalarının uygulanması için güçlü yazılımlara ihtiyaç duyulmaktadır (Mikut ve Reischl, 2011, s.431) Veri madenciliği algoritmalarında başarıya ulaşmak için çok sayıda veri madenciliği yazılımı geliştirilmiştir. Bu yazılımların bazıları ücretli bazıları ise ücretsiz olarak kullanıcılara sunulmaktadır (Doğan, 2017, s.88).

Veri madenciliği uygulamaları için geliştirilen ve yaygın olarak kullanılan bazı yazılımlar şunlardır: WEKA, RapidMiner, R, Orange, KNIME açık kaynak kodlu ve ücretsiz, SPSS Clementine, SAS Enterprise Miner, MS SQL Server Analysis Services (Dener vd., 2009, s.788) ise kapalı kaynak kodlu (ticari) ve ücretli yazılımlardır. Bu yazılımlar ilerleyen paragraflarda ayrıntılı olarak açıklanmıştır.

1.9.1. WEKA

WEKA (Waikato Environment for Knowledge Analysis), Yeni Zelanda Waikato Üniversitesi'nde (Tamayo vd., 2018, s.76) Java programlama kullanılarak geliştirilmiş, 1996 yılında ilk resmi sürümü yayınlanmış, tüm modern bilgisayarlarda çalışabilen açık kaynak kodlu bir yazılımdır. Kullanıcı dostu bir ara yüze sahiptir. Veri analizinin tahmin edici modelleri için görselleştirme araçlarını ve algoritmalar topluluğunu içinde barındırır. WEKA, basit makine öğrenme, veri ön işleme, kümeleme, sınıflandırma, birliktelik analizi, ilişkilendirme, görselleştirme gibi çeşitli standart veri madenciliği görevlerinin hazır olarak geldiği bir veri madenciliği yazılımıdır (Wu vd., 2018, s.102; Aher ve Lobo, 2011, s.23).

Bu yazılım SQL (Structured Query Language) veri tabanlarına Java Database Connectivity kullanarak erişir. Dosya uzantısı olarak .arff (Attribute Relationship File Format) kullanılmaktadır. Bu uzantı WEKA'ya özeldir (Kaya ve Özel, 2014, s.49-50). WEKA eğitim, tarım, sağlık, endüstri ve birçok çeşitli alanda uygulanan, sınıflandırma (C4.5, J48, SVM, ID3, Naive Bayes) (Abidin vd., 2017, s.1223), kümeleme (Canopy, Cobweb, EM, Farthest First, Filtered Clusterer, Hierarchical Clusterer, Make Density Based Clustere, Simple K-Means), birliktelik analizi (Apriori) algoritmasını içinde barındıran kullanımı yaygın veri madenciliği araçlarındadır. WEKA veri madenciliği yazılımı çalıştırıldığında Şekil 1.2.'deki gibi bir ara yüz ekrana gelmektedir.



Şekil 1.2. WEKA programı ara yüzü

WEKA'da analiz edilecek veriyi sisteme yüklemek için Şekil 1.2.'deki Explorer butonuna tıklanır. Ardından ekrana gelen preprocess sekmesinden Open file butonuna tıklayarak analiz edilecek veri dosyası sisteme yüklenir. Eklenen veri setindeki bilgilere göre kaç adet attribute (özellik) ve satır olduğu Current relation bölümünden görülebilmektedir. Ayrıca her attribute ait istatistiksel bilgi ve veri tiplerine ait bilgiler Selectes attribute bölümünde görüntülenir. Veri dosyası (arff, csv) programa yüklendikten sonra WEKA ile veri ön işleme yapılabilir. Ön işlem den geçirilmiş veri yazılım içerisinde hazır olarak bulunan algoritmalar ile analiz edilir.

1.9.2. RapidMiner

RapidMiner, Dortmund Teknoloji Üniversitesinin Yapay Zeka biriminde Ingo Mierswa, Ralf Klinkenberg ve Simon Fischer tarafından geliştirilmiş açık kaynak kodlu bir yazılımdır (Kaya ve Özel, 2014, s.50). İş analizi, tahmin edici analiz, metin madenciliği vb. konularla ilgilenen makine öğrenimi üzerine kurulu bir araçtır. Oluşturulan modellerin değerlendirilmesi için çapraz doğrulama ve bağımsız doğrulama kümelerini kullanır (Baruah ve Choudhary, 2017, s.270).

RapidMiner kullanımını kolay kullanıcı dostu bir ara yüze sahiptir. Ayrıca açık kaynak kodlu yazılım olması dolayısıyla geliştiriciler temel yazılıma ek işlevsellik katabilir (Prekopcsak vd., 2013, s.4). Java programlama dili ile oluşturulan bu yazılım, kullanıcının kod yazdirmasını gerektirmeden hazır veri analiz süreçleri olan veri yükleme, veri ön işleme, görselleştirme, öngörülmesi analitik, istatistiksel modelleme, değerlendirme, dağıtım gibi makine öğrenme prosedürleri sağlar. Excel, Access, Oracle, IBM (International Business Machines), Db2, MS SQL, Sybase vb. veri tabanlarından veri çekebilen, çok katmanlı veri görünümü konseptine sahip yüksek boyutlu grafik çizimleri yapabilen bir veri madenciliği aracıdır (Gupta ve Malhotra, 2015, s.24; Ristoski vd, 2015, s.142).

1.9.3. R

R, Auckland Üniversitesi İstatistik bölümü bilim adamlarından Robert Gentleman ve Ross Ihaka tarafından, çok çeşitli istatistiksel hesaplama ve grafik

oluşturmak için geliştirilen, açık kaynak kodlu veri madenciliği yazılımıdır. (Kaya ve Özel, 2014, s.49; Shmueli vd., 2017, s.11). R, hem akademik çalışmalarda hem de endüstride yaygın olarak kullanılan, açık kaynak kodlu yazılımın tüm avantajlarına sahip, çok kullanışlı bir yazılımdır (Olson ve Wu, 2017, s.119). Bu yazılım ile uygulanabilen bazı veri madenciliği görevleri şunlardır (Zhao, 2013, s.2):

- Makine Öğrenimi ve İstatistiksel Öğrenme,
- Küme Analizi ve Sonlu Karışım Modelleri,
- Zaman Serisi Analizi,
- Çok Değişkenli İstatistik,
- Mekânsal Verilerin Analizi.

1.9.4. Orange

Orange, Makine Öğrenmesi tabanlı, açık kaynak kodlu bir Veri Madenciliği yazılımıdır. Slovenya Ljubljana Üniversitesi'nde Bilgisayar Fakültesi, Bilgi ve Bilişim Bilimleri Bioinformatics Laboratuvarında 'Python' ve 'C++' dillerinde geliştirilmektedir. Keşifsel veri analizi için kullanılan bir programdır. Aynı zamanda bir Python Kütüphanesi olarak da kullanılabilir. Basit veri ön işleme, görselleştirme, öğrenme algoritmalarının ampirik değerlendirilmesi ve tahmini modelleme, model değerlendirme bileşenlerine sahiptir (Naik ve Samant, 2016, s.664; Kranjc vd., 2017, s.40). Bu bileşenlere 'widget' adı verilmektedir (Patel, 2015, s.209). Ayrıca metin madenciliği ve biyoinformatik eklentileri de mevcuttur (Yıldız ve Şeker, 2016, s.17).

1.9.5. KNIME

KNIME (Konstanz Information Miner), (Melagraki ve Afantitis, 2013, s.9) Eclipse platformunu temel alan genel amaçlı bir veri madenciliği yazılımıdır. İlk kez 2004 yılında Konstanz Üniversitesi tarafından geliştirilmeye başlanan bu yazılımın ilk sürümü 2006 yılında piyasaya sürülmüştür. KNIME açık kaynak kodlu bir yazılım olmasına karşın ticari lisans ile daha üst seviyeye yükseltilebilen bir yazılımdır (Jovic vd., 2014, s.1117).

KNIME, yeni algoritmaların, veri bağlantılarının ve görselleştirme yöntemlerinin kolay ilişkilendirilmesini sağlayan modüler yapıda bir yazılımdır. Yazılım, iş akışında verileri değiştirmek ve işlemek için kilit birim olarak adlandırılan düğümleri kullanır. Bu düğümler grafiksel bir ara yüz kullanılarak birbirine bağlanır. Bu ara yüz üzerinden farklı yöntemler (veri yükleme, veri ön işleme, model oluşturma, veri görselleştirme) seçilebilir, kullanıcı dostu sürükle bırak yöntemi ile öğeler (ilişki düğümleri, giriş bağlantıları, çıkış bağlantıları) oluşturulabilir ve iş akışı kolayca uygulanabilir. KNIME ile veri analizi, tahmini modelleme ve değerlendirme, yapısal özellik analizi, kural tabanlı tarama vb. veri işleme teknikleri uygulanabilir (O'Hogan ve Kell, 2015, s.387-391; Steinmetz vd., 2015, s.173).

1.9.6. IBM SPSS Modeler (SPSS Clementine)

SPSS Clementine olarak da bilinen IBM SPSS Modeler yazılımı veri madenciliği uygulamalarında en çok tercih edilen yazılımlardan bir tanesidir. IBM firması tarafından geliştirilmiş bu yazılım CRISP-DM (Cross Industry Standard Process Model for Data Mining) modeli çerçevesinde tahmin edici modeller geliştirir. Kullanıcıların programlama kodu yazmalarına gerek olmadığı, içinde veri madenciliği algoritmaları bulunan, görsel ara yüze sahip modüler bir veri madenciliği yazılımıdır (Özseven ve Ersöz, 2016, s.86-87; Aksoy ve Narlı, 2015, s.150).

Bu yazılım veri toplama, veri ön işleme, dönüştürme, model oluşturma, modeli değerlendirme ve örüntü oluşturma gibi veri madenciliği süreçlerini desteklemektedir (Lu vd., 2013, s.4). Farklı veri kaynaklarına ulaşabilen yazılım hızlı model oluşturan ve bu modelleri karşılaştıran kullanışlı bir yapıdadır (Narlı vd., 2014, s.45). Veriyi ön işleme, görselleştirme teknikleri, uygulama şablonları ve akıllı algoritmaları ile geniş bir veri madenciliği yelpazesi sunmaktadır (Al Ghoson, 2010, s.64).

1.9.7. SAS Enterprise Miner

SAS Enterprise Miner, SAS Corporation tarafından üretilen SAS Analytics'in tahmini ve betimleyici modelleme, metin inceleme, tahmin etme, optimizasyon,

simülasyon ve deneysel tasarım için entegre edilmiş (Al Ghoson, 2010, s.62), çok büyük miktardaki verinin analizinde kullanılan, son derece kesin tahminler ve açıklayıcı modeller oluşturan bir veri madenciliği yazılımıdır. Veri madenciliğinin veri ön işleme, ilişki oluşturma, tahmin etme, model seçimi, veri modelleme ve geliştirme gibi yöntemlerini içerir.

Bu yazılım zaman serileri, kümeleme analizi (Nakkeeran vd., 2012, s.1), karar ağaçları, sınıflandırma (Piwczyński vd., 2013, s.19), doğrusal ve lojistik regresyon, yapay sinir ağları gibi teknikleri kullanır.

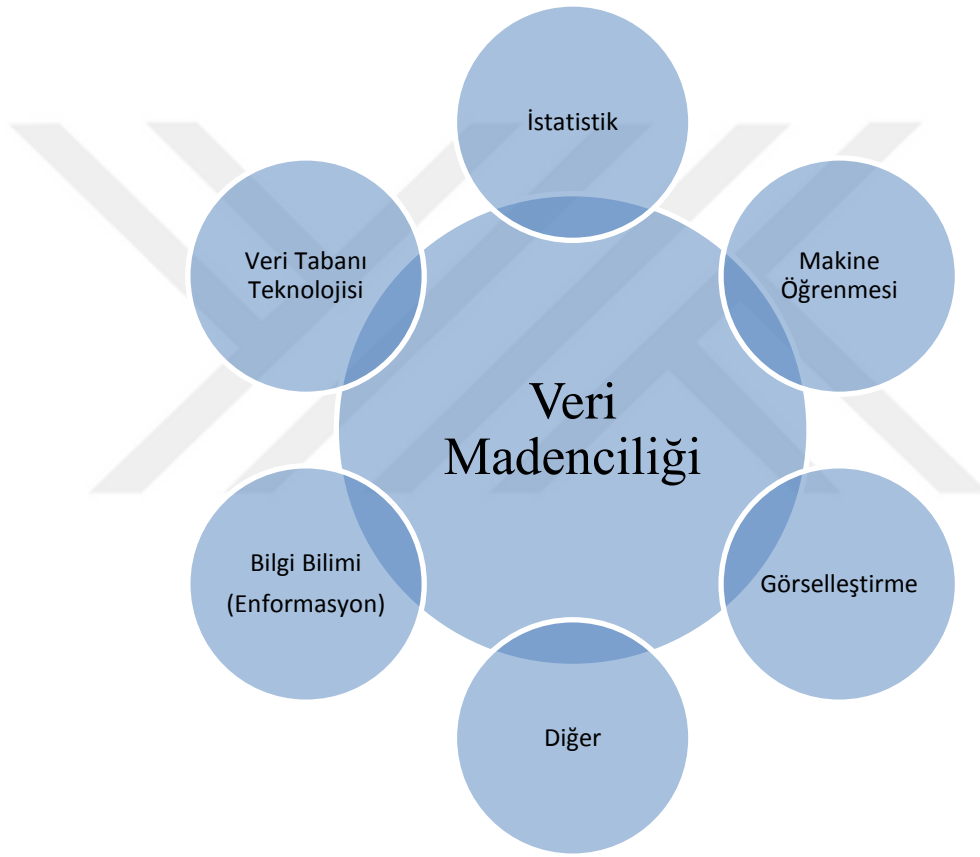
1.9.8. MS SQL Server Analysis Services

MS SQL Server ilişkisel veri tabanı olmasının yanında veri madenciliği modelleri ile de ön plana çıkmaktadır. MS SQL Server Analysis Services, Microsoft araştırma ile birlikte SQL Server veri madenciliği ürün ekibi tarafından geliştirilen 9 zengin algoritma kümesini içerir. Bu Algoritmalar Microsoft karar ağaçları, Microsoft kümeleme, Microsoft zaman serileri, Microsoft birliktelik kuralları, Microsoft sekans kümeleme, Microsoft bayes teoremi, Microsoft sinir ağları, Microsoft doğrusal regresyon ve Microsoft lojistik regresyon şeklindedir (Aggarwal vd., 2012, s.167). MS SQL Server Analysis Service veri madenciliği motoru ve OLAP (Online Analytical Processing - çevrim içi analitik işleme) motoru olan gelişmiş özelliklere sahip iki önemli bileşeni mevcuttur. Bu iki bileşen veri madenciliği için önemli tekniklerdir ve birbirlerini tamamlarlar (Tang vd., 2005, s.80).

1.10. Veri Madenciliği'nin Farklı Disiplinlerle İlişkisi

Veri madenciliği birçok disiplini içinde barındıran ve yöntemlerini kullanan disiplinler arası bir tekniktir. Veri madenciliğinin temelini oluşturan bu disiplinler, istatistik, yapay zeka, veri tabanı teknolojisi (Demiral vd., 2017, s.243), makine öğrenmesi, görselleştirme, bilgi bilimi ve diğer disiplinlerdir (Alagöz vd., 2014, s.5). Veri madenciliği bu disiplinler arasında köprü görevi gören bir alandır. Veri madenciliği istatistik biliminin manüel olarak yaptığı algoritmaları otomatik olarak

yapar. Makine Öğrenmesi alanında uygulanan Yapay Zekâ, örüntü tanıma, birliktelik kuralları, sınıflandırma, kümeleme vb. birçok tekniği kullanır. Anlamsız veri yığınlarından anlamlı bilgiler elde eder ve veri grafikleştirme tekniklerini kullanarak daha anlaşılır bilgi sunumu yapar. Şekil 1.3.'te veri madenciliğinin diğer disiplinlerle olan ilişkisi şema olarak gösterilmektedir.



Şekil 1.3. Veri madenciliğinin diğer disiplinlerle ilişkisi
Kaynak: Alagöz vd. (2014); Savaş vd. (2012)

Şekil 1.3.'ten anlaşıldığı üzere veri madenciliği istatistik, makine öğrenmesi, veri tabanı teknolojileri, bilgi bilimi, görselleştirme ve diğer disiplinleri içinde barındıran, pratik çözümler üreten bir tekniktir.

1.11. Veri Madenciliğinin Uygulama Alanları

Son dönemlerde hızlı bir gelişim gösteren bilişim teknolojileri sayesinde birçok sektör veri tabanlarında veri depolamaktadır. Günümüz ekonomik koşulları ve

yaşanan hızlı değişimler nedeniyle önsezilere dayanarak karar almak risklidir. Riski azaltmanın yolu ise bilgiye dayalı karar destek çözümleridir. Veri madenciliği teknikleri ile bilgiye dayalı karar destek sistemi oluşturulabilir. Bu sebeple veri madenciliği tekniklerini kullanmak birçok sektör için kaçınılmazdır (Savaş vd., 2012, s.3).

Veri madenciliği yoğun olarak üretilen veri sonucunda oluşan veritabanlarının bulunduğu tüm sektörlerde uygulama alanı bulabilir (Can vd., 2012, s.5). Bu teknik veriyi bilgiye dönüştürmek için iş zekâsının en önemli araçlarından biri haline gelmiştir. Bu sebeple çeşitli sektörlerdeki kapsamlı araştırma çalışmaları bu tekniğin potansiyel araçlarına odaklanmakta (Zarei vd., 2018, s.79) ve birçok sektörde geleceğe yönelik kritik kararlar almak için yaygın olarak kullanılmaktadır (Santur vd., 2016, s.141).

Günümüzde veri madenciliğinin kullanıldığı alanlardan bazıları şunlardır: eğitim (Kahveci ve Özdemir, 2016, s.1), kütüphane (Demiral vd., 2017, s.241), bankacılık ve finans (Çalış ve Baynal, 2016, s.15), sigortacılık (Doğan vd., 2014, s.106), ticaret ve pazarlama (Çelik, 2017, s.63; Dolgun ve Ersel, 2014, s.2), tıp ve sağlık (Bircan ve Çam, 2016, s.85; Kharya, 2012, s.56) ve diğ. sektörler. Aşağıdaki bölümlerde veri madenciliğinin kullanıldığı bu sektörlerle ait açıklamalar yer almaktadır.

1.11.1. Eğitim Sektörü

Bilişim teknolojileri ile birlikte gelişen eğitim bilgi sistemleri çok sayıda kaynaktan gelen büyük miktarda ayrıntılı veriyi depolayabilir. E-öğrenme kaynakları, enstrümantal eğitim yazılımları, eğitimde internet kullanımı, uzaktan eğitim sistemlerinin yaygınlaşması, öğrenci bilgilerinin devlet veri tabanlarında tutulması vb. durumlar eğitim alanında büyük miktarda veri depolanmasına neden olmuştur. Bu depolanan verinin tamamı veri madenciliği açısından keşfedilecek altın madeni gibidir. Eğitim kurumlarının karşı karşıya olduğu en büyük problemlerden biri eğitsel verilerin üssel olarak büyümesidir. Bu büyüme veri öbeklerinin

anlaşılabilir bir şekilde yorumlanmasını engellemektedir. Yönetici ve eğitimcilerin alacakları kararların kalitesini arttırmak için depolanan bu verinin analiz edilmesi gerekir (Romero ve Ventura, 2013, s.12). Analiz sonuçlarına göre kararlar almak eğitim sistemlerine dair beklenen hedeflere ulaşmada büyük kolaylıklar sağlar (Kurt ve Erdem, 2012, s.111).

Eğitim alanında uygulanan veri madenciliğinin amaçları arasında öğrencilerin başarı ve başarısızlık nedenlerinin tespit edilmesi, başarı oranlarının artırılması, eğitim ve öğretimde oluşan aksaklıkların tespit edilmesi, etkin eğitim ortamlarının oluşturulması (Özbay, 2015, s.265) ve doğru kararların alınması sayılabilir. Tüm bu sebeplerden dolayı Eğitimsel Veri Madenciliği (EVM) alanı ortaya çıkmıştır. EVM uygulamaları eğitim alanında bilişim teknolojilerinin yaygınlaşması ile birlikte artış göstermiş yeni bir yaklaşımdır (Özbay ve Ersoy, 2017, s.526).

EVM, disiplinler arası bir araştırma alanıdır (Romero ve Ventura, 2013, s.12). Ancak bu yöntemin uygulanması henüz gelişme aşamasındadır. Bu sebeple teknolojisi ile uygulaması arasında büyük farklar bulunmaktadır (Zhao ve Wang, 2017, s.73).

1.11.2. Kütüphanecilik

Günümüzde, yönetim kararlarını desteklemek için büyük miktarda veriyi yönetmek, kütüphanelerin karşılaştığı güçlüklerden biridir (Pérez, 2017, s.135). Kütüphane verileri içinde oluşan bilgi kalıplarını keşfetmek, kütüphane kullanıcılarını anlamının anahtarıdır. Veri tabanında yapılan bilgi keşifleri sayesinde karar vericiler farklı kullanıcı gruplarının ihtiyaçlarını tanımlayabilirler (Nicholsan, 2003, s. 146). Bir kütüphane ve kullanıcıları arasındaki etkileşimin kalitesini artırmak için, kütüphanelerde veri madenciliği tekniklerinin uygulanması doğru bir yaklaşımdır (Siguenza-Guzman vd., 2015, s.504).

Veri madenciliği; farklı kullanıcı gruplarının ihtiyaçlarını karşılamak, kütüphane yönetiminin karar verme mekanizmalarına yardımcı olmak ve kütüphanelerin veri kaynaklarından etkili bilgiler keşfetmek için uygulanabilir

(Shieh, 2009, s.355). Bu amaçla Scott Nicholson 2003 yılında kütüphane veri tabanlarında yaptığı veri madenciliği çalışmalarını ‘bibliomining’ olarak tanımlamış ve literatüre yeni bir terim kazandırmıştır. Bibliomining, ‘Bibliometri’ ve ‘datamining’ kelimelerinden türetilmiştir. Bu yöntem kullanıcı davranış kalıplarını çıkarmak için veri madenciliği tekniklerini muazzam miktarda ki kütüphane verilerine uygulayan, veri madenciliği ve bibliometri (kitap ve diğer iletişim ortamlarına matematik ve istatistiksel yöntemlerin uygulanması) tekniklerinin birleşimi bir yöntemdir (Azam vd., 2013, s.235; Haro vd., 2016, s.203).

Bibliomining süreci, Nicholson (2003) tarafından sunulan çalışmaya göre, iç ve dış veri kaynaklarının tanımlanması, veri ambarının oluşturulması, uygun analiz araçlarının seçimi, veri madenciliği kullanarak kalıpları keşfetme, sonuçların analiz edilmesi, raporların oluşturulması ve yorumlanması olmak üzere çeşitli aşamalardan oluşmaktadır. Bu teknik ve metotlarla veri analizi, yöneticilere etkili destek sağlayabilir. Bu şekilde kütüphane için malzeme satın alınması, malzemenin kitap rafında yer alması, mali konuların değerlendirilmesi, son kullanıcılara daha iyi hizmet verilmesi gibi gerçek ihtiyaçlara yönelik çözümler sağlanabilir (Haro vd., 2016, s.203-205).

1.11.3. Bankacılık ve Finans

Bankacılık sistemleri ile müşteri bilgileri, işlem ayrıntıları, risk profilleri, kredi kartı ayrıntıları, limit ve teminat ayrıntıları, uyumluluk, ticaret finansmanı verileri olmak üzere gün geçtikçe artan büyük miktarda veri toplanmaktadır. Bankalarda kredi kararları, ilişki başlatma, yatırım kararları vb. birçok kararlar alınır. Bu kritik kararları alırken bankacılık sistemleri tarafından depolanan veriye ihtiyaç duyulur. Ancak manüel olarak yapılan işlemler hem zaman alıcıdır hem de hata riski yüksektir. Veri madenciliği teknikleri ile büyük hacimli verilerden hızlı bir şekilde doğru bilgiler elde etmek ve doğru finansal kararlar almak mümkündür (Pulakkazhy ve Balan, 2013, s.1252). Ayrıca veri madenciliği teknikleri ile banka etkinlik kriterleri ölçülebilir ve finansal performans göstergeleri tahmin edilebilir (Seyrek ve Ata, 2010, s.67).

Veri madenciliği bankacılık sektöründe, hisse senedi fiyatlarının tahmini, yeni yatırımların yönetimi, yatırım portföyünün belirlenmesi, pazarlama stratejilerinin oluşturulması, risk analizleri, kredi ve kredi kartı dolandırıcılığı tahminleri, kredi limitinin belirlenmesi ve ücret yönetimi için kullanılabilir (Keleş, 2017, s.129). Ayrıca veri madenciliği ile internet bankacılığı kullanan ve kullanmayan müşteriler tespit edilerek internet bankacılığı kullanıcı profili elde edilebilir (Gürsoy ve Bilgin, 2016, s. 421).

1.11.4. Sigortacılık

Sigortacılıkta veri madenciliği teknikleri ile yeni poliçe talebinde bulunabilecek müşteriler tespit edilebilir. Sigorta dolandırıcıları ve riskli müşteriler tespit edilerek risk profili çıkartılabilir (Yıldız, 2014;5). Ayrıca sigortacılık sektöründe veri madenciliği uygulamaları ile hangi müşterilerin hangi sigorta poliçelerini tercih ettiklerinin bulunması, değerli müşterilerin ortaya çıkartılması sağlanabilir. Bu bilgilerle geleceğe yönelik doğru tahminlerde bulunulabilir. Böylece müşteri özelliklerine göre satış kampanyası düzenlenmesi için yardımcı bilgiler elde edilerek müşteri ilişkileri yönetimine katkıda bulunulabilir (Doğan vd., 2014, s.105-114).

1.11.5. Ticaret ve Pazarlama

Veri madenciliği pek çok alanda uygulandığı gibi ticaret ve pazarlama alanında da yaygın biçimde kullanılmaktadır (Yılmaz ve Patır, 2011, s.110-111). Şirketler pazarlama, satış ve hizmet süreçlerinde müşteriler ile uzun süreli ilişkiler kurmayı, müşterileri tanımayı ve farklı müşterilere özel hizmetler sunmayı hedeflemektedirler. Bunu gerçekleştirebilmek içinse depolanan verinin analiz edilmesi, sonuçların incelenmesi ve karar destek mekanizmalarında kullanılması gerekir. Bu noktada veri madenciliği farklı analiz teknikleri sunarak müşteri ilişkileri yönetimi için doğru sonuçlara ulaşılmasını, etkin pazarlama stratejileri ve rekabet avantajı elde etmek için öz bilginin elde edilmesini sağlar (Doğan vd., 2014, s.106; Taşkın ve Emel, 2010, s.396).

Ayrıca İnternetin yaşamımızda vazgeçilmez bir unsur haline dönüşmesi, e-ticaret sitelerinde artış olarak kendini göstermiştir. E-ticaret yapan şirketler web sitelerine daha çok ziyaretçi çekmeyi hedeflemekle birlikte mevcut müşteriyi de ellerinde tutma çabasıdadırlar. Site ziyaretçilerinin gelecek davranışlarını tahmin etmek için işlemsel ve davranışsal verisinin analiz edilmesi gerekir. Bu durum müşteri veri analizini önemli duruma getirmiştir (Çelik, 2017, s.63).

1.11.6. Sağlık

Günümüzde bilişim teknolojilerindeki gelişmeler sayesinde tıp ve sağlık alanında çok sayıda veri sayısal ortamda depolanabilmekte ve kolay bir biçimde erişilebilmektedir. Hastane bilgi sistemleri ile hasta demografik verisi, hastalık tanısı, hastalığa ait tedavi ve tetkikler vb. birçok veri kayıt altına alınmaktadır. Çağımızın en önemli araştırma alanlarından biri tıptır. Bu sebeple bu alanda oluşan veri önemli bir araştırma kaynağıdır (Can vd., 2012, s.6). Veri madenciliği teknikleri, tıp ve sağlık araştırmacıları için çok sayıda numune arasındaki kalıpları ve ilişkileri belirlemek ve bunlardan istifade etmek için popüler bir araştırma aracı haline gelmiştir (Kharya, 2012, s.56) ve son 10 yılda bu alanda veri madenciliği uygulamaları hızlı gelişim kaydetmiştir (Chen vd.,2017, s.389).

Veri madenciliği teknikleri, sağlık ve tıp alanlarında hasta davranış kalıplarının tespit edilmesi, hastalık teşhisi, hasta profili çıkartılması, sağlık hizmetlerinin daha etkin şekilde uygulanması (Bircan ve Çam, 2016, s.85-87), sağlık politikalarının belirlenmesi, sağlık sektöründeki kaynakların ve kurumların yönetilmesi (Santur vd., 2016, s.145), ameliyatlarda yüksek risk faktörlerinin belirlenmesi, hastalığa uygulanacak tedavi yönteminin belirlenmesi, tedavi yöntemlerinin başarılarının saptanması, hastaların demografik özelliklere göre sınıflandırılması (Keleş, 2017, s.130), kanser tespiti (Aydın ve Keleş, 2017, s.1) gibi amaçlar için kullanılmaktadır.

1.11.7. Diğer Sektörler

Veri madenciliği yukarıdaki bölümlerde sayılan sektörlerin dışında veri tabanı kullanılarak veri depolanan tüm sektörlerde uygulama alanı bulabilir. Çağımızda

gelişen bilişim teknolojileri sayesinde hemen hemen tüm sektörlerde ait veriyi depolamak mümkündür. Depolanan veriyi kullanıp doğru sonuçlara ulaşmak ve oluşan bu sonuçlara göre doğru kararlar almak sektörler için önemlidir.

Bu bağlamda veri madenciliği teknikleri mühendislik, endüstri kolları, telekomünikasyon, borsa (Santur vd., 2016, s.145), kamu kuruluşları, bilim, inşaat (Keleş, 2017, s.128), vb. alanlarında da uygulanabilir.



2. BÖLÜM AMPİRİK LİTERATÜR

Bu bölümde WEKA veri madenciliği yazılımının apriori algoritması ve diğer algoritmaları ile hazırlanmış ulusal ve uluslar arası çalışmalardan bazılarına yer verilmiştir.

2.1. Ulusal Çalışmalar

Sözen vd. (2017), çalışmalarında WEKA veri madenciliği yazılımının Apriori algoritmasını kullanarak mobilya seçiminde etkili olan dayanıklılık, işlevsellik, estetik ve maliyet gibi faktörleri analiz etmişlerdir. Çalışmada, herhangi bir mobilya kullanan 74 adet kişi üzerinde yapılan anket verisi kullanılmıştır. Analiz sonucunda 20 adet kural tespit edilmiştir. Elde edilen kurallar ile farklı tüketicilerin mobilya seçerken ne tür hususları göz önünde bulundurduğu ile ilgili çıkarımlarda bulunulmuştur. Elde edilen birliktelik kurallarına göre evli kişilerin mobilya satın alırken daha çok estetiğe dikkat ettiği görülmüştür. Öğrenim durumu yüksek lisans ve doktora olan kimselerin mobilya seçerken daha çok işlevsel olmasına dikkat ettikleri gözlenmiştir.

Pehlivanoglu ve Duru (2015), Kocaeli ilinde yer alan bir ortaokul öğrencilerinin sosyal ağ kullanımına ait anket verisini yine veri madenciliği WEKA yazılımı ile analiz etmişlerdir. Apriori algoritması ile öğrencilerin sosyal medyayı niçin kullandığına ve sosyal medyanın öğrenciler üzerindeki etkilerine dair birliktelik kuralları çıkartmışlardır. Analiz sonucunda kız ve erkek öğrencilerin çoğunlukla Facebook ağını kullandığı, 5., 6. ve 7. sınıf öğrencilerinin çoğunlukla Instagram ve Twitter kullandığı çıkarımlarında bulunmuşlardır. Ayrıca öğrenci genelinin Facebook ağını paylaşım için değil oyun oynamak için kullandıklarını ve öğrencilerin sosyal ağlara en çok tabletler üzerinden eriştiklerini tespit etmişlerdir.

Keleş ve Kaya (2014), çalışmalarında duvar işçiliğinde verimliliği etkileyen faktörleri yine WEKA programının apriori algoritmasını kullanarak incelemişlerdir. Analiz için Türkiye’de duvar inşa eden 68 adet firmadan alınan verilere sistematik bir zaman çalışması yapılmıştır. Ekip sayısı, yaş, tecrübe ve verimlilik değerleri

kullanılarak 10 adet kural tespit edilmiştir. Algoritma sonucunda elde edilen kurallar ile inşaat sektörü için verimliliği etkileyen önemli faktörler tespit edilmiştir. Analiz sonucunda en yüksek güven aralığına sahip olan kurala göre ekip sayısı=fazla, yaş=genç, tecrübe=orta ise %89 olasılıkla verimlilik yüksek olmaktadır. Ekip sayısı = az, yaş=genç ise %80 olasılıkla verimlilik düşük olmaktadır.

Aytaç (2013), ise yüksek lisans çalışmasında, veri madenciliği; WEKA yazılımının PredictiveApriori algoritmasını kullanmışlardır. Uygulamada birçok bilimsel çalışma için deneysel veri setleri barındıran ‘UCI Makine Öğrenmesi ve Akıllı Sistemler’ isimli veri deposunda ki ‘Bank Marketing’ isimli veri seti kullanılmıştır. Portekiz’de bulunan bir bankaya ait 17 farklı kampanyayı kapsayan ikincil veriler üzerinde gerçekleştirilen birliktelik analizi sonucunda çeşitli kurallar elde edilmiştir. Birliktelik analizi sonucu kampanyayı kabul eden öğrencilerin %94’nün bekâr olduğu, konut kredisi kullanan müşterilerin %92’sinin kampanyaları kabul etmediği, konut kredisi ve bireysel kredi kullananların kampanyayı kabul ettiği, mesleği girişimci olan ve kampanya teklifini telefonla uzun süre dinleyen kişilerin %75’inin evli olduğu sonuçlarına varılmıştır.

Gülen ve Özdemir (2013), ise çalışmalarında Yasemin Karakaya Bilim ve Sanat Merkezi’nde eğitim gören 12 yaş ve üstü üstün yetenekli öğrencilerin ilgi alanlarını tahmin etmek ve ilgi duydukları alanları belirlemek için WEKA veri madenciliği yazılımını kullanmışlardır. Araştırmada 113 öğrenciye ait veri; akademik benlik kavramı ölçeği, boş zamanları değerlendirme anketi ve ebeveyn veri toplama formu ile elde edilmiştir. Üstün yetenekli öğrencilerin ilgi alanlarını tespit etmek için yukarıdaki çalışmalardan farklı olarak Part, Ridor, DecisionTable, JRip, BFTree, FT, J48, LADTree, SimpleCart ve NaiveBayes algoritmaları kullanılmıştır. Öğrencilerin ilgi alanlarına ait birliktelik kuralları ise Apriori algoritması ile belirlenmiştir. Birliktelik analizi sonucunda mekaniğe ilgisi olan öğrencilerin %65’nin fen bilimlerine, sosyal bilimlere ilgisi olan öğrencilerin %63’nün fen bilimlerine, sanat dalına ilgisi olan öğrencilerin %50’sinin yabancı dillere de ilgisi olduğu sonuçlarına varılmıştır.

2.2. Uluslararası Çalışmalar

Bu bölümde WEKA veri madenciliği yazılımının Apriori ve diğer algoritmaları ile hazırlanmış bazı uluslararası çalışmalardan bahsedilmiştir. Ayrıca kütüphane kullanımı ile öğrenci başarısı arasındaki ilişkiyi inceleyen bir çalışmaya da yer verilmiştir.

Tamayo vd. (2018) tarafından yapılan çalışmada WEKA veri madenciliği yazılımının karar ağacı algoritmaları kullanılmıştır. Üniversiteye 2012-2013, 2013-2014, 2014-2015 ve 2015-2016 yılları arasında giren öğrencilerin; üniversiteye giriş sınav sonuçları, cinsiyet, liseyi bitirdikleri okul türü, İngilizce 1, Cebir ve ana ders final notları gibi öğrenci verisi kullanarak öğrencilerin mezuniyet notlarını tahmin etmeye yönelik model hazırlanmıştır. Araştırma sonucunda WEKA'nın REPTree, RandomTree, RandomForest, J48 algoritmaları karşılaştırılmıştır. Bu kapsamda verimlilik, doğruluk ve kullanıcı dostu olması açısından RandomForest algoritmasının diğer algoritmalara göre mezuniyet notlarını daha iyi tahmin ettiğini tespit etmişlerdir.

Gour vd. (2016) ise çalışmalarında Hindistanda bulunan Narmada Nehri'ne ait 1990 - 2010 yılları arasındaki su kalitesi parametre verisini analiz ederek ilginç birliktelik kuralları elde etmişlerdir. Analiz için tercih edilen veri madenciliği algoritması WEKA yazılımı içerisinde mevcut Apriori algoritmasıdır. 9 adet parametre üzerinden gerçekleştirilen birliktelik analizi sonucunda %100 güvenilirlikte 20 adet kural elde edilmiştir. Elde edilen kurallar sonucunda suyun amonyum nitrojen seviyesi düştüğünde su kalitesinde 1 derecelik bir düşme olduğunu tespit etmişlerdir. Ayrıca suyun sabit bir PH değeri için biyokimyasal oksijen ihtiyacının arttığını, oksijen eritin parametresi ile su kirliliği arasında ters ilişki olduğu sonuçlarına varılmıştır. Su içerisindeki biyokimyasal oksijen parametresi ile su kalitesi arasında ters orantı ve Amonyum nitrojenin parametresi ile fosfat parametresi arasında doğru orantı olduğu bulgularına ulaşmışlardır.

Renaud vd. (2015)'in 'Mining library and university data to understand library use patterns' adlı çalışmalarında ise bir devlet üniversitesinin 20 yıllık kütüphane verisi ile o üniversiteye ait 20 yıllık öğrenci verisi incelenmiştir. Çalışmada kütüphaneye ait üye verisi, kayıtlı kitap verisi, turnike verisi, kütüphane içi sirkülasyon verisi kullanılmıştır. Kütüphane kullanıcı davranışı ve kitap kullanım kalıplarının ortaya koyulduğu çalışmada ayrıca kütüphane kullanımı ile öğrencinin mezuniyet notu arasında ki ilişki incelenmiştir. Fakülte bazında yapılan analiz sonucunda bazı bölümlerde negatif korelasyona rastlanırken, bazı bölümlerde pozitif korelasyona rastlanılmıştır.

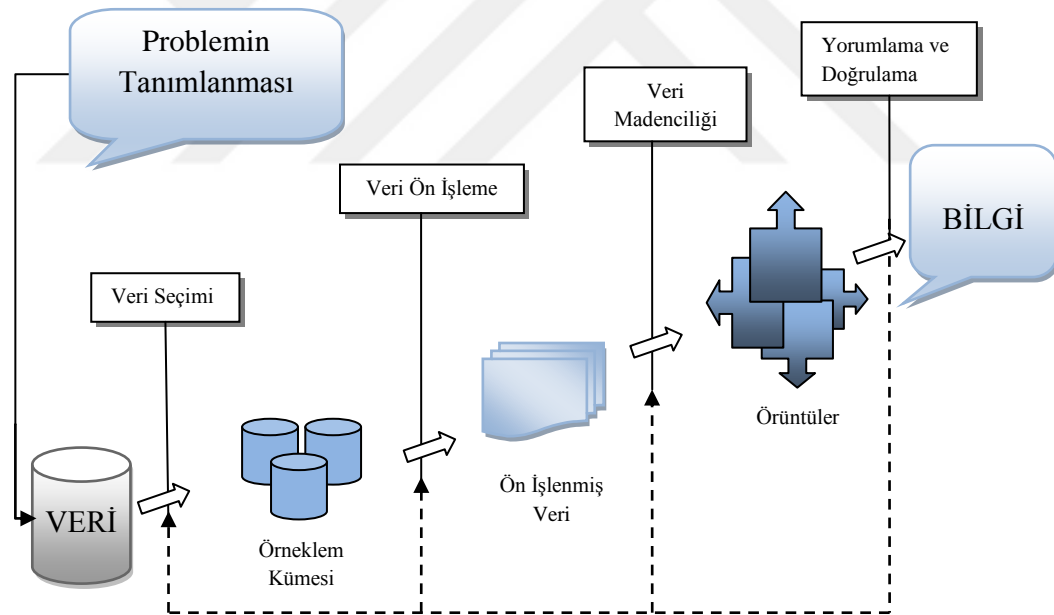
Natek ve Zwilling (2014), bir yüksek öğretim kurumunun canlı video akışı ile öğrenen üniversite öğrencileri üzerine yapılan veri madenciliği çalışmalarında ise Microsoft veri madenciliği ile WEKA veri madenciliği yazılımları karşılaştırılmıştır. Öğrencilerin çevrimiçi öğrenme davranışlarını ve derslerindeki performanslarını analiz etmek için karar ağaçları algoritması ve klasik istatistiksel yöntemlerden regresyon analizi kullanılarak karma bir analiz gerçekleştirilmiştir. Çalışma sonucunda öğrencilerin oturum açma süreleri, sordukları soru adedi, sohbet mesajları ile dönem sonu başarı notu arasında bir ilişki olmadığı sonucuna varılmıştır. Çalışma ayrıca Microsoft ve WEKA yazılımlarının yüksek tahmin başarısı gösterdikleri ve bu iki yazılımında küçük veri setlerinde başarılı sonuçlar ürettiklerini ortaya koymaktadır.

Borkar ve Rajeswari (2013)'e ait çalışmada, Pune Üniversitesi'nde Bilgisayar Uygulamaları Yüksek Lisansına devam eden 60 öğrencinin üniversite performans düzeyinin; mezuniyet notu, üniversiteye devam süresi, ödev notu, ünite testi performansı ve üniversiteye giriş puanı ile arasındaki ilişki kuralları tespit edilmiştir. Çalışmada veri madenciliğinin Apriori algoritması, WEKA yazılımı kullanılarak gerçekleştirilmiştir. Analiz sonucunda üniversite performans düzeyinin ünite testi performansı, ödev notu, devam süresi ve mezuniyet notu ile ilişkili olduğu sonucuna varılmıştır.

3. BÖLÜM VERİ TABANINDA BİLGİ KEŞFİ SÜRECİ VE VERİ MADENCİLİĞİ YÖNTEMLERİ

Veri tabanlarında bilgi keşfi sık olarak veri madenciliği kavramı ile karıştırılmaktadır. Pek çok araştırmacı ve uygulayıcı bu iki kavramı benzer anlamlarda (Wu vd., 2018, s.100) ve birbirinin yerine kullanmaktadır. Veri tabanlarında bilgi keşfi, veriden anlamlı bilgilerin keşfedilmesi sürecinin tümüne verilen addır. Veri madenciliği bu sürecin en önemli aşamasıdır (Koyuncugil ve Özgülbaş, 2009, s.22; Özdemir vd., 2009, s.350).

Şekil 3.1.'de veri tabanında bilgi keşfi adımları ve veri madenciliğinin bu süreçte ki yeri gösterilmiştir.



Şekil 3.1. Veri tabanında bilgi keşfi süreci
Kaynak: Alagöz vd. (2014); Albayrak (2017)

Veri tabanında bilgi keşfi sürecinin adımları problemi tanımlama, analiz için uygun veriyi seçme, seçilen veriyi ön işlemden geçirme, veri madenciliği, veri madenciliği sonucunda oluşan örüntüleri değerlendirip yorumlama ve doğrulama, en sonunda bilgi çıkarımı şeklindedir. Bu süreçte en doğru ve güvenilir bilgiye ulaşmak

için sürecin herhangi bir adımına geri dönmek ve sistemi değerlendirip o adımı tekrar etmek gerekebilir.

3.1. Problemin Tanımlanması

Sürecin en önemli aşamalarından biridir. Veri madenciliği çalışmalarında başarılı olmak için yapılacak olan çalışmanın, organizasyonun hangi amacı için uygulanacağını net bir şekilde tanımlanması gerekir. Tanımlanan amaca göre belirlenen problem ve problemin çözümünde ulaşılabilecek nokta ölçümlenmelidir (Savaş vd., 2012, s.8; Alagöz vd., 2014, s.6) Zaman ve maliyet getirisi kazandıracak problemin tanımlanması aşağıdaki süreçlerden oluşmaktadır (Gülten vd., 2017, s.244):

- Araştırma konusunun tespiti,
- Araştırma amacının tespiti,
- Durum değerlendirmesi,
- Planlama sürecinin oluşturulması.

3.2. Veri Seçme

Veri tabanında bilgi keşfi sürecinin önemli bir adımı da veri seçme adıdır. Bu adımda, yapılacak analize uygun veri belirlenir (Tekerek, 2011, s.162). Keşfin gerçekleştirileceği değişkenlerin alt kümesine veya veri örneklerine odaklanılarak (D'Oca ve Hong,2015, s.399) uygulayacağımız modele bağlı, uygun veri seçilir. Örneğin; tahmin edici model için, bağımlı ve bağımsız değişkenler ile bu modelin eğitiminde kullanılacak olan veri kümesinin seçilmesi gerekir (Alagöz, 2014, s.7). Bunun için bir kaç veri kümesi birleştirilerek uygun bir örneklem kümesi elde edilebilir (Sever ve Buket, 2003, s.177). Elde edilen örneklem kümesi veri ön işlemeden geçirilerek analiz için hazırlanır.

3.3. Veri Ön İşleme

Verilerin hazırlanması olarak da adlandırılan veri ön işleme aşaması sürecin en uzun ve zaman alan aşamasıdır (Munková, 2013, s.1198). Veri veritabanında bilgi

keşfi sürecinde araştırmacılar zamanlarının %50'si ile %80'ni arasındaki bir süreyi veri ön işleme ayırmaktadır. Bu sebeple de veri ön işleme veri analizlerinin anahtar sürecidir (Doğan, 2017, s.82). Modelin kurulması aşamasına geçildiğinde ortaya çıkan sorunları düzeltmek için zaman zaman bu aşamaya tekrar dönülüp sürecin bazı adımlarını tekrarlamak gerekebilir (Alagöz vd., 2014, s.7).

Veri analiz aşamasına geçilmeden önce verinin ön işleme tabi tutulması gerekir; çünkü değişken niteliklere sahip farklı veri türleri vardır. Veri setinde eksik veri, çoğaltılmış veri, tutarsız veri veya gürültülü veri (hatalı veya yanlış değer almış) olabilir (Amatriain vd., 2015, s.42). Verideki bu tür anomaliler veri analizi sırasında zorluklar çıkartabilir, yanıltıcı ve güvenilmez sonuçlar doğurabilir (Singhal ve Jena, 2013, s.251). Veri ön işleme hatalı veriyi düzeltmek ve filtrelemek için gereklidir (Nisbet, 2018, s.471). Gürültülü, tutarsız verinin temizlenmesi, eksik verinin tamamlanması ve çoğaltılmış verinin indirgenmesi gerekir. Buradaki amaç veri madenciliği araçları ve algoritmaları tarafından verinin en iyi biçimde analiz edilmesini sağlamak, daha güvenilir ve kaliteli sonuçlar elde etmektir.

Veri ön işleme teknikleri veri birleştirme, veri temizleme, veri dönüştürme (uyumlaştırma), veri indirgeme şeklinde sıralanabilir (Oğuzlar, 2003, s.70). Aşağıdaki bölümlerde veri ön işleme adımları açıklanmıştır.

3.3.1. Veri Birleştirme

Araştırma amacına uygun olarak toplanan ham veri birçok heterojen kaynaktan veya farklı veri tabanlarından gelmiş olabilir. Bu durum veri analizini zorlaştırabilir. Veriyi tek bir veritabanına toplamak analizi de kolaylaştırır (Maley vd., 2016, s.115). Veri birleştirme ile farklı kaynaklardan gelen verinin bir kombinasyonu oluşturulur ve analiz için tek bir veri tabanında toplanması sağlanır (Chen vd., 2014, s.183).

Veri birleştirme aşamasından sonra birbirini tekrar eden fazla veri, uyumsuz veri veya eksik veri oluşabilir. Birleştirme aşamasından sonra bu sorunların düzeltilmesi analiz aşamasında hatalı sonuçların çıkmaması için gereklidir (Demiral vd., 2017, s.244).

3.3.2. Veri Temizleme

Veri seçiminden sonra elimizdeki veride veya veri birleştirme aşamasından sonra elde edilen birleşmiş veride sorunlu veriler olabilir. Veri analizinden önce sorunlu verilerin temizlenmiş olması gerekir. Bu aşamada yapılan veri temizleme işlemi analiz kalitesini arttıracak ve daha doğru sonuçlar elde etmemizi sağlayacaktır.

Doğru ve güvenilir sonuçlar elde etmek için gerekli olan veri temizleme aşaması (Emre ve Erol, 2017, s.165) eksik, çoğaltılmış, tutarsız ve gürültülü verinin silinmesi veya değiştirilerek işlenmesi aşamasıdır (D'Oca ve Hong,2015, s.399). Temizlik, sorunlu veri türleri tespit edilerek gerçekleştirilir. Genellikle veri temizleme; hataları arayıp tanımlama, hata türlerini tanımlama, hata türlerini kayıt etme, hataları düzeltme, gelecekte oluşabilecek hataları azaltmak için veri giriş prosedürlerini değiştirme gibi 5 tamamlayıcı prosedürü içerir. Veri temizleme veri madenciliğinde veri tutarlılığını korumak için önemli bir aşamadır (Chen vd., 2014, s.183).

3.3.3. Veri Dönüştürme (Uyumlaştırma)

Veri yığınlarının temel özelliklerinden birisi de karmaşık ve büyük hacimli olmalarıdır. Bunun sebebi ise farklı veri toplayıcılarının farklı veri şablon ve uygulamalar kullanarak kayıt etmesidir. Sağlık sektöründen bir örnek vermek gerekirse her bir insanın demografik özelliklerine ait veri metin biçiminde kaydedilirken, röntgen ve tomografi gibi veri görsel veri biçiminde depolanır (Wu vd., 2014, s.99).

Ayrıca farklı veri tabanlarından elde edilen veri, farklı veri tiplerinde kaydedilmiş olabilir. Örneğin cinsiyet değişkeni bir veri tabanında metin olarak (kadın için K harfi, erkek için E harfi vb.) tanımlanırken bir başka veri tabanında sayısal olarak (kadın için 0 rakamı, erkek için 1 rakamı vb.) tanımlanmış olabilir. Farklı biçimlerdeki bu cinsiyet verisinin kullanılabilmesi için ortak bir veri biçimine dönüştürülmesi gerekir. Dönüştürme işlemi ile veri türü farklılıkları ortadan kaldırılır.

Veri dönüştürme işlemi normalleştirme, toplama, genelleme şeklinde yapılabilir. Normalleştirme genel olarak, sayısal bir değişkene ait verilerin 0-1 gibi belirli bir değerler grubu arasındaki değişime göre ölçeklendirilmesidir. Toplamada aynı öz nitelikten iki veya daha fazla değer bir araya toplanır. Örneğin, birden fazla kategoriye bir kategoriye toplayıp, kategorik değişkenlerin atanması sayılabilir (İşletme İ.Ö., İşletme, İşletme Y.L. kategorilerinin toplanıp bu kategoriye '1' değerinin atanması gibi). Genelleme toplama işlemine benzer. Genellemeye düşük seviye öznitelikler üst düzey özniteliklere dönüştürülür. Örneğin, kronik böbrek hastalığı hastalarının analizinde, hastanın kreatinin seviyeleri gibi sürekli bir sayısal değişken kullanmak yerine, kabul edilmiş kılavuzlar tarafından tanımlanan evreler için bir değişken kullanılabilir (Maley vd., 2016, s.119).

3.3.4. Veri İndirgeme (Azaltma)

Veri ön işlemenin son aşaması veri indirgeme diğer adıyla veri azaltmadır. Veri setinin büyüklüğü uygulanacak algoritmaların verimliliğini etkilemektedir. Aynı sonuçların elde edilebileceği küçük bir veri seti oluşturulması uygulama süresinin azalmasını sağlayacaktır (Kılınç, 2015, s.15).

Veri indirgeme orijinal verilerin bütünlüğünden ödün vermeden veri kümesinin daha etkili bir gösterimi için girdi verisini azaltma işlemidir. Veri indirgeme ile veri boyutu daha küçük, ancak aynı analitik sonuçlar üreten bir form haline getirilir. Bu adımın amacı, yapılacak istatistiksel analizin daha etkili olacağı bir veri kümesinin yeni bir sürümünü oluşturmaktır (Maley vd., 2016, s.120; Singhal ve Jena, 2013, s.251). Veri indirgeme analiz amacına bağlı olarak veri kümesini temsil eden tipik özellikleri bulup dikkate alınan değişkenlerin etkin sayısına ulaşmayı içermektedir.

3.4. Veri Madenciliği Aşaması

Veri tabanında bilgi keşfi sürecinin en önemli adımı veri madenciliği aşamasıdır. Sürecin bu adımı veri ön işleme adımı hazırlanan veriyi kullanarak

araştırma problemine göre veri madenciliği modelinin seçilmesini, kurulmasını, değerlendirilmesini ve kullanılmasını içerir.

Modelin seçilmesi aşamasında veri madenciliğinin hangi algoritmasının kullanılacağına karar verilir (Özdemir vd., 2009, s.351). Araştırma problemine uygun veri madenciliği modelinin seçilmesi için birkaç deneme yapmak, analize uygun algoritmaları bulmak için gerekli olabilir. Bu sebeple veri tabanındaki veri desen ve özelliklerini incelemek önemlidir.

Veri madenciliği pek çok farklı görevi yerine getirmek için birçok algoritma kullanır. Bu algoritmalar veri tabanındaki ön işlenmiş veriyi inceler ve veri özelliklerine en uygun modeli seçer (Aydın ve Özkul, 2015, s.37). Araştırmaya uygun modelin seçilmesi, birçok modelin kurulması ve değerlendirilmesi ile mümkündür (Savaş vd, 2012, s.8).

Kurulan modelin değerlendirilmesi ve doğrulanması gerekir. Doğrulama seçilen modelin, araştırma verisi ile ne kadar iyi performans gösterdiğini değerlendirmek için kullanılan bir süreçtir. Modeli kullanmadan önce modelin kalitesini ve özelliklerini anlamak için doğrulamak önemlidir. Bunun için çeşitli yaklaşımlar vardır. İlki, veride veya modelde sorun olup olmadığını belirlemek için istatistiksel geçerliliğin çeşitli ölçütlerini içermektedir. İkincisi, model doğruluğunu test etmek için verileri eğitim ve test setlerine ayırmaktır. Bu yöntemler veri madenciliği modellerinin doğruluğunu test etmek için yararlıdır ve yinelemeli olarak kullanılabilir (Microsoft SQL Server, 2018).

Kurulan model zamanla verilerin farklılaşması nedeni ile değişikliğe uğrayabilir. Modelin sürdürülebilirliği için izlenmesi, kontrol edilmesi ve gerekirse tekrardan düzenlenmesi gerekir (Akpınar, 2000, s.7).

Veri madenciliği modelleri birçok akıllı algoritmadan oluşmaktadır. Bu algoritmalar ile örüntüler elde edilebilir, gelecekte gerçekleşebilecek bir durum tahmin edilebilir. Aşağıdaki bölümlerde veri madenciliği yöntemleri ve modelleri ayrıntılı biçimde açıklanmıştır.

3.5. Değerlendirme

Veri madenciliği ile ortaya çıkarılan örüntülerin değerlendirilmesi gerekir. Değerlendirme aşaması keşfedilen bilginin geçerlilik, yararlılık, basitlik, yenilik vb. kıstaslara göre test edilmesidir (Sever ve Oğuz, 2003, s.177). Keşfedilen bilginin belirlenen amaca uygunluğu ile alakası önemlidir ve bu bilgi amaca yönelik olarak kullanılmalıdır (Özdemir vd., 2009, s.348). Eğer elde edilen bilgi başlangıçta tanımlanan amacı karşılamıyorsa sürecin belli adımlarına geri dönülmesi ve tekrarlanması gerekebilir.

3.6. Bilgi Sunumu

Sürecin bir diğer adımı ise elde edilen bilgiyi değerlendirildikten sonra kullanıcılara sunulması aşamasıdır. Veri madenciliği sonucunda elde edilen sonuçlar genellikle karmaşık yapıdadır. Kullanıcıların bu sonuçları anlayabilmeleri için daha sade bir dilde, anlayabilecekleri bilgi biçiminde aktarılması gerekir. Genellikle elde edilen bilginin sunumunda görselleştirme tekniklerinden yararlanır. Grafik ve tablolar vasıtası ile yapılan sunumlar bilgi sunumunda etkili yöntemlerdir.

3.7. Veri Madenciliği Yöntemleri

Veri madenciliğinde elde bulunan veri setine ve uygulanacak alana göre farklı yöntemler kullanılmaktadır (Albayrak, 2017, s.755). Veri analizinde hangi yöntem veya yöntemlerin kullanılacağı veritabanında bilgi keşfi sürecinde tanımlanan probleme göre belirlenir. Bu bağlamda veri madenciliğinde tahmin edici ve tanımlayıcı modeller olmak üzere 2 adet genel yöntem bulunmaktadır.

Karar alma sürecinde önemli olan tahmin edici modeller bir veri setindeki olayın sonuç değerlerinden hareket ederek model geliştirilmesi ve kurulan bu model ile sonuçları bilinmeyen bir olayın sonuç değerinin tahmin edilmesi için geliştirilmiş modellerdir (Alagöz vd., 2014, s.7). Veri madenciliğinde zaman serileri analizi, sınıflandırma ve regresyon tahmin edici modellerdir.

Tanımlayıcı modeller karar vermede rehberlik etmesi için mevcut veri örüntülerinin tanımlanmasını ve veri kümesi içerisinde ne tür ilişkilerin olduğunun anlaşılmasını sağlar (Sevindik vd., 2012, s.188). Veri madenciliğinin birliktelik kuralları ve ardışık zamanlı örüntüler ile kümeleme analizleri tanımlayıcı modellerdir.

3.7.1. Sınıflama ve Regresyon

Sınıflandırma ve regresyon, önemli veri sınıflarını ortaya koyan, gelecekteki bir verinin bu sınıflardan hangisine ait olduğunu tahmin eden veri madenciliği yöntemleridir. Sınıflama, kategorik değerleri tahmin eder, regresyon ise süreklilik gösteren değerlerin tahmin edilmesinde kullanılır. Regresyon analizi, bir veya daha fazla bağımsız değişken ile bağımlı değişken arasındaki ilişkiyi modellemek için kullanılır. Veri madenciliğinde bağımsız değişkenler zaten bilinen niteliklerdir, istenen ise bağımlı değişkenleri tahmin etmektir. (Baradwaj ve Pal, 2011, s.64; Çalış vd., 2014, s.5).

Sınıflama teknikleri ile veri seti içinde sınıfı belli olamayan gözlemlerin çeşitli özelliklerine göre, nitelikleri önceden bilinen, eğitim seti ile tanımlanan bir veri sınıfına ataması yapılır (Vadim, 2018, s.235; Bilen vd., 2014, s.82). Bu yöntem ile veri kümesi içerisindeki kategorisi bilinmeyen bir verinin kategorik değerleri tahmin edilebilir (Alagöz vd., 2014, s.8).

Sınıflandırma ve regresyon kapsamında ele alınabilecek bazı veri madenciliği problemleri şunlardır:

- Kredi- borç onayı tespiti,
- Dolandırıcılık tespiti,
- Hastalık teşhisi,
- Ayrılacak müşterilerin tahmini,
- Ses ve Karakter tanıma.

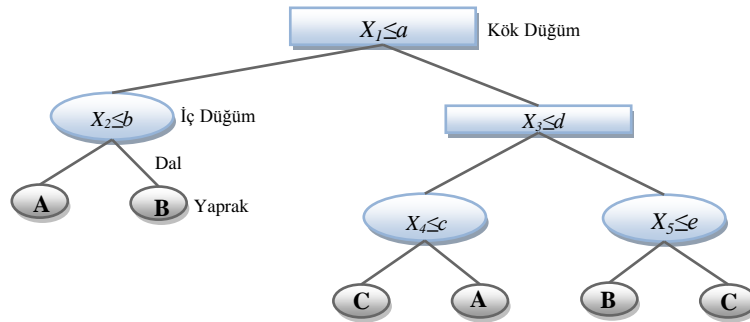
Ne yazık ki, birçok gerçek dünya problemi basitçe tahmin edilemez yapıdadır. Bu nedenle, gelecekle ilgili değerleri tahmin etmek için daha karmaşık teknikler gerekebilir. Bu sebeple aynı model tipleri hem regresyon hem de sınıflandırma için kullanılabilir. Örneğin, Yapay sinir ağları ve karar ağaçları ile hem sınıflandırma hem de regresyon modelleri oluşturabilir (Baradwaj ve Pal, 2011, s.64).

Sınıflandırma ve regresyon problemleri için geliştirilmiş çeşitli veri madenciliği teknikleri bulunmaktadır. Bu tekniklerden en çok kullanılan algoritmalar karar ağaçları, yapay sinir ağları, bayes sınıflandırıcılar, k-en yakın komşu, genetik algoritmalar, destek vektör makineleri, doğrusal regresyon, lojistik regresyon şeklindedir.

3.7.1.1. Karar Ağaçları

Karar ağacı, hem sınıflandırma hem de regresyon için yaygın olarak kullanılan veri madenciliğinin tanımlayıcı ve tahmin edici algoritmalarından biridir. Bir hedefe ulaşma ihtimali olan stratejinin belirlenmesine yardımcı olmak için kullanılır. Bu yöntem karar vericiler için karar alırken hangi faktörlere dikkat edilmesi gerekliliğinin ve her bir faktörün geçmişteki bir olayı nasıl etkilediğinin tespitine yardımcı olur. Bu teknik adından da anlaşılacağı üzere akış diyagramı benzeri bir ağaç yapısındadır.

Şekil 3.2. 'de karar ağacı örneği görülmektedir.



Şekil 3.2. Üç sınıftan oluşan örnek karar ağacı yapısı
Kaynak: Kavzoğlu ve Çölkesen (2010)

Tahmin kesinliğini artırmak amacıyla ağaçlar oluşturmak için, gözlemler tekrarlanan şekilde dallara ayrılır. Şekil 3.2.'deki Her dal bir düğüm ile birbirine bağlanır. Her kök düğüm dikdörtgenlerle, yaprak düğümleri ise ovalerle gösterilir. Her iç düğüm girdi değişkenlerinden birine karşılık gelir ve girdi değişkeninin değerlerine dayalı olarak alt düğümlere bölünür (Ahmed ve Elaraby, 2014, s.45). Her yaprak veya kök düğüm, bir hedef değişkenin belirli değerini, temsil eder. Sınıflandırma ağacı öğrenme işlemi sırasında her iç düğümdeki örnekler, bir öznitelğe dayalı alt kümelere ayrılır ve bu süreç türetilen her alt kümede 'özyinelemeli bölümlenme' adı verilen özyinelemeli bir şekilde tekrarlanır. Yineleme işlemi, bir düğümdeki bir alt küme bölme tahminini iyileştirmediginde veya kullanıcı tarafından tanımlanan kısıtlamalar nedeniyle bölünme imkânsız olduğunda, aynı hedef değere sahiptir. Bir karar ağacı büyüdükçe her adımda, girdi değişkenlerinden biri örnekleri bölmek için seçilir. Seçilen değişkene bağlı olarak, bölme noktası bir öznitelik değeri testi ile belirlenir. Gini ve entropi, sınıflandırma ile regresyon ağaçları için yaygın olarak kullanılan testlerdir (Kim, 2016, s.158).

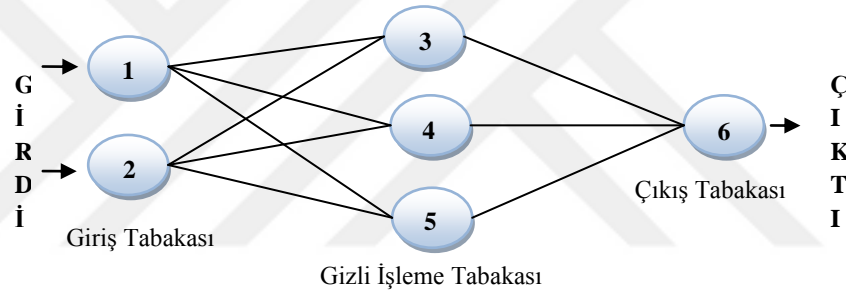
Karar ağaçları bilgiye ulaşmaktaki önemin artmasıyla gitgide daha popüler hale gelen güçlü bir sınıflandırma ve regresyon tekniğidir. Karar ağaçlarında birçok algoritma bulunmaktadır. Bu algoritmalar arasında en popülerleri arasında ID3, C4.5, C5.0, CART (Classification and Regression Tree), CHAID (Chi Squared Automatic Interaction Detector) ve QUEST (Quick Unbiased Efficient Statistical Tree) (Chaurasia ve Pal, 2013, s.211; Çalış vd., 2014, s.6; Gupta vd., 2017, s.16; Yavuz vd, 2017, s.184) algoritmaları sayılabilir.

3.7.1.2. Yapay Sinir Ağları

Yapay sinir ağları birçok alanda problem çözümü için kullanılan esnek yapıda güçlü yöntemlerden biridir. Diğer sınıflama yöntemlerine göre bağımlı değişkenler ve kestirimci değişkenler arasındaki doğrusal olmayan, karmaşık ilişkileri tespit edebilen (Irmak vd., 2012, s.103) yapay sinir ağları bir Makine Öğrenmesi tekniğidir. Ancak veri madenciliği kapsamına da girmektedir ve bu kapsamda veri madenciliğinin en etkili yöntemlerden birisidir (Özel ve Topsakal, 2014, s.47).

Doğal beyindeki sinir bağlantılarının karmaşık ağlarını taklit eden yapay sinir ağları (Raith vd.,2017, s.65), düğüm veya nöron adı verilen işlem elemanlarından oluşan (Kurt vd., 2017, s.101) denetimli bir makine öğrenme yöntemidir. Bu teknik bir katmanı takip eden nöronların diğer katmandaki nöronlara bağlanması ile oluşan bir tekniktir (Kaynar vd., 2017, s.5). Nöronlar arasındaki bağlantının ve bu bağlantıların ağırlıkları üzerine kurulu yapıdadır. Kurulan modelin karmaşıklığı bağlantının yapısına bağlıdır. Ancak oluşturulan modellerin yorumlanması genellikle zordur (Alagöz vd., 2014, s.9).

Şekil 3.3. 'te yapay sinir ağlarının genel yapısı görülmektedir.



Şekil 3.3. Yapay sinir ağları genel yapısı

Kaynak: Alagöz vd. (2014); Kaya ve Yıldız (2014)

Veri tabanlı sistemler olan Yapay Sinir Ağları modele ilişkin değişken tahminlerini, giriş-işlem-çıkış aşamalarına göre yapar. Dışarıdan girdileri alan nöronlardan oluşan giriş tabakası üzerindeki girdi değerleri üzerinde her hangi bir işlem uygulamaz. Bu tabaka girdi değerini bir sonraki tabaka olan gizli işleme tabakasına iletir. Gizli işleme tabakası birden çok tabakadan oluşur. Bu tabaka içerisindeki bir nöron işlemini yaptıktan sonra bir sonraki aşamadaki tabakanın nöronlarına tüm çıktıyı gönderir. Çıktıları dışarıya ileten nöronlardan oluşan çıktı tabakası ise tek tabakadan oluşur (Ataseven, 2013, s.103).

3.7.1.3. Destek Vektör Makineleri

Destek vektör makineleri; Vanpik (1998) tarafından önerilmiş, temel istatistiksel yöntemlere dayanan güçlü sınıflandırma ve regresyon yöntemlerindedir (Kaya ve Yıldız, 2014, s.92). Destek vektör makineleri; veri madenciliğinin karmaşık

sınıflandırma ve örüntü tanıma problemlerinin çözümünde etkin sonuçlar veren, dış bükey optimizasyonuna dayalı, yapısal risk minimizasyon ilkesine dayanan matematiksel algoritma tabanlı denetimli makine öğrenmesi algoritmalarından biridir (Ayhan ve Erdoğan, 2014, s.175-177; Cleophas ve Zwinderman, 2013, s. 155). Makine öğrenmesi algoritmaları, büyük ve karmaşık veri kümelerinde gizli kalıpları ortaya çıkarabilen, karar verme süreçlerinde sağlam istatistiksel bilgiler ortaya koyan algoritmalar (Biggio vd., 2012, s.1467).

Bu yöntemde amaç veri noktalarını en iyi sınıflandıran optimum düzlemin bulunmasıdır (Çetin ve Mikail, 2016, s.82). Destek vektör makineleri sisteme girilen eğitim verisini kullanarak örtük orijinal girdi alanını yüksek boyutlu bir özellik alanına haritalandırır. Daha sonra, özellik uzayında, sınıf sınırlarının kenar boşluklarını en üst düzeye çıkararak en uygun hiper düzlem belirlenir. Optimal hiper düzleme en yakın olan eğitim noktalarına destek vektörleri denir. Karar yüzeyi elde edildikten sonra, yeni verinin sınıflandırılması için kullanılır (Bui vd., 2012, s.7).

3.7.1.4. Bayes Sınıflandırıcılar

Veri madenciliğinin sınıflandırma yöntemlerinden olan bayes sınıflandırıcılar, temeli bayes teorisine dayanan belirli bir sınıfa dâhil edilme olasılığı ile sınıf üyeliğini tahmin eden istatistiksel sınıflandırıcılardır. Naive Bayes ve Bayes Ağları gibi çeşitli yöntemleri bulunan bu yöntem uygulama kolaylığı, hesaplama verimliliği ve gerçek veri problemlerinde iyi performans göstermesi nedeniyle popüler sınıflandırma algoritmaları arasındadır. Bu yöntemin bir diğer avantajı örüntü oluştururken ve değerlendirirken hızlı çalışması ve birçok alana uyarlanabilmesidir. Literatür incelendiğinde, çoğunlukla görüntü işleme ve metin madenciliğinin de kullanılmaktadır (Kabakchieva, 2013, s.67; Olgun ve Özdemir, 2012, s.304).

Bayes sınıflandırıcılar, birden çok etken faktörün olduğu bir olayın oluşmasında, hangi faktörün etki payının daha yüksek olduğunun hesaplanması esasına dayanır (Kaya ve Yıldız, 2014, s.92). Evrensel doğrular ve gözlemler kullanarak bir durumun modelini oluşturmayı ve sonuçlar üretmeyi amaçlar. Kesinlik

içermeyen bir durumun tahmininde gözlemleri ve sübjektif değerleri kullanır (Akar ve Gündoğdu, 2014, s.9).

3.7.1.5. K-en Yakın Komşu

Parametrik olmayan eğitilmiş öğrenme algoritmalarından olan k-en yakın komşu algoritması (Filiz vd., 2017, s.233), yakınlık arama, benzerlik arama veya en yakın nokta arama olarak bilinen en yakın komşu arama ve en yakın (veya en benzeri) noktaları bulmak için bir optimizasyon problemidir (Sani, 2018, s.106). Bu teknik sınıflandırma için kullanılan bir teknik olup sistemin işleyişi için eğitim verisi bulunmaktadır. Böylece sınıfı bilinmeyen veri, eğitim verisinde bulunan sınıfa göre atanır. Bu yaklaşım benzer özellikli verinin aynı sınıfta yer alması gerektiği temeline dayanır. Bu sebeple veri arasındaki benzerlik, uygun uzaklık fonksiyonları ile ölçülür (Çetin ve Mikail, 2016, s.80).

Literatürde k-NN algoritması olarak da bilinen bu yöntem öğrenme verisinde belirlenen sayısal sınıflara yeni bir sayısal gözlem girildiğinde bu yeni gözlemin en yakın komşularını bulur ve yeni gözlemin sınıfını belirler (Yukselturk vd., 2014, s.124). Örnek tabanlı bir sınıflandırıcı olan k-en yakın komşu algoritması az parametre ile etkin sonuçlar elde edebilen basit yapıya sahip bir tekniktir (Onan ve Korukoğlu, 2016).

3.7.1.6. Lojistik Regresyon

Çok değişkenli yöntemlerden biri olan lojistik regresyon yöntemi, bağımlı değişkenin ikili, üçlü, daha çok olduğu ve kategorik olması durumlarında, bağımlı değişkenin bağımsız değişkenle sebep-sonuç ilişkisini tespit etmek ve sınıflandırma yapmak için kullanılan istatistiksel bir tekniktir (Kaygın vd., 2016, s.150; Çırak ve Çoklu, 2013, s.73).

Bu teknikte amaç bağımlı ve bağımsız değişkenler arasındaki ilişkiyi tanımlarken en az değişkeni kullanarak en iyi uyuma sahip, istatistiksel olarak kabul edilebilir bir model kurmaktır. Veri madenciliğinin sınıflandırma tekniklerinden olan

lojistik regresyon tekniği kolay uygulanma ve anlaşılabilirliği nedeni ile sosyal bilimler (Güner, 2014, s.56), biyoloji, sağlık, tarım, ekonomi gibi alanlarda sıklıkla kullanılan bir yöntemdir.

Bağımlı ve bağımsız değişken arasındaki ilişki $y = f(x)$ gibi basit bir fonksiyon (y =bağımlı değişken, x =bağımsız değişken) ile temsil edilir. Bu fonksiyona göre x değişkeninin değeri biliniyorsa y değişkeninin değeri logaritmik olarak belli bir hata değeri ile tahmin edilebilir. Bu teknik aşağıdaki lojistik kümülâtif dağılım fonksiyonunu kullanır (Ekmekçi vd., 2016, s.614).

$$y = f(x) = \frac{1}{1 + e^{-z}} \quad (3.1.)$$

Burada z fayda fonksiyonunu tanımlar.

$$z = (\beta_0 + \beta_1x_1 + \beta_2x_2 + \dots + \beta_nx_n) + e \quad (3.2.)$$

Burada, β_0 sabiti, $\beta_1 \dots \beta_n$ ise n teriminin her biri için regresyon katsayı ağırlıklarındır. Her bir ölçüm için her tahmin değişkeni $x_1 \dots x_n$ ile temsil edilir, n veri kümesi içerisindeki bağımsız değişken sayısı, e terimi ise modelin hata değeridir (Terrell ve Mutlu, 2012, s.284).

Lojistik regresyonun inceleyebileceği veri madenciliği problem türleri şu şekildedir (Veri Bilimcisi, 2018):

- Bir kişinin akciğer kanseri olma ihtimali kilosu ve 1 günde içilen sigara adedi ile ilişkili mi?
- Yaş, kilo, kalori ve yağ alımı kalp krizi geçirmede etkili mi?

3.7.2. Zaman Serileri Analizi

Bir zaman serisi, zaman içindeki sıralı ölçümlerden elde edilen değerler topluluğunu temsil eder. Zaman serisi verileri, borsa günlük dalgalanmaları, bilimsel deneyler, tıbbi ve biyolojik deneysel gözlemler, sosyal ağlardan elde edilen çeşitli veriler, konum güncellemeleri gibi hemen hemen her uygulama alanından benzeri

görülmemiş bir ölçekte ve oranda üretilmektedir. Bu sebeple son dönemlerde bu tür verileri sorgulama ve inceleme konusundaki ilgi de fazlasıyla artmaktadır. Günümüzde zaman serileri analizi, çeşitli araştırma alanlarındaki ekonomik tahminler, saldırı tespitleri, gen analizleri, tıbbi gözetim analizleri gibi gerçek yaşam problemlerinin çözümünde kullanılmaktadır (Esling ve Agon, 2012, s.13-14; Wang vd., 2013, s.276).

Zaman serisi analizinde verilerin zamana bağlı olarak değişimleri incelenmektedir. Bu analiz hareketli ortalama, göreceli güç endeksi, momentum ve değişim oranı gibi yöntemlerle, verinin zaman üzerindeki farklılıklarını tespit edip aykırı değerleri yakalamak, zamana bağlı olarak değişen olaylarda gerçekleşmesi muhtemel olayları tahmin etmek, eksik verileri tamamlamak ve aykırı değerlerdeki hataları düzeltmek amacıyla kullanılabilir (Seker, 2015b, s. 24-30).

3.7.3. Kümeleme

Kümeleme heterojen kayıtlardan oluşan bir veri setini, denetimli ve denetimsiz öğrenme benzerlik ölçütlerine dayalı olarak verinin doğasına göre homojen gruplara ayıran bir veri madenciliği tekniğidir (Ghoson, 2010, s.59). Kümeleme analizi veriye dair anlamlı bir bakış açısı kazanmak için gözlemleri birbirinden farklı kümelere ayırmayı amaçlayan makine öğrenme tekniğidir (Mago vd., 2018, s.345). Kümeleme analizi sonucunda aynı küme içindeki gözlemler; farklı kümelere atanan gözlemlere göre daha ilişkilidir (Wu vd., 2018, s.103).

Kümeleme analizinde sınıflandırma analizlerinden farklı olarak sınıf değeri ilk başta bilinmemektedir. Bu teknikle ham veri setine ait gruplanmamış gözlemler, uzaklık veya benzerlik ölçütü kullanılarak kümelere ayrılır. Oluşturulan kümelere isim verilerek gözlemler sınıf değerlerine atanır. Kümeleme sonucunda küme içi benzerliğin ve kümeler arası farklılığın yüksek olması, kümelemenin başarılı sonuçlar ürettiğini gösterir (Bilen vd., 2014, s.82; Gülen ve Özdemir, 2013, s.217).

Veri madenciliğinde veriyi kümelemek için yaygın olarak kullanılan bazı teknikler şunlardır: K-Means, K-Medoids, Bulanık C-Ortalamlar, Kohonen Ağları, Hiyerarşik Kümeleme.

3.7.3.1. K-Means

1967'de J. B. Macqueen tarafından ilk kez yayınlanank-means algoritması, kümeleme algoritmaları içinde yaygın olarak kullanılan en popüler algoritmalarından biridir (Bargavi, 2017, s.169; Ghoson, 2010, s.60).

Nesneler arasındaki uzaklığa dayalı tipik bir kümeleme algoritmasıdır ve mesafeler arasındaki benzerlik ölçüsüne dayanır (Wu vd., 2018, s.103).

Nesneler arasındaki mesafe uzaklığı aşağıdaki Öklid uzaklığı formülü ile hesaplanır (Joyendri, 2017, s.78):

$$d_{ij} = \sum_{k=1}^p \{x_{ik} - x_{jk}\}^2 \quad (3.3.)$$

Burada d_{ij} = nesnenin ile j arasındaki mesafesini, p= verinin boyutunu, x_{ik} = Boyut k için cisim i'nin koordinatı, x_{jk} =k boyutunda j nesnesinin koordinatını temsil eder.

Bu algoritma random seçilen k adet merkez nokta ile başlar. Veri setindeki her bir nokta kendisine en yakın olan merkez noktaya ait kümeye atanır. Merkez değeri, kendine ait olan noktaların ortalaması alınarak hesap edilir. Bu işlem merkez değeri değişmeyene kadar tekrar edilir. Merkez değerinde bir hareketlenme olmadığında işlem sonlandırılır (Sarıman, 2011, s.195).

Bu algoritmanın düşük miktarda saklama kapasitesiyle çalışabilmesi ve yüksek kapsama hızı gibi bazı avantajları mevcut iken; küme sayısına kullanıcının karar vermesi, kaç adet kümeye ayrılacağı kararının verilmesindeki zorluk, nesnelerin keskin olarak belli bir kümeye ait olması durumu gibi bazı dezavantajları da bulunmaktadır.

3.7.3.2. K-Medoids

K-Medoids algoritması, istatistiksel analizde en iyi bilinen bölme tabanlı kümeleme yöntemlerinden biridir. Bu yöntem gerçek veri setlerindeki gürültülü veriye karşı dayanıklıdır ve daha önce herhangi bir sınıflandırma bilgisi bulunmayan verinin bölümlendirilmesinde kullanılabilir (Modak, 2018, s.3). Veri setindeki nesnelerin çeşitli yapısal özelliklerine göre medoid olarak adlandırılan k adet temsilci nesneyi bulma esasına dayanan bir tekniktir. Medoid (temsilci nesne) kümedeki tüm nesnelerin en merkezi konumudur (Hamzaoui vd.,2018, s.4).

Bu algoritma aşağıdaki adımları temel alarak veri setini kümelere ayırır (Khalvati vd., 2018, s.159):

1. **Adım:** İlk kümeler için rastgele n adet örnekten k adet medoid seçer.
2. **Adım:** İlk kümeleri oluşturmak için her bir veri örneğini en yakın medoide atar.
3. **Adım:** Her kümenin en merkez noktasını bulur.
4. **Adım:** Her bir veriyi, önceki adımda seçilen en yakın medoide yeniden atar ve 3 adıma küme üyeliği sabitlene kadar geri döner.

Algoritmada hareketlenme sabitlendiğinde kümeleme işlemi de tamamlanmış olur.

3.7.3.3. Bulanık C-Ortalamlar

Bulanık C-Ortalamlar algoritması, 1973'te Dunn tarafından ortaya atılmış, 1981'de ise Bezdek tarafından geliştirilmiş bir algoritmadır.

Bulanık C-Ortalamlar uygulanması kolay, büyük verileri kümeleyebilme, her bir veri noktasının tam olarak bir küme veya birden çok küme içerisine yerleştirebilme gibi avantajları olan, geleneksel kümeleme yaklaşımlarından farklı olarak kararlılık oranları açısından daha iyi çıkışa ve yüksek sınıflandırma testi verimliliğine sahip (Anamisa vd., 2018, s.2), hızlı ve iyi sonuçlar üreten gözetimsiz bir kümeleme yöntemidir (Zare ve Koch, 2018, s.65).

Bu teknik, veri noktaları arasındaki mesafeye dayalı analiz için kullanılır. Kümeler, veri noktaları arasındaki mesafeye göre oluşur ve her küme için küme merkezleri oluşturulur. Bir veri kümesi, her küme için veri kümesindeki merkez noktasına sahip n adet kümeye gruplanır ve her veri gruplandığı küme içindeki nesnelere yüksek düzeyde benzerdir (Ghosh ve Dubey, 2013, s.36).

Bulanık C-Ortalamlar için gerekli adımlar şu şekildedir (Erilli, 2014, s.37; Ghosh ve Dubey, 2013, s.36):

1. **Adım:** Başlangıç değerlerinin belirlenmesi: c='küme sayısı', m='bulanıklık indeksi', ϵ ='işlem bitirme kriteri' ve U='üyelik dereceleri matrisi' veya V='küme prototipleri' random olarak üretilir.
2. **Adım:** U küme prototiplerinin random olarak üretildiği varsayılır ise bu değerler ile üyelik dereceleri matrisi hesaplanabilir.

$$u_{ik} = \left[\sum_{j=1}^c \left(\frac{d_{ji}}{d_{jk}} \right)^{2/(m-1)} \right]^{-1} \quad (3.4.)$$

3. **Adım:** U küme prototipleri Adım 2 eşitliğine göre güncellenir.
4. **Adım:** $\|U^{(t)} - U^{(t-1)}\| \leq \epsilon$ ise algoritma durdurulur, değilse Adım 2 tekrarlanır.

Algoritma uygulandıktan sonra hangi nesnenin hangi kümeye gireceğine üyelik dereceleri kullanılarak karar verilir. Her nesne için küme üyeliği en yüksek olan kümeye o nesne dâhil edilir. Bir nesne birden çok kümeye dâhil edilebilir (Erilli, 2014, s.37).

3.7.3.4. Kohonen Ağları

1981'de Teuvo Kohonen tarafından geliştirilmiş kohonen ağları, (Kohonen, 2013, s.52) diğer adı ile KDH (Kendini Düzenleyen Haritalama), yapay sinir ağlarının bir türüdür. Çok boyutlu verinin tek veya iki boyutlu uzayda görsel sunumu amaçlanarak ortaya atılan bu teknik;kümeleme, sınıflandırma, görselleştirme ve soyutlama gibi görevler için geliştirilmiştir (Bikari vd., 2017, s.149).

Veri setinde bilinmeyen örüntülerin ortaya çıkartılmasında kullanılan, geniş uygulama alanına sahip veri madenciliği yöntemlerinden biridir. KDH, büyük ölçekli veri setlerindeki doğal küme sayısını bulmada başarılı, denetimsiz iki katmanlı, giriş ve çıkış nöronlarından oluşan özel yapay sinir ağıdır. Bu teknikte veri setindeki değişken sayısı, giriş nöronlarının sayısını belirler. Çıkış nöronlarının her biri ise bir kümeyi simgeler. Çıkış katmanındaki nöronların dizilimi topolojik komşuluk açısından önemlidir. Deneme – yanılma yoluyla karar verilen dizilim doğrusal, altıgen, küp veya dikdörtgensel biçiminde olabilir. Uygulamada en çok dikdörtgensel ve altıgen dizilimler tercih edilmektedir (Taşkın ve Emel, 2010, s.400; Özçalıcı, 2016, s.24).

Rekabetçi öğrenme kuralı kullanan ağ yapısı ile KDH, girdi özelliklerinin belirlenmesi temel işlevine dayanır ve aşağıdaki algoritmayı kullanır (Tezbaşaran, 2016, s.146):

$$w_c(t + 1) = w_c(t) + \alpha(t)[x_i(t) - w_c(t)] \text{ Eğer } x \text{ doğru sınıflandırılmış ise,}$$

$$w_c(t + 1) = w_c(t) - \alpha(t)[x_i(t) - w_c(t)] \text{ Eğer } x \text{ yanlış sınıflandırılmış ise,}$$

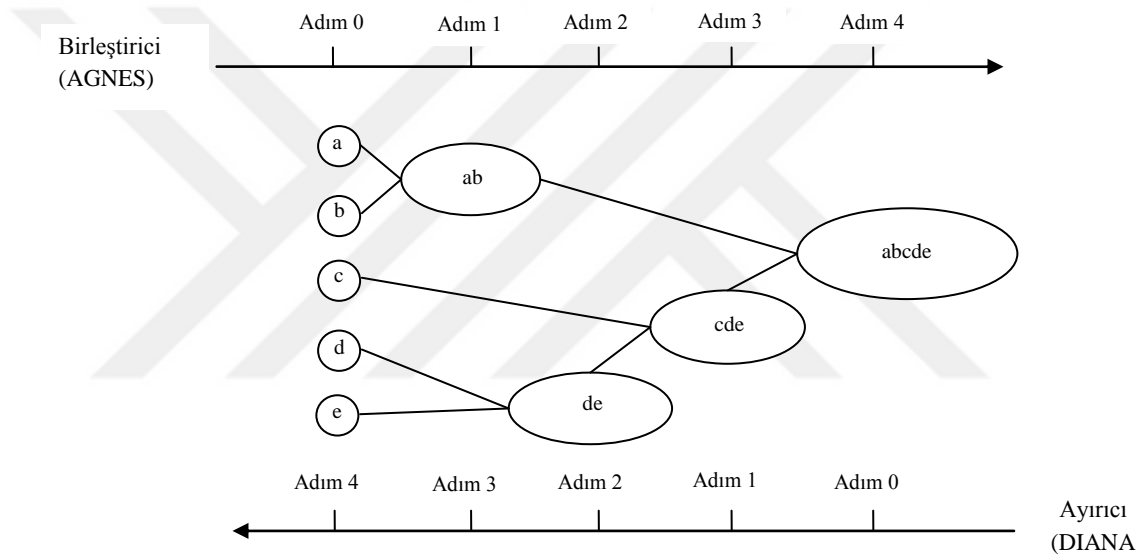
$$w_i(t + 1) = w_i(t) \quad \text{Eğer } i \neq c$$

Algoritmada eğitim girdi vektörlerinin ($x_i(t)$), c kümelerine sınıflandırılması ağırlık yenilenmesi ($w_c(t + 1)$) koşulu olarak formüllendirilir. $\alpha(t)$ her adımda azalan scalar bir değerdir ve genellikle 0.01 veya 0.02 başlangıç değerleridir (Tezbaşaran, 2016, s.146).

3.7.3.5. Hiyerarşik Kümeleme

Kümeleme analizleri içerisinde yaygın olarak kullanılan hiyerarşik (aşamalı) kümeleme, parametrelerin belirsiz olduğu, kaç küme oluşturulacağına bilinmediği durumlarda aşağıdan yukarıya veya yukarıdan aşağıya doğru (Seker, 2015a, s.32), küme ağacı şeklinde ayırma esasına dayanmaktadır. Hiyerarşik kümeleme algoritmalarında bir nesne belli bir kümeye atandıktan sonra başka bir kümeye dâhil olamaz (Bilen vd., 2014, s.82).

Bu teknik, küme birimlerini birbirleri ile farklı aşamalarda bir araya getirip ardışık kümeler oluşturmayı ve oluşan bu kümelere dâhil olacak verilerin hangi uzaklık veya benzerlik seviyesinde olduğunu tespit etmeye yarayan bir algoritmadır. Hiyerarşik kümeleme algoritmalarında Şekil 3.4.'te görünen dendrogram adı da verilen öbek ağaçlarından yararlanır. Birleştirici (AGNES - Agglomerative Nesting) ve ayırıcı (DIANA - Divisive Analysis) hiyerarşik kümeleme olmak üzere 2 genel yöntem mevcuttur.



Şekil 3.4. Birleştirici ve ayırıcı hiyerarşik kümeleme
Kaynak: Selvi ve Çağlar (2017)

Kaufmann ve Rousseeuw (1990) tarafından ortaya atılan birleştirici kümeleme tekniği verileri kümelemek için aşağıdan yukarıya doğru çalışan bir yöntemdir. Şekil 3.4.'ten de anlaşılacağı üzere birleştirici kümeleme yönteminde 0. adımda veri kümesindeki her nesne bir küme olarak kabul edilmektedir. Daha sonra birbirine en yakın iki nesne yeni bir küme olarak birleştirilir. Her aşamada gözlem sayısı azalmaktadır (Özbek ve Atik, 2013, s.197). Nesnelere arasındaki benzerlikler belirlenirken Öklid veya Manhattan uzaklık formülleri kullanılabilir.

Ayırıcı hiyerarşik kümeleme yukarıdan aşağıya doğru (Kovaleva ve Mirkin, 2005, s.416) çalışan bir strateji izler. Bu teknik Şekil 3.4.'ten de anlaşılacağı üzere 0.

adımında veri setinde bulunan nesnelerin tümü bir küme olarak kabul edilir. Sonraki her adımda kendi aralarında benzer olan nesneler bir araya getirilerek kümeler oluşturulur. Algoritmanın her adımında kümeler daha küçük kümelere bölünür (Selvi ve Çağlar, 2017, s.418). Bu işlem homojen kümeler elde edilene kadar devam eder.

3.7.4. Birliktelik Kuralları ve Ardışık Zamanlı Örüntüler

Veri madenciliğinin en önemli konularından bir tanesi birliktelik kuralları ve ardışık zamanlı örüntülerdir. Veri tabanlarında bir arada sık olarak görülen ilişkilerin ortaya çıkartılmasını ve her verinin diğer veri ile bağlantısının büyüklüğünü açıklamayı sağlayan bu teknik, çoğunlukla pazarlama amaçlı olarak veri madenciliğinde sıkça kullanılmaktadır. Çıkarttığı kurallar dolayısıyla müşteri davranışlarını tanımlamada etkili olan bu tekniğin en önemli uygulama alanları arasında katalog ve yerleşim düzeni tasarımı, pazar sepet analizi, promosyon analizleri, çapraz pazarlama bulunmaktadır (Doğan, 2017, s.931; Doğan vd., 2014, s.107; Erpolat, 2012, s.138).

Birliktelik kuralları eş zamanlı olarak gerçekleşen olaylar arasındaki ilişkileri tanımlarken, ardışık zamanlı örüntüler birbiri ile ilişkisi olan; fakat birbirini takip eden dönemlerde gerçekleşen olaylar arasındaki ilişkileri tanımlar (Çankırı vd. 2009).

Birliktelik kurallarında tespit edilebilecek bazı uygulama örnekleri şöyledir:

- A kitabını ödünç alan öğrenci B kitabını da ödünç alır.
- Makarna satın alan müşteriler ketçap da satın alır.

Ardışık zamanlı örüntüler tekniğiyle tespit edilebilecek bazı uygulama örnekleri şöyledir:

- C tatilini rezervasyon yapan bir müşteri 5 gün içerisinde D turuna da katılır.
- X hastalığına yakalanan bir hasta 1 yıl içinde Y hastalığına da yakalanır.

Birliktelik kural çıkarımında kullanılan bazı algoritmalar bulunmaktadır. Birliktelik kuralları öğeler arasındaki destek ve güven kriterleri ile hesaplanmaktadır (Karabatak ve İnce, 2012, s.1). A durumu meydana geldiğinde B durumunun da meydana gelme olasılığını ($A \Rightarrow B$) bulan birliktelik kuralları iki durum arasındaki ilişkiyi tespit eder. Birliktelik kural desteği ve güveni aşağıdaki formüller ile hesaplanır (Doğrul vd., 2015, s.270; Doğan 2014, s.107):

$$\text{Kural desteği } (s) (A \Rightarrow B) = \frac{n(A \cup B)}{n(N)} \quad (3.5.)$$

Formüle göre kural desteği (s), $A \cup B$ 'yi (A ve B'nin bir arada yer aldığı kayıtların sayısı) kapsayan öğe sayısının, veri tabanındaki toplam öğe sayısına (N) oranıdır.

$$\text{Güven } (\alpha) (A \Rightarrow B) = \frac{n(A \cup B)}{n(A)} \quad (3.6.)$$

Formüle göre güven (α), $A \cup B$ 'yi (A ve B'nin bir arada yer aldığı kayıtların sayısı) kapsayan öğe sayısının A kümesini kapsayan öğe sayısına oranıdır.

Birliktelik analizinde kullanılan bazı algoritmaları Apriori, Predictive Apriori, FPGrowth, Filtered Associator, Generalized Sequential Patterns, Tertius (Doğan, 2015, s.53), Eclat ve Frequent pattern biçiminde sıralamak mümkündür.

3.7.4.1. Apriori Algoritması

Apriori algoritması veri madenciliğinde birliktelik kuralı çıkarımı için yaygın biçimde kullanılan, 1994 yılında Agrawal ve Srikant tarafından geliştirilmiş bir algoritmadır. Algoritmanın temel yaklaşımı eğer k-öge kümesi minimum destek kriterini sağlıyorsa, kümenin alt kümeleri de sağlar şeklindedir. Öge kümesi, 1 yâda daha çok elemandan oluşan küme, k-öge kümesi içinde k tane öge bulunan kümedir (Yalçın vd., 2013, s.115).

Apriori algoritması veri setindeki (k+1) satırı araştırmak için düz bir arama olarak bilinen yinelemeli bir yaklaşımı kullanır. İlk olarak 1-öge kümesi, her bir

öğenin minimum destek kriterini sağlayan öğelerini toplamak için veri tabanını tarar, Ortaya çıkan set L1 olarak adlandırılır. Daha sonra 2-öğe kümesi bulmak için L1'i kullanır ve L2 olarak adlandırılır. L3'ü bulmak içinse L2'yi kullanır. Her Lk'nın bulunması için veri tabanı taranır. Süreç sık geçen öğe kümesi bulunmadığında sonlanır (Singh vd. 2013, s.1).

Apriori algoritması genellikle alışveriş uygulamalarında kullanılması sebebiyle sıklıkla market sepet analizi olarak bilinmektedir. Bir veri kümesi içerisindeki nesnelerin birbirleri ile ilişkisi destek ve güven değerleri ile hesaplanır. Destek bir veri kümesi içinde ilişkinin ne kadar sık olduğunu, güven ise A nesnesini almış bir kişinin hangi olasılıkla B nesnesini de alacağını ifade etmektedir. Destek ve güven kriterlerinin her biri ne kadar büyükse ilişkide o kadar büyük demektir (Özseven ve Dügenci, 2011, s.64). Destek ve güven kriterleri aşağıdaki denklemler ile hesaplanır (Yalçın vd.,2013, s.115):

$$Destek (A) = \frac{A \text{ öğe kümesi sayısı}}{Toplam \text{ öğe küme sayısı}} \quad (3.7.)$$

$$Destek (A,B) = \frac{(A,B) \text{ öğe küme sayısı}}{Toplam \text{ öğe küme sayısı}} \quad (3.8.)$$

$$Güven (A,B) = \frac{(A,B) \text{ öğe küme sayısı}}{A \text{ Öğe küme sayısı}} \quad (3.9.)$$

$$Güven (A,B) = \frac{Destek (A,B)}{Destek (A)} \quad (3.10.)$$

A ve B birbirinden farklı nesneler için, A için destek (1) A'yı kapsayan tüm öğe kümelerinin toplam öğe küme sayısına oranıdır. A ve B nesneleri için destek (2) tüm öğe kümeleri içerisinde bu iki nesnenin birlikte bulunma olasılığıdır. B nesnesinin hangi olasılıkla A öğe kümeleri içerisinde olacağı, yani güven değeri ise (3) veya (4) formüllerinden biri ile hesaplanır.

A nesnesini alan bir kişi aynı zamanda B nesnesini de alıyorsa bu durumun birliktelik kuralı ile gösterimi: $A \Rightarrow B$ [destek=%10, güven=%85] biçimindedir. Destek kuralın kullanışlığını güven ise doğruluğunu ifade etmektedir.

4. BÖLÜM VERİ MADENCİLİĞİ İLE KÜTÜPHANE KULLANIMI VE DERS BAŞARISI ARASINDAKİ İLİŞKİNİN İNCELENMESİ

Bu bölümde araştırmanın amacı, önemi, kapsamı, sınırlılıkları ve yöntemine değinilmiştir. Ardından uygulama sürecine ait bilgilere, analiz sonucunda elde edilen bulgulara ve yorumlara yer verilmiştir.

4.1. Araştırmanın Amacı ve Önemi

Bu araştırmanın amacı, Uşak Üniversitesi İİBF İşletme bölümü öğrencilerinin 2007 – 2018 yıllarını kapsayan güz ve bahar akademik dönemlerinde kütüphaneden ödünç almış olduğu zorunlu ders içerikli kitaplar ile 2007 – 2018 yıllarını kapsayan güz ve bahar akademik dönemlerinde zorunlu derslerden almış oldukları harf notu ve başarı durumları arasındaki ilişkiyi veri madenciliği birliktelik analizi ile tespit etmektir. Çalışma sonucunda elde edilen sonuçların Uşak Üniversitesi öğretim üyeleri ve kütüphane personeline karar verme aşamalarında yol göstermesi hedeflenerek yeni bir kaynak olması amaçlanmıştır.

Gerçekleştirilen bu araştırma çalışması, üniversite mevcut kaynaklarında, ders başarı durumları ile kütüphane ödünç kitap bilgilerini birleştirerek analiz eden bir sistemin mevcut olmayışı ve bu açığı kapatacak alternatif bir çözümün sunulması nedeniyle özgün yapıdadır. Çalışma ilerleyen dönemlerde iki sistemi birbirine bağlayan bir otomasyon sisteminin yazılabilmesi açısından örnek niteliğindedir.

4.2. Araştırmanın Kapsamı ve Sınırlılıkları

Araştırma Uşak Üniversitesi Merkez Kütüphanesi İİBF işletme bölümü öğrencilerinin 2007-2018 yılları arasındaki güz ve bahar dönemlerinde kütüphaneden ödünç almış oldukları zorunlu ders içerikli kitap verisi ile öğrencilerin 2007-2018 yılları arasında güz ve bahar dönemlerindeki ders başarıları ve ders geçme-kalma durum verileri arasındaki ilişkiyi kapsamaktadır. Uşak Üniversitesi 2006 yılında kurulmuş bir üniversitedir; ancak kütüphane verisi 2007 yılı itibarıyla elektronik

ortama kayıt edilmiştir. 2007 yılı öncesi kütüphane verisine ulaşılamaması sebebiyle araştırmada 2007-2018 yılları üzerine odaklanılmıştır.

Çalışma Uşak Üniversitesinin İİBF İşletme bölümü öğrencilerinin eğitim-öğretim dönemlerinin tamamında almış oldukları zorunlu dersler ve bu derslere ait ödünç alınan kitaplar üzerinden gerçekleştirilmiştir. Bu kapsamda öğrencilerin almış oldukları 37 adet zorunlu ders bulunmaktadır. Fakat araştırmaya tüm zorunlu dersler dâhil edilmemiş olup yalnızca 17 âdeti dâhil edilmiştir. Bunun sebebi, veri madenciliğinin uygulanabilmesi için yeterli sayıda ham verinin bulunduğu derslerin dâhil edilmesi gerekliliğidir. Böylece analizde daha çok veri kullanarak sağlıklı sonuçlar elde edilebilmiştir. Bu kapsamda aşağıda öğrencilerin almış oldukları zorunlu dersler ve araştırma da kullanılan zorunlu dersler listelenmiştir.

Tablo 4.1. Zorunlu Ders Toplamları ve Analize Tabi Tutulan Dersler

1.Sınıf Zorunlu Dersleri	Genel İşletme I, Genel İşletme II, İktisada Giriş I, İşletme Matematiği I, İşletme Matematiği II, Genel Muhasebe I, Genel Muhasebe II, Borçlar Hukuku, Temel Bilgi Teknolojisi, Türk Dili I, Türk Dili II, Yabancı Dil Dersleri I, Yabancı Dil Dersleri II, Atatürk İlkeleri ve İnkılâp Tarihi I, Atatürk İlkeleri ve İnkılâp Tarihi II.
Analiz Edilen 1. Sınıf Zorunlu Dersleri	Genel İşletme I, Genel İşletme II, İktisada Giriş I, Genel Muhasebe I, Genel Muhasebe II.
2. Sınıf Zorunlu Dersleri	Makro İktisat, İşletme Yönetimi, Örgüt Teorisi, Davranış Bilimleri, Pazarlama İlkeleri, Kamu Maliyesi, İstatistik I, İstatistik II, Sosyal Bilimlerde Araştırma Yöntemleri, Ticaret Hukuku, Yabancı Dilde Dinleme ve Konuşma.
Analiz Edilen 2. Sınıf Zorunlu Dersleri	Makro İktisat, İşletme Yönetimi, Davranış Bilimleri, Pazarlama İlkeleri, Sosyal Bilimlerde Araştırma Yöntemleri.
3. Sınıf Zorunlu Dersleri	Örgütsel Davranış, İnsan Kaynakları Yönetimi, Stratejik Yönetim ve İşletme Politikası, Maliyet Muhasebesi, Finansal Yönetim I, Sayısal Yöntemler.
Analiz Edilen 3. Sınıf Zorunlu Dersleri	Örgütsel Davranış, İnsan Kaynakları Yönetimi, Stratejik Yönetim ve İşletme Politikası, Maliyet Muhasebesi, Finansal Yönetim I.
4.Sınıf Zorunlu Dersleri	Mali Tablolar Analizi, Muhasebe Uygulamaları, Yatırım Proje Değerleme, Hakla İlişkiler.
Analiz Edilen 4. Sınıf Zorunlu Dersleri	Mali Tablolar Analizi, Muhasebe Uygulamaları.

Tablo 4.1.'de görüldüğü üzere 1. Sınıf zorunlu dersleri 15 adet olup araştırmada Genel İşletme I, Genel İşletme II, İktisada Giriş I, Genel Muhasebe I, Genel Muhasebe II dersleri analiz edilmiştir. 2. sınıf zorunlu dersleri ise 11 adet olup araştırmada Makro İktisat, İşletme Yönetimi, Davranış Bilimleri, Pazarlama İlkeleri, Sosyal Bilimlerde Araştırma Yöntemleri dersleri analiz edilmiştir. 3. sınıf zorunlu dersleri 6 adet olup araştırmada Örgütsel Davranış, İnsan Kaynakları Yönetimi, Stratejik Yönetim ve İşletme Politikası, Maliyet Muhasebesi, Finansal Yönetim I dersleri analiz edilmiştir. 4. sınıf dersleri ise 4 adet olup Mali Tablolar Analizi, Muhasebe Uygulamaları dersleri analiz edilmiştir.

Ders içeriği ile ödünç alınan kitap içeriğinin aynı olması önemlidir. Alınan kitapla ders içeriğinin aynı olması için uzman görüşü alınmış ve öğrencilerin ödünç almış oldukları kitaplar incelenmiştir. Hangi kitabın hangi ders ile aynı içeriğe sahip olduğu tespit edilmiş ve analiz bu doğrultuda yapılmıştır.

Araştırmada kullanılan veriler yalnızca İİBF İşletme bölümü öğrencilerine aittir; dolayısıyla araştırmanın üniversitenin tamamında genelleştirilebilir olması ve karşılaştırma yapılabilmesi için kütüphane ve öğrenci verisinin tüm üniversiteyi kapsamaması gerekmektedir. Ancak analiz için yalnızca İİBF İşletme bölümü öğrencilerine ait veriye ulaşılabilmektedir. Bu durum araştırmayı üniversitenin tamamına genellemeyi engellemektedir. Kütüphane kullanımı ile ilgili turnike verisinin sistemde kayıtlı olmayışı yani öğrencinin kitabı ödünç almaksızın kütüphane içinde yararlanmış olmasına dair verinin kayıtlı olmayışı araştırmanın kısıtlarından biridir. Ayrıca öğrenci başarısında kütüphane kullanımından başka birçok faktörün de ders başarısına katkıda bulunması ve bu faktörlerin verisine ulaşamaması da araştırma sınırlılığıdır.

4.3. Araştırma Yöntemi

Araştırmada veri tabanından bilgi keşfi sürecinin tüm adımları uygulanmıştır. Sürecin en önemli adımı büyük ölçekli veri yığınlarını istatistiksel olarak analiz etmede yardımcı veri işleme tekniği olan veri madenciliğidir. Araştırmaya veri

madenciliği yöntemi; veri madenciliği yazılımlarından biri olan WEKA yazılımı ile uygulanmıştır. WEKA; açık kaynak kodlu ve kullanımı kolay bir veri madenciliği yazılımı olması, ayrıca araştırmanın iskelet yapısını oluşturan birliktelik analizlerinden Apriori algoritmasının yazılım içerisinde mevcut olması nedeniyle tercih edilmiştir. Apriori algoritması birliktelik kuralları içerisinde en çok bilinen kullanımı yaygın bir algoritmadır. Ayrıca WEKA; birçok akademik çalışmada ve çeşitli alanlarda kullanılan, hızlı ve güvenilir sonuçlar üreten, sonuçları kolay yorumlanan bir yazılımdır.

Ham veriler genellikle karmaşık yapıdadır. Bu sebeple eldeki veri WEKA yazılımında analiz edilmeden önce veri ön işlemden geçirilmiştir. Veri ön işlem için kullanılan yöntem ise MS Access veri tabanında hazırlanmış SQL sorgularıdır. MS Access, Microsoft tarafından geliştirilmiş bir programdır ve veriyi depolama, silme, listeleme vb. işlemlerin SQL soruları ile kolaylıkla yapılabilmesi nedeniyle bu yöntem tercih edilmiştir.

4.4. Uygulama Süreci

Uygulama sürecinde veri tabanından bilgi keşfi sürecinin adımları gerçekleştirilmiştir. Süreç; problemin tanımlanması, araştırma analizine uygun veri seçimi, seçilen verinin ön işlemden geçirilmesi, ön işlemden geçirilmiş ve analize uygun duruma getirilmiş veriye veri madenciliğinin uygulanması, araştırma bulgularının sunumu ve yorumu biçimindedir. Aşağıdaki bölümlerde, gerçekleştirilen uygulama sürecinin adımları açıklanmıştır.

4.4.1. Problemin Tanımlanması

Problemin tanımlanması sürecin en önemli adımlarından biridir; çünkü tanımlanan problem sürecin tüm adımlarını etkileyecektir. Veri madenciliği çalışmalarında başarılı olabilmek için problemin açık bir dille tanımlanması önemlidir. Araştırma kapsamında araştırma amacına uygun olarak 2 adet problem cümlesi tanımlanmıştır. Bu bağlamda cevap aranan araştırma problemleri aşağıdaki gibidir.

Araştırma Problemi 1: İİBF İşletme bölümü öğrencilerinin kütüphaneden ödünç aldıkları zorunlu ders içerikli kitap kullanımı ile o derse ait ‘geçti’ - ‘kaldı’ durumu arasındaki ilişki nedir?

Araştırma Problemi 2: İİBF İşletme bölümü öğrencilerinin kütüphaneden ödünç aldıkları zorunlu ders içerikli kitap kullanımı ile o derse ait harf notu arasındaki ilişki nedir?

4.4.2. Veri Seçimi

Araştırmanın bir diğer aşaması veri seçimidir. Uygulamada kullanılan veri araştırma amacına ve tanımlanan problemlere uygun bir şekilde seçilmiştir. Verilerin elde edilmesi kapsamında T.C. Uşak Üniversitesi Sosyal ve Beşeri Bilimler Bilimsel Araştırma ve Yayın Etiği Kurulunun 09.11.2017 tarihli kararı ile gerekli izinler alınarak araştırma verilerine ulaşılmıştır. Kurula ait karar Ek 1’de görülmektedir.

Kütüphane verileri kütüphane yetkilileri tarafından Excel formatında teslim edilmiştir. Uşak Üniversitesi Merkez Kütüphanesine ait veriler kütüphane personeli tarafından düzenli bir şekilde kayıt altına alınmaktadır. Öğrencilerin ödünç almış oldukları kitaplar YORDAM Kütüphane Bilgi-Belge ve Dijital Arşiv Otomasyon Programı vasıtası ile elektronik ortama kayıt edilmektedir. Öğrencilerin kütüphaneden kitap ödünç alabilmeleri için öncelikle öğrenci kimlikleri ile birlikte kütüphaneye üye olmaları gerekmektedir. Alınan her ödünç kitap yine aynı program vasıtası ile öğrenci bilgileri, kitap bilgileri ve ödünç alım tarihi ve diğer bilgilerle birlikte veri tabanına kayıt edilmektedir. Yapılan bu kayıtlar sonucunda kütüphane veri tabanında İİBF İşletme bölümü öğrencilerine ait orta büyüklükte bir veri kaydı oluşmuştur.

Bununla birlikte öğrenci notlarına dair veriler Uşak Üniversitesi İİBF İşletme bölüm başkanlığı tarafından XML dosya formatında teslim edilmiştir. Öğrenci ders notları dersi yürüten öğretim üyesi tarafından OBS otomasyon uygulaması kullanılarak sisteme kayıt edilmektedir. Derslere ait sınav ağırlıkları vize sınavı için %40, final sınavı için %60, dersi geçemeyen öğrenciler için bütünleme sınavı

%60'tır. Bu ağırlıklar dersi yürüten öğretim üyeleri tarafından değiştirilebilmektedir. Derse ait başarı notu, mutlak veya dersin başarı ortalaması esas alınarak bağlı değerlendirme yöntemi kullanılarak OBS otomasyon uygulaması ile otomatik olarak hesaplanmaktadır.

Bu kapsamda uygulamada kullanılan veri Uşak Üniversitesi Merkez Kütüphanesinde 2007 - 2018 yıllarında İİBF İşletme bölümü öğrencilerinin kütüphaneden ödünç almış oldukları kitap kayıtları, Uşak Üniversitesi öğrenci bilgi sisteminde (OBS) 2007-2018 yıllarında oluşan İİBF İşletme bölümü öğrencilerinin ders başarı durumlarıdır. Araştırmada gizlilik ilkelerine bağlı kalınmıştır. Öğrencilere ait öğrenci numaraları ve diğer özel bilgiler araştırmaya dâhil edilmemiştir.

4.4.3. Veri Ön İşleme

Veri madenciliği uygulamalarında en zahmetli ve zaman alıcı adım veri ön işleme adımıdır. Araştırma kapsamında öğrenci ödünç kitap verisi oldukça karmaşık yapıdadır. Veri 2 adet Excel tablosundan oluşmaktadır ve sütun adları farklılık göstermektedir. Tablolar içerisinde birbirini tekrar eden sütunlar mevcut olmakla birlikte araştırma için anlam ifade etmeyen sütunlar da bulunmaktadır. Ayrıca tablolarda işletme bölümü dışındaki bazı bölümlere ait ödünç alımlarda bulunmaktadır. Veri ön işleminden geçirilmeden önce Excel tabloları birleştirilmiştir. Excel tabloları birleştirildikten sonra verinin ham hali 70790 satır, 106 sütundan oluşmaktadır. Kütüphane verisi Microsoft Office Access veri tabanına aktarılmadan önce farklı olan sütun adları tek bir sütun ismine dönüştürülmüştür. Araştırma için gereksiz olan sütunlar silinmiş üye, eser adı, kitap ödünç tarihi, bölüm ve sınıflama sütunları ise veri içerisinde bırakılmıştır.

Excel tablosundaki değişikliklerin ardından Access veri tabanını kullanarak 'ARASTIRMA' isimli bir veri tabanı oluşturulmuştur. Oluşturulan bu veri tabanına Excel tablosu, 'Dış veri / Excel' sekmesi kullanılarak aktarılmıştır. Veri aktarılırken 'id' isimli bir alan daha eklenmiş ve bu alan birincil anahtar olarak belirlenmiştir. Aktarılan tabloya 'kutuphane' ismi verilmiştir. Üye, eser adı, bölüm ve sınıflama

alanlarının veri türü metin, kitap ödünç tarihi alanının veri türü ise tarih/saat olarak belirlenmiştir. Access veri tabanında SQL sorgularının çalıştırılabilmesi için tablo alan isimlerinde Türkçe karakter ve boşluk bulunmaması gerekmektedir. Bu sebeple alan isimlerindeki Türkçe karakterler temizlemiş ve boşluk karakteri yerine ‘_’ karakteri kullanılmıştır. ‘kutuphane’ tablosundaki veri incelendiğinde işletme bölümü dışındaki bazı bölümlerin olduğu görülmüş ve bu bölümler SQL sorguları kullanılarak silinmiştir. İşletmeye ait bölüm isimlerinin el ile sisteme girilmesinden dolayı farklı isimlerde kayıt edildiği görülmüştür. ‘işletme, İŞLETME Yönetimi, İŞLETME’ gibi farklılık gösteren isimlerin tamamı SQL sorguları ile ‘İşletme’ olarak düzeltilerek tek bir isme çevrilmiştir.

Araştırma kapsamında işletme bölümüne ait 17 adet zorunlu ders verisi, 2007-2018 yılları arasında, güz ve bahar yarıyılları dikkate alınarak 459 adet XML (Extensible Markup Language) dosyası olarak teslim alınmıştır. Teslim alınan verinin her birinin satır sayısında değişiklik görülmekle birlikte 15 sütundan oluşmaktadır. XML (Extensible Markup Language) dosyaları ‘ARASTIRMA’ veri tabanına; ‘Dış veri/XML Dosyası’ sekmesi kullanılarak aktarılmıştır. Aktarılan tabloya ‘dersler’ ismi verilmiştir. Tüm XML dosyaları tek bir tabloya eklenerek veri birleştirilmiştir. Elde edilen ‘dersler’ tablosundaki veri incelendiğinde genel olarak düzenli yapıdadır; ancak araştırma için gereksiz olan alanlar bulunduğu için bu alanlar tablodan silinmiştir. Gereksiz alanlar silindikten sonra öğrenci no, ders adı, geçme durumu, notu ve dönem tarihi alanları tablo içerisinde bırakılmıştır. Öğrenci no, ders adı, geçme durumu ve notu alanlarının veri türü metin, dönem tarihi alanının veri türü ise tarih/saat olarak belirlenmiştir. SQL sorgularının çalıştırılabilmesi için ‘kutuphane’ tablosunda olduğu gibi ‘dersler’ tablosunda bulunan alan adlarındaki Türkçe karakterler temizlenmiş ve boşluk karakteri yerine ‘_’ karakteri kullanılmıştır.

Veride ki temizleme ve birleştirme işlemlerinden sonraki aşama veriyi WEKA veri madenciliği programında analiz edilebilecek duruma getirmektir. WEKA’da kullanılacak birliktelik analizine göre her öğrencinin ödünç almış olduğu kitapların

tek bir satırda listelenmesi gerekmektedir. Veri tabanında ise her kitap ayrı bir satırda bulunmaktadır. Ayrıca öğrencinin geçme durumu ve not durumunun da aynı satırda bulunması analiz için gerekmektedir. Öğrencinin ödünç almış olduğu kitap tarihi ile analiz edilen dersin akademik döneminin ve analiz edilen kitap türü ile ders içeriğinin aynı olması da önemlidir. Bu nedenle analize uygun veri satırları oluşturmak için SQL sorgularından yararlanılmıştır. Her ders için ayrı bir SQL sorgusu yazılarak gerekli veri listeleri elde edilmiştir. SQL sorguları sonucunda elde edilen veri listelerinin örnek tablo görünümü Tablo 4.2.'de görülmektedir.

Tablo 4.2. Analize ait örnek veri satırı

Öğrenci No	Ders Adı	Kitap 1	Kitap 2	Kitap 3	Kitap 4	Geçme Durumu	Notu
1	İktisada Giriş	t	t	?	t	Geçti	AA
2	İktisada Giriş	t	t	?	?	Geçti	CC
3	İktisada Giriş	t	t	?	?	Geçti	AA
4	İktisada Giriş	?	t	t	?	Kaldı	FF

Tablo 4.2.'ye göre 2007-2018 tarihleri arasında İktisada Giriş dersini alan öğrencilerin, dersi aldığı akademik takvim içerisinde ödünç almış oldukları kitaplar ile ders başarı durumlarını gösteren örnek veri listesidir. Öğrenci numaraları 'kutuphane' ve 'dersler' tabloları arasında ilişki kurulabilmesi için kullanılmıştır. Veri listesi oluşturulurken öğrenci numaraları 1'den başlanarak numaralandırılmış ve eski numaralar silinerek araştırma içinde kullanılmamıştır. Listeye göre öğrenci listedeki kitaplardan birini ödünç aldıysa o kitaba ait satıra 't' simgesi eklenmiştir. WEKA'nın çalışma prensibine göre boş sütunlar hata vermektedir, bu sebeple ödünç alınmayan kitaba ait sütuna ise '?' simgesi eklenmiştir.

WEKA yalnızca arff (Attribute Relation File Format) ve csv (Comma Separated Variables) dosyalarını kabul eden bir yazılımdır. Her ders için ayrı olarak oluşturulan veri listeleri '.arff' dosya uzantısı ile kaydedilmiştir. Şekil 4.1.'de, Tablo

4.2.'de listelenmiş örnek veri satırının arff dosya formatına dönüştürülmüş biçimi görülmektedir.

```
@relation Iktisada_Giris
@attribute 'kitap 1' { t}
@attribute 'kitap 2' { t}
@attribute 'kitap 3' { t}
@attribute 'kitap 4' { t}
@attribute 'kitap_tur' { Iktisada_Giris}
@attribute 'notu' { AA, BA, BB, CB, CC, DC, DD, DZ, FD, FF}
@attribute 'durum' { Gecti, Kaldi}
@data
t,t,?,t,Iktisada_Giris,AA,Gecti
t,t,?,?,Iktisada_Giris,CC,Geçti
t,t,?,?,Iktisada_Giris,AA,Gecti
?,t,t,? Iktisada_Giris,FF,Kaldi
```

Şekil 4.1. Örnek arff dosyası

Şekil 4.1.'e göre kaydedilen derslere ait her arff dosyasına '@relation ders_adi' ilişki ismi verilmiştir. Veri listelerinde bulunan her sütun ismi ise attribute yani özellik olarak tanımlanmıştır. @ data komutundan sonraki satırlar her bir öğrencinin almış olduğu kitapları belirtmektedir. Attribute göre alınan kitap 't' simgesi ile belirtilmiştir, '?' simgesi ise o kitabın öğrenci tarafından ödünç alınmadığını ifade etmektedir. Arff dosyalarının hazırlanmasıyla veri ön işleme tamamlanmıştır.


4.4.4. Veri Seti

Bu bölümde analizde kullanılan veri setini tanımak amaçlı istatistiksel bilgilere değinilmiştir.

Uşak Üniversitesi Merkez Kütüphane koleksiyonunda bulunan kitaplar LC (Library of Congress) uluslararası sınıflama şemasını kullanmaktadır. Bu sisteme göre kitaba ait ilk harf genel konuyu, ikinci harf ise bir alt kümeyi tanımlamaktadır. LC sınıflama sisteminin tam listesi Ek 2'de bulunmaktadır. Harflerin hangi konuları temsil ettiği araştırma için önemlidir. Harf kodlarının ardından kitaplara ait yer


numaraları bulunmaktadır. Yer numaraları ile birlikte her kitap için ayrı bir sınıflama kodu bulunmaktadır.

Şekil 4.2.'de İşletme bölümü öğrencilerinin 2007-2018 yılları arasında ödünç almış oldukları kitapların LC sınıflama sistemine göre dağılımı görülmektedir.



Şekil 4.2. Ödünç alınan kitapların LC sınıflama sistemine göre dağılımı

Şekil 4.2. incelendiğinde, beklendiği üzere ödünç alınan kitapların büyük bir kısmı 'H' serisinden yani sosyal bilimler serisinden oluşmaktadır. H serisi kitapların alt kümelerine göre dağılımı ise Şekil 4.3.'te görülmektedir.



Şekil 4.3. H Serisi Kitapların Alt Kümelere Dağılımı

Şekil 4.3.'e göre kitap alımının en çok olduğu seri HF, HD, HG ve HB serisidir. İşletme bölümü öğrencilerinin 2007-2018 yılları arasındaki 11 yıllık dönemde Genel İşletme I, Genel İşletme II, İktisada Giriş I, Genel Muhasebe I, Genel Muhasebe II, Makro İktisat, İşletme Yönetimi, Davranış Bilimleri, Pazarlama İlkeleri, Sosyal Bilimlerde Araştırma Yöntemleri, Örgütsel Davranış, İnsan Kaynakları Yönetimi, Stratejik Yönetim ve İşletme Politikası, Maliyet Muhasebesi,

Finansal Yönetim I, Mali Tablolar Analizi, Muhasebe Uygulamaları dersleri olan 17 adet zorunlu derse ait harf notlarının yüzdelik dağılımı ile geçme/kalma durumları Tablo 4.3.'te görülmektedir.

Tablo 4.3. Ders harf notları ve geçme/kalma durumlarının yüzdelik dağılımı.

Ders Adı	AA %	BA %	BB %	CB %	CC %	DC %	DD %	FD %	FF %	Geçti %	Kaldı %
Genel İşletme I	3,59	3,35	9,89	13,14	31,48	8,98	1,24	0,57	28,33	63,23	36,77
Genel İşletme II	4,00	4,08	10,04	13,30	27,27	12,23	1,38	0,21	27,62	61,50	38,50
İktisada Giriş I	3,56	4,87	9,35	13,22	29,39	8,62	1,38	0,11	29,5	63,95	36,05
Genel Muhasebe I	3,12	3,22	8,72	9,80	26,02	8,92	2,48	0,34	37,38	56,70	43,93
Genel Muhasebe II	3,02	3,22	6,21	8,29	26,89	13,56	2,44	0,29	36,07	54,08	45,92
Makro İktisat	3,67	3,40	7,64	9,22	30,76	7,76	1,54	0,12	35,89	58,32	41,68
İşletme Yönetimi	3,52	5,30	11,69	13,56	33,47	11,23	0,97	0,08	20,17	69,75	30,25
Davranış Bilimleri	6,40	7,39	14,83	13,17	34,39	8,72	1,33	0,33	13,45	78,40	21,60
Pazarlama İlkeleri	10,94	7,01	16,99	17,95	26,58	5,76	2,11	0,29	12,38	82,34	17,66
Sosyal Bilimlerde Araştırma Yöntemleri	6,22	5,99	15,86	13,96	31,49	6,26	0,95	0,23	19,05	75,72	24,28
Örgütsel Davranış	42,22	13,33	10,77	10,55	10,77	3,94	2,24	0,11	6,08	93,07	6,93
İnsan Kaynakları Yönetimi	0,80	1,60	9,64	13,85	29,51	8,48	0	0	36,11	55,47	44,53
Stratejik Yönetim ve İşletme Politikası	7,99	7,34	18,13	15,16	34,54	6,37	0,76	0,11	9,61	85,32	14,68
Maliyet Muhasebesi	8,74	8,39	16,18	13,58	26,31	5,79	0,90	0,05	20,07	76,09	23,91
Finansal Yönetim I	1,76	2,72	14,15	18,19	39,10	4,31	0	0	19,77	76,01	23,99
Mali Tablolar Analizi	6,72	6,44	21,66	13,82	42,67	0	0	0	6,68	91,32	8,68
Muhasebe Uygulamaları	10,19	8,79	21,97	14,24	38,05	0,62	0	0	6,15	93,67	6,33

Uşak Üniversitesi yönetmeliğine göre AA, BA, BB, CB, CC notları şartsız başarılı notlardır. DC, DD ve FD notları şartlı başarılı notlardır. FF notu ise başarısızdır. Tablo 4.3. incelendiğinde derslere ait not durumunun daha çok CC ve

FF sütunlarında fazla olduğu görülmektedir. Geçme - kalma duruna bakıldığı zaman Genel Muhasebe I, Genel Muhasebe II, Makro İktisat, İnsan Kaynakları Yönetimi derslerine ait geçme ve kalma yüzdelerinin yakın olduğu, diğer derslerde ise geçme durumunun kalma durumundan oldukça yüksek olduğu görülmektedir.

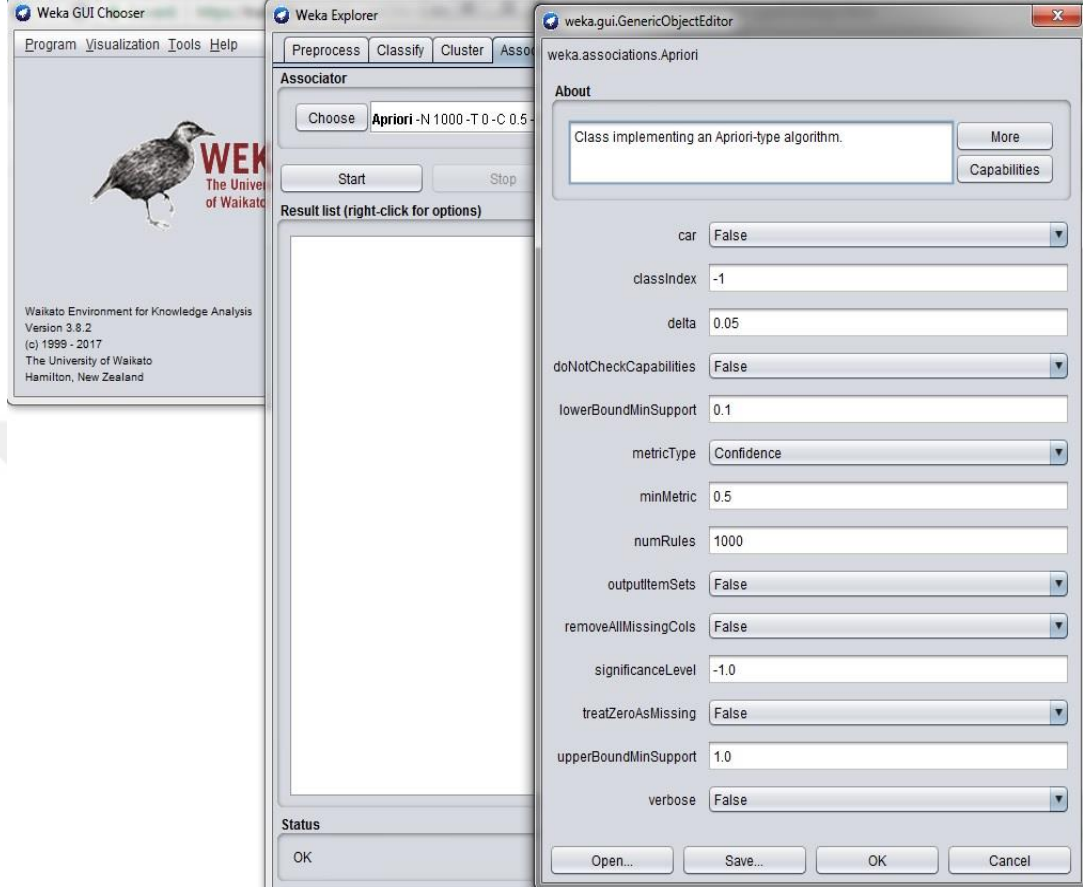
4.5. Araştırmanın Bulguları ve Yorumları

Veri ön işleme aşamasının ve tanımlayıcı bulgulara ait bilgilerin ardından veri madenciliği aşamasına geçilmiştir. Bu aşamada veri ön işleme aşamasında elde edilen arff dosyaları WEKA 3.8 veri madenciliği programında analiz edilmiştir. Analiz için tercih edilen algoritma Apriori algoritmasıdır. Bu algoritmanın tercih edilme sebebi araştırma problemine cevap verecek bir algoritma olmasıdır.

Veri kümeleri arasındaki ilişki kurallarını çıkarmak için kullanılan apriori algoritması veri içerisindeki k adet elemandan oluşan bir listedeki, k-1 elemanı tarar ve alt frekans örüntüsü yetersiz olan elemanları eler. Geriye kalan elemanlar üzerinden tarama işlemine devam ederek ilişki kuralları çıkarır.

Belli bir güven aralığı içinde istenen sayıda kuralı bulana kadar en küçük destek seviyesini aşamalı olarak azaltan Apriori algoritması WEKA içerisinde Apriori modülü ile ifade edilmektedir (Tapkan vd., 2011, s.260).

Veri ön işleme aşamasında elde edilen arff uzantılı dosyalar WEKA yazılımı içerisindeki Preprocess / Open file butonu ile sisteme yüklenmiştir. Bu işlem analiz edilecek her arff dosyası için ayrı olarak yapılmıştır. Dosya yüklemenin ardından Associate / Choose sekmesi aracılığı ile Apriori algoritması seçilmiştir. Ardından algoritma için gerekli ayarlamalar yapılarak araştırma modeli kurulmuştur. Şekil 4.4.'de analiz edilen tüm dersler için Apriori algoritması genel ayarları görülmektedir.



Şekil 4.4. Apriori algoritması genel ayarlarına ait ekran görüntüsü

Şekil 4.4.'te görüldüğü üzere birliktelik analizinde kullanılan maksimum destek değeri 1 (%100), minimum destek değeri 0.1 (%10), delta 0.05'tir. Bu değerler WEKA yazılımında varsayılan olarak gelen değerdir. Minimum güven değeri ise 0.5 olarak belirlenmiştir.

Kural sayısı yazılım içerisinde otomatik olarak 10 adet olarak gelmektedir. Analiz sonucunda elde edilecek kural sayısı tahmin edilemediğinden bu değer 1000 olarak değiştirilmiştir. Böylelikle elde edilebilecek tüm kurallar görülebilmektedir.

Algoritma çalıştırılırken Şekil 4.4.'te görülen değerlerde değişiklik yapılmamış ve tüm zorunlu derslerde kullanılmıştır. Veri seti üzerinde gerçekleştirilen birliktelik analizi sonucunda oluşan kurallar aşağıdaki bölümlerde görülmektedir.

4.5.1. Genel İşletme I Dersine Ait Birliktelik Kuralları

Genel İşletme I dersine ait 13 adet özellik (attribute) üzerinden gerçekleştirilen analiz sonucunda 97 adet kural tespit edilmiştir. Kurallar içerisinde çalışmaya en uygun düşen 7 adet değerli kural bulunmaktadır. Genel işletme I dersi için kullanıldığı tahmin edilerek analize giren kitap isimleri Genel İşletmecilik, Temel İşletmecilik Bilgisi, İşletmecilik: Kuram ve Uygulama, İşletme Biliminin Temel İlkeleri'dir. Analiz ile ulaşılan kurallar ve açıklamaları Tablo 4.4.'te görülmektedir.

Tablo 4.4. Genel İşletme I Dersine Ait Birliktelik Kuralları

Kural No	Kural ve Kural Açıklaması	Güven %
1	Kural: HD 37 .T8 G46=t 21 ==> durum=Gecti 21 Açıklama: HD 37 .T8 G46 kodlu Genel İşletmecilik isimli kitabı ödünç alan 21 öğrenci bulunmaktadır. Bunlardan 21'i yani %100'ü Genel İşletme I dersinden geçmiştir.	100
2	Kural: HF 5351/.O94=t durum=Gecti 28 ==> notu=CC 21 Açıklama: HF 5351/.O94 kodlu Temel İşletmecilik Bilgisi isimli kitabı ödünç alıp geçen 28 öğrenciden 21'i yani %80'i Genel İşletme I dersinden CC harf notu ile geçmiştir.	80
3	Kural: HD 37 /.T8 D46=t 28 ==> durum=Gecti 21 Açıklama: HD 37 /.T8 D46 kodlu İşletmecilik: Kuram ve Uygulama adlı kitabı ödünç alan 28 öğrenci bulunmaktadır. Bunlardan 21'i yani %75'i Genel İşletme I dersinden geçmiştir.	75
4	Kural: HF 5351/ .E77=t 28 ==> notu=CC durum=Gecti 21 Açıklama: HF 5351/ .E77 kodlu İşletme Biliminin Temel İlkeleri kitabını ödünç alıp geçen 28 öğrenciden 21'i yani %75'i Genel İşletme I dersinden CC harf notu ile geçmiştir.	75
5	Kural: kitap_tur=Genel_Isletme_I 203 ==> durum=Gecti 140 Açıklama: Genel İşletme I türünden kitap ödünç 203 öğrenci bulunmaktadır. Bunlardan 140'ı yani %69'u Genel İşletme I dersinden geçmiştir.	69
6	Kural: kitap_tur=Genel_Isletme_I durum=Gecti 140 ==> notu=CC 84 Açıklama: Genel İşletme I türü kitap ödünç alan ve geçen 140 öğrenciden 84'ü yani %60'ı CC harf notu ile geçmiştir.	60
7	Kural: HF 5351/.O94=t 56 ==> durum=geçti 28 Açıklama: HF 5351/.O94 kodlu Temel İşletmecilik Bilgisi isimli kitabı ödünç alan 56 öğrenci bulunmaktadır. Bunlardan 28'i yani % geçmiştir.	50

Tablo 4.4.'te görüldüğü üzere Genel İşletme I dersi için elde edilen kurallar, en düşük %50 en yüksek %100 güven aralığındadır. 5. kurala göre ise Genel İşletme I içerikli kitap ödünç alanların %69'nun ilgili dersten geçmiş olduğu görülmüştür. Bu bağlamda Genel İşletme I dersi için kitap ödünç alımı ile dersten geçme durumu "geçti" arasında kuvvetli ilişki olduğu "kaldı" arasında ilişki olmadığı söylenebilir.

4.5.2. Genel İşletme II Dersine Ait BirlikteK Kuralları

Genel İşletme II dersine ait 15 adet özellik üzerinden gerçekleştirilen analiz sonucunda 48 adet kural tespit edilmiştir. Elde edilen kurallar içerisinde çalışmaya en uygun düşen 5 adet değerli kural bulunmaktadır. Genel İşletme II dersi için kullanıldığı tahmin edilerek analize giren kitap isimleri Modern İşletmecilik, Girişimcilik ve Küçük İşletme Yöneticiliği, Genel İşletme'dir. Analiz sonucunda ulaşılan kurallar ve açıklamaları Tablo 4.5.'te görülmektedir.

Tablo 4.5. Genel İşletme II Dersine Ait BirlikteK Kuralları

Kural No	Kural ve Kural Açıklaması	Güven %
1	Kural: HD 37.T8 M83=t 9 ==> durum=Kaldı 8 Açıklama: HD 37.T8 M83 kodlu Modern İşletmecilik isimli kitabı ödünç alan 9 öğrenci bulunmaktadır. Bunlardan 8'i yani %89'u Genel İşletme II dersinden kalmıştır.	89
2	Kural: HD 62.5 /D66 G57=t 18 ==> durum=Gecti 13 Açıklama: HD 62.5 /D66 G57 kodlu Girişimcilik ve Küçük İşletme Yöneticiliği isimli kitabı ödünç alan 18 öğrenci bulunmaktadır. Bunlardan 13'ü yani %72'si Genel İşletme II dersinden geçmiştir.	72
3	Kural: kitap_tur=genel_Isletme_II 82 ==> durum=Gecti 49 Açıklama: Genel İşletme II içerikli kitap ödünç alan 82 öğrenciden 49'u yani %60'ı Genel İşletme II dersinden geçmiştir.	60
4	Kural: HF 5351/.G46=t 17 ==> durum=Gecti 10 Açıklama: HF 5351/.G46 kodlu Genel İşletme isimli kitabı ödünç alan 17 öğrenci bulunmaktadır. Bunlardan 10'u yani %89'u Genel İşletme II dersinden geçmiştir..	59
5	Kural: kitap_tur=genel_Isletme_II durum=Gecti 49 ==> notu=CC 27 Açıklama: Genel İşletme II türünden kitap ödünç alan ve geçen 49 öğrenciden 27'si yani %55'i dersi CC harf notu ile geçmiştir.	55

Tablo 4.5.'te görüldüğü üzere Genel İşletme II için elde edilen kurallar, en düşük %55 en yüksek %89 güven aralığındadır. 3. kurala göre ise Genel İşletme II içerikli kitap ödünç alanların %60'nın ilgili dersten geçmiş olduğu görülmüştür. Bu bağlamda Genel İşletme II dersi için kitap ödünç alımı ile dersten geçme durumu "geçti" arasında olumlu ilişki olduğu "kaldı" arasında ilişki olmadığı söylenebilir.

4.5.3. İktisada Giriş I Dersine Ait Birliktelik Kuralları

İktisada Giriş I dersine ait 17 adet özellik üzerinden gerçekleştirilen analiz sonucunda 138 adet kural tespit edilmiştir. Elde edilen kurallar içerisinde çalışmaya en uygun düşen 5 adet değerli kural bulunmaktadır. İktisada Giriş I dersi için kullanıldığı tahmin edilerek analize giren kitap isimleri Mikro Ekonomi, Mikro İktisat'tır. Analiz sonucunda ulaşılan kurallar ve açıklamaları Tablo 4.6.'da görülmektedir.

Tablo 4.6. İktisada Giriş I Dersine Ait Birliktelik Kuralları

Kural No	Kural ve Kural Açıklaması	Güven %
1	Kural: HB 172 /D56=t 8 ==> durum=Gecti 8 Açıklama: HB 172 /D56 kodlu Mikro Ekonomi isimli kitabı ödünç alan 8 öğrenci bulunmaktadır. Bunlardan 8'i yani %100'ü İktisada Giriş I dersinden geçmiştir.	100
2	Kural: HB 172/.K35=t 16 ==> durum=Kaldi 12 Açıklama: HB 172/.K35 kodlu Mikro İktisat isimli kitabı ödünç alan 16 öğrenci bulunmaktadır. Bunlardan 12'si yani %75'i İktisada Giriş I dersinden kalmıştır.	75
3	Kural: HB 171.5/.P37=t 16 ==> durum=Gecti 8 Açıklama: HB 171.5/.P37 kodlu Mikro Ekonomi isimli kitabı ödünç alan 16 öğrenci bulunmaktadır. Bunlardan 8'i yani %50'si İktisada Giriş I dersinden geçmiştir.	50
4	Kural: kitap_tur=İktisada_Giris 88 ==> durum=Gecti 44 Açıklama: İktisada Giriş türünde kitap ödünç alan 88 öğrenci bulunmaktadır. Bunlardan 44'ü yani %50'i geçmiştir.	50
5	Kural: kitap_tur=İktisada_Giris 88 ==> durum=Kaldı 44 Açıklama: İktisada Giriş türünde kitap ödünç alan 88 öğrenci bulunmaktadır. Bunlardan 44'ü yani %50'i kalmıştır.	50

Tablo 4.6.'da görüldüğü üzere İktisada Giriş I dersi için elde edilen kurallar, en düşük %50 en yüksek %100 güven aralığındadır. Tabloya göre İktisada Giriş I içerikli kitap ödünç alanların %50'sinin ilgili dersten geçtiği %50'sinin ise kaldığı görülmektedir. Bu duruma dayanarak İktisada Giriş I dersi için kitap ödünç alımı ile dersten geçme durumu "geçti" arasında olumlu ilişki ve "kaldı" arasında olumlu ilişki olduğu söylenebilir.

4.5.4. Genel Muhasebe I Dersine Ait Birliktelik Kuralları

Genel Muhasebe I dersine ait 27 adet özellik üzerinden gerçekleştirilen analiz sonucunda 65 adet kural tespit edilmiştir. Elde edilen kurallar içerisinde çalışmaya en uygun düşen 4 adet değerli kural bulunmaktadır. Genel Muhasebe I dersi için kullanıldığı tahmin edilerek analize giren kitap isimleri 3 farklı LC kodu bulunan Genel Muhasebe'dir. Analiz sonucunda ulaşılan kurallar ve açıklamaları Tablo 4.7.'de görülmektedir.

Tablo 4.7. Genel Muhasebe I Dersine Ait Birliktelik Kuralları

Kural No	Kural ve Kural Açıklaması	Güven %
1	Kural: HF 5625/.C46=t 16 ==> durum=Gecti 16 Açıklama: HF 5625/.C46 kodlu Genel Muhasebe isimli kitabı ödünç alan 16 öğrenci bulunmaktadır. Bunlardan 16'sı yani %100'ü Genel Muhasebe I dersinden geçmiştir.	100
2	Kural: HF 5625 /C66 G46=t 16 ==> durum=Gecti 13 Açıklama: HF 5625 /C66 G46 kodlu Genel Muhasebe isimli kitabı ödünç alan 18 öğrenci bulunmaktadır. Bunlardan 13'ü yani %75'i Genel Muhasebe I dersinden geçmiştir.	81
3	Kural: HF 5625/.S97=t 20 ==> durum=Gecti 16 Açıklama: HF 5625/.S97 kodlu Genel Muhasebe isimli kitabı ödünç alan 20 öğrenci bulunmaktadır. Bunlardan 16'sı yani %67'si Genel Muhasebe I dersinden geçmiştir.	80
4	Kural: kitap_tur=Genel_Muhasebe_I 232 ==> durum=Gecti 168 Açıklama: Genel Muhasebe türünden kitap ödünç alan 232 öğrenci bulunmaktadır. Bunlardan 168'i yani %72'si Genel Muhasebe I dersinden geçmiştir.	72

Tablo 4.7.'de görüldüğü üzere Genel Muhasebe I dersi için elde edilen kurallar, en düşük %72 en yüksek %100 güven aralığındadır. 4. kural incelendiğinde Genel Muhasebe I içerikli kitap ödünç alanların %72'sinin ilgili dersten geçtiği görülmektedir. Bu bağlamda Genel Muhasebe I dersi için kitap ödünç alımı ile dersten geçme durumu "geçti" arasında kuvvetli ilişki olduğu "kaldı" arasında ilişki olmadığı söylenebilir.

4.5.5. Genel Muhasebe II Dersine Ait Birliktelik Kuralları

Genel Muhasebe II dersine ait 19 adet özellik üzerinden gerçekleştirilen analiz sonucunda 52 adet kural tespit edilmiştir. Elde edilen kurallar içerisinde çalışmaya en uygun düşen 6 adet değerli kural bulunmaktadır. Analize giren kitap isimleri Genel Muhasebe, Muhasebe Uygulamaları, Muhasebe Denetimi ve Mali Analiz'dir. Analiz sonucunda ulaşılan kurallar ve açıklamaları Tablo 4.8.'te görülmektedir.

Tablo 4.8. Genel Muhasebe II Dersine Ait Birliktelik Kuralları

Kural No	Kural ve Kural Açıklaması	Güven %
1	Kural: HF 5625/.S97=t 14 ==> durum=Gecti 14 Açıklama: HF 5625/.S97 kodlu Genel Muhasebe isimli kitabı ödünç alan 14 öğrenci bulunmaktadır. Bunlardan 14'ü yani %100'ü Genel Muhasebe II dersinden geçmiştir.	100
2	Kural: kitap_tur=Genel_Muhasebe_II 61 ==> durum=Gecti 48 Açıklama: Genel Muhasebe II kitap türünden kitap ödünç alan 61 öğrenci bulunmaktadır. Bunlardan 68'i yani %79'u Genel Muhasebe II dersinden geçmiştir.	79
3	Kural: HF 5625/.M83=t 9 ==> durum=Gecti 7 Açıklama: HF 5625/.M83 kodlu Muhasebe Uygulamaları isimli kitabı ödünç alan 9 öğrenci bulunmaktadır. Bunlardan 7'si yani %78'i Genel Muhasebe II dersinden geçmiştir.	78
4	Kural: HF 5667/.G875=t 12 ==> durum=Gecti 9 Açıklama: HF 5667/.G875 kodlu Muhasebe Denetimi ve Mali Analiz isimli kitabı ödünç alan 12 öğrenci bulunmaktadır. Bunlardan 9'u yani %75'i Genel Muhasebe II dersinden geçmiştir.	75
5	Kural: HF 5667/.C65=t 9 ==> durum=Gecti 6 Açıklama: HF 5667/.C65 kodlu Muhasebe Denetimi isimli kitabı ödünç alan 9 öğrenci bulunmaktadır. Bunlardan 6'sı yani %67'si Genel Muhasebe II dersinden geçmiştir.	67
6	Kural: kitap_tur=Genel_Muhasebe_II durum=Gecti 48 ==> notu=CC 26 Açıklama: Genel Muhasebe II kitap türünden kitap ödünç alan ve geçen 48 öğrenciden 26'sı yani %54'ü CC harf notu ile geçmiştir.	54

Tablo 4.8.'de görüldüğü üzere Genel Muhasebe II dersi için elde edilen kurallar, en düşük %54 en yüksek %100 güven aralığındadır. 2. kural incelendiğinde Genel Muhasebe II içerikli kitap ödünç alanların %79'unun ilgili dersten geçtiği görülmektedir. Bu kurala göre Genel Muhasebe II dersi için kitap ödünç alımı ile dersten geçme durumu "geçti" arasında kuvvetli ilişki olduğu "kaldı" arasında ilişki olmadığı söylenebilir.

4.5.6. Makro İktisat Dersine Ait Birliktelik Kuralları

Makro İktisat dersine ait 17 adet özellik üzerinden gerçekleştirilen analiz sonucunda 74 adet kuraldan çalışmaya en uygun düşen 9 adet değerli kural bulunmaktadır. Makro İktisat dersi için kullanıldığı tahmin edilerek analize giren kitaplar Makro Ekonomi Türkçe, Makro Ekonomi: Teori ve Politika, Makro Ekonomi'dir. Kurallar ve açıklamaları Tablo 4.9.'da görülmektedir.

Tablo 4.9. Makro İktisat Dersine Ait Birliktelik Kuralları

Kural No	Kural ve Kural Açıklaması	Güven %
1	Kural: HB 172.5/F58=t 15 ==> durum=Gecti 15 Açıklama: HB 172.5/F58 kodlu Makro Ekonomi Türkçe isimli kitabı ödünç alan 12 öğrenci bulunmaktadır. Bunlardan 12'si yani %100'ü geçmiştir.	100
2	Kural: HB 172.5/P37=t 32 ==> durum=Gecti 25 Açıklama: HB 172.5/P37 kodlu Makro Ekonomi: Teori ve Pol. isimli kitabı ödünç alan 32 öğrenci bulunmaktadır. Bunlardan 25'i yani %78'i geçmiştir.	78
3	Kural: HB 172.5/Y560=t 16 ==> durum=Gecti 12 Açıklama: HB 172.5/Y560 kodlu Makro Ekonomi isimli kitabı ödünç alan 16 öğrenci bulunmaktadır. Bunlardan 12'si yani %75'i geçmiştir.	75
4	Kural: HB 172.5/ .D67=t durum=Gecti 16 ==> notu=CC 12 Açıklama: HB 172.5/ .D67 kodlu Makro Ekonomi isimli kitabı ödünç alan ve geçen 16 öğrenciden 12'si yani %75'i derten CC harf notu ile geçmiştir.	75
5	Kural: kitap_tur=Makro_Iktisat 100 ==> durum=Gecti 72 Açıklama: Makro iktisat türünden kitap alan 100 öğrenci bulunmaktadır. Bunlardan 72'si yani %72'si Makro İktisat dersinden geçmiştir.	72
6	Kural: HB 172.5/ .D67=t 24 ==> durum=Gecti 16 Açıklama: HB 172.5/ .D67 kodlu Makro Ekonomi isimli kitabı ödünç alan 24 öğrenci bulunmaktadır. Bunlardan 16'sı yani %67'si dersten geçmiştir.	67
7	Kural: HB 172.5/P37=t durum=Gecti 24 ==> notu=CC 16 Açıklama: HB 172.5/P37 kodlu Makro Ekonomi: Teori ve Politika isimli kitabı ödünç alan ve geçen öğrencilerin %67'si CC harf notu ile geçmiştir.	67
8	Kural: HB 172.5/P37=t 32 ==> notu=CC 17 Açıklama: HB 172.5/P37 kodlu Makro Ekonomi: Teori ve Politika isimli kitabı ödünç alan 32 öğrenciden 17'sini yani %53'nün harf notu CC'dir.	53
9	Kural: kitap_tur=Makro_Iktisat durum=Gecti 72 ==> notu=CC 38 Açıklama: Makro iktisat türünden kitap ödünç alan ve geçen 72 öğrenciden 38'si yani %52'si CC harf notu ile geçmiştir.	52

Tablo 4.9.'da görüldüğü üzere Makro iktisat dersi için kurallar, en düşük %52 en yüksek %100 güven aralığındadır. 5. kural incelendiğinde ders içerikli kitap ödünç alanların %72'sinin dersten geçtiği görülmektedir. Bu kurala dayanarak kitap ödünç alımı ile dersten geçme durumu "geçti" arasında kuvvetli ilişki olduğu "kaldı" arasında ilişki olmadığı söylenebilir.

4.5.7. İşletme Yönetimi Dersine Ait Birliktelik Kuralları

İşletme Yönetimi dersine ait 10 adet özellik üzerinden gerçekleştirilen analiz sonucunda 74 adet kural tespit edilmiştir. Elde edilen kurallar içerisinde çalışmaya en uygun düşen 6 adet değerli kural bulunmaktadır. İşletme Yönetimi dersi için kullanıldığı tahmin edilerek analize giren kitap isimleri Girişimcilik ve Küçük İşletme Yöneticiliği, Küreselleşme Sürecinde İşletme Yönetimi'dir. Analiz sonucunda ulaşılan kurallar ve açıklamaları Tablo 4.10.'da görülmektedir.

Tablo 4.10. İşletme Yönetimi Dersine Ait Birliktelik Kuralları

Kural No	Kural ve Kural Açıklaması	Güven %
1	Kural: HD 62.5/D66 G57=t 36 ==> durum=Gecti 33 Açıklama: HD 62.5/D66 G57 kodlu Girişimcilik ve Küçük İşletme Yöneticiliği isimli kitabı ödünç alan 36 öğrenci bulunmaktadır. Bunlardan 33'ü yani %92'si İşletme Yönetimi dersinden geçmiştir.	92
2	Kural: kitap_tur=İşletme_yonetimi 126 ==> durum=Gecti 108 Açıklama: İşletme yönetimi türünde kitap ödünç alan 126 öğrenci bulunmaktadır. Bunlardan 108'si yani %86'sı geçmiştir.	86
3	Kural: HF 5351/.T88 K87=t 36 ==> durum=Gecti 30 Açıklama: HF 5351/.T88 K87 kodlu Küreselleşme Sürecinde İşletme Yönetimi isimli kitabı ödünç alan 36 öğrenci bulunmaktadır. Bunlardan 30'u yani %83'ü İşletme Yönetimi dersinden geçmiştir.	83
4	Kural: HD 62.5 /K83 G57=t durum=Gecti 15 ==> notu=CC 12 Açıklama: HD 62.5 /K83 G57 kodlu Girişimcilik ve Küçük İşletme Yönetimi isimli kitabı ödünç alan ve geçen 15 öğrenciden 12'si yani %75'nin harf notu CC'dir.	75
5	Kural: HF 5351/.T88=t durum=Gecti 30 ==> notu=CC 21 Açıklama: HF 5351/.T88 kodlu Küreselleşme Sürecinde İşletme Yönetimi isimli kitabı ödünç alan ve geçen 30 öğrenciden 21'i yani %70'i CC ile geçmiştir.	70
6	Kural: kitap_tur=İşletme_yonetimi durum=Gecti 108 ==> notu=CC 60 Açıklama: İşletme yönetimi türünde kitap ödünç alan ve geçen 108 öğrenciden 60'ı yani %56'sı CC harf notu ile geçmiştir.	56

Tablo 4.10.'da görüldüğü üzere İşletme Yönetimi dersi için en düşük %56 en yüksek %92 güven aralığında kurallar bulunmaktadır. 2. kural incelendiğinde kitap ödünç alanların %86'sının dersten geçtiği görülmektedir. Bu bağlamda İşletme Yönetimi dersi için kitap ödünç alımı ile dersten geçme durumu "geçti" arasında çok kuvvetli ilişki olduğu "kaldı" arasında ilişki olmadığı söylenebilir.

4.5.8. Davranış Bilimleri Dersine Ait Birliktelik Kuralları

Davranış Bilimleri dersine ait 15 adet özellik üzerinden gerçekleştirilen analiz sonucunda 107 adet kural tespit edilmiştir. Elde edilen kurallar içerisinde çalışmaya en uygun düşen 7 adet değerli kural bulunmaktadır. Davranış Bilimleri dersi için kullanıldığı tahmin edilerek analize giren kitap isimleri davranış Bilimlerine Giriş, Davranış Bilimleri, Örgütsel Davranış, Örgütsel Davranış ve Yönetim Psikolojisi'dir. Analiz sonucunda ulaşılan kurallar ve açıklamaları Tablo 4.11.'de görülmektedir.

Tablo 4.11. Davranış Bilimleri Dersine Ait Birliktelik Kuralları

Kural No	Kural ve Kural Açıklaması	Güven %
1	Kural: HF 5548.8/D38=t 20 ==> durum=Gecti 20 Açıklama: HF 5548.8/D38 kodlu Davranış Bilimlerine Giriş isimli kitabı ödünç alan 20 öğrenci bulunmaktadır. Bunlardan 20'si yani %100'ü Davranış Bilimleri dersinden geçmiştir.	100
2	Kural: HF 5548.8/E76=t durum=Gecti 12 ==> notu=CC 12 Açıklama: HF 5548.8/E76 kodlu Davranış Bilimleri isimli kitabı ödünç alan ve geçen 12 öğrenciden 12'si yani %100'ü CC harf notu geçmiştir.	100
3	Kural: kitap_tur=davranis_bilimleri 112==> durum=Gecti 92 Açıklama: Davranış bilimleri türünden kitap ödünç alan 112 öğrenci bulunmaktadır. Bunlardan 92'si yani %82'si geçmiştir.	82
4	Kural: HD 58.7/.094=t 16 ==> notu=CC durum=Gecti 12 Açıklama: HD 58.7/.094 kodlu Örgütsel Davranış isimli kitabı ödünç alan 16 öğrenciden 12'si yani %75'i CC harf notu ile geçmiştir	75
5	Kural: HD 58.82/.E64=t 16 ==> durum=Gecti 12 Açıklama: HD 58.82/.E64 kodlu Örgütsel Davranış ve Yönetim Psikolojisi isimli kitabı ödünç alan 16 öğrenci bulunmaktadır. Bunlardan 12'si yani %75'i Örgütsel Davranış dersinden geçmiştir.	75
6	Kural: kitap_tur=Davranis_Bilimleri durum=Gecti 92 ==> notu=CC 64 Açıklama: Davranış bilimleri türünde kitap ödünç alan ve geçen 92 öğrenciden 64'ü yani %70'i CC harf notu ile geçmiştir.	70
7	Kural: HF 5548.8/D38=t durum=Gecti 12 ==> notu=BB 8 Açıklama: HF 5548.8/D38 kodlu Davranış Bilimlerine Giriş isimli kitabı ödünç alan ve geçen 12 öğrenciden 8'si yani %60'ı BB ile geçmiştir.	66

Tablo 4.11.'de görüldüğü üzere Davranış Bilimleri için en düşük %66 en yüksek %100 güven aralığında kurallar bulunmaktadır. 3. kurala göre Davranış Bilimleri türünden kitap ödünç alanların %82'sinin ilgili dersten geçtiği görülmektedir. Bu bağlamda Davranış Bilimleri dersi için kitap ödünç alımı ile dersten geçme durumu "geçti" arasında kuvvetli ilişki olduğu "kaldı" arasında ilişki olmadığı söylenebilir.

4.5.9. Pazarlama İlkeleri Dersine Ait Birliktelik Kuralları

Pazarlama İlkeleri dersine ait 16 adet özellik üzerinden gerçekleştirilen analiz sonucunda 63 adet kural içerisinde çalışmaya en uygun düşen 7 adet değerli kural bulunmaktadır. Pazarlama İlkeleri dersi için kullanıldığı tahmin edilerek analize giren kitap isimleri Pazarlama İlkeleri, Pazarlama Stratejileri, Tüketici Davranışı ve Pazarlama Stratejileri: Global ve Yerel Yaklaşım, Pazarlama: İlkeler - Yönetim - Örnek Olaylar, Satış Sanatı Pazarlamadır. Analiz sonucunda ulaşılan kurallar ve açıklamaları Tablo 4.12.'de görülmektedir.

Tablo 4.12. Pazarlama İlkeleri Dersine Ait Birliktelik Kuralları

Kural No	Kural ve Kural Açıklaması	Güven %
1	Kural: HF 5415/.M83=t 44==> durum=Gecti 44 Açıklama: HF 5415/.M83 kodlu Pazarlama İlkeleri isimli kitabı ödünç alan 44 öğrenci bulunmaktadır. Bunlardan 44'ü yani %100'ü ilgili dersten geçmiştir.	100
2	Kural: HF 5415 /P39=t 12 ==> durum=Gecti 12 Açıklama: HF 5415 /P39 kodlu Pazarlama Stratejileri isimli kitabı ödünç alan 12 öğrenci bulunmaktadır. Bunlardan 12'si yani %100'ü geçmiştir.	100
3	Kural: HF 5415.32 /K63 T85=t 12 ==> durum=Gecti 12 Açıklama: HF 5415.32 /K63 T85 kodlu Tüketici Davranışı ve Pazarlama Stratejileri: Global ve Yerel Yaklaşım isimli kitabı ödünç alan 12 öğrenci bulunmaktadır. Bunlardan 12'si yani %100'ü geçmiştir.	100
4	Kural: HF 5415/Y85 P39=t 12 ==> durum=Gecti 12 Açıklama: HF 5415/Y85 P39 kodlu Pazarlama : İlkeler - Yönetim - Örnek Olaylar isimli kitabı ödünç alan öğrencilerin yani %100'ü geçmiştir.	100
5	Kural: kitap_tur=Pazarlama_Ilkeleri 120 ==> durum=Gecti 104 Açıklama: Pazarlama ilkeleri türünden kitap ödünç alan 120 öğrenci bulunmaktadır. Bunlardan 104'ü yani %88'i ilgili dersten geçmiştir.	87
6	Kural: HF 5415/.M83=t durum=Gecti 52 ==> notu=CC 44 Açıklama: HF 5415/.M83 kodlu Pazarlama İlkeleri isimli kitabı ödünç alan ve geçen 52 öğrenciden 44'ü yani %75'i CC harf kodlu ile geçmiştir.	84
7	Kural: HF 5438.25 /C37=t 20 ==> durum=Gecti 12 Açıklama: HF 5438.25 /C37 kodlu Satış Sanatı Pazarlama isimli kitabı ödünç alan 20 öğrenci bulunmaktadır. Bunlardan 12'si yani %60'ı geçmiştir.	60

Tablo 4.12.'de görüldüğü üzere Pazarlama İlkeleri dersine ait birliktelik analizi sonucuna göre en düşük %60 en yüksek %100 güven aralığında kurallar bulunmaktadır. 5. kural incelendiğinde Pazarlama İlkeleri türünden kitap ödünç alanların %87'sinin ilgili dersten geçtiği görülmektedir. Bu kurala dayanarak Pazarlama İlkeleri dersi için kitap ödünç alımı ile dersten geçme durumu "geçti" arasında çok kuvvetli ilişki olduğu "kaldı" arasında ilişki olmadığı söylenebilir.

4.5.10. Sosyal Bilim. Araş. Yön. Dersine Ait Birliktelik Kuralları

Sosyal Bilim. Araş. Yön. dersine ait 22 adet özellik üzerinden gerçekleştirilen analiz sonucunda 75 adet kuraldan çalışmaya en uygun düşen 6 adet değerli kural bulunmaktadır. İlgili ders için kullanıldığı tahmin edilerek analize giren kitaplar; Sosyal Bilimlerde Araştırma Yöntemleri Spss Uygulamalı, Nicel-Nitel Araştırma Teknikleri Sos. Bil. Araş. Tek. Nicel Mi? Nitel Mi?, Sosyal Bilimlerde Araştırma Yöntemleri ve Teknikleri, Spss Uygulamalı Temel İstatistik yöntemlerdir. Analiz sonucunda ulaşılan kurallar ve açıklamaları Tablo 4.13.'te görülmektedir.

Tablo 4.13. Sosyal Bilim. Araş. Yön. Dersine Ait Birliktelik Kuralları

Kural No	Kural ve Kural Açıklaması	Güven %
1	Kural: kitap_tur=Sosyal_Bilim_Aras_Yon 104==> durum=Gecti 104 Açıklama: Sosyal Bilimlerde Araştırma Yöntemleri türünde kitap ödünç alan 104 öğrenci bulunmaktadır. Bunlardan 104'ü yani %100'ü geçmiştir.	100
2	Kural: H 61.6/ S67=t 24 ==> durum=Gecti 24 Açıklama: H 61.6/ S67 kodlu Sosyal Bilimlerde Araştırma Yöntemleri SPSS Uygulamalı isimli kitabı ödünç alan 204 öğrenci bulunmaktadır. Bunlardan 24'ü yani %100'ü ilgili dersten geçmiştir.	100
3	Kural: H 62 /K87 N53=t 12 ==> durum=Gecti 12 Açıklama: H 62 /K87 N53 kodlu Nicel-Nitel Arş. Tek. Sos. Bil. Araş. Tek. Nicel Mi? Nitel Mi? isimli kitabı ödünç alan öğrencilerin %100'ü geçmiştir.	100
4	Kural: H 62/A95 S67=t 12 ==> durum=Gecti 12 Açıklama: H 62/A95 S67 kodlu Sosyal Bilimlerde Araştırma Yöntemleri ve Teknikleri isimli kitabı ödünç alan öğrencilerin %100'ü geçmiştir.	100
5	Kural: HA 29.5/ U58 S67=t 12 ==> durum=Gecti 12 Açıklama: HA 29.5/ U58 S67 kodlu SPSS Uygulamalı Temel İstatistik Yöntemler isimli kitabı ödünç alan 12 öğrenci bulunmaktadır. Bunlardan 12'si yani %100'ü Sosyal Bilimlerde Araştırma Yöntemleri dersinden geçmiştir.	100
6	Kural: H 61.6/ S67=t durum=Gecti 24 ==> notu=BB 12 Açıklama: H 61.6/ S67 kodlu Sosyal Bilimlerde Araştırma Yöntemleri SPSS Uygulamalı isimli kitabı ödünç alan ve geçen 24 öğrenciden 12'si yani %50'si dersi BB harf notu ile geçmiştir.	50

Tablo 4.13.'te görüldüğü üzere en düşük %50 en yüksek %100 güven aralığında kurallar bulunmaktadır. 1. kural incelendiğinde Sosyal Bilimlerde Araştırma Yöntemleri türünden kitap ödünç alanların %100'nün ilgili dersten geçtiği görülmektedir. Bu bağlamda Sos. Bilim. Araş. Yön. dersi için kitap ödünç alımı ile dersten geçme durumu “geçti” arasında çok kuvvetli ilişki olduğu “kaldı” arasında ilişki olmadığı söylenebilir.

4.5.11. Örgütsel Davranış Dersine Ait Birliktelik Kuralları

Örgütsel Davranış dersine ait 13 adet özellik üzerinden gerçekleştirilen analiz sonucunda 70 adet kural tespit edilmiştir. Elde edilen kurallar içerisinde çalışmaya en uygun düşen 6 adet değerli kural bulunmaktadır. Örgütsel Davranış dersi için kullanıldığı tahmin edilerek analize giren kitap isimleri Örgütsel Davranış, Örgütsel Davranış: İnsanın Üretim Gücü, Bilgi Yönetimi ve Öğrenen Örgütler'dir. Analiz sonucunda ulaşılan kurallar ve açıklamaları Tablo 4.14.'de görülmektedir.

Tablo 4.14. Örgütsel Davranış Dersine Ait Birliktelik Kuralları

Kural No	Kural ve Kural Açıklaması	Güven %
1	Kural: HD 58.7/.O94=t 44 ==> durum=Gecti 44 Açıklama: HD 58.7/.O94 kodlu Örgütsel Davranış isimli kitabı ödünç alan 44 öğrenci bulunmaktadır. Bunlardan 44'ü yani %100'ü geçmiştir.	100
2	Kural: HD 58.7/.B37=t 28 ==> durum=Gecti 28 Açıklama: HD 58.7/.B37 kodlu Örgütsel Davranış: İnsanın Üretim Gücü isimli kitabı ödünç alan 28 öğrenci bulunmaktadır. Bunlardan 28'i yani %100'ü Örgütsel Davranış dersinden geçmiştir.	100
3	Kural: kitap_tur=Orgutsel_Davranis 136 ==> durum=Gecti 129 Açıklama: Örgütsel Davranış türünde kitap ödünç alan 136 öğrenci bulunmaktadır. Bunlardan 129'u yani %95'i geçmiştir.	95
4	Kural: HD 30.213 /A34=t 12 ==> durum=Gecti 8 Açıklama: HD 30.213 /A34 kodlu Bilgi Yönetimi ve Öğrenen Örgütler isimli kitabı ödünç alan 12 öğrenci den 8'i yani %66'sı geçmiştir.	67
5	Kural: HD 58.7/.O94=t durum=Gecti 44 ==> notu=AA 28 Açıklama: D 58.7/.O94 kodlu Örgütsel Davranış isimli kitabı ödünç alan ve geçen 44 öğrenciden 28'si yani %64'ü AA harf notu ile geçmiştir.	64
6	Kural: kitap_tur=Orgutsel_Davranis durum=Gecti 76 ==> notu=AA 40 Açıklama: Örgütsel Davranış türünde kitap ödünç alan ve Örgütsel davranış dersinden geçen 74 öğrenciden 40'ı yani %53'ü AA harf notu ile geçmiştir.	53

Tablo 4.14.'te görüldüğü üzere Örgütsel Davranış dersi için en düşük %53 en yüksek %100 güven aralığında kurallar bulunmaktadır. 3. kural incelendiğinde Örgütsel Davranış türünden kitap ödünç alanların %95'inin ilgili dersten geçtiği görülmektedir. Bu bağlamda Örgütsel Davranış dersi için kitap ödünç alımı ile dersten geçme durumu "geçti" arasında kuvvetli ilişki olduğu "kaldı" arasında ilişki olmadığı söylenebilir.

4.5.12. İnsan Kaynakları Dersine Ait Birliktelik Kuralları

İnsan Kaynakları Yönetimi dersine ait gerçekleştirilen analiz sonucunda 44 adet kural tespit edilmiştir. Kurallar içerisinde çalışmaya en uygun düşen 6 adet değerli kural bulunmaktadır. İnsan Kaynakları dersi için kullanıldığı tahmin edilerek analize giren kitap isimleri İnsan Kaynakları Yönetimi İnsan Kaynakları Planlaması Norm Kadro Uygulaması, Endüstri ilişkileri boyutunda çok uluslu şirketler ve İnsan Kaynağı Yönetimi: Teori ve Uygulama, İş ve İnsan İlişkileridir. Ulaşılan kurallar ve açıklamaları Tablo 4.15.'te görülmektedir.

Tablo 4.15. İnsan Kaynakları Yönetimi Dersine Ait Birliktelik Kuralları

Kural No	Kural ve Kural Açıklaması	Güven %
1	Kural: HF 5549/ A33=t 20 ==> durum=Gecti 20 Açıklama: HF 5549/ A33 kodlu İnsan Kay. Yön. İnsan Kay. Plan. Norm Kadro Uyg. isimli kitabı ödünç alan 20 öğrenci bulunmaktadır. Bunlardan 20'si yani %100'ü İnsan kaynakları dersinden geçmiştir.	100
2	Kural: HF 5548/.K88=t durum=Gecti 12 ==> notu=CC 12 Açıklama: HF 5548/.K88 kodlu Endüstri İlişkileri Boyutunda Çok Uluslu Şirketler ve İnsan Kaynağı Yönetimi: Teori ve Uygulama isimli kitabı ödünç alan 12 öğrenciden 12'si yani %100'ü CC harf notu ile geçmiştir.	100
3	Kural: HQ 734/.K63=t 20 ==> durum=Kaldi 16 Açıklama: HQ 734/.K63 kodlu İş ve İnsan İlişkileri isimli kitabı ödünç alan 20 öğrenci bulunmaktadır. Bunlardan 16'sı yani %80'ni kalmıştır.	80
4	Kural: HF 5549/ A33=t durum=Gecti 20 ==> notu=CC 12 Açıklama: HF 5549/ A33 kodlu İnsan Kay. Yön. İnsan Kay. Plan. Norm Kadro Uyg. isimli kitabı ödünç alan 20 öğrenciden 12'si yani %60'ı dersten CC Harf notu ile geçmiştir.	60
5	Kural: kitap_tur=İnsan_Kaynakları 132 ==> durum=Gecti 72 Açıklama: İnsan Kaynakları türünden kitap ödünç alan 132 öğrenciden 72'si yani %55'i İnsan Kaynakları Yönetimi dersinden geçmiştir.	55
6	Kural: kitap_tur=İnsan_Kaynakları durum=Gecti 72 ==> notu=CC 36 Açıklama: İnsan kaynakları türünde kitap ödünç alan ve geçen 72 öğrenciden 36'sı yani %50'si CC harf notu ile geçmiştir.	50

Tablo 4.15.'te görüldüğü üzere İnsan Kaynakları Yönetimi dersi için en düşük %50 en yüksek %100 güven aralığında kurallar bulunmaktadır. 5. kural incelendiğinde İnsan Kaynakları Yönetimi türünden kitap ödünç alanların %55'inin dersten geçtiği görülmektedir. Bu kurala dayanarak ilgili ders için kitap ödünç alımı ile dersten geçme durumu “geçti” arasında olumlu ilişki olduğu “kaldı” arasında ilişki olmadığı söylenebilir.

4.5.13. Stratejik Yön. ve İşletme Politikası Dersine Ait Birliktelik Kuralları

Stratejik Yön. ve İşletme Politikası dersine ait 14 adet attribute üzerinden gerçekleştirilen analiz sonucunda 150 adet kural tespit edilmiştir. Elde edilen kurallar içerisinde çalışmaya en uygun düşen 10 adet değerli kural bulunmaktadır. Stratejik Yön. ve İşletme Politikası dersi için kullanıldığı tahmin edilerek analize giren kitap isimleri Genel ve Endüstriyel Yönetim, İşletmelerde Stratejik Yönetim, Stratejik Yönetim ve Liderlik, Stratejik Yönetim ve İşletme Politikası, İşletmeciler İçin Yönetim Bilimi: Temel Kavramlar Kuram ve İlkeler, Stratejik Yönetim, Stratejik Liderlik'tir. Analiz sonucunda ulaşılan kurallar ve açıklamaları Tablo 4.16.'da görülmektedir.

Tablo 4.16. Stratejik Yön. ve İşletme Politikası Dersine Ait Birliktelik Kuralları

Kural No	Kural ve Kural Açıklaması	Güven %
1	Kural: HD 31 /F396=t 20 ==> durum=Gecti 20 Açıklama: HD 31 /F396 kodlu Genel ve Endüstriyel Yönetim isimli kitabı ödünç alan 20 öğrenci bulunmaktadır. Bunlardan 20'si yani %100'ü Stratejik Yönetim ve İşletme Politikası dersinden geçmiştir.	100
2	Kural: HD 30.28/U54=t 20 ==> durum=Gecti 20 Açıklama: HD 30.28/U54 kodlu İşletmelerde Stratejik Yönetim isimli kitabı ödünç alan 20 öğrenci bulunmaktadır. Bunlardan 20'si yani %100'ü Stratejik Yönetim ve İşletme Politikası dersinden geçmiştir.	100
3	Kural: HD 57.7/ U53=t 15 ==> durum=Gecti 15 Açıklama: HD 57.7/ U53 kodlu Stratejik Yönetim ve Liderlik isimli kitabı ödünç alan 15 öğrenci bulunmaktadır. Bunlardan 15'i yani %100'ü geçmiştir.	100
4	Kural: HD 30.28/E67=t 10 ==> durum=Gecti 10 Açıklama: HD 30.28/E67 kodlu İşletmelerde Stratejik Yönetim ve İşletme Politikası isimli kitabı ödünç alan 10 öğrenci bulunmaktadır. Bunlardan 10'u yani %100'ü Stratejik Yönetim ve İşletme Politikası dersinden geçmiştir.	100
5	Kural: HF 5548.8 / K63=t 10 ==> durum=Gecti 10 Açıklama: HF 5548.8 / K63 kodlu İşletmeciler İçin Yönetim Bilimi: Temel kavramlar Kuram ve İlkeler isimli kitabı ödünç alan 10 öğrenci bulunmaktadır. Bunlardan 10'u yani %100'ü geçmiştir.	100
6	Kural: kitap_tur=Stratejik_Yonetim 105 ==> durum=Gecti 95 Açıklama: Stratejik Yönetim türünden kitap ödünç alan 105 öğrenciden 95'i yani %90'nı Stratejik Yönetim ve İşletme Politikası dersinden geçmiştir.	90
7	Kural: HD 30.28/.E735=t 30 ==> durum=Gecti 25 Açıklama: HD 30.28/.E735 kodlu Stratejik Yönetim isimli kitabı ödünç alan 30 öğrenci bulunmaktadır. Bunlardan 25'i yani %83'i Stratejik Yönetim ve İşletme Politikası dersinden geçmiştir.	83
8	Kural: HD 57.7/Y55=t 20 ==> durum=Gecti 15 Açıklama: HD 57.7/Y55 kodlu Stratejik Liderlik isimli kitabı ödünç alan 20 öğrenci bulunmaktadır. Bunlardan 15'i yani %75'i Stratejik Yönetim ve İşletme Politikası dersinden geçmiştir.	75

Tablo 4.16. 'nın devamı

Kural No	Kural ve Kural Açıklaması	Güven %
9	Kural: HD 57.7/ U53=t durum=Gecti 15 ==> notu=BA 8 Açıklama: HD 57.7/ U53 kodlu Stratejik Yönetim ve Liderlik isimli kitabı ödünç alan ve geçen 15 öğrenciden 8'i yani %67'si Stratejik Yönetim ve İşletme Politikası dersinden BA harf notu ile geçmiştir.	67
10	Kural: HD 57.7/Y55=t durum=Gecti 15 ==> notu=BA 8 Açıklama: HD 57.7/Y55 kodlu Stratejik Liderlik isimli kitabı ödünç alan ve geçen 15 öğrenciden 8'i yani %67'si Stratejik Yönetim ve İşletme Politikası dersinden BA harf notu ile geçmiştir.	67

Tablo 4.16.'da görüldüğü üzere Stratejik Yön. ve İşletme Politikası dersine ait birliktelik analizi sonucuna göre elde edilen kurallar, en düşük %67 en yüksek %100 güven aralığındadır. 6. kural incelendiğinde Stratejik Yön. ve İşletme Politikası dersi türünden kitap ödünç alanların %90'ının ilgili dersten geçtiği görülmektedir. Bu kurala göre Stratejik Yönetim ve İşletme Politikası dersi için kitap ödünç alımı ile dersten geçme durumu "geçti" arasında çok kuvvetli bir ilişki olduğu "kaldı" arasında ilişki olmadığı söylenebilir.

4.5.14. Maliyet Muhasebesi Dersine Ait Birliktelik Kuralları

Maliyet Muhasebesi dersine ait 15 adet attribute üzerinden gerçekleştirilen analiz sonucunda 76 adet kural içerisinden çalışmaya en uygun düşen 6 adet değerli kural mevcuttur. Maliyet Muhasebesi dersi için kullanıldığı tahmin edilerek analize giren kitap isimleri Maliyet Muhasebesi (Teori ve Uygulama), Maliyet Muhasebesi ve Yönetim: Tek Düzen Hesap Planına Uygun, Yönetim ve Maliyet Muhasebesi Uygulamaları, Maliyet Muhasebesi, Tekdüzen Hesap Planına Uygun Maliyet Muhasebesi'dir. Ulaşılan kurallar ve açıklamaları Tablo 4.17.'de görülmektedir.

Tablo 4.17. Maliyet Muhasebesi Dersine Ait Birliktelik Kuralları

Kural No	Kural ve Kural Açıklaması	Güven %
1	Kural: HF 5681/.C47 .M35=t 60 ==> durum=Gecti 60 Açıklama: HF 5681/.C47 .M35 kodlu Maliyet Muhasebesi (Teori ve Uygulama) isimli kitabı ödünç alan 60 öğrenci bulunmaktadır. Bunlardan 60'ı yani %100 Maliyet Muhasebesi dersinden geçmiştir.	100
2	Kural: HF 586/.B89=t 15==> durum=Gecti 15 Açıklama: HF 586/.B89 kodlu Maliyet Muhasebesi ve Yönetim: Tek Düzen Hesap Planına Uygun isimli kitabı ödünç alan 15 öğrenci bulunmaktadır. Bunlardan 15'i yani %100 Maliyet Muhasebesi dersinden geçmiştir.	100
3	Kural: HF 5686/ .M3 C35=t 24 ==> durum=Gecti 21 Açıklama: HF 5686/ .M3 C35 kodlu Yönetim ve Maliyet Muhasebesi Uygulamaları isimli kitabı ödünç alan 24 öğrenci bulunmaktadır. Bunlardan 21'i yani %88 Maliyet Muhasebesi dersinden geçmiştir.	88
4	Kural: kitap_tur=Maliyet_Muhasebesi 138 ==> durum=Gecti 111 Açıklama: Maliyet Muhasebesi türünde ödünç kitap alan 138 adet öğrenciden 111'i yani %80'ni Maliyet Muhasebesi dersinden geçmiştir.	80
5	Kural: notu=AA durum=Gecti 27 ==> HF 5686/.S39=t 21 Açıklama: AA harf notu ile geçen 27 öğrenciden 21'i yani %78'i HF 5686/.S39 kodlu Maliyet Muhasebesi isimli kitabı ödünç almışlardır.	78
6	Kural: HF 5686/.C8 .A83=t 27 ==> durum=Gecti 18 Açıklama: HF 5686/.C8 .A83 kodlu Tekdüzen Hesap Planına Uygun Maliyet Muhasebesi isimli kitabı ödünç alan 27 öğrenci bulunmaktadır. Bunlardan 18'i yani %67'si Maliyet Muhasebesi dersinden geçmiştir.	67

Tablo 4.17.'de görüldüğü üzere Maliyet Muhasebesi dersine ait birliktelik analizi sonucuna göre kurallar en düşük %67 en yüksek %100 güven aralığındadır. 4. kural incelendiğinde Maliyet Muhasebesi türünden kitap ödünç alanların %80'inin ilgili dersten geçtiği görülmektedir. Bu bağlamda Maliyet Muhasebesi dersi için kitap ödünç alımı ile dersten geçme durumu "geçti" arasında kuvvetli ilişki olduğu "kaldı" arasında ilişki olmadığı söylenebilir.

4.5.15. Finansal Yönetim I Dersine Ait Birliktelek Kuralları

Finansal Yönetim I dersine ait 14 adet attribute üzerinden gerçekleştirilen analiz sonucunda 186 adet kural tespit edilmiştir. Elde edilen kurallar içerisinde çalışmaya en uygun düşen 13 adet değerli kural bulunmaktadır. Finansal Yönetim I dersi için kullanıldığı tahmin edilerek analize giren kitap isimleri Finansal Yönetim, İşletme Finansı ve Finansal Yönetim, Değere Dayalı İşletme Finansı ve Finansal Yönetim, İşletmelerde Finansal Yönetim, Yönetim: Örnek Olayları ve Örnek Çözümleri'dir. Analiz sonucunda ulaşılan kurallar ve açıklamaları Tablo 4.18.'de görülmektedir.

Tablo 4.18. Finansal Yönetim I Dersine Ait Birliktelek Kuralları

Kural No	Kural ve Kural Açıklaması	Güven %
1	Kural: HG 4026/.B87=t 15 ==> durum=Gecti 15 Açıklama: HG 4026/.B87 kodlu Finansal Yönetim isimli kitabı ödünç alan 15 öğrenci bulunmaktadır. Bunlardan 15'i yani %100'ü Finansal Yönetim I dersinden geçmiştir.	100
2	Kural: HG 4026/.F56=t 15 ==> durum=Gecti 15 Açıklama: HG 4026/.F56 kodlu Finansal Yönetim isimli kitabı ödünç alan 15 öğrenci bulunmaktadır. Bunlardan 15'i yani %100'ü Finansal Yönetim I dersinden geçmiştir.	100
3	Kural: HG 4026/.U88=t 15 ==> durum=Gecti 15 Açıklama: HG 4026/.U88 kodlu İşletme Finansı ve Finansal Yönetim isimli kitabı ödünç alan 15 öğrenci bulunmaktadır. Bunlardan 15'i yani %100'ü Finansal Yönetim I dersinden geçmiştir.	100
4	Kural: HG 4026 /B85 F56=t 15 ==> durum=Gecti 15 Açıklama: HG 4026 /B85 F56 kodlu Finansal Yönetim isimli kitabı ödünç alan 15 öğrenci bulunmaktadır. Bunlardan 15'i yani % geçmiştir.	100
5	Kural: HG 4026 /B85 F56=t HG 4026 /E73=t 10 ==> durum=Gecti 10 Açıklama: HG 4026 /B85 F56 kodlu Finansal Yönetim isimli ve HG 4026 /E73 kodlu Değere Dayalı İşletme Finansı ve Finansal Yönetim isimli kitabı birlikte ödünç alan 10 öğrenci bulunmaktadır. Bunlardan 10'u yani %100'ü Finansal Yönetim I dersinden geçmiştir.	100
6	Kural: HG 4026/.A34=t durum=Gecti 10 ==> notu=CB 10 Açıklama: HG 4026/.A34 kodlu Finansal Yönetim isimli kitabı ödünç alan 10 öğrenci bulunmaktadır. Bunlardan 10'u yani %100'ü geçmiştir.	100
7	Kural: HG 4026/.C493=t HG 4026/.U88=t 10 ==> durum=Gecti 10 Açıklama: HG 4026/.C493 kodlu İşletmelerde Finansal Yönetim ve HG 4026/.U88 kodlu İşletme Finansı ve Finansal Yönetim isimli kitapları birlikte ödünç alan 10 öğrenci bulunmaktadır. Bunlardan 10'u yani %100'ü Finansal Yönetim I dersinden geçmiştir.	100

Tablo 4.18.'in devamı

Kural No	Kural ve Kural Açıklaması	Güven %
8	Kural: HG 4026 /O353=t 10 ==> durum=Gecti 10 Açıklama: HG 4026 /O353 kodlu Finansal Yönetim: Örnek Olayları ve Örnek Çözümleri isimli kitabı ödünç alan 10 öğrenci bulunmaktadır. Bunlardan 10'u yani %100'ü Finansal Yönetim I dersinden geçmiştir.	100
9	Kural: HG 4026/.C493=t 34 ==>durum=Gecti 29 Açıklama: HG 4026/.C493 kodlu İşletmelerde Finansal Yönetim isimli kitabı ödünç alan 34 öğrenci bulunmaktadır. Bunlardan 29'u yani %86'sı Finansal Yönetim I dersinden geçmiştir.	85
10	Kural: kitap_tur=Finansal_Yonetim 120 ==>durum=Gecti 99 Açıklama: Finansal Yönetim I türünden kitap ödünç alan 120 öğrenciden 99'u yani %83'ü Finansal Yönetim I dersinden geçmiştir.	83
11	Kural: HG 4026 /E73=t 25 ==> durum=Gecti 20 Açıklama: HG 4026 /E73 kodlu Değere Dayalı İşletme Finansı: Finansal Yönetim isimli kitabı ödünç alan 25 öğrenci bulunmaktadır. Bunlardan 20'si yani %80'ni Finansal Yönetim I dersinden geçmiştir.	80
12	Kural: HG 4026 /B85 F56=t durum=Gecti 15 ==> notu=CB 10 Açıklama: HG 4026 /B85 F56 kodlu Finansal Yönetim isimli kitabı ödünç alan ve geçen 15 öğrenciden 10'u yani %67'si CB harf notu ile geçmiştir.	67
13	Kural: HG 4026/.U88=t durum=Gecti 15 ==> notu=BB 10 Açıklama: HG 4026/.U88 kodlu İşletme Finansı ve Finansal Yönetim isimli kitabı ödünç alan ve geçen 15 öğrenciden 10'u yani %67'si BB harf notu ile geçmiştir.	67

Tablo 4.18.'de görüldüğü üzere Finansal Yönetim I dersine ait birliktelik analizi sonucuna göre en düşük %67 en yüksek %100 güven aralığında kurallar bulunmaktadır. 10. kural incelendiğinde Finansal Yönetim I türünden kitap ödünç alanların %83'nün ilgili dersten geçtiği görülmektedir. Bu kurala dayanarak Finansal Yönetim I dersi için kitap ödünç alımı ile dersten geçme durumu “geçti” arasında kuvvetli ilişki olduğu “kaldı” arasında ilişki olmadığı söylenebilir.

4.5.16. Mali Tablolar Analizi Dersine Ait Birliktelik Kuralları

Mali Tablolar Analizi dersine ait 12 adet attribute üzerinden gerçekleştirilen analiz sonucunda 108 adet kural tespit edilmiştir. Elde edilen kurallar içerisinde çalışmaya en uygun düşen 6 adet değerli kural bulunmaktadır. Mali Tablolar Analizi dersi için kullanıldığı tahmin edilerek analize giren kitap isimleri Mali Tablolar Analizi, Finansal Tablolar ve Mali Analiz Teknikleri, Muhasebe Denetimi ve Mali Analiz'dir. Analiz sonucunda ulaşılan kurallar ve açıklamaları Tablo 4.19.'da görülmektedir.

Tablo 4.19. Mali Tablolar Analizi Dersine Ait Birliktelik Kuralları

Kural No	Kural ve Kural Açıklaması	Güven %
1	Kural: kitap_tur=Mali_Tablolar_Analizi 72 ==> durum=Gecti 72 Açıklama: Mali tablolar analizi türünde kitap ödünç alan 72 öğrenciden 72'si yani %100'ü Mali Tablolar Analizi dersinden geçmiştir.	100
2	Kural: HF 5681 /B45 M35=t durum=Gecti 16 ==> notu=CC 16 Açıklama: HF 5681 /B45 M35 kodlu Mali Tablolar Analizi isimli kitabı ödünç alan ve geçen 16 öğrenciden 16'sı yani %100'ü ilgili dersten geçmiştir.	100
3	Kural: HF 5681/.G83=t durum=Gecti 16 ==> notu=CC 16 Açıklama: HF 5681/.G83 kodlu Mali Tablolar Analizi isimli kitabı ödünç alan ve geçen 16 öğrenciden 16'sı yani %100'ü ilgili dersten geçmiştir.	100
4	Kural: HF 5681/.A63=t 12 ==> durum=Gecti 12 Açıklama: HF 5681/.A63 kodlu Finansal Tablolar ve Mali Analiz Teknikleri isimli kitabı ödünç alan 12 öğrenci bulunmaktadır. Bunlardan 12'si yani %100'ü Mali Tablolar Analizi dersinden geçmiştir.	100
5	Kural: notu=CB durum=Gecti 12 ==> HF 5667/.G875=t 8 Açıklama: CB harf notu ile geçen 12 öğrenciden 8'i yani %67'si HF 5667/.G875 kodlu Muhasebe Denetimi ve Mali Analiz isimli kitabı ödünç almışlardır.	67

Tablo 4.19.'da görüldüğü üzere Mali Tablolar Analizi dersine ait birliktelik analizi sonucuna göre en düşük %67 en yüksek %100 güven aralığında kurallar bulunmaktadır. 1. kural incelendiğinde Mali Tablolar Analizi türünden kitap ödünç alanların %100'ünün ilgili dersten geçtiği görülmektedir. Bu kurala dayanarak Mali Tablolar Analizi dersi için kitap ödünç alımı ile dersten geçme durumu "geçti" arasında çok kuvvetli ilişki olduğu "kaldı" arasında ilişki olmadığı söylenebilir.

4.5.17. Muhasebe Uygulamaları Dersine Ait Birliktelik Kuralları

Muhasebe Uygulamaları dersine ait 20 adet özellik üzerinden gerçekleştirilen analiz sonucunda 47 adet kural tespit edilmiştir. Elde edilen kurallar içerisinde çalışmaya en uygun düşen 6 adet değerli kural bulunmaktadır. Muhasebe Uygulamaları dersi için kullanıldığı tahmin edilerek analize giren kitap isimleri Şirketler Muhasebesi: Tek Düzen Muhasebe Planına Uygun, Tek Düzen Hesap Planına Göre Hazırlanmış, Banka İşlemleri ve Muhasebesi, Şirketler Muhasebesi, Banka Muhasebesi'dir. Kurallar ve açıklamaları Tablo 4.20.'de görülmektedir.

Tablo 4.20. Muhasebe Uygulamaları Dersine Ait Birliktelik Kuralları

Kural No	Kural ve Kural Açıklaması	Güven %
1	Kural: kitap_tur=Muhasebe_Uygulamalari 105 ==> durum=Gecti 105 Açıklama: Muhasebe uygulamaları türünden kitap ödünç alan 105 öğrenciden 105'i yani %100'ü Muhasebe Uygulamaları dersinden geçmiştir.	100
2	Kural: HF 5686/.A47=t 24 ==> durum=Gecti 24 Açıklama: HF 5686/.A47 kodlu Şirketler Muhasebesi: Tek Düzen Muhasebe Planına Uygun isimli kitabı ödünç alan 24 öğrenci bulunmaktadır. Bunlardan 24'ü yani %100'ü Muhasebe Uygulamaları dersinden geçmiştir.	100
3	Kural: HF 5686/.K57=t 24 ==> durum=Gecti 24 Açıklama: HF 5686/.K57 kodlu Tek Düzen Hesap Planına Göre Hazırlanmış isimli kitabı ödünç alan 24 öğrenci bulunmaktadır. Bunlardan 24'ü yani %100'ü ilgili dersten geçmiştir.	100
4	Kural: HG 1707/.A475 2000=t 21 ==> durum=Gecti 21 Açıklama: HG 1707/.A475 2000 kodlu Banka İşlemleri & Muhasebesi isimli kitabı ödünç alan 21 öğrenci bulunmaktadır. Bunlardan 21'i yani %100'ü Muhasebe Uygulamaları dersinden geçmiştir.	100
5	Kural: HF 5686/.C35=t 15 ==> durum=Gecti 15 Açıklama: HF 5686/.C35 kodlu Şirketler Muhasebesi isimli kitabı ödünç alan 15 öğrenci bulunmaktadır. Bunlardan 15'i yani %100'ü geçmiştir.	100
6	Kural: HG 2160/.M84=t 15 ==> durum=Gecti 15 Açıklama: HG 2160/.S48 kodlu Banka ve Muhasebesi isimli kitabı ödünç alan 15 öğrenci bulunmaktadır. Bunlardan 15'i yani %100'ü geçmiştir.	100

Tablo 4.20.'de görüldüğü üzere Muhasebe Uygulamaları dersine ait birliktelik analizi sonucuna göre kuralların tamamı %100 güvene sahiptir. 1. kural incelendiğinde Muhasebe Uygulamaları türünden kitap ödünç alanların %100'ünün ilgili dersten geçtiği görülmektedir. Bu bağlamda Muhasebe Uygulamaları dersi için kitap ödünç alımı ile dersten geçme durumu "geçti" arasında çok kuvvetli ilişki olduğu "kaldı" arasında ilişki olmadığı söylenebilir.

5. BÖLÜM SONUÇ VE ÖNERİLER

Günümüz bilişim teknolojileri vasıtasıyla gerçekleşen yoğun veri üretimi birçok sektör için, üretilen veriyi doğru bir şekilde kullanma ve veriden anlamlı bilgiler elde etme ihtiyacını doğurmaktadır. Doğru yöntemlerle analiz edilen veriden elde edilen bilgi sayesinde karar vericiler karar aşamalarında stratejik hareket etme şansını da yakalayabilirler. Ancak üretilen veriyi klasik yöntemlerle analiz etmek zor ve zahmetli olabilmektedir. Bu aşamada veri madenciliğinin gelişmiş teknikleri ile problemleri çözmek, ilişkileri kurmak, aykırılıkları tespit etmek, gelecekte oluşabilecek durumları tahmin etmek mümkündür.

Bu çalışmada Uşak Üniversitesi İİBF İşletme bölümü öğrencilerinin 2007 – 2018 yılları arasında bahar ve güz akademik dönemlerinde kütüphaneden ödünç almış oldukları zorunlu ders içerikli kitaplar ile 2007 – 2018 yılları arasında bahar ve güz akademik dönemlerinde zorunlu derslere ait geçme - kalma durumları ve harf notları arasındaki ilişki analiz edilmiştir. Analiz sonucunda Araştırma Problemi 1. ve Araştırma Problemi 2.'de tanımlanan problemlere cevaplar aranmıştır. Bu doğrultuda öğrencilerin kütüphaneden ödünç almış oldukları kitaplar ile ders başarıları arasındaki ilişkiler incelenmiştir. Analiz ile elde edilen bilgilerin, kütüphane ve öğretim üyelerinin karar verme aşamalarında alacakları kararların kalitesini arttırmaya yardımcı bilgiler olması amaçlanmıştır.

Analiz için tercih edilen yöntem veri madenciliğidir. Veri madenciliği WEKA yazılımı ile uygulanmıştır. WEKA açık kaynak kodlu, kullanımı kolay ve analiz sonuçları anlaşılır bir yazılımdır. Ayrıca birçok akademik çalışmada tercih edilen bir yazılımdır. Analiz için tercih edilen veri madenciliği yöntemi, birliktelik analizidir. Birliktelik analizi ile veri seti içerisinde sık geçen öğeler bulunarak ilişki kuralları elde edilebilir. Birliktelik analizi içerisinde en çok bilinen algoritma Apriori algoritmasıdır. Analiz WEKA veri madenciliği yazılımında mevcut olan Apriori algoritması ile gerçekleştirilmiştir.

Apriori algoritması ile 17 adet zorunlu ders analiz edilerek zorunlu ders içerikli kitap kullanımı ile o derse ait başarı durumu arasındaki birliktelik kuralları elde edilmiştir. Analiz sonucunda değerli kurallar elde edilen dersler Genel İşletme I,

Genel İşletme II, İktisada Giriş I, Genel Muhasebe I, Genel Muhasebe II, Makro İktisat, İşletme Yönetimi, Davranış Bilimleri, Pazarlama İlkeleri, Sosyal Bilimlerde Araştırma Yöntemleri, Örgütsel Davranış, İnsan Kaynakları Yönetimi, Stratejik Yönetim ve İşletme Politikası, Maliyet Muhasebesi, Finansal Yönetim I, Mali Tablolar Analizi, Muhasebe Uygulamaları'dır.

Bu kapsamda kütüphane kullanımı ve ders başarısı arasındaki ilişkiye bakıldığında Araştırma Problemi 1'de tanımlanan problem sorusuna cevap veren ve dersten geçmeye yüksek oranda katkı sağlayan (güven: %100) kitaplar bulunmaktadır. Bu kitaplar **Genel İşletme I** dersi için '*Genel İşletmecilik*', **İktisada Giriş I** dersi için '*Mikro Ekonomi*', **Genel Muhasebe** dersi için '*Genel Muhasebe*', **Makro İktisat** dersi için '*Makro Ekonomi Türkçe*' isimli kitaplardır. Ayrıca dersten geçmeye yüksek oranda katkı sağlayan (güven: %100) kitapların, **Davranış Bilimleri** dersi için '*Davranış Bilimlerine Giriş, Örgütsel Davranış ve Yönetim Psikolojisi*', **Pazarlama İlkeleri** dersi için '*Pazarlama İlkeleri, Pazarlama Stratejileri, Tüketici Davranışı ve Pazarlama Stratejileri: Global ve Yerel Yaklaşım, Pazarlama: İlkeler - Yönetim - Örnek Olaylar*' isimli kitaplar olduğu tespit edilmiştir. Yukarıda sayılan kitapların yanı sıra **Sosyal Bilimlerde Araştırma Yöntemleri** dersi için '*Sosyal Bilimlerde Araştırma Yöntemleri SPSS Uygulamalı, Nicel-Nitel Araştırma Teknikleri Sos. Bil. Araş. Tek. Nicel Mi? Nitel Mi?, Sosyal Bilimlerde Araştırma Yöntemleri ve Teknikleri, SPSS Uygulamalı Temel İstatistik Yöntemler*', **Örgütsel Davranış** dersi için '*Örgütsel Davranış, Örgütsel Davranış: İnsanın Üretim Gücü*', **İnsan Kaynakları Yönetimi** dersi için '*İnsan Kay. Yön. İnsan Kay. Plan. Norm Kadro Uyg., Endüstri İlişkileri Boyutunda Çok Uluslu Şirketler ve İnsan Kaynağı Yönetimi : Teori ve Uygulama*' isimli kitapların dersten geçmeye yüksek oranda (güven: %100) katkısı görülmektedir. Yine **Stratejik Yönetim ve İşletme Politikası** dersi için '*Genel ve Endüstriyel Yönetim, İşletmelerde Stratejik Yönetim, Stratejik Yönetim ve Liderlik, İşletmelerde Stratejik Yönetim ve İşletme Politikası, İşletmeciler İçin Yönetim Bilimi: Temel Kavramlar Kuram ve İlkeler*', **Maliyet Muhasebesi** dersi için '*Maliyet Muhasebesi (Teori ve Uygulama), Maliyet Muhasebesi ve Yönetim: Tek Düzen Hesap Planına Uygun*'

isimli kitapların dersten geçmeye yüksek oranda (güven: %100) katkısı bulunmaktadır. Bununla birlikte **Finansal Yönetim** dersi için '*Finansal Yönetim, İşletme Finansı ve Finansal Yönetim, Değere Dayalı İşletme Finansı ve Finansal Yönetim İşletmelerde Finansal Yönetim, Finansal Yönetim: Örnek Olayları ve Örnek Çözümleri*', **Mali Tablolar Analizi** dersi için '*Mali Tablolar Analizi, Finansal Tablolar ve Mali Analiz Teknikleri*' isimli kitapların yine dersten geçmeye yüksek oranda (güven: %100) katkısı görülmüştür. Bu kitapların yanı sıra **Muhasebe Uygulamaları** dersi için '*Şirketler Muhasebesi: Tek Düzen Muhasebe Planına Uygun, Tek Düzen Hesap Planına Göre Hazırlanmış ve Son Değişikliklere Göre Gözden Geçirilmiş Şirketler Muhasebesi, Banka İşlemleri & Muhasebesi, Şirketler Muhasebesi, Banka ve Muhasebesi*' isimli kitapların dersten geçmeye yüksek oranda (güven: %100) katkısı tespit edilmiştir. Akademisyenler ile kütüphane yetkililerinin, öğrencilere kitap ödünç alımlarında yukarıda sayılan kitapları da tavsiye etmeleri önerilebilir.

Ayrıca Araştırma Problemi 1'de tanımlanan problem sorusuna cevap veren ve dersten geçmeye katkı sağlayan (güven:%75 - %99) kitapların ise, **Genel İşletme I** dersi için '*İşletmecilik: Kuram ve Uygulama*', **Genel İşletme II** dersi için '*Modern İşletmecilik*', **Genel Muhasebe I** dersi için '*Genel Muhasebe*', **Genel Muhasebe II** dersi için '*Muhasebe Uygulamaları, Muhasebe Denetimi ve Mali Analiz*' isimli kitaplar olduğu görülmektedir. Bununla birlikte **Makro İktisat** dersi için '*Makro Ekonomi: Teori ve Politika, Makro Ekonomi*', **İşletme Yönetimi** dersi için '*Girişimcilik ve Küçük İşletme Yöneticiliği, Küreselleşme Sürecinde İşletme Yönetimi*' isimli kitapların katkısı tespit edilmiştir. Ayrıca **Stratejik Yönetim ve İşletme Politikası** dersi için '*Stratejik Yönetim ve Stratejik Liderlik*', **Maliyet Muhasebesi** dersi için '*Yönetim ve Maliyet Muhasebesi Uygulamaları*' isimli kitapların dersten geçmeye katkı sağladığı (güven:%75 - %99) görülmektedir. Yine akademisyenler ile kütüphane yetkililerinin, öğrencilere kitap ödünç alırken bu kitapları da tavsiye etmeleri önerilebilir.

Yine Araştırma Problemi 1’de tanımlanan problem soruna göre (güven:%75 ve üzeri) ders başarısında katkısı sık geçmeyen kitaplara da rastlanmıştır. Bu kitaplar **İktisada Giriş I** dersi için ‘*Mikro İktisat*’, **İnsan Kaynakları Yönetimi** dersi için ‘*İş ve İnsan İlişkileri*’ isimli kitaplardır. Tespit edilen bu kitaplara ait karşılaştırılma yapılabilmesi için başka üniversitelerde ki durumunun da araştırılması önerilmektedir.

Araştırma Problemi 2’de tanımlanan problem sorusuna cevap veren (güven: %75 ve üzeri) kitaplar ise **Genel İşletme I** dersi için ‘*İşletme Biliminin Temel İlkeleri*’, **Makro İktisat** dersi için ‘*Makro Ekonomi*’, **İşletme Yönetimi** dersi için ‘*Girişimcilik ve Küçük İşletme Yönetimi*’, **Davranış Bilimleri** dersi için ‘*Davranış Bilimleri ve Örgütsel Davranış*’, **Pazarlama İlkeleri** dersi için ‘*Pazarlama İlkeleri*’ isimli kitaplardır. Bu kitapların CC harf notuyla geçme arasında ilişkisi tespit edilmiştir. **Maliyet Muhasebesi** dersi için ise ‘*Maliyet Muhasebesi*’ isimli kitabın AA harf notu ile geçmeye katkı sağladığı tespit edilmiştir. Diğer dersler için ise Araştırma Problemi 2’ye cevap veren kitaplara rastlanamamıştır. Bu durum araştırmayı kısıtlamaktadır. Ayrıca yukarıda sayılan dersler için CC harf notu ile geçmenin daha sık oluşu dikkat çekmektedir. Bu durumun nedenlerinin de araştırılması önerilmektedir.

Analiz edilen derslere ait bilgiler karşılaştırıldığında elde edilen bir diğer sonuç ise tüm zorunlu dersler için kitap ödünç alımı ile dersten geçme durumu arasında ilişki bulunduğu sonucudur. Ancak dersten kalma durumu arasında yalnızca İktisada Giriş I dersi için ilişkiye rastlanılmıştır. Bu durumdan yola çıkarak genel olarak, İİBF İşletme bölümü için kitap ödünç alımının dersten geçmeyi etkilediği bir diğer ifadeyle kitap kullanımının dersten geçme durumuna olumlu katkıda bulunduğu sonucuna varabiliriz.

Veri madenciliği çalışmalarında daha ayrıntılı bilgiler elde edilmesi için veri tabanlarına ulaşmak önemlidir. Bu ulaşım ile ilgili kısıtlılıklar derinlemesine inceleme yapılmasını engelleyebilmektedir. Bundan sonraki çalışmalar için analizin tüm üniversiteyi kapsaması ve ders harf notlarındaki yığılmaya ait sebeplerin

araştırılması önerilmektedir. Ayrıca çalışmada analize giren kitaplar ile ilgili sonuçların diğer üniversitelerdeki durumunu karşılaştırabilmek için benzer uygulamaların yapılması gereklidir. Bu çalışmada yalnızca kitap ödünç alan öğrencilerin ders başarısına odaklanılmıştır. İleriki çalışmalar için kütüphaneden kitap ödünç alan öğrencilerin, kitap almayan öğrencilere göre başarı farkları incelenebilir. Ayrıca kitap ödünç alımı ile ders başarısı arasındaki ilişkiyi tek bir platformda birleştirerek analiz edecek bir otomasyon sistemi oluşturulması ve yapay zeka uygulaması diğer çalışmalar için önerilmektedir.

EKLER**EK 1: Yayın Etiği Kurulu Kararları**

T.C.
UŞAK ÜNİVERSİTESİ
SOSYAL VE BEŞERİ BİLİMLER
BİLİMSEL ARAŞTIRMA VE YAYIN ETİĞİ KURULU KARARLARI

TOPLANTI SAYISI: 12**KARAR TARİHİ: 09.11.2017**

Üniversitemiz Bilimsel Araştırma ve Yayın Etiği Yönergesi gereğince, Sosyal ve Beşeri Bilimler Bilimsel Araştırma ve Yayın Etiği Kurulu, Kurul Başkanı Prof. Dr. Sayın DALKIRAN toplanarak gündem maddesinin görüşülmesine geçilmiştir.

KARAR 2017-66

Yüksek Lisans öğrencisi Şükran ARMUTLU'nun Yrd. Doç. Dr. Gülten DEMİRAL danışmanlığında yapmayı planladığı "Veri Madenciliği Yöntemiyle Kütüphaneden Yararlanma Düzeyi ve Ders Başarısı Arasındaki İlişkinin İncelenmesi: Uşak Üniversitesi Örneği" başlıklı araştırmasının ve bu araştırma kapsamında uygulanacak yöntemlerin etik açıdan uygun olduğuna katılanların oybirliği ile karar verilmiştir.

No	Üyenin Adı Soyadı	İmza	No	Üyenin Adı Soyadı	İmza
1	Prof. Dr. Sayın DALKIRAN Başkan	İMZA	4	Prof. Dr. Lütfi ÖZAV Üye	İMZA
2	Prof. Dr. Cemil ERTUĞRUL Başkan Yardımcısı	İMZA	5	Prof. Dr. Ali YILMAZ Üye	İMZA
3	Prof. Dr. Suat ŞAHİNLER Üye	İMZA	6	Prof. Dr. Sadiye TUTSAK Üye	GÖREVLİ
7	Prof. Dr. Mehmet KARAYAMAN Üye	İMZA		Av. Zakire BAYRAKTAR DÜZGÜN Raportör	İMZA

ASLI GİBİDİR
AVUKAT
Zakire BAYRAKTAR DÜZGÜN



EK 2: LC Sınıflama Sistemi

- A Genel yapıtlar
 B Felsefe, Psikoloji, Din
 C Tarihe yardımcı bilimler
 CB Uygarlık tarihi
 CC Arkeoloji
 CT Biyografi
 D Tarih
 DRTürkiye tarihi
 DS Asya tarihi
 E-F Amerika tarihi
 G Coğrafya, Antropoloji, Turizm
 GN Antropoloji
 GR Folklor
 GV Rekreasyon, Spor
 H Sosyal bilimler
 HA İstatistikler
 HB Ekonomik teori
 HC Ekonomik tarih
 HD Sanayi, İşletme
 HE Taşımacılık,
 Telekomünikasyon
 HF Ticaret
 HG Finans
 HJ Kamu maliyesi
 HM Sosyoloji
 J Siyaset bilimi
 JK – JQ Siyaset ve yönetim
 JK Türkiye
 JX Uluslararası hukuk,
 Uluslararası ilişkiler
 K Hukuk
 KB-KKZ Tek tek bölge ya da
 ülkeler
 KB Türkiye
 L Eğitim
 LC Eğitim biçimleri
 M Müzik
 N Güzel sanatlar
 NA Mimarlık
 NK Dekoratif sanatlar,
 Uygulamalı sanatlar,
 Dekorasyonve süsleme
 P Dil ve edebiyat
 PE İngiliz dili
 PL Türk dili ve edebiyatı
 PR İngiliz edebiyatı
 PS Amerikan edebiyatı
 Q Bilim
 QA Matematik, İstatistik,
 Bilgisayar
 QC Fizik
 QD Kimya
 QK Botanik
 R Tıp
 S Tarım
 T Teknoloji
 TA Mühendislik. İnşaat
 mühendisliği
 TK Elektrik mühendisliği.
 Elektronik, Nükleer
 mühendislik
 TL Havacılık, Uzay havacılığı
 TR Fotoğrafçılık
 TX Ev ekonomisi
 U Askerlik
 V Denizcilik
 Z Kaynakçalar, Kütüphanecilik

EK 3: Analize Giren Kitaplar Listesi

Kitap Kod	Kitap Ad	Yazar
HD 37 .T8 G46	Genel İşletmecilik Bilgileri	Ahmet Aksoy
HD 37 /.T8 D46	İşletmecilik: Kuram ve Uygulama	Gülten Eren Gümüş Tekin
HF 5351/ .E77	İşletme biliminin temel ilkeleri	Mümin Ertürk
HF 5351/.O94	Temel işletmecilik bilgisi	Hüseyin Özgen, Azmi Yalçın
HD 37.T8 M83	Modern İşletmecilik	İsmet Mucuk
HD 62.5 /D66 G57	Girişimcilik ve Küçük İşletme Yöneticiliği	Serpil Döm
HF 5351/.G46	Genel İşletme	Şan Özalp v.d.
HB 172 /D56	Mikro Ekonomi	Zeyner Dinler
HB 172/.K35	Mikro İktisat	Murat Kalenderoğlu, Mahmut Kalenderoğlu
HB 171.5/.P37	Mikro Ekonomi	M. İlker Parasız
HF 5625/.C46	Genel Muhasebe	Özgül Cemalcılar
HF 5625 /C66 G46	Genel Muhasebe	Kemalettin Çonkar vd.
HF 5625/.S97	Genel Muhasebe	Fevzi Sürmeli, Yılmaz Benli Giray
HF 5625/.M83	Muhasebe Uygulamaları	Sabri Bektöre
HF 5667/.G875	Muhasebe Denetimi ve Mali Analiz	Ersin Güredin
HF 5667/.C65	Muhasebe Denetimi	Ferruh Çömlekçi
HB 172.5/F58	Makro Ekonomi Türkçe	Salih Ak
HB 172.5/P37	Makro Ekonomi: Teori ve Politika	M. İlker Parasız
HB 172.5/Y560	Makro Ekonomi	Kemal Yıldırım vd.
HB 172.5/ .D67	Makro Ekonomi	Rudiger Dornbusch
HD 62.5/D66 G57	Girişimcilik ve Küçük İşletme Yöneticiliği	Serpil Döm
HF 5351/.T88 K87	Küreselleşme Sürecinde İşletme Yönetimi	Hasan Tutar
HF 5548.8/.D38	Davranış Bilimlerine Giriş	Enver Özkalp
HF 5548.8/.E76	Davranış Bilimleri	Fezullah Eroğlu
HD 58.7/.O94	Örgütsel Davranış	Enver Özkalp
HD 58.82/.E64	Örgütsel Davranış ve Yönetim Psikolojisi	Erol Eren
HF 5415/.M83	Pazarlama İlkeleri	İsmet Mucuk
HF 5415 /P39	Pazarlama Stratejileri	Ömer Torlak, Remzi Altunışık
HF 5415.32 /K63 T85	Tüketici Davranışı ve Pazarlama Stratejileri: global ve yerel yaklaşım	Erdoğan Koç
HF 5415/Y85 P39	Pazarlam : İlkeler - Yönetim - Örnek Olaylar	Cemal Yükselen
HF 5438.25 /C37	Satış Sanatı Pazarlama	Herbert Newton
H 61.6/ S67	Sosyal Bilimlerde Araştırma Yöntemleri SPSS Uygulamalı	Engin Yıldırım vd.
H 62 /K87 N53	Nicel-Nitel Araş. Tek.: sosyal bilimlerde araştırma teknikleri nicel mi? nitel mi?	Elif Kuş
H 62/A95 S67	Sosyal Bil. Araş. Yönt.ve Teknikleri	Aysel Aziz
HA 29.5/ U58 S67	SPSS Uygulamalı Temel İstatistik Yöntemler	Özkan Ünver vd.
HD 58.7/.O94	Örgütsel Davranış	Enver Özkalp vd.

Kitap Kod	Kitap Ad	Yazar
HD 58.7/.B37	Örgütsel Davranış: İnsanın Üretim Gücü	İbrahim Ethem Başaran
HD 30.213 /A34	Bilgi Yönetimi ve Öğrenen Örgütler	Ali Ekber Akgün
HF 5549/ A33	İnsan Kaynakları Yönetimi , İns. Kay. planlaması norm kadro uygulaması	Murat Akçayaka
HF 5548/.K88	Endüstri ilişkileri boyutunda çok uluslu şirketler ve insan kaynağı yönetimi : teori ve uygulama	Gülten Kutsal vd.
HQ 734/.K63	İş ve İnsan İlişkileri	Hakan Koç
HD 31 /F396	Genel ve Endüstriyel Yönetim	Henri Fayol
HD 30.28/.U54	İşletmelerde Stratejik Yönetim	Hayri Ülgen
HD 57.7/ U53	Stratejik Yönetim ve Liderlik	Mesud Ünal
HD 30.28/E67	İşletmelerde Stratejik Yönetim ve İşletme Politikası	Erol Eren
HF 5548.8 / K63	İşletmeciler İçin Yönetim Bilimi : temel kavramlar, kuramlar ve ilkeler	Hakan Koç, Melih Topaloğlu
HD 30.28/.E735	Stratejik Yönetim	Erol Eren, Necdet Timur
HD 57.7/Y55	Stratejik Liderlik	Hakan Yılmaz
HF 5681/.C47.M35	Maliyet Muhasebesi (Teori ve Uygulama)	Ertuğrul Çetiner
HF 586/.B89	Maliyet ve Yönetim Muhasebesi: tekdüzene uygun bir sistem yaklaşımı	Kamil Büyükmirza
HF 5686/ .M3 C35	Yönetim ve Maliyet Muhasebesi Uygulamaları	Yurdakul Çaldağ
HF 5686/.C8 .A83	Tekdüzen Hesap Planına Uygun Maliyet Muhasebesi	Celaleddin Atamanalp vd.
HG 4026/.B87	Finansal Yönetim	Nurhan Aydın vd.
HG 4026/.F56	Finansal Yönetim	Mine Tükenmez vd.
HG 4026/.U88	İşletme Finansı ve Finansal Yönetim	Öcal Usta
HG 4026 /B85 F56	Finansal Yönetim	Semih Büker vd.
HG 4026 /E73	Değere Dayalı İşletme Finansı ve Finansal Yönetim	Metin Kamil Ercan, Ünsal Ban
HG 4026/.C493	İşletmelerde Finansal Yönetim	Ali Ceylan
HG 4026 /O353	Finansal Yönetim: Örnek Olayları ve Örnek Çözümleri	Osman Okka
HF 5681 /B45 M35	Mali Tablolar Analizi	Sabri Bektöre vd.
HF 5681/.G83	Mali Tablolar Analizi	Ümit Gücenme
HF 5681/.A63	Finansal Tablolar ve Mali Analiz Teknikleri	Nalan Akdoğan, Nejat Tenker
HF 5667/.G875	Muhasebe Denetimi ve Mali Analiz	Ersin Gürledin, Fevzi Sürmeli
HF 5686/.A47	Şirketler Muhasebesi: Tek Düzen Muhasebe Planına Uygun	Bilgütay Akşit
HF 5686/.K57	Tek Düzen Hesap Planına Göre Hazırlanmış ve son değişikliklere göre gözden geçirilmiş Şirketler Muhasebesi	Yunus Kışal
HG 1707/.A475 2000	Banka İşlemleri & Muhasebesi	Osman Altuğ
HF 5686/.C35	Şirketler Muhasebesi	Yurdakul Çaldağ
HG 2160/.M84	Banka ve Muhasebesi	Muharrem Müftüoğlu

KAYNAKÇA

- Abidin, D., Öztürk, Ö. ve Özacar, T. (2017). Klasik Türk Müziğinde Makam Tanıma İçin Veri Madenciliği Kullanımı. *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 32(4), 1221-1232.
- Abrar, V. A. & Wahyudi, M. D. R. (2016). Implementasi Heterogenous Distributed Database System Oracle Xe 10g dan MySQL Rekam Medis Poliklinik UIN Sunan Kalijaga. *Creative Information Technology Journal*, 4(1), 9-17.
- Aggarwal, N., Kumar, A., Khatter, H. & Aggarwal, V. (2012). Analysis The Effect of Data Mining Techniques on Database. *Advances in Engineering Software*, 47, 164-169.
- Aher, S. B. & Lobo, L. M. R. J. (2011). Data Mining In Educational System Using Weka. In *IJCA Proceedings on International Conference on Emerging Technology Trends (ICETT) Vol3*, 20-25.
- Ahmed, A. B. E. D. & Elaraby, I. S. (2014). Data Mining: A Prediction for Student's Performance Using Classification Method. *World Journal of Computer Application and Technology*, 2(2), 43-47.
- Akar, M. ve Gündoğdu, S. (2014). Bayes Teorisinin Su Ürünlerinde Kullanım Olanakları. *Journal of Fisheries Sciences*, 8 (1), 8-16.
- Aksoy, E. ve Narli, S. (2015). Matematik Alanında Üstün Yetenekli Öğrencilerin Öğrenme Stillerinin Karar Ağaçları Kullanılarak İncelenmesi. *Türk Üstün Zekâ ve Eğitim Dergisi*, 5(2), 147-155.
- Al Ghoson, A. M. (2010). Decision Tree İnduction & Clustering Techniques in SAS Enterprise Miner, SPSS Clementine, and IBM Intelligent Miner-a comparative analysis. *International Journal of Management and Information Systems*, 14(3), 57-70.
- Alagöz, A., Öge, S. ve Ortakarpuz, M. (2014). Bir Kurumsal Zekâ Teknolojisi Olarak Veri Madenciliği İle Muhasebe Bilgi Sistemi İlişkisi. *Selçuk Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 1-21.
- Alan, M. A. (2012). Veri Madenciliği ve Lisansüstü Öğrenci Verileri Üzerine Bir Uygulama. *Dumlupınar Üniversitesi Sosyal Bilimler Dergisi*, (33), 165-174.
- Albayrak, M. (2017). Bilimsel Araştırmalarda Veri Madenciliği Kullanımı. *International Journal of Social Sciences and Education Research*. 3(3), 751-760.
- Albayrak, A. S. ve YILMAZ, Ö. G. Ş. K. (2009). Veri Madenciliği: Karar ağacı Algoritmaları ve İMKB Verileri Üzerine Bir Uygulama. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 14(1), 31-52.

- Amatriain, X., Jaimes, A., Oliver, N. & Pujol, J. M. (2015). Data Mining Methods for Recommender Systems. *In Recommender Systems Handbook. Springer US*, 39-71.
- Amato, G., Candela, L., Castelli, D., Esuli, A., Falchi, F., Gennaro, C., et al (2018). How Data Mining and Machine Learning Evolved from Relational Data Base to Data Science. *Springer International Publishing*, 287-306.
- Anamisa, D. R., Yusuf, M. & Syakur, M. A. (2018). Determination System of Food Vouchers for The Poor Based On Fuzzy C-Means Method. *In Journal of Physics: Conference Series*, 953(1),1-7.
- Argüden, Y. ve Erşahin, B. (2008). Veri Madenciliği: Veriden Bilgiye, Masraftan Değere. *ARGE Danışmanlık Yayınları*, (10).
- Ataseven, B. (2013). Yapay Sinir Ağları İle Öngörü Modellemesi. *Öneri Dergisi*, 10(39),101-115.
- Atlı, D.(2014) Bilgi Çağında İşletmeler Açısından Bilgi Yönetimi ve Stratejik Önemi. *XVI. Akademik Bilişim Konferansı*. 631-637.
- Aydın, E. A. ve Keleş, M. K. (2017). Breast cancer Detection Using K-Nearest Neighbors Data Mining Method Obtained From the Bow-Tie Antenna Dataset. *International Journal of RF and Microwave Computer-Aided Engineering*, 27(6), 1-10.
- Aydın, S. ve Özkul, A.E. (2015). Veri Madenciliği ve Anadolu Üniversitesi Açıköğretim Sisteminde Bir Uygulama. *Eğitim ve Öğretim Araştırmaları Dergisi*, 4(3), 36-44.
- Ayhan, S. ve Erdoğan, Ş. (2014). Destek Vektör Makineleriyle Sınıflandırma Problemlerinin Çözümü İçin Çekirdek Fonksiyonu Seçim. *Eskişehir Osmangazi Üniversitesi İİBF Dergisi*, 9(1), 175- 198.
- Aytaç, M. B. (2013), Doğrudan Pazarlama Aracı Olarak Tele Pazarlama İçin Veri Madenciliği Çözümleri: Banka Müşterileri Üzerine Bir Uygulama. Yüksek Lisans Tezi, Gazi Üniversitesi, Bilişim Enstitüsü, Ankara.
- Azam, I., Sohrawardi, S. J., Das, H. S., Alam, M. S., Alvy, M. S. & Rahman, R. M. (2013). Bibliomining on North South University Library Data. *In Digital Information Management (ICDIM), Eighth International Conference*, 235-240.
- Baradwaj, B. K & Pal, S. (2011). Mining Educational Data to Analyze Students' Performance. *International Journal of Advanced Computer Science and Applications*, 2(6), 63-69.

- Bargavi, C. (2017). Analysis of accuracy and Performance of Big Data Using Data Mining Techniques in Hadoop Mapreduce. *Advances in Natural and Applied Sciences*, 11(4), 169-175.
- Baruah, A. & Choudhary, K. (2017) Comparison of Accuracies of Parkinson's Disease Dataset Using Different Data Mining Tools. *International Journal of Technical Research & Science*. 2(4), 269-278.
- Bikari, S., Ünal, S. ve Deveci, F. G. (2017). Tüketicilerin Çevreye Yönelik Tutumları ve Kişilik Özellikleri Açısından Kohonen Ağları (Self-Organizing Map-Som) İle Bölümlendirilmesi. *Uluslararası İktisadi ve İdari İncelemeler Dergisi*, 145-162.
- Bircan, H. ve S. Çam, (2016). Veri Madenciliğinde Kümeleme Analizi ve Sağlık Sektöründe Bir Uygulaması. *Cumhuriyet Üniversitesi İktisadi ve İdari Bilimler Dergisi*, Vol.17, No.2, s.85-96.
- Biggio, B., Nelson, B. & Laskov, P. (2012). Poisoning Attacks Against Support Vector Machines. *29th International Conference on Machine Learning*, 1467-1474.
- Bilen, Ö., Hotaman, D., Aşkın, Ö. E. ve Büyüklü, A. H. (2014). LYS Başarılarına Göre Okul Performanslarının Eğitsel Veri Madenciliği Teknikleriyle İncelenmesi: 2011 İstanbul Örneği. *Eğitim ve Bilim*, 39(172), 78-94.
- Borkar, S. & Rajeswari, K. (2013). Predicting Students Academic Performance Using Education Data Mining. *International Journal of Computer Science and Mobile Computing*, 2(7), 273-279.
- Bui, T. D., Pradhan, B., Lofman, O. & Revhaug, I. (2012). Landslide Susceptibility Assessment in Vietnam Using Support Vector Machines, Decision Tree, and Naive Bayes Models. *Mathematical Problems in Engineering*, 2012, 1-26.
- Can, M. B., Eren, Ç., Koru, M., Özkan, Ö. ve Rzayeva, Z. (2012). Veri Kümelerinden Bilgi Keşfi: Veri Madenciliği. *Başkent Üniversitesi Tıp Fakültesi XIV. Öğrenci Sempozyumu*, 1-14.
- Ceylan, Z., Gürsev, S. ve Bulkan, S. (2017). İki Aşamalı Kümeleme Analizi ile Bireysel Emeklilik Sektöründe Müşteri Profilinin Değerlendirilmesi. *Bilişim Teknolojileri Dergisi*, 10(4), 475-485.
- Chaurasia, V. & Pal, S. (2013). Early Prediction of Heart Diseases Using Data Mining Techniques. *Caribbean Journal of Science and Technology*, 1, 208-217.
- Chen, M., Mao, S. & Liu, Y. (2014). Big data: A survey. *Mobile Networks and Applications*, 19, 171-209.

- Chen, J., Wei, W., Guo, C., Tang, L. & Sun, L. (2017). Textual Analysis and Visualization of Research Trends in Data Mining for Electronic Health Records. *Health Policy and Technology*, 6(4), 389-400.
- Cleophas, T. J. & Zwinderman, A. H. (2013). Support Vector Machines. *Machine Learning in Medicine*, 155-161.
- Çağdaş, K. ve Erdem, O. A. (2012). Öğrenci Başarısını Etkileyen Faktörlerin Veri Madenciliği Yöntemleriyle İncelenmesi. *Politeknik Dergisi*, 15(2), 111-116.
- Çalış, A. ve Baynal, K. (2016). Veri Madenciliğinde Kümeleme Analizi ile Bankacılık Sektöründe Bir Uygulama. *Beykent Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, 9(1), 13-41.
- Çalış, A., Kayapınar, S. ve Çetinyokuş, T. (2014). Veri Madenciliğinde Karar Ağacı Algoritmaları İle Bilgisayar ve İnternet Güvenliği Üzerine Bir Uygulama. *Journal of Industrial Engineering*, 25(3-4), 2-19.
- Çankırı, S., Kartal, E., Yıldırım, K. ve Gülseçen, S. (2011). Organizasyonlarda Bilgi Yönetimi Sürecinde Veri Madenciliği Yaklaşımı. *ÜNAK 2009*, 148-167.
- Çelik, S. (2017). Web Günlük Dosyalarının Analizi için Web Kullanım Madenciliğinin Uygulanması. *İstanbul Üniversitesi İşletme Fakültesi Dergisi*, 46(1), 62-75.
- Çeşmeli, M. Ş., Bozkurt, Ö. Ç., Kalkan, A. ve Pençe, İ. (2015). Yönetim Bilişim Sistemleri Bölümü Öğrencilerinin Yönetim ve Bilişim Derslerindeki Başarılarının Veri Madenciliği Yöntemleri İle İncelenmesi. *Yönetim Bilişim Sistemleri Dergisi*, 1(2), 36-47.
- Çetin, F. A. ve Mikail, N. (2016). Hayvancılıkta Veri Madenciliği Uygulamaları. *Türkiye Tarımsal Araştırmalar Dergisi*, 3(1), 79-88.
- Çırak, G. ve Çokluk, Ö. (2013). Yükseköğretimde Öğrenci Başarılarının Sınıflandırılmasında Yapay Sinir Ağları ve Lojistik Regresyon Yöntemlerinin Kullanılması. *Mediterranean Journal of Humanities*, 3(2), 71-79.
- D'Oca, S. & Hong, T. (2015). Occupancy Schedules Learning Process Through a Data Mining Framework. *Energy and Buildings*, 88, 395-408.
- Dangare, C. S. & Apte, S. S. (2012). Improved Study of heart Disease Prediction System Using Data Mining Classification Techniques. *International Journal of Computer Applications*, 47(10), 44-48.
- Demiral, G., Soba, M. ve Armutlu, Ş. (2017). Kütüphane Veri Tabanında Veri Madenciliği: Uşak Üniversitesi Örneği. *Bartın Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 8(16), 241-264.

- Deperliođlu, Ö. ve Sarpkaya, Y. (2009). Öğretim Yönetim Sistemleri İçin Örnek Veri Tabanı Tasarımı. *International Journal of Informatics Technologies*, 2(1),15-21.
- Dinçerden, E. (2017). Yönetim Bilişim Sistemleri: Kurumsal Enformasyon ve İş İletişimi. *Akdeniz İletişim Dergisi*, (27) 135-148.
- Dođan, K. ve Arslantekin, S. (2016). Büyük Veri: Önemi, Yapısı ve Günümüzdeki Durum. *Dtcf Dergisi*, 56(1), 15-36.
- Dođan, O. (2017). Ücretsiz Veri Madenciliđi Araçları ve Türkiye’de Bilinirlikleri Üzerine Bir Araştırma. *Ege Stratejik Araştırmalar Dergisi*, 8(1), 77-93.
- Dođan, O. (2015). Bir E-Ticaret Sitesi Kullanıcı Hesaplarında Şifre Yapılarının Birliktelik Kuralları ile İncelenmesi, *İnternet Uygulamaları ve Yönetimi Dergisi*, 6(2), 49-61.
- Dođan, M. (2014). Büyük Veri'nin Kişiler ve Kurumlar Üzerindeki Etkileri. Yüksek Lisans Tezi, İstanbul Bilgi Üniversitesi, Sosyal Bilimler Enstitüsü, İstanbul.
- Dođan, B., Erol, B. ve Buldu, A. (2014). Sigortacılık Sektöründe Müşteri İlişkileri Yönetimi İçin Birliktelik Kuralı Kullanılması. *Marmara Fen Bilimleri Dergisi*, 3, 105-114.
- Dođrul, G., Akay, D. ve Kurt, M. (2016). Tırafık Kazalarının Birliktelik Kuralları İle Analizi. *Gazi Mühendislik Bilimleri Dergisi*, 1(2), 265-284.
- Dolgun, M. Ö. ve Ersel, D. (2014). Doğrudan Pazarlama Stratejilerinin Belirlenmesinde Veri Madenciliđi Yöntemlerinin Kullanımı. *İstatistikçiler Dergisi: İstatistik & Aktüerya*, 7, 1-13.
- Ekmekçi, N., Kasap, O. Y., Ketenci, U. G., Kalıpsız, O. ve Aktaş, M. S. (2016) Çok Yanıtlı Doğrusal Regresyon Algoritmasıyla Lojistik Regresyon ve Birliktelik Kuralı Sonuçlarının Birleştirilmesi. *Proceedings of the 10th Turkish National Software Engineering Symposium*, 611-622.
- Emre, İ. E. ve Erol, Ç. S. (2017). Veri Analizinde İstatistik Mi Veri Madenciliđi Mi?.*International Journal of Informatics Technologies*, 10(2), 161-167.
- Erilli, N. A. (2014). TR72 Bölgesi İlçelerinin Sosyo-Ekonomik Verilere Göre Bulanık Kümeleme Analizi İle Sınıflandırılması. *Ekonomik ve Sosyal Araştırmalar Dergisi*,10(2), 33-45.
- Erpolat, S. (2012). Otomobil Yetkili Servislerinde Birliktelik Kurallarının Belirlenmesinde Apriori ve FP-Growth Algoritmalarının Karşılaştırılması. *Anadolu Üniversitesi Sosyal Bilimler Dergisi*, 12(2), 137-146.

- Ertuğrul, İ., Organ, A. ve Şavlı, A. (2013). Veri Madenciliği Uygulamasına İlişkin PAÜ Hastanesinde Hasta Profilinin Belirlenmesi. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 19(2), 97-103.
- Esling, P. & Agon, C. (2012). Time-Series Data Mining. *ACM Computing Surveys*, 45(1), 12-44.
- Fan, W. & Bifet, A. (2013). Mining Big Data: Current Status, and Forecast to the Future. *ACM SIGKDD Explorations Newsletter*, 14(2), 1-5.
- Filiz, E., Karaboğa, H. A. ve Akoğul, S. (2017). Bıst-50 Endeksi Değişim Değerlerinin Sınıflandırılmasında Makine Öğrenmesi Yöntemleri ve Yapay Sinir Ağları Kullanımı. *Ç.Ü. Sosyal Bilimler Enstitüsü Dergisi*, 26(1), 231-241.
- Gantz, J. & Reinsel, D. (2012). The Digital Universe in 2020: Big data, Bigger Digital Shadows, and Biggest Growth in the Far East. *IDC iView: IDC Analyze the future*, 1-16.
- Ghosh, S. & Dubey, S. K. (2013). Comparative Analysis of K-Means and Fuzzy C-Means Algorithms, *International Journal of Advanced Computer Science and Applications*, 4(4), 35-39.
- Gour, S., Jaloree, S. & Gour, M. (2016). Water Quality Assessment Using Association Rule Mining for River Narmada. *Indian Journal of Science and Technology*, 9(10), 1-5.
- Gupta, B., Rawat, A., Jain, A., Arora, A. & Dhama, N. (2017). Analysis of Various Decision Tree Algorithms for Classification in Data Mining. *International Journal of Computer Applications*, 163(8), 15-19.
- Gülen, Ö. Ç. ve Özdemir, S. (2013). Analysis of Gifted Students' Interest Areas Using Data Mining Techniques. *Üstün Yetenekli Eğitimi Araştırmaları Dergisi*, 1(3), 213-226.
- Güner, Z. B. (2014). Veri Madenciliğinde Cart ve Lojistik Regresyon Analizinin Yeri: İlaç Provizyon Sistemi Verileri Üzerinde Örnek Bir Uygulama. *Sosyal Güvençe Dergisi*, (6), 53-99.
- Gürsoy, U. T. ve Bilgin, S. (2016). Banka Müsterilerinin İnternet Bankacılığına İlişkin Yaklaşımlarının Veri Madencılığı Teknikleri İle İncelenmesi. *Kafkas Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 7(14), 421-442.
- Hamzaoui, Y., Amnai, M., Choukri, A. & Fakhri, Y. (2018). Novel Clustering Method Based on K-Medoids and Mobility Metric. *International Journal of Interactive Multimedia and Artificial Intelligence*, 5(1), 1-5.

- Haro, V., Pérez, W. & Saquicela, V. (2016). Bibliomining para descubrir reglas de asociación en el Centro de Documentación Regional “Juan Bautista Vázquez”. *Maskana*, 203-211.
- Irmak, S., Köksal, C. D. ve Asilkan, Ö. (2012). Hastanelerin Gelecekteki Hasta Yoğunluklarının Veri Madenciliği Yöntemleri İle Tahmin Edilmesi. *Uluslararası Alanya İşletme Fakültesi Dergisi*, 4(1), 101-114.
- Joyendri, A. (2017). Strategi Customer Relationship Management Untuk Meningkatkan Loyalitas Pelanggan Dan Volume Penjualan Menggunakan Teknik Clustering K-Means. *Telematika*, 14(2), 75–82.
- Jovic, A., Brkic, K. & Bogunovic, N. (2014). An Overview of Free Software Tools for General Data Mining. *37. International Convention on IEEE*, 1112-1117.
- Kabakchieva, D. (2013). Predicting Student Performance by Using Data Mining Methods for Classification. *Cybernetics and Information Technologies*, 13(1), 61-72.
- Karabatak, M. ve İnce, M. C. (2012). Apriori Algoritması ile Öğrenci Başarı Analizi. *Emo Bilimsel Dergi*, 1-5.
- Kahveci, F. ve Özdemir, A. (2016). Öğrenci Bilgi Sisteminde Değerlendirmenin Veri Madenciliği ile Yapılması. *Yönetim Bilişim Sistemleri Dergisi*, 1(3), 1-10.
- Kaplan, M. S., Caetano, R., Giesbrecht, N., Huguet, N., Kerr, W. C., McFarland, B. H. vd. (2017). The National Violent Death Reporting System: Use of the Restricted Access Database and Recommendations for the System’s Improvement. *American journal of preventive medicine*, 53(1), 130-133.
- Kaya, M. ve Özel, S. A. (2014). Açık Kaynak Kodlu Veri Madenciliği Yazılımlarının Karşılaştırılması. *XVI. Akademik Bilişim Konferansı*. 47-53.
- Kaya, Ç. ve Yıldız, O. (2014). Makine Öğrenmesi Teknikleriyle Saldırı Tespiti: Karşılaştırmalı Analiz. *Marmara Fen Bilimleri Dergisi*, 3, 89-104.
- Kaynar, O., Tuna, M. F., Görmez, Y. ve Deveci, M. A. (2017). Makine Öğrenmesi Yöntemleriyle Müşteri Kaybı Analizi. *C.Ü. İktisadi ve İdari Bilimler Dergisi*, 18(1), 1-14.
- Kaygın, C. Y., Tazegül, A. ve Yazarkan, H. (2016). İşletmelerin Finansal Başarılı ve Başarısız Olma Durumlarının Veri Madenciliği ve Lojistik Regresyon Analizi İle Tahmin Edilebilirliği. *Ege Akademik Bakış*, 16(1), 147-159.
- Kavzoğlu, T. ve Çölkesen, İ. (2010). Karar Ağaçları ile Uydu Görüntülerinin Sınıflandırılması. *Harita Teknolojileri Elektronik Dergisi*, 2(1), 36-45.
- Keleş, M. K.(2017). An Overview: The Impact of Data Mining Applications on Various Sectors. *Technical Journal*, 11(3), 128-132.

- Keleş, A. E. ve Kaya, M. (2014). Duvar İnşa Edilmesinde Verimliliği Etkileyen Faktörlerin Apriori Veri Madenciliği Yöntemi Kullanılarak Analizi. *Akademik Bilişim Konferansı*, 831-836.
- Khalvati, L., Keshtgary, M. & Rikhtegar, N. (2018). Intrusion Detection Based on a Novel Hybrid Learning Approach. *Journal of AI and Data Mining*, 6(1), 157-162.
- Kharya, S. (2012). Using Data Mining Techniques for Diagnosis and prognosis of Cancer Disease. *International Journal of Computer Science, Engineering and Information Technology*, 2, 55-66.
- Kohonen, T. (2013). Essentials of the Self-Organizing Map. *Neural Networks*, 37, 52–65.
- Kovaleva, E. V. & Mirkin, B. G. (2015). Bisecting K-means and 1D Projection Divisive Clustering: A Unified Framework and Experimental Comparison. *Journal of Classification*, 32(3), 414-442.
- Kılınç, Ç. (2015). Veri Madenciliği Yöntemlerini Kullanarak Anemi Sınıflandırılmasına Yönelik Bir Uygulama. Yüksek Lisans Tezi. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Koyuncugil, A.S. ve Özgülbaş, N. (2009). Veri Madenciliği: Tıp ve Sağlık Hizmetlerinde Kullanımı ve Uygulamaları. *Bilişim Teknolojileri Dergisi*, 2(2), 21-32.
- Kim, K. (2016). A Hybrid Classification Algorithm by Subspace Partitioning Through Semi-Supervised Decision Tree. *Pattern Recognition*, 60, 157-163.
- Kranjc, J., Orač, R., Podpečan, V., Lavrač, N. & Robnik-Šikonja, M. (2017). ClowdFlows: Online Workflows for Distributed Big Data Mining. *Future Generation Computer Systems*, 68, 38-58.
- Kurt, R., Karayılmazlar, S. İmren, E. ve Çabuk, Y. (2017). Yapay Sinir Ağları İle Öngörü Modellemesi: Türkiye Kâğıt-Karton Sanayi Örneği. *Bartın Orman Fakültesi Dergisi*, 19(2), 99-106.
- Liao, S. H., Chu, P. H. & Hsiao, P. Y. (2012). Data Mining Techniques and Applications – A Decade Review from 2000 to 2011. *Expert Systems with Applications*, 39(12), 11303-11311.
- Lu, Y., Ma, T., Yin, C., Xie, X., Tian, W. & Zhong, S. (2013). Implementation of the Fuzzy C-Means Clustering Algorithm in Meteorological Data. *International Journal of Database Theory and Application*, 6(6), 1-18.
- Mago, N., Shirwaikar, R. D., Acharya, U. D., Hegde, K. G., Lewis, L. E. S. & Shivakumar, M. (2018). Partition and Hierarchical Based Clustering

- Techniques for Analysis of Neonatal Data. *Proceedings of International Conference on Cognition and Recognition*, 345-355.
- Malley, B., Ramazzotti, D. & Wu, J. T. Y. (2016). Data Pre-processing. *Secondary Analysis of Electronic Health Records*, 115-141.
- Melagraki, G. & Afantitis, A. (2013). Enalos KNIME Nodes: Exploring Corrosion Inhibition of Steel in Acidic Medium. *Chemometrics and Intelligent Laboratory Systems*, 123, 9-14.
- Mikail, N. ve Çetin, F. A. (2016). Hayvancılıkta Veri Madenciliği Uygulamaları. *Türkiye Tarımsal Araştırmalar Dergisi*, 3(1), 79-88.
- Microsoft SQL Server (2018). 28 Ocak 2018 tarihinde <https://technet.microsoft.com/> adresinden erişildi.
- Mikut, R. & Reischl, M. (2011). Data Mining Tools. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 1(5), 431-443.
- Modak, S., Chattopadhyay, T. & Chattopadhyay, A. K. (2018). Unsupervised Classification of Eclipsing Binary Light Curves Through k-medoids Clustering. arXiv preprint arXiv:1801.09406, 1-39. 28 Şubat 2018 tarihinde <https://arxiv.org/pdf/1801.09406.pdf> adresinden erişildi.
- Moslehi, F., Haeri, A. R. & Moini, A. R. (2017). Analyzing and Investigating the Use of Electronic Payment Tools in Iran Using Data Mining Techniques. *Journal of AI and Data Mining*. 6(2), 417-437.
- Munková, D., Munk, M. & Vozár, M. (2013). Data Pre-Processing Evaluation for Text Mining: Transaction/Sequence Model. *Procedia Computer Science*, 18, 1198-1207.
- Nakkeeran, K., Garla, S. & Chakraborty, G. (2012). Application of Time Series Clustering Using SAS® Enterprise Miner TM for a Retail Chain. *SAS® Global Forum*, 200, 1-9.
- Narlı, S., Aksoy, E. ve Ercire, Y. E. (2014). Veri Madenciliği ile İlköğretim Matematik Öğretmen Adaylarının Öğrenme Stillерinin ve Aralarındaki İlişkilerin İncelenmesi. *International Journal of Educational Studies in Mathematics*, 1(1), 37-57.
- Natek, S. & Zwilling, M. (2014). Student Data Mining Solution–Knowledge Management System Related to Higher Education Institutions. *Expert Systems with Applications*, 41, 6400-6407.
- Nicholson, S. (2003). The bibliomining process: Data Warehousing and Data Mining for Library Decision Making. *Information Technology and Libraries*, 22(4), 146-156.

- Nisbet, R., Miner, G. & Yale, K. (2018). Handbook of Statistical Analysis and Data Mining Applications. Elsevier, 2.
- O'Hagan, S. & Kell, D. B. (2015). Software Review: the KNIME Workflow Environment and Its Applications in Genetic Programming and Machine Learning. *Genetic Programming and Evolvable Machines*, 16(3), 387-391.
- Oğuzlar, A. (2003). Veri ön işleme. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 21, 67-76.
- Olgun, M. O. ve Özdemir, G. (2012). İstatistiksel Özellik Temelli Bayes Sınıflandırıcı Kullanarak Kontrol Grafiklerinde Örüntü Tanıma. *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 27(2), 303-311.
- Olson, D. L. & Wu, D. D. (2017). Data Mining Models and Enterprise Risk Management. *In Enterprise Risk Management Models*, 119-132.
- Özbay, Ö. (2015) Veri Madenciliği Kavramı ve Eğitimde Veri Madenciliği Uygulamaları. *Inesjournal Uluslar Arası Eğitim Bilimleri Dergisi*, 2(5), 262-272.
- Özbek, H. ve Atik, H. (2013). İnovasyon Göstergeleri Bakımından Türkiye'nin Avrupa Birliği Ülkeleri Arasındaki Yeri: İstatistiksel Bir Analiz. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 42, 193-210.
- Özdemir, A., Aslay, F. Y. ve Çam, H. (2009). Veri Tabanında Bilgi Keşfi Süreci: Gümüşhane Devlet Hastanesi Uygulaması. *SÜ İİBF Sosyal Ekonomik Araştırmalar Dergisi*, 1(20), 347-365.
- Özbay, Ö. ve Ersoy, H. (2017) Öğrenme Yönetim Sistemi Üzerindeki Öğrenci Hareketliliğinin Veri Madenciliği Yöntemleriyle Analizi. *Gazi Üniversitesi Gazi Eğitim Fakültesi Dergisi*, 37(2), 523-558.
- Özçalıcı, M. (2016). Hisse Senetlerinin Özdüzenleyici Haritalarla Kümelendirilmesi: BIST50 Endeksinde Yer Alan Hisseler Üzerine Bir Uygulama. *İstanbul Üniversitesi İşletme Fakültesi Dergisi*, 45(1), 22-33.
- Özel, C. ve Topsakal, A. (2014). Veri Madenciliği Kullanarak Beton Basınç Dayanımının Belirlenmesi. *Cumhuriyet Üniversitesi Fen Fakültesi Fen Bilimleri Dergisi*, 35(1), 43-57.
- Özseven, T. ve Ersöz, T. (2016). E-Ticaret Verilerinin Müşteri Profili Açısından Değerlendirilmesi. *Uluslararası Yönetim İktisat ve İşletme Dergisi*, 12(28), 85-98.
- Özseven, T. ve Düğenci, M. (2011). LOG Analiz: Erişim Kayıt Dosyaları Analiz Yazılımı ve GOP Üniversitesi Uygulaması. *Bilişim Teknolojileri Dergisi*, 4(2), 55-66.

- Patel, J. A. (2015). Classification Algorithms and Comparison in Data Mining. *International Journal of Innovations & Advancement in Computer Science*, 4, 206-210.
- Pehlivanoglu, M. K. ve Duru, N. (2015). Veri Madenciliği Teknikleri Kullanılarak Ortaokul Öğrencilerinin Sosyal Ağ Kullanım Analizi: Kocaeli İli Örneği. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 3, 508-517.
- Pérez, W., Haro, V. & Saquicela, V. (2017). Bibliomining: Aplicación de Text Mining Para Descubrir Preferencias de Usuarios en el Centro de Documentación Regional “Juan Bautista Vázquez”. *Maskana*, 8, 135-144.
- Ristoski, P., Bizer, C. & Paulheim, H. (2015). Mining the Web of Linked Data with Rapidminer. *Journal Web Semantics*, 35(3), 142-151.
- Piwczyński, D., Nogalski, Z. & Sitkowska, B. (2013). Statistical Modeling of Calving Ease and Stillbirths in the Classification Tree Technique. *Livestock Science*, 154(1-3), 19-27.
- Raith, S., Vogel, E. P., Anees, N., Keul, C., Güth, J. F., Edelhoff, D. et al. (2017). Artificial Neural Networks as a Powerful Numerical Tool to Classify Specific Features of a Tooth Based on 3D Scan Data. *Computers in Biology and Medicine*, 80, 65-76.
- Renaud, J., Britton, S., Wang, D. & Ogihara, M. (2015). Mining Library and University Data to Understand Library Use Patterns. *The Electronic Library*, 33(3), 355-372.
- Roiger, R. J. (2017). Data Mining: A Tutorial-Based Primer. *CRC Press Yayın evi*.
- Romero, C. & Ventura, S. (2013). Data Mining in Education. *Overview*, 3, 12-27.
- Prekopcsak, Z., Makrai, G., Henk, T. & Gaspar-Papanek, C. (2013). Radoop: Analyzing Big Data with Rapidminer and Hadoop. *In Proceedings of the 2nd RapidMiner community meeting and conference*. 1-12.
- Pulakkazhy, S. & Balan, R. V. S. (2013). Data mining in banking and its applications-a review. *Journal of Computer Science*, 9 (10), 1252-1259
- Sağiroglu, S. ve Sinanc, D. (2013). Big Data: A Review. In Collaboration Technologies and Systems (CTS). *International Conference on, IEEE*. 42-47.
- Sani, S.S. (2018). A Case Study for Application of Fuzzy Inference and Datamining in Structural Health Monitoring. *Journal of AI and Data Mining*, 6(1), 105-120.
- Santur, S. G., Santur, S. G. ve Karaköse, M. (2016). Knowledge Mining Approach for Healthy Monitoring From Pregnancy Data With Big Volumes.

International Journal of Intelligent Systems and Applications in Engineering, 4, 145-148.

- 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. ve Yılmaz, M. (2012). Veri Madenciliği ve Türkiye'deki Uygulama Örnekleri. *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi*, 11(21), 1-23.
- Seker, S.E. (2015a). Sosyal Ağlarda Veri Madenciliği (Data Mining on Social Networks). *YBS Ansiklopedi*, 2(2), 30-39.
- Seker, S.E. (2015b). Zaman Serisi Analizi (Time Series Analysis), *YBS Ansiklopedi*, 2(4), 23-31.
- Selvi, H.Z. ve Çağlar, B. (2017). Çok Değişkenli Haritalama İçin Kümeleme Yöntemlerinin Kullanılması. *Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 6(2), 415-429.
- Sevindik, T., Kayışlı, K. ve Ünlükahraman, O. (2012). Web Tabanlı Eğitimde Veri Madenciliği. *Turkish Journal of Computer and Mathematics Education*, 3(3), 183-193.
- Seyrek, İ. H. ve Ata, H. A. (2010). Veri Zarflama Analizi ve Veri Madenciliği ile Mevduat Bankalarında Etkinlik Ölçümü. *Journal of BRSA Banking & Financial Markets*, 4(2), 67-84.
- Sever, H. ve Oğuz, B. (2003). Veri Tabanlarında Bilgi Keşfine Formel Bir Yaklaşım Kısım I: Eşleştirme Sorguları ve Algoritmalar. *Bilgi Dünyası*, 3(2), 173-204.
- Shmueli, G., Bruce, P. C., Yahav, I., Patel, N. R. & Lichtendahl Jr, K. C. (2017). Data Mining for Business Analytics: Concepts, Techniques, and Applications in R. *CRC Press*.
- Steinmetz, F. P., Mellor, C. L., Meinel, T. & Cronin, M. T. (2015). Screening Chemicals for Receptor-Mediated Toxicological and Pharmacological Endpoints: Using Public Data to Build Screening Tools within a KNIME Workflow. *Molecular informatics*, 34(2-3), 171-178.
- Siguenza-Guzman, L., Saquicela, V., Avila-Ordóñez, E., Vandewalle, J. & Cattrysse, D. (2015). Literature Review of Data Mining Applications in academic Libraries. *The Journal of Academic Librarianship*, 41(4), 499-510.

- Silahtaroglu, G. ve Ergul, H. (2016). Şehirleşme, Mekân-İnsan Etkileşiminin Birey Algısına Yansıması: Bir Veri Madenciliği Analizi. *Beykent Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, 9(2), 95-124.
- Sin, K. & Muthu, L. (2015). Application of Big Data In Education Data Mining and Learning Analytics--A Literature Review. *Journal On Soft Computing*, 5(4). 1035-1049.
- Singh, J., Ram, H. & Sodhi, D. J. (2013). Improving Efficiency of Apriori Algorithm Using Transaction Reduction. *International Journal of Scientific and Research Publications*, 3(1), 1-4.
- Singhal, S. & Jena, M. (2013). A Study on WEKA Tool for Data Preprocessing, Classification and Clustering. *International Journal of Innovative Technology and Exploring Engineering (IJITEE)*, 2(6), 250-253.
- Sözen, E., Bardak, T., Peker, H. ve Bardak, S. (2017) Apriori Algoritması Kullanılarak Mobilya Seçimde Etkili Olan Faktörlerin Analizi. *İleri Teknoloji Bilimleri Dergisi*, 6(3), 679-684.
- Tamayo, J. D., Francisco, N. V., Malonzo, M. E. P. & Bugay, A. P. (2018). Predicting Students' Degree Completion Using Decision Trees. *International Journal of Computer (IJC)*, 28(1), 75-89.
- Tang, Z., Maclennan, J. & Kim, P. P. (2005). Building Data Mining Solutions With OLE DB for DM and XML for Analysis. *Sigmod Record*, 34(2), 80-85.
- Tapkan, P., Özbakır, L. ve Baykasoğlu, A. (2011). Weka ile Veri Madenciliği Süreci ve Örnek Uygulama. *Endüstri Mühendisliği Yazılımları ve Uygulamaları Kongresi*.
- Taşkın, Ç. ve Emel, G. G. (2010). Veri Madenciliğinde Kümeleme Yaklaşımları ve Kohonen Ağları ile Perakendecilik Sektöründe Bir Uygulama. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 15(3), 395-409.
- Tekerek, A. (2011). Veri Madenciliği Süreçleri ve Açık Kaynak Kodlu Veri Madenciliği Araçları. *Akademik Bilişim*, 11, 2-4.
- Terrell, A. & Mutlu, B. (2012). A Regression-Based Approach to Modeling Addressee Backchannels. *In Proceedings of the 13th Annual Meeting of the Special Interest Group on Discourse and Dialogue*, 280-289.
- TDK (2018). 28 Ocak 2018 tarihinde <http://www.tdk.gov.tr/> adresinden erişildi.
- Tozak, E. Y., Ersöz, T. ve Ersöz, F. (2017). Demir-Çelik Sektöründe Meydana Gelen İş Kazalarının Veri Madenciliği Kullanılarak Analizi. *3. Ulusal Sigorta ve Aktüerya Kongresi*, Vol.3, 137-144.

- Urso, A., Fiannaca, A., La Rosa, M., Ravi, V. & Rizzo, R. (2017). *Data Mining: Classification and Prediction*, Elsevier.
- Vadim, K. (2018). Overview of Different Approaches to Solving Problems of Data Mining. *Procedia Computer Science*, 123, 234–239.
- Veri Bilimcisi (2018). 19 Şubat 2018 tarihinde <https://veribilimcisi.com/> adresinden erişildi.
- Vural, Y. ve Sağıroğlu, Ş. (2010). Veritabanı Yönetim Sistemleri Güvenliği: Tehditler ve Korunma Yöntemleri. *Politeknik Dergisi*, 13(2), 71-81.
- Wang, X., Mueen, A., Ding, H., Trajcevski, G., Scheuermann, P. & Keogh, E. (2013). Experimental Comparison of Representation Methods and Distance Measures for Time Series Data. *Data Mining and Knowledge Discovery*, 26(2), 275-309.
- Wu, X., Zhu, X., Wu, G. Q. & Ding, W. (2014). Data Mining with Big Data. *IEEE Transactions on knowledge and Data Engineering*, 26(1), 97-107.
- Wu, H., Yang, S., Huang, Z., He, J. & Wang, X. (2018). Type 2 Diabetes Mellitus Prediction Model Based on Data Mining. *Informatics in Medicine Unlocked*, 10,100-107.
- Yağcı, M., Ekiz, H. ve Gelbal, S. (2015). Yeni Bir Çevrimiçi Sınav Modeli Geliştirilmesi ve Uygulanması. *Journal of Kırşehir Education Faculty*, 16(1), 296-298.
- Yalçın, N., Güngör, E. ve Yurtay, N. (2013). Apriori Algoritması ile Teknik Seçmeli Ders Seçim Analizi. *UZEM 2013 Ulusal Uzaktan Eğitim ve Teknolojileri Sempozyumu*, 114-119.
- Yavuz, H. Ç., Dibek, M. İ. ve Yalçın, S. (2017). Türk ve Vietnamlı Öğrencilerin PISA 2012 Matematik Okuryazarlığı İle Dürtü ve Güdülenme Özellikleri Arasındaki İlişkiler. *İlköğretim Online*, 16(1), 178-196.
- Yıldız, M. (2014). Bir Kurumsal Zekâ Teknolojisi Olarak Veri Madenciliği İle Muhasebe Bilgi Sistemi İlişkisi. *Selçuk Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 1-21.
- Yıldız, M. ve Şeker, Ş. E. (2016). Veri Madenciliği Araçları (Data Mining Tools). *YBS Ansiklopedi*, 3, 10-19.
- Yılmaz, M. (2013). Küreselleşmenin Oluşumuna Zemin Hazırladığı Yeni Ekonomik Anlayış: Bilgi Ekonomisi. *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 27(1), 241-255.

- Yukselturk, E., Ozekes, S. ve Türel, Y. K. (2014). Predicting Dropout Student: An Application of Data Mining Methods In An Online Education Program. *European Journal of Open, Distance and E-learning*, 17(1), 118-133.
- Zahedi, F. & Zare-Mirakabad, M. R. (2014). Employing Data Mining to Explore Association Rules In Drug Addicts. *Journal of AI and Data Mining*, 2(2), 135-139.
- Zare, M. & Koch, M. (2018). Groundwater Level Fluctuations Simulation and Prediction by ANFIS-and Hybrid Wavelet-ANFIS/Fuzzy C-Means (FCM) Clustering Models: Application to the Miandarband Plain. *Journal of Hydro-environment Research*, 18, 63-76.
- Zarei, A., Maleki, M. & Feiz, D. (2018). Competitive Intelligence Text Mining: Words Speak. *Journal of AI and Data Mining*, 6(1), 79-92.
- Zhao, Y. (2012). R and Data Mining: Examples and Case Studies. *Academic Press Yayın Evi*.
- Zhao, J. & Wang, J. (2017). A Design of College Ideological and Political Education Management System Based on Data Mining Technology. *Revista de la Facultad de Ingeniería*, 32(14), 73-78.