

KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ENDÜSTRİ MÜHENDİSLİĞİ
ANABİLİM DALI

YÜKSEK LİSANS TEZİ

VERİ MADENCİLİĞİNDE APİRİORİ ALGORİTMASI VE DEPO
DÜZENLEME PROBLEMİNDE SATIŞ VERİLERİ ÜZERİNDEN
BİRLİKTELİK ANALİZİ

RAFİA ÖZTOPUZ EREN

KOCAELİ 2020

KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ENDÜSTRİ MÜHENDİSLİĞİ
ANABİLİM DALI

YÜKSEK LİSANS TEZİ

**VERİ MADENCİLİĞİNDE APRİORİ ALGORİTMASI VE
DEPO DÜZENLEME PROBLEMİNDE SATIŞ VERİLERİ
ÜZERİNDEN BİRLİKTELİK ANALİZİ**

RAFİA ÖZTOPUZ EREN

Dr.Öğr. Üyesi Atakan ALKAN
Danışman, Kocaeli Üniversitesi

Doç.Dr. Gülşen AKMAN
Jüri Üyesi, Kocaeli Üniversitesi

Dr.Öğr. Üyesi Serab ONURSAL
Jüri Üyesi, İstanbul Ticaret Üniversitesi

Tezin Savunulduğu Tarih: 02.09.2020

ÖNSÖZ VE TEŞEKKÜR

Bu çalışmayı yapabilmem konusunda bana imkan veren danışman hocam Dr. Öğr. Üyesi Atakan ALKAN'a teşekkür ederim. Ayrıca hayatım boyunca beni hep destekleyen, her zaman yanımda olan değerli aileme sonsuz minnetlerimi sunuyorum.

Ağustos – 2020

Rafia ÖZTOPUZ EREN



İÇİNDEKİLER

ÖNSÖZ VE TEŞEKKÜR	i
İÇİNDEKİLER	ii
ŞEKİLLER DİZİNİ.....	iv
TABLolar DİZİNİ	v
SİMGELER VE KISALTMALAR DİZİNİ	vi
ÖZET.....	vii
ABSTRACT.....	viii
GİRİŞ	1
1. VERİ MADENCİLİĞİ, DEPO TASARIMI VE LİTERATÜR TARAMASI.....	3
1.1. Veri Madenciliği	3
1.1.1. Veri madenciliğinin tarihçesi	4
1.1.2. Veri madenciliği kullanım alanları	5
1.1.3. Veri madenciliği tanımları	6
1.1.4. Veri madenciliği süreci	8
1.1.4.1. Verilerin temizlenmesi	9
1.1.4.2. Veri bütünleştirme	10
1.1.4.3. Veri indirgeme	10
1.1.4.4. Veri dönüştürme	10
1.1.4.5. Veri madenciliği modelinin uygulanması	10
1.1.4.6. Sonuçların sunumu ve değerlendirilmesi	10
1.2. Depo Yerleşimi ve Tasarımı	11
1.2.1. Depo içi yerleşim planı	11
1.2.2. Depolama faaliyetleri.....	13
1.2.3. Depo düzenleme.....	14
1.3. Literatür Taraması.....	14
2. VERİ MADENCİLİĞİ YÖNTEMLERİ VE YAZILIMLARI	19
2.1. Veri Madenciliği Yöntemleri	19
2.1.1. Sınıflandırma.....	20
2.1.1.1. Karar ağaçları	20
2.1.1.2. Yapay sinir ağları	22
2.1.1.3. Genetik algoritmalar	24
2.1.1.4. K komşu yöntemi	24
2.1.1.5. Bayes sınıflandırma algoritması	25
2.1.2. Kümeleme analizi	26
2.1.3. Birliktelik kuralı analizi	26
2.1.3.1. Birliktelik kurallarının matematiksel modeli.....	27
2.1.3.2. Birliktelik kuralı analizinde kullanılan algoritmalar	28
2.2. Veri Madenciliği Yazılımları	33
2.2.1. IBM SPSS modeller	33
2.2.2. WEKA.....	34
2.2.3. Statistica data miner	34
2.2.4. RapidMiner	35

3. UYGULAMA	36
3.1. İşletme Tanıtımı	36
3.2. Problemin Tanımı	36
3.3. Algoritmanın Uygulanması.....	38
3.4. Algoritma Sonuçları ve Değerlendirilmesi	44
4. SONUÇLAR VE ÖNERİLER.....	50
KAYNAKLAR	52
EKLER.....	57
KİŞİSEL YAYIN VE ESERLER	69
ÖZGEÇMİŞ	70



ŞEKİLLER DİZİNİ

Şekil 1.1. Veri madenciliği adımları	8
Şekil 1.2. Veri madenciliği süreci	9
Şekil 1.3. Depo Türleri.....	12
Şekil 2.1. Veri madenciliği yöntemleri	19
Şekil 2.2. Karar ağacı örneği.....	21
Şekil 2.3. Karar ağacı oluşturulması ve test verisine uygulanması.....	22
Şekil 2.4. Yapay sinir ağlarının genel yapısı	23
Şekil 2.5. k komşu yöntemi algoritmasının adımları	25
Şekil 2.7. Apriori algoritmasının akış diyagramı	31
Şekil 2.6. Apriori algoritması örnek uygulama.....	32
Şekil 3.1. IBM SPSS Modeller programı ana sayfası	39
Şekil 3.2. Type modülünde bağımlı ve bağımsız değişkenlerin atanması	43
Şekil 3.3. Apriori modülünde destek ve güven değerlerinin belirtilmesi	44
Şekil 3.4. Apriori algoritması sonucu elde edilen verilerin özeti.....	45
Şekil 3.5. Apriori algoritması sonucu ürünler arası ilişki grafiği.....	46
Şekil 3.6. Depo yerleşim düzeni	48

TABLolar DİZİNİ

Tablo 1.1. Veri madenciliđi tarihçesi.....	5
Tablo 3.1. Ürünler ve satış birimleri.....	38
Tablo 3.2. Uygulamada kullanılan veri setinden bir kesit.....	42
Tablo 3.3. Yerleşim düzenine göre sipariş toplama mesafeleri.....	49
Tablo A.1. Algoritma sonuçları – Güven %10 Destek %50.....	58
Tablo A.2. Algoritma sonuçları – Güven %10 Destek %60.....	63
Tablo A.3. Algoritma sonuçları – Güven %20 Destek %50.....	66
Tablo A.4. Algoritma sonuçları – Güven %15 Destek %50.....	67



SİMGELER VE KISALTMALAR DİZİNİ

C	:	Aday Nesne Kümesi
D	:	Veri Bütünlüğündeki Tüm Hareketler
K	:	İlgi Değeri
L	:	Geniş Nesne Kümesi
P	:	Bir olayın olma olasılığı
T	:	Ürünlerin hareketleri

Kısaltmalar

CART	:	Classification and Regression Trees (Sınıflandırma ve Regresyon Ağaçları
CRISP-DM	:	Cross-Industry Standart Process for Data Mining
ID3	:	Iterative Dichotomiser 3 (Tekrarlı İkilikçi Ağaç)
ODBC	:	Open DataBase Connectivity (Veri Bankası Bağlantısı)
SETM	:	Set-Oriented Mining
SPRINT	:	Scalable Paralel Introduction of Desicion Tree (Karar Ağacının Ölçeklenebilir Paralel İndüksiyonu)
SQL	:	Structured Query Language (Yapılandırılmış Sorgu Dili)
Vb	:	Ve benzeri
Vd.	:	Ve diğerleri

VERİ MADENCİLİĞİNDE APRIORİ ALGORİTMASI VE DEPO DÜZENLEME PROBLEMİNDE SATIŞ VERİLERİ ÜZERİNDEN BİRLİKTELİK ANALİZİ

ÖZET

Günümüze kadar gerçekleşen bilişim teknolojilerindeki gelişim birçok alanda insanlara fayda sağlamaktadır. Ancak bu gelişimle beraber sürekli artan verilerin depolanmasıyla veri yığınları oluşmakta ve bu yığınların içerisinden yararlı bilgiyi edinmek oldukça zorlu bir süreci gerektirmektedir. Bu zorluklar veri madenciliği kavramını ortaya çıkarmış ve gittikçe gelişmesini sağlamıştır. Günümüzde geliştirilmiş veri madenciliği programları sayesinde veri madenciliği yöntemlerini kullanmak oldukça kolaylaşmıştır.

Veri madenciliği yöntemlerinden biri olan birliktelik kuralı analizi birçok alanda bizlere katkıda bulunmaktadır. En yaygın kullanıldığı alanlardan biri, satış pazarlama gibi konularda stratejik kararların alınması gereken durumlardır. Bunun yanında depo yerleşiminde de verimliliği artıracak bir etken olarak düşünülmektedir. Bu çalışmada da bu konu üzerine bir uygulama yapılacak ve bir işletmenin deposundaki ürünlerin birbirleriyle olan ilişkisi incelenecektir. Uygulama esnasında en çok tercih edilen Apriori algoritması kullanılmaktadır.

Anahtar Kelimeler: Apriori Algoritması, Birliktelik Kuralları, Veri Madenciliği.

APRIORI ALGORITHM IN DATA MINING AND ASSOCIATION ANALYSIS BASED ON SALES DATA IN WAREHOUSE LAYOUT PROBLEM

ABSTRACT

The development in information technologies, that has taken place until today, benefits people in many areas. However, with this development, data stacks occur with the storage of ever-increasing data. Obtaining useful information from these stacks necessitate a very difficult process. These difficulties have revealed the concept of data mining and have enabled it to evolve. Nowadays, thanks to the developed data mining programs, using data mining methods has become very easy. Association rule analysis, which is one of the data mining methods, contributes us in many areas. One of the most widely used areas is the situations where strategic decisions should be taken on issues such as sales and marketing. In addition to this, it is considered as a factor that will increase efficiency in warehouse layout. In this study, an application will be carried out on this subject and the relationship between the products in an enterprise's warehouse will be examined. During the application, Apriori algorithm, the most preferred algorithm, is used.

Keywords: Apriori Algorithm, Association Rules, Data Mining.

GİRİŞ

Son yıllarda bilişim teknolojilerinde gerçekleşen giderek artan gelişim sayesinde bilgisayar alanında birçok yenilikler oluşmaktadır. Bunun yanı sıra günümüzde teknolojiye ulaşım ve teknolojinin kullanımı da oldukça kolaylaşmıştır. Endüstriyel alanda da şirketler daha hızlı ve kullanımı kolay yazılımlara rahatça sahip olabilmektedirler. Bu sayede bilgi teknolojilerinin artmasıyla bağlantılı olarak endüstri alanında da verilerin toplanabilmesi ve depolanabilmesi hızla gelişmektedir.

Teknolojinin gelişimiyle her veri dijital ortamda saklanabilmektedir. Depolanan verilerin her geçen gün artması sebebiyle veri tabanlarında da benzer artış oluşmaktadır. Ancak bu veri yığınlarının tek başına bir anlam ifade etmesi imkansızdır. Bu verilerin analizi ve anlamlı hale getirilmesi ihtiyaç haline gelmiştir. Bu ihtiyacı karşılamak amacıyla veri madenciliği ortaya çıkmıştır.

Veri madenciliği, istatistik, matematik ve bilgisayar bilimlerinden faydalanarak büyük veri tabanları içerisinde önemli bağıntı ve kuralları oluşturarak elde etmek istediğimiz veriyi ortaya çıkarır ve geleceğe ilişkin tahminlerde bulunulmasına katkı sağlar. Veri madenciliği, veri tabanlarında bilgi keşfi olarak da adlandırılır (Gemici, 2012). Veri madenciliği yöntemlerini ve algoritmalarını kullanabilmek için bilgisayar programlarına ihtiyaç duyulmaktadır. Ancak çağımızda bu programların gelişmiş ve yaygın olarak kolayca kullanılabiliyor olması bilginin ve veri madenciliğinin önemini arttırmıştır.

Veri madenciliği tıp, finans, pazarlama, mühendislik gibi ve daha birçok alanda kullanılabilir. Veri madenciliği tanımlayıcı ve tahmin edici olmak üzere iki ana başlığa ayrılır. Tanımlayıcı teknikler birliktelik kuralları ve kümeleme, tahmin edici teknikler ise sınıflandırma ve regresyon olarak örneklendirilebilir.

Bu çalışmada, gerçek verilerden tanımlayıcı teknik olan birliktelik analizi kurallarının çıkarılması amaçlanmıştır. Bu birliktelik ilişkilerini oluşturmak için veri madenciliği algoritmalarından apriori algoritması kullanılmıştır. Birinci bölümde, yapılan çalışma konusuna dair genel bilgiler verilmiş ve daha öncesinde bu konuyla

ilgili alıřmalardan rneklerle bir literatr alıřması yer almaktadır. İkinci blmde ise veri madencilięi yntemleri ve alıřmada uygulanacak olan birliktelik kurallarından apriori algoritması incelenmiřtir. Aynı zamanda apriori algoritmasının adımları ve parametreleri hakkında bilgi verilmiřtir. nc blmde ise veri madencilięi yazılımları hakkında kısa bilgiler verilmiřtir. Drdnc blmde uygulama sonuları ve deęerlendirmeler ele alınmıřtır. Sonu kısmında ileride yapılabilecek alıřmalara dair nerilerde bulunulmuřtur.



1. VERİ MADENCİLİĞİ, DEPO TASARIMI VE LİTERATÜR TARAMASI

1.1. Veri Madenciliği

Gün geçtikçe veri tabanlarında saklanan veriler hızla artmaktadır. Verilerin boyutunun çok büyük olması, verilerden anlamlı ifadeler çıkarıp herhangi bir konuda karar vermeyi neredeyse imkansızlaştırmaktadır. Bu veri yığınlarından kullanılabilir veriyi ve veriler arasındaki örüntüyü elde etmekte veri madenciliğinden yararlanılmaktadır. Veri madenciliği teknikleri bu bilgileri gelişen teknolojiyle kolayca bize sunmaktadır.

Veri madenciliğinin ortaya çıkma nedeni, verinin bilgiye nasıl dönüştürüleceği sorunudur (Özcan, 2014). Veri madenciliği, şimdiye kadar elde edilen verilerden anlamlı bilgiler edinmek, verilerde gizli olan bir takım örüntüleri, bağıntıları bulmak, değişkenler arasındaki ilişkileri tespit etmek ve karar verme sürecine katkıda bulunmak amacıyla uygulanan bir yaklaşımdır (Seyrek ve Ata, 2010). Veri madenciliği istatistik ve makine öğrenimi tekniklerinden yararlanarak veri tabanlarından örüntülere dair önemli bilgi çıkarımları sağlamaya yarayan disiplinler arası bir alandır.

Veri Madenciliğinin bir başka tanımı ise çok büyük miktardaki gözlenebilir verinin analiz edilmesiyle, beklenmedik veri ilişkilerinin ve sonuçların veri sahibine anlaşılır bir şekilde iletilmesidir. Diğer bir tanım ise şu şekildedir; Daha önceden bilinmeyen, geçerli ve uygulanabilir bilgilerin geniş veri tabanlarından elde edilmesi ve bu bilgilerin kuruluş kararları verirken kullanılabilmesidir. Daha basit olarak veri madenciliği büyük ölçekli veriler arasından değerli olan bilgiyi bulup ortaya çıkarılmasına denir (Silahtaroglu, 2016).

1.1.1. Veri madenciliğinin tarihçesi

Veri madenciliğinin temeli 1900'lü yılların ortalarında ilk bilgisayarın bulunmasına kadar dayanmaktadır. Başlangıçta hesaplama yönelik oluşturulan bilgisayarlar veri depolama işlemleri için de kullanılmaya başlanmıştır. 1960'lı yıllarda veri tabanı kavramı ortaya çıkmaya başlamıştır. Yine o yıllarda bilim insanları veri tabanlarını veri depolama haricinde üzerinde işlem yapılabilir şekilde de kullanmaya başlamışlardır. Böylece basit algoritmalar geliştirilmeye başlanmıştır.

Gün geçtikçe artan veriler için bu verilerin kayıtlı tutulacağı alanların da gelişmesi gerekmektedir. Bu sayede veri ambarı diye anılan kavram da ortaya çıkmış bulunmaktadır. Kaybedilmesi ve ihtiyaç duyulduğunda tekrar kullanılabilmesi istenen veriler fiziksel sürücülerde depolanmaya başlandı. Daha sonrasında bu çoğalan verilerin yönetilmesi ve değerlendirilmesinde oluşan zorlukların sayesinde veri modelleme yöntemleri ortaya çıkmıştır.

Şebeke ve hiyerarşik veri modelleri ilk geliştirilen basit modellerdendir. Şebeke veri modelleme kayıt tipi olmakta ve bağlantıların olduğu veri modelidir. Hiyerarşik veri modelleri ise ağaç tipindedir, temelinde bir kök ve onun dallarından oluşmaktadır. Bu modellerde çoklu ilişkiler kurulamamasından dolayı çekilen güçlükler ilişkisel veri tabanlarının doğmasına sebep olmuştur. Günümüzde de en çok kullanılan model haline gelmiştir.

1990'lı yıllarda veri madenciliği kavramı ortaya atılmıştır. Bu yıllarda sürekli artarak büyümekte olan veri tabanlarında istenilen değerli bilgilerin sorgularla elde edilemeyeceği anlaşıldı ve bu sayede veri analizlerinin bilgisayar modülleri tarafından yapılması için sistemler geliştirildi (Savaş vd., 2012). Yine 1990 yıllarında Visual Basic, ODBC, Excel, Access gibi kavramlar da ortaya çıkmıştır. Veri madenciliği tarihinin sürecine ilişkin bilgiler kısaca Tablo 1.1' de gösterilmektedir.

Veri madenciliği ortaya çıktığı andan beri sürekli gelişmektedir. Günümüzde veri madenciliği çok geniş kullanım alanına sahiptir. Teknolojinin gelişimi veri madenciliğinin de gelişmesine olanak sağlamaktadır.

Tablo 1.1. Veri madenciliği tarihçesi

1950	İlk bilgisayar
1960	Veri tabanı ve verilerin depolanması
1970	İlişkisel veri tabanı yöntemleri Basit kurallı uzman sistemler ve makine öğrenimi
1980	Büyük veri tabanları SQL sorgu dili
1990	Veri madenciliği için ilk yazılım
2000	Veri madenciliğinin her alanda kullanılması

1.1.2. Veri madenciliği kullanım alanları

Gün geçtikçe ekonomik sistemler içerisinde verinin önemi artmaktadır. Doğru bilgiye ulaşmak ve doğru kararların alınabilmesi kurum ve kuruluşların rekabet ortamında sağlam adımlar atmasını sağlamaktadır. Bilgisayarın artık hayatın tamamen her adımında olması gerçekleşen her işlemin de kayıt altına alınmasını beraberinde getirmektedir. Bu büyük veri tabanları içerisinde de veri madenciliği yöntemleri uygulanarak elde edilen bilgi çok değerli hale gelmektedir.

Büyük ve kurumsal şirketlerin hemen hemen hepsi veri madenciliği araçlarını ve uygulamalarını birlikte kullanarak tahminsel analizleri gerçekleştirmektedir. Veri madenciliği en çok müşteri için değer yaratmak, onun ihtiyaçlarını öngörmek ve onlara daha iyi hizmet verebilmek gibi amaçlarla kullanılmaktadır. Ancak bunun yanı sıra bankacılık, pazarlama, sigortacılık, sağlık, güvenlik ve savunma gibi pek çok alanda da uygulanmaktadır.

Pazarlama yönetimi: Pazarlama yönetiminde en çok müşterilerin satın alma alışkanlıkları incelenmektedir. Müşteri bir ürün aldığı anda bununla birlikte genelde hangi ürünler daha alınır gibi soruları veri madenciliği sayesinde kolayca elde edilmektedir.

Pazarlama yönetiminde veri madenciliği kullanımının bir başka amacı da müşterilerin demografik özelliklerinin ürün alışverişine etkilerini tanımlama konusudur. Müşterilerin yaş, cinsiyet, medeni hali, eğitim durumu gibi faktörlerin satın alma alışkanlıkları üzerindeki etkilerinin incelenmesi de yine veri madenciliği aracılığıyla kolayca yapılabilmektedir. Ayrıca veri madenciliği teknikleri müşteri ilişkileri yönetimi, satış tahmini ve değerlendirme, çapraz satış gibi konularda da etkili sonuçlar vermektedir.

Bankacılık yönetimi: bankacılık sektöründe veri madenciliği gelişmekte olan bir kavramdır. Müşterilerin kredi taleplerinin değerlendirilmesi, kredi kartı harcamalarına göre müşteri gruplandırılması, kredi kartı sahtekârlıklarının belirlenebilmesi, genel piyasa analizleri, hisse senedi fiyat analizleri, farklı finansal göstergeler arasındaki örüntülerin bulunması gibi durumlarda veri madenciliğinden yararlanılmaktadır (Gemici, 2012).

Sigortacılık: Veri madenciliğinin kullanımının önemli olduğu alanlardandır. Dolandırıcılıkların tespiti, risk sahibi müşterilerin ve poliçe yapma ihtimali olan müşterilerin belirlenebilmesi gibi konularda veri madenciliği teknikleri kullanılabilir.

Havayolları: yeni uçuş hatlarının belirlenmesinde, hizmet açısından kalitenin geliştirilmesinde vb. konularda stratejik kararların alınabilmesi için veri madenciliği teknikleri büyük öneme sahiptirler.

Tıp: veri madenciliği tıp alanında da büyük bir gelişme göstermektedir. Hasta takibi ve tedavi süreçlerine dair veriler sayesinde erken tedavi sağlanabilmektedir. Ayrıca ameliyat riski taşıyan hastalar için de yapılması gerekenler veri madenciliği sayesinde öğrenilebilmektedir.

1.1.3. Veri madenciliği tanımları

Bilgi: Eldeki verilerin analiz sonucu değer kazanmasıdır. Bu analiz verilerin toplanması, değerlendirilmesi ve iletilmesi gibi işlemlerden oluşmaktadır.

Veri: Depolanan bütün kayıtların işlenmemiş haline veri denir. Verilerin gözden geçirilmesi ve işlemlerden geçmesiyle bilgi oluşur. Verilerin bilgiye dönüştürülmesi

dođru kararlar alınabilmesi için önemli bir etkidir. Verilerin işlenmesi, ham veri de denilen işlem görmemiş kayıtların bir araya getirilerek düzenlenmesi ve böylece analizler yapılarak faydalı çıktıların oluşması sürecidir. Sadece bilginin oluşması önemli değildir. Bilginin yorumlanabilmesi için o konuda uzmana da ihtiyaç duyulmaktadır.

Veri tabanı: Veri tabanı, tüm kayıt ve dosyaların birbirleriyle organize olduğu sistemli bir veri topluluğudur. Kullanıcılar tarafından istendiğinde erişilebilen, verilerin yönetilebilmesi, taşınabilmesi, güncellenebilmesi gibi işlemlerin uygulanabileceği veri topluluğudur.

Veri tabanlarının geniş alan kaplamasından ve erişimin zorlaşmasından dolayı bir yönetim sistemine ihtiyaç duyulmaktadır. Veri tabanı yönetim sistemlerinin amacı verilere kolay erişim sağlayabilmek için bir yazılım içerir. Veri tabanı yönetim sistemleri veri işleme dilleri sayesinde kullanıcıların isteklerini karşılamak amacıyla kullanılır. Tüm hareketleri denetler, güvenlik ve doğrulama gibi görevleri üstlenir.

Veri Ambarı: Veri ambarı, farklı kaynaklardan gelen verilerin üzerinde sorgulama işlemi ve analizlerin yapılabildiği büyük depolara verilen isimdir. Genellikle geçmişe ait çok büyük veri kayıtlarına sahiptir.

Veri ambarı kullanıcılara gerçekte şimdiye kadar neler olduğunu ve analizler sonucunda geleceğe dair planlamaların nasıl olması gerektiği bilgisini sunar.

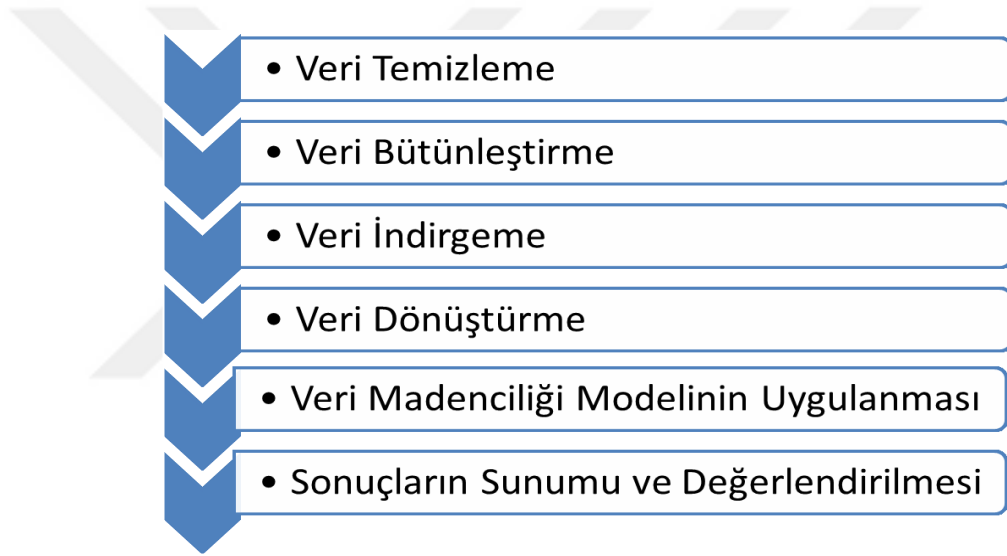
Veri ambarlarındaki verilerin değişik özelliklere sahip olmaktadır. Sistem kullanıcı için verileri basitleştirir ve farklı veri tipindeki dosyaları bir türe dönüştürerek bütünleştirir. Bunun yanı sıra veri ambarına girilen veriler asla değiştirilemez.

Klasik veri tabanı sistemlerinde SQL sorguları veri tabanlarına gönderilir ve çıkan sonuçlar düzenlenir. Veri ambarlarında ise istenen veriler daha önceden ilgili alanlardan alınır. Alınan bu veriler düzenlenir ve artık hazır durumda bulunan veriler sayesinde gelen sorgulara cevap vermesi amaçlanır. Bu işlemlerin önceden yapılması ve hazırda bulundurulması sorgulama sırasında performansı artırmakla birlikte iş yükünü de azaltmaktadır. Bu bağlamda kullanıcıya rahat bir ortam sunmaktadır (Gülçe, 2010).

İyi tasarlanmış bir veri ambarı sorguları çok hızlı gerçekleştirir, yüksek veri hacmi sağlar. Ayrıca son kullanıcılara, gerek yüksek gerekse çok ince ayrıntılı düzeyde çeşitli ihtiyaçları karşılamak üzere daha yakın inceleme için veriden “kesit alma” veya veri hacmini azaltma esnekliği sunar. Veri ambarı, son kullanıcılara raporlar, panolar ve diğer ara yüzleri sağlayan ara katman iş zekası ortamları için işlevsel bir temel oluşturur (www.oracle.com/tr).

1.1.4. Veri madenciliği süreci

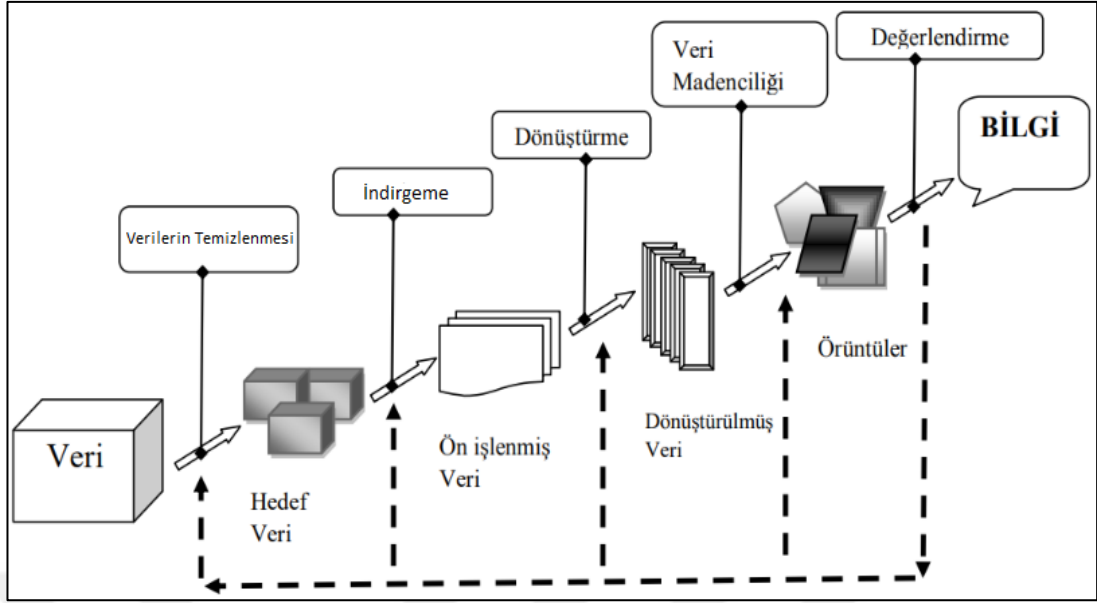
Veri madenciliği standart bir süreçtir. Bu sürecin adımları Şekil 1.1’de gösterildiği şekildedir.



Şekil 1.1. Veri madenciliği adımları

Bu aşamalardan ilk dördü sistem için oldukça önemlidir. Bu aşamalardaki herhangi bir yanlışlık veya eksiklik algoritma sürdürülürken ortaya çıkabilecek sorunlara yol açabilir. Algoritmada sorunlarla karşılaşıldığında tekrar önceki adımlara dönülür ve verilerin tekrar düzenlenmesi gerekebilir. Bu durum verilerin hazırlanması ve modelin kurulması basamakları için, bir analistin veri keşfi sürecinin toplamı içerisinde enerji ve zamanının %50 - %85’ini harcamasına neden olmaktadır (Gülçe, 2010).

Şekil 1.2’de daha iyi anlaşılması için sürecin işleyişini simgeleyen bir görsel verilmiştir.



Şekil 1.2. Veri madenciliği süreci

1.1.4.1. Verilerin temizlenmesi

Veri madenciliğinde modelin kurulabilmesi için gereken verilerin toplanmasında gereksiz veya hatalı bilgiler olabilmektedir. Bu aşamada ilgisiz, hatalı veya eksik verilerin temizliği modelin uygulanmasında verilerin kalitesi açısından büyük önem taşımaktadır. ‘Gürültü’ diye adlandırılan yanlış verilerin analiz esnasında yanlış sonuç çıkarılmasına neden olacağından verilerin temizlenmesi gerekmektedir.

Kayıp verilerin belirlenmesi ve problemin giderilmesi işlemleri de verilerin temizlenmesi kapsamına girmektedir. Bu sorunun giderilmesi farklı şekillerde sağlanmaktadır. Eğer az sayıda kayıp veri varsa ve bunlar toplam veri sayısına oranlandığında sonuçların hassasiyetini etkilemeyecek düzeydeyse bu veriler silinebilir (Silahtaroğlu, 2016). Ancak çok sayıda ve veri setini etkileyecek kayıp veriler varsa bunların doldurulması gerekmektedir. Bu işlem kayıp verilerin yerine veri setine de bağımlı olarak hepsine aynı veri veya ortalama bir değer girilmesi ve değişkenlere göre tahminleme yöntemiyle eksik bilgilerin tamamlanmaya çalışılması şeklinde olmalıdır.

1.1.4.2. Veri bütünleştirme

Veriler farklı veri tabanlarından çekilebilmektedir. Bu nedenle elde edilen tüm veriler aynı formda olmayabilirler. Farklı bir deyişle aynı veri bir veri tabanında A diye nitelendirilirken diğler bir veri tabanında B diye adlandırılabilir. Aynı veri tabanından çekilseler bile zamanla değışik adlandırılan veriler olabilmektedir. Bu gibi farklı tür verilerin deęerlendirilebilmesi için aynı şekilde düzenlenmeleri gerekir. Bu aşamada bu dönüştürme yani veri bütünleştirme işlemi yapılır.

1.1.4.3. Veri indirgeme

Veri madenciliğinde işlemler fazla vakit alabilir. Bu yüzden gereksiz veri grupları veya sonuca etki etmeyecek veri grupları elenebilir. Benzer veri grupları varsa bunlar yerine en az özellik baz alınarak işlem süresi daha kısa hale getirilebilir. Bu süreç veri indirgeme olarak adlandırılır.

1.1.4.4. Veri dönüştürme

Verilerin özellikleri korunarak veri madencilięi modeline uygun hale getirme işlemidir (Ersöz, 2019). Bu aşamada çok deęişken olup işlemi karmaşık hale getirecek verilerde gruplandırma işlemi de yapılabilmektedir.

1.1.4.5. Veri madencilięi modelinin uygulanması

Veri madencilięi yöntemlerinin kullanılabilmesi için veriler toplanır ve bahsedilen işlemler yapılır. Veri tabanı uygun hale getirildikten sonra veri madencilięi modelleri ve yöntemleri arasından probleme ve istenilen bilgiye göre bir algoritma belirlenir ve uygulanır. Bu algoritmalar sınıflandırma, kümeleme ve birliktelik kuralları konularından biri olmaktadır.

1.1.4.6. Sonuçların sunumu ve deęerlendirilmesi

Algoritma uygulandıktan sonra veri madencilięinden elde edilen sonuçlar düzenlenir. Elde edilen ilginç örüntüler yorumlanır ve karar vericilere sunulur. Bu sonuçlar doğrultusunda mevcut sistemde bazı önlemler alınabilir veya iyileştirmeler yapılabilir.

1.2. Depo Yerleşimi ve Tasarımı

Depo kavramı şu şekilde tanımlanabilir; hammaddeleri, yarı mamulleri ve nihai ürünleri tedarik kaynaklarından alarak gruplara ayıran, kayıtlarını tutan ve stoklama görevini üstlenen, gerekli durumlarda hem iç hem de dış müşterilere dağıtımını sağlayan tesislerdir (Şenocak, 2014). Depo çeşitleri kullanım amaçlarına göre birçok isimde tanımlanır. Bunlar Şekil 1.3’de gösterildiği gibi gruplandırılmaktadır.

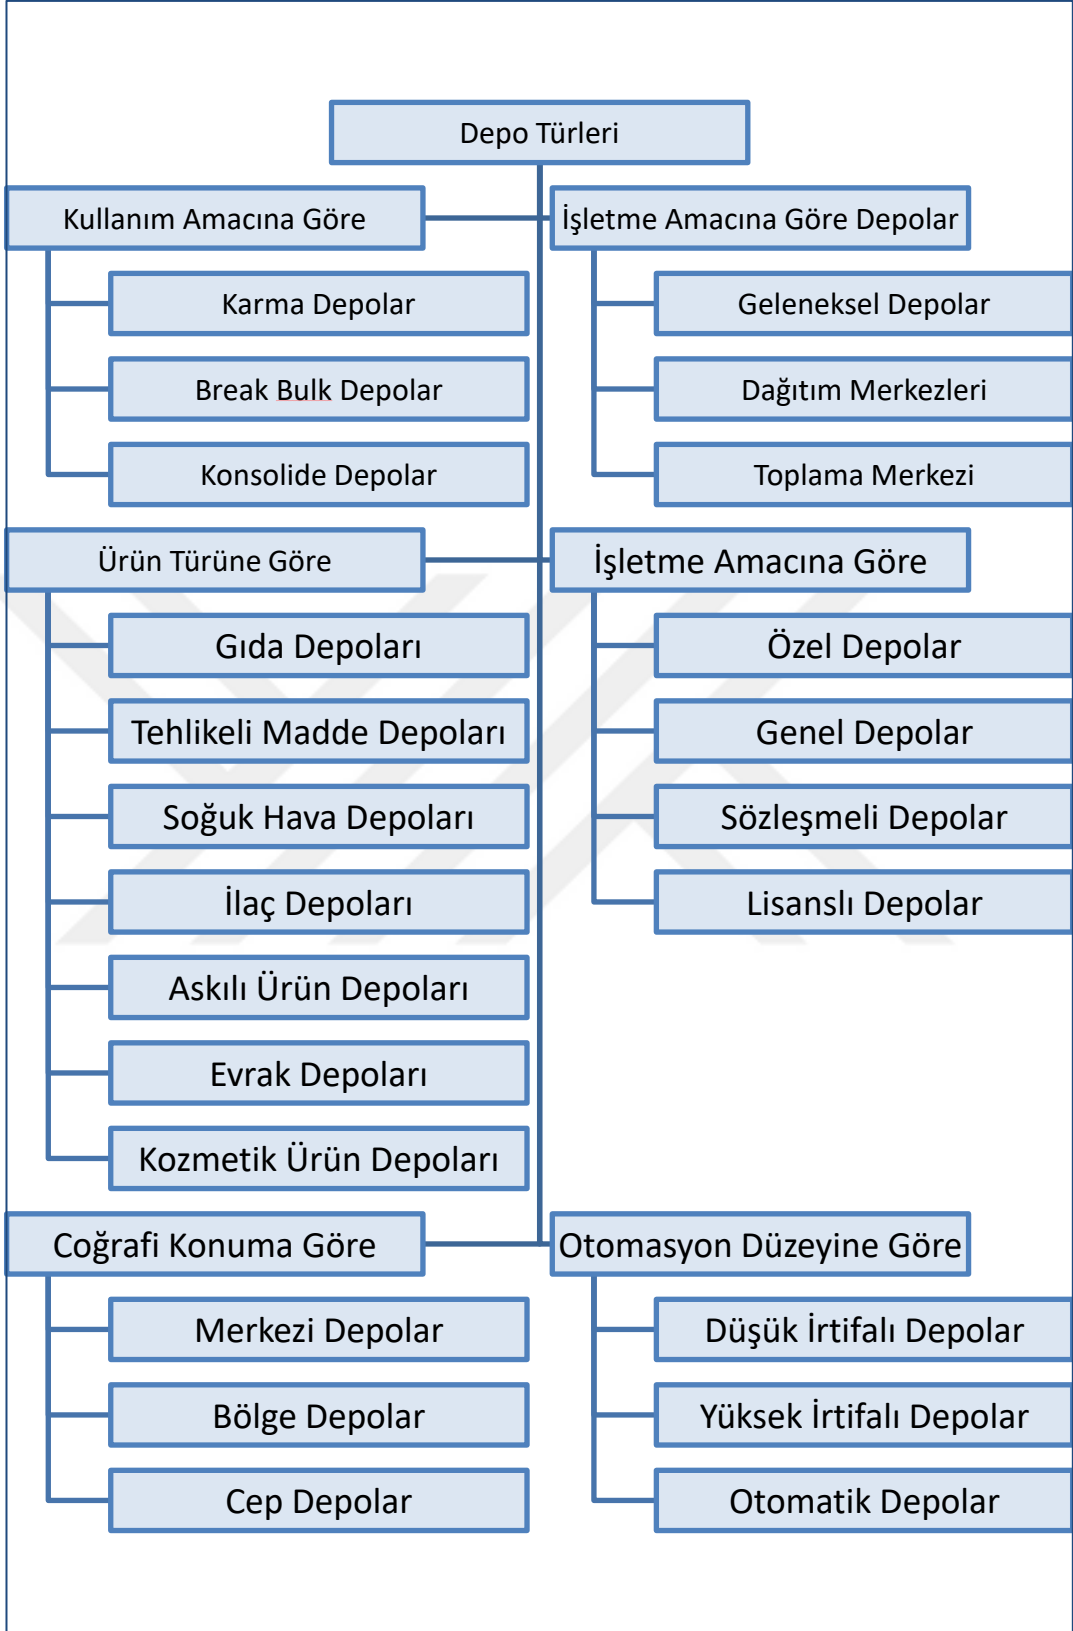
Depo tasarımı ve yerleşimi depo yönetiminin önemli unsurlarından biri olup, etkin bir depo yerleşimi operasyon maliyetlerini önemli ölçüde azaltmaktadır (Toktaş Palut ve Okçuoğlu, 2019). Bununla beraber müşteri talepleri de firmaları sipariş teslim sürelerinde iyileştirmeler yapmaya zorlamaktadır. Bu gibi unsurlar rekabet ortamında işletmelerin depo tasarımı, yerleşimi ve yönetimi konularını daha fazla önemsemelerini sağlamıştır.

1.2.1. Depo içi yerleşim planı

Depo faaliyetlerinin en önemli işlevi ürünlerin stoklanması ve müşterilere dağıtılması aşamalarıdır. Bu konuda yüksek verim sağlamak için depo içi yerleşim planının etkin bir şekilde oluşturulması gerekmektedir. Depo yerleşim planı, depodaki ürünlerin hareket özellikleri göz önünde bulundurularak buldukları yerlerin uygun biçimde düzenlenmesinin yapılmasıdır (auzefkitap.istanbul.edu.tr).

“Depo tasarımı, deponun maliyet ve/veya performansı açısından gerekli amaçlara ulaşması için birçok farklı tasarım parametresi ile ilgili kararların alınması süreci olarak tanımlanabilmektedir” (Baskak ve Karakış, 2014).

Depo yerleşim tasarımı depo alanının nasıl belirleneceği ve bu alandaki ürün bloklarının ne şekilde olması gerektiği gibi problemleri kapsamaktadır. Bu planlamaların etkin bir şekilde oluşturulması sipariş hazırlanırken zaman ve hareket açısından büyük fayda sağlamaktadır. Etkin depo yönetimi, maliyetlerin minimum düzeye indirme konusunda firmalara katkı sağlamaktadır.



Şekil 1.3. Depo Türleri (Şenocak, 2014)

Depolama konusunda en önemli adım depo alanlarının yerinin seçimidir. Üretim için gerekli hammaddelerin tedarikçilerden alınması ve optimum maliyetle üretime katılabilmesi, nihai ürünlerin yine maliyet açısından minimum düzeyde müşterilere ulaştırılması konusunda depolama alanının uygun ve doğru seçilmesi kritik önem taşımaktadır (Sargın, 2017). Bunun yanında talepler göz önünde bulundurularak depo kapasitesinin de belirlenmesi depo düzenlemede önemli rol oynamaktadır.

Depo alanı seçiminden sonraki önemli adım depoda bulunan malzemelerin konumlarını belirlemektir. Bu konuda planlama yapılırken üretime yakınlık, kullanım sıklığı ve malzemelerin büyüklükleri gibi faktörler göz önünde bulundurulur (Işık, 2019).

1.2.2. Depolama faaliyetleri

Depolama sistemi; ürünleri saklamak, sınıflandırmak, kalite kontrol, ambalajlama, etiketleme, sevkiyata hazırlama, stok kontrolü gibi işlemleri içermektedir. Depolama genel olarak hareket, stoklama ve bilgi yönetimi gibi işlevlerden oluşmaktadır.

Hareket işlevi: Bu aşamada hareket işlevi kapsamında mal kabulü ve sipariş toplama kısmını ele alabiliriz. Mal kabul işlemleri depolarda sistematik bir biçimde işlemektedir. Ürünlerin boşaltılması, depoya alınması, kontrol işlemlerinin yapılması, stok kaydının tutulması gibi işlemler mal kabulü faaliyetleri içerisinde yer almaktadır.

Sipariş toplama işlemi depo hareketleri içerisindeki en önemli işlemlerdendir. Siparişler toplanmadan önce stok kontrolü yapılmalı ve ürünlerin bulunduğu yerlere göre bir planlama yapılmalıdır. Bu işlem sırasında tüm ürünler bir araya getirilip kontrol edilir ve gerekli ambalajlama işlemleri sonrasında araçlara yüklenir.

Stoklama işlevi: Depolama depo alanlarının öncelikli amacı olarak düşünülebilir. Ürünler müşteri talebi olduğunda karşılayabilmek için depolanırlar. Ürünler depo içerisindeki belirlenmiş olan düzene göre konumlandırılır ve müşteri isteyene kadar bu noktada uygun şartlarda saklanır.

Bilgi yönetimi: Depo yönetiminde bilgilerin güncel ve doğru olması en önemli gerekliliktir. Bu nedenle depo düzenine ve ürünlere dair verilerin sürekli takip

edilmesi ve raporlanması gerekmektedir. Stok miktarları, ürün konumları, giriş-çıkış kayıtları, depo alanı ve personelle ilgili bilgiler de dahil olmak üzere tüm veriler depo yönetimi açısından güvenilir ve hızlı erişilebilir olmalıdır.

1.2.3. Depo düzenleme

Depo yönetimi konusunda depoya ürünler geldikten sonraki en önemli süreç ürünlerin depo içerisindeki lokasyonlarının belirlenmesidir. Bu durumda iyi bir depolama planı oluşturulmalıdır. Planlama yapılırken ürünlerin miktarları, boyutları ve ağırlıkları göz önünde bulundurulur. Büyük boyutlu ürünler depo içerisinde hareketi kısıtlamayacak yerlere konumlandırılırken ağır ürünler de alçak alanlara yerleştirilmelidir. Bunun yanında ürünlerin sipariş hareketliliği kriteri de büyük önem taşımaktadır. sürekli sipariş alınan ürünlerin çıkış alanına yakın konumlandırılması hem hareketi en aza indirgeyecektir hem de sipariş toplama süresini daha iyileştirecektir.

Siparişin hazırlanma süresini en çok etkileyen faktör ürünleri doğru yerleştirmektir. Frazelle (2002) yerleştirme kurallarını şu şekilde tanımlamıştır: doğrudan yerleştirme, yönlendirilmiş yerleştirme, kümelenmiş ve ardışık yerleştirme, serpiştirme. Ürünleri mal kabulüne geçirmeden doğrudan yerlerine konması işleme doğrudan yerleştirme denmektedir. Yönlendirilmiş yerleştirme ise depo yönetiminin yerleştirme yapacak personele ürünleri koymasına gerektiği yerleri söylediği yerleştirme türüdür. Burada depo yönetimi en verimli olacak biçimde yerleştirmeyi önceden belirlemesi gerekmektedir. Kümelenmiş ve ardışık yerleştirmede ürünler öncelikle yerlerine ve sıralarına göre ayrıştırılmaktadır. Serpiştirme işleminde hem yerleştirme hem de sipariş toplama işlemleri bir arada planlanmaktadır. Yerleştirme aracının boş gezme sürelerini minimize etmek için kullanılmaktadır (Hopbağlı, 2009).

1.3. Literatür Taraması

Veri madenciliği temelleri 1900'lü yıllara dayanmaktadır. 1970 yılında E.F. Codd ilişkisel modeli oluşturarak günümüz veri tabanı yönetim sistemlerinin bir nevi temellerini atmış bulunmuştur. Bilim adamları bu gelişmeyle birlikte basit kurallara dayanan uzman sistemler geliştirerek makine öğrenimini başlatmışlardır. 1980'lerde

SQL ve benzeri dillerde yazılan sistemlerin kullanılması yaygınlaşmıştır. 1990’larda artık içindeki veri miktarı katlanarak artan veri tabanlarından, faydalı bilgilerin nasıl bulunabileceği düşünölmeye başlanmıř ve bu konuda çalıřmalara ve yayınlara başlanmıřtır (SAVAř vd., 2012). Bilgi keřfi ve veri madencilięi kavramlarının oluřması ve geliřmesiyle birlikte 1992 yılında veri madencilięine dair ilk yazılım ortaya çıkmıřtır. Sonrasında giderek geliřen bu kavram ve yöntemler her alanda kullanılmaya başlanmıřtır.

Lin ve McClean 2001’de, řirketlerin iflas etme ihtimallerinin tahminiyle ilgili veri madencilięi yaklařımı geliřtirmişlerdir. Lian vd. 2002 yılında veri madencilięi tekniklerini montaj hattı uygulamalarında kullanmışlardır.

Cox vd. 2002 ‘de yaptıkları çalıřmada, yapay sinir aęları teknięiniyle bir ürünün kalite standartlarının en iyi düzeyde olması için üretim esnasında gerekli girdi miktarını belirlemişlerdir.

Yavař, 2003’te gerçekteřtirdięi çalıřmada bir kiřisel iletiřim sistemleri aęında mobil kullanıcıların hareketleri veri madencilięi kullanılarak belirlenmesi ve bu modeller kullanılarak kullanıcıların bir sonraki hareketlerinin ne olduęunun belirlenebilmesi için yeni bir algoritma ortaya sunmuřtur. Çalıřmanın ilk ařaması önceki verilerden yararlanılarak oluřturulan kullanıcı hareket modelini oluřturmaktır. İkinci ařamada hareket modelleri sayesinde hareket kuralları üretilmiştir. Çalıřma sonucunda ise bu kurullarla bir sonraki hareket tahmini gerçekteřtirilmiştir.

Facca ve Lanzi 2005 yılında veri madencilięinin bir türü olan web madencilięi analizi için bir makine öęrenme algoritması kullanmıştır. Hong vd. 2005 yılında veri madencilięi tekniklerini kullanarak bir tedarikçi seçim modeli önermişlerdir.

Akbulut 2006’da bir kozmetik markasının müşteri gruplarını belirleyerek, ayrılma eęiliminde olan müşterilerine özel pazarlama stratejileri geliřtirmiřtir. Gruplandırma iřlemi için kümeleme tekniklerini kullanmıştır. Ayrıca ayrılma eęilimindeki müşterileri belirlemek için de sınıflandırma tekniklerinden yararlanmıştır.

2006 yılında Kalikov tarafından yapılan çalıřmada bir yayınevinin internet sitesindeki verileri dikkate alınarak, birliktelik kuralları teknięi ile müşterilerin

sepetleri ve sipariş tabloları incelenmiştir. Ürün kategorilerinin değerlendirilmesi, müşterilerin meslek ve ilgi alanı açısından dağılımları, müşteri ilgi alanlarına göre satış grafikleri ve ödeme seçenekleri ile ilgili bir veri madenciliği uygulaması gerçekleştirilmiştir.

Lee vd. 2006 yılında sınıflama ve regresyon teknikleriyle beraber kredi derecelendirme uygulaması gerçekleştirmişlerdir.

Özçakır ve Çamurcu'nun 2007 yılında yaptıkları çalışmada, bir firmanın pastane satış verileri üzerinde veri madenciliği uygulamak için birliktelik kuralları ile bir yazılım tasarlanmıştır.

Çalışkan ve Soğukpınar (2008) veri madenciliği yöntemlerinden “K-means” ve “K en yakın komşu” yöntemlerinin iyileştirilmesi amacıyla k-means ve k en yakın komşu yöntemlerini bir arada kullanan hibrit bir yapı geliştirmiştir.

Kılınç (2009) çalışmasında, birliktelik kurallarından olan apriori algoritmasıyla bir elektronik firmasının kalite verilerini incelemiştir. Analiz sonucu çok sayıda oluşturulan kurallar içerisinde bir eleme metodolojisi sunmuş ve sonuçları değerlendirmiştir.

Savaş vd.(2012) veri madenciliğinin bilimsel çalışmalarda kullanımını incelemiştir.

Doğan vd. 2014 yılında bir sigorta şirketi müşterilerinin verilerine apriori algoritması uygulanmış ve sigorta çeşitleri satışları arasında birliktelik kurallarını bulmuşlardır. Satış kampanyalarını ve pazarlama stratejilerini geliştirebilecek kurallar ortaya çıkarılmıştır.

Keleş ve Kaya (2014) gerçekleştirdikleri çalışmada duvar işçilerinin gruptaki çalışanların sayısı, yaşı ve tecrübe düzeyleri gibi etkenlerin günlük verimlilik değerini ne derece etkilediğini bulmak için apriori algoritmasını uygulamışlardır. Verimliliğin arttırılabilmesini sağlamayı amaçlayan kuralları bulmayı amaçlamışlardır.

Köse (2015) satış verilerindeki ilişkileri birliktelik kuralı analizi ile incelemiştir.

Dođan (2017) ve Albayrak (2017) de veri madenciliđinin bilimsel alıřmalarda kullanımlarını incelemiřlerdir. Yıldırım ve Birant 2018 yılında bulut biliřim teknolojileri kullanılarak uygulanan veri madenciliđi yöntemlerini incelemiřlerdir.

Sebik ve Blbl 2018 yılında sađlık veri tabanında bulunan, nceden teřhisi konulmuř vakaların bilgilerini kullanarak, WEKA veri madenciliđi yazılımı aracılıđıyla hangi algoritmanın bu alanda daha bařarılı olabileceđine iliřkin bir alıřma yapmıřlardır.

Dmrek 2018 yılında veri madenciliđinde Birliktelik Kuralları ve Apriori algoritması ile sepet analizi yapmıřtır. Uygulamanın yapıldıđı iřletmenin satıřlarını arttırmak amacıyla, reyonlarda apraz rn diziliminin uygulanmasıyla mřterilerin hareketlerinin uyumu arařtırılmıřtır.

Sađın 2018 yılında yaptıđı alıřmada perakende sektrndeki bir iřletmenin verileri zerinde market sepet analizi ile iliřkili rn kategorilerini belirlemiřtir. Apriori ve FP-Growth algoritmaları kullanılarak elde edilen sonular karřılařtırılmıřtır. Ayrıca veri seti iki blme ayrılarak ilk setin sonularıyla ikinci setin sonularının tutarlılıđı incelenmiřtir. Budak vd. (2018) bir web sitesinde yapılan site ii aramaların verileri zerinde apriori algoritmasını kullanarak birliktelik analizi yapmıřlardır.

Tař (2018) ve Gedle (2019) birliktelik analizi kuralları ile satıř verilerindeki birliktelik iliřkilerini incelemiřlerdir. Ayberkin ve zen'in 2019'da yaptıđı alıřmada Apriori algoritmasını kullanarak verileri analiz eden bir yazılımın tasarımı yapılmıřtır.

Gler 2019 yılında farklı algoritmalar ile enerji tketime verileri zerinde veri madenciliđi gerekleřtirilmiřtir. Grcanok (2020) e-ticaret satıř verileri zerinden tketicilerin eđilimleri, alışkanlıkları gibi durumlarda rnlere olan eđilimlerini veri madenciliđi ile incelemiřtir.

Depo dzenlemesi konusunda literatre bakacak olursak nt vd. (2007) depo yerleřim planını iyileřtirebilmek iin belirli kısıtlar ile birlikte bir paracık sr optimizasyonu uygulamıřlardır. De Koster vd. (2007) sipariř toplama sreci tasarımı ve kontrolne iliřkin alıřmaları derlemiřtir. Bunun yanında Tuna ve Tunel (2012)

de depo ynetiminde sipariř toplama sistemlerine iliřkin bir literatr alıřması yapmıřtır. Yener (2014) alıřmasında depo ii yerleřim tasarımında maliyetleri minimize etmek amacıyla veri madencilięinde birliktelik kurallarından faydalanmıřtır. řener (2015) alıřmasında depo ii yerleřim planlamasında rnleri envanter sınıflandırmasını gz nnde bulundurarak maliyeti dřrmeyi amalamıřtır. Iřık (2019) depo dzenlemesinde rnn doęru yerleřimi ve deponun verimli kullanılabilmesi iin ok kriterli karar verme yntemlerinden olan AHP ve TOPSIS yntemlerini kullanmıřtır.

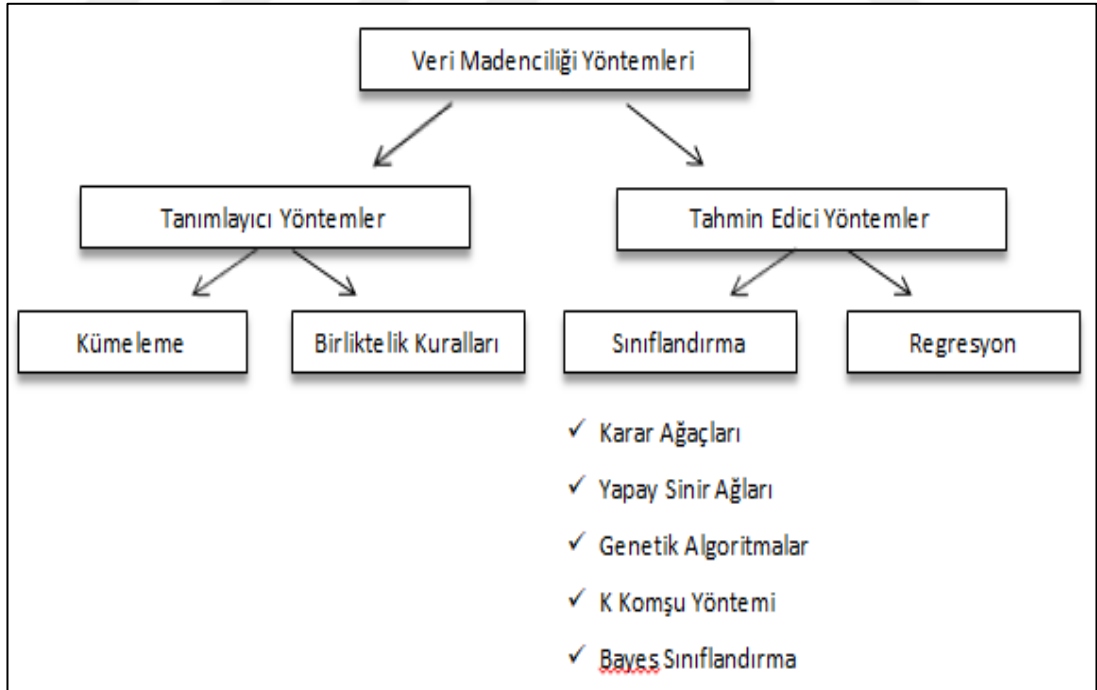


2. VERİ MADENCİLİĞİ YÖNTEMLERİ VE YAZILIMLARI

2.1. Veri Madenciliği Yöntemleri

Veri madenciliğinde kullanılan yöntemler ikiye ayrılmaktadır. Bunlar tahmin edici ve tanımlayıcı yöntemler olarak nitelendirilmektedir. Tahmin edici modellerde eldeki bilinen verilerden yola çıkılarak bir model oluşturulur ve sonuçları hakkında bilgi sahibi olunmayan veriler üzerinden ulaşılabilecek sonuçlar tahmin edilmeye çalışılır. Tanımlayıcı modeller ise karar verme sürecinde fayda sağlayabilecek mevcut verilerdeki örüntüleri anlamlandırmayı sağlamaktadır. Farklı bir deyişle, tanımlayıcı modeller verilerin içerisindeki gizli kalmış ilişkileri inceler.

İşlevlerine göre değerlendirirsek, sınıflandırma ve regresyon gibi analizler tahmin edici, kümeleme ve birliktelik analizi ise tanımlayıcı modeller sınıfına girmektedir. Şekil 2.1’de veri madenciliği yöntemleri belirtilmiştir.



Şekil 2.1. Veri madenciliği yöntemleri

2.1.1. Sınıflandırma

Sınıflandırma veri madenciliğinde en yaygın kullanılan yöntemlerden birisidir. İstenilen bir değişken bağımlı değişken ve diğerleri tahmin edici (bağımsız) değişkenler olarak adlandırılır. Amaç, girdi olarak tahmin edici değişkenlerin yer aldığı modelde, çıktının bağımlı değişkenin değerinin bulunduğu anlamlı bir model kurmaktır. Bağımlı değişken sayısal değil ise problem sınıflama problemi, Eğer bağımlı değişken sayısal ise problem regresyon problemi olarak adlandırılır (Gülçe, 2010).

Kullanılmakta olan başlıca teknikleri aşağıdaki gibi sıralayabiliriz:

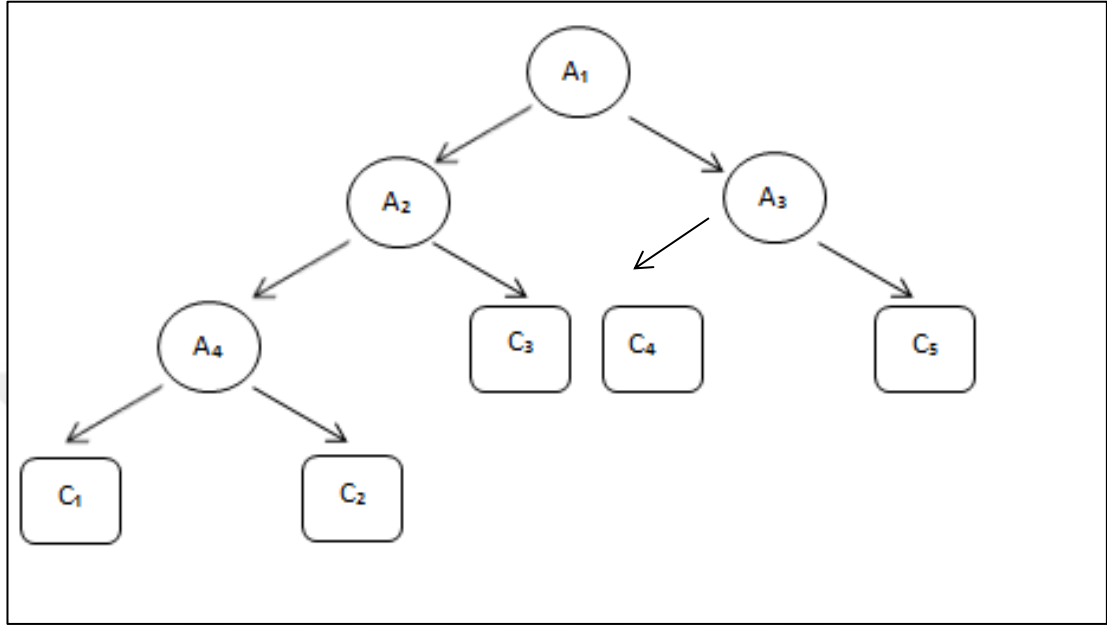
- Karar Ağaçları
- Yapay Sinir Ağları
- Genetik Algoritmalar
- K Komşu Yöntemi
- Bayes Sınıflandırma Algoritması

2.1.1.1. Karar ağaçları

Karar ağaçları sınıflandırma teknikleri arasında en çok kullanılan yöntemdir. Bunun nedeninin, karar ağaçlarının oluşturulmasının ve değerlendirilmesinin ucuz, güvenilir ve her türlü veri tabanına uyum sağlanmasının kolay olması olarak ifade edilebilir (Altunkaynak, 2017).

Karar ağaçları karar düğümleri, dallar ve yapraklardan oluşmaktadır. Her bir karar düğümü bir önem testini ifade eder. Bu test sonucunda veri kaybı olmadan ağaç dallara ayrılmaktadır. Bu dallanma işleminde hiçbir dal başka bir dala bağlantı oluşturmaz ve her biri üst düzeydeki ayrımlara bağımlıdır. Dalın sonunda bir sınıflama işlemi gerçekleşiyorsa orada yaprak oluşur ve bu yaprak veri tabanında oluşturulması gereken sınıflardan birisidir.

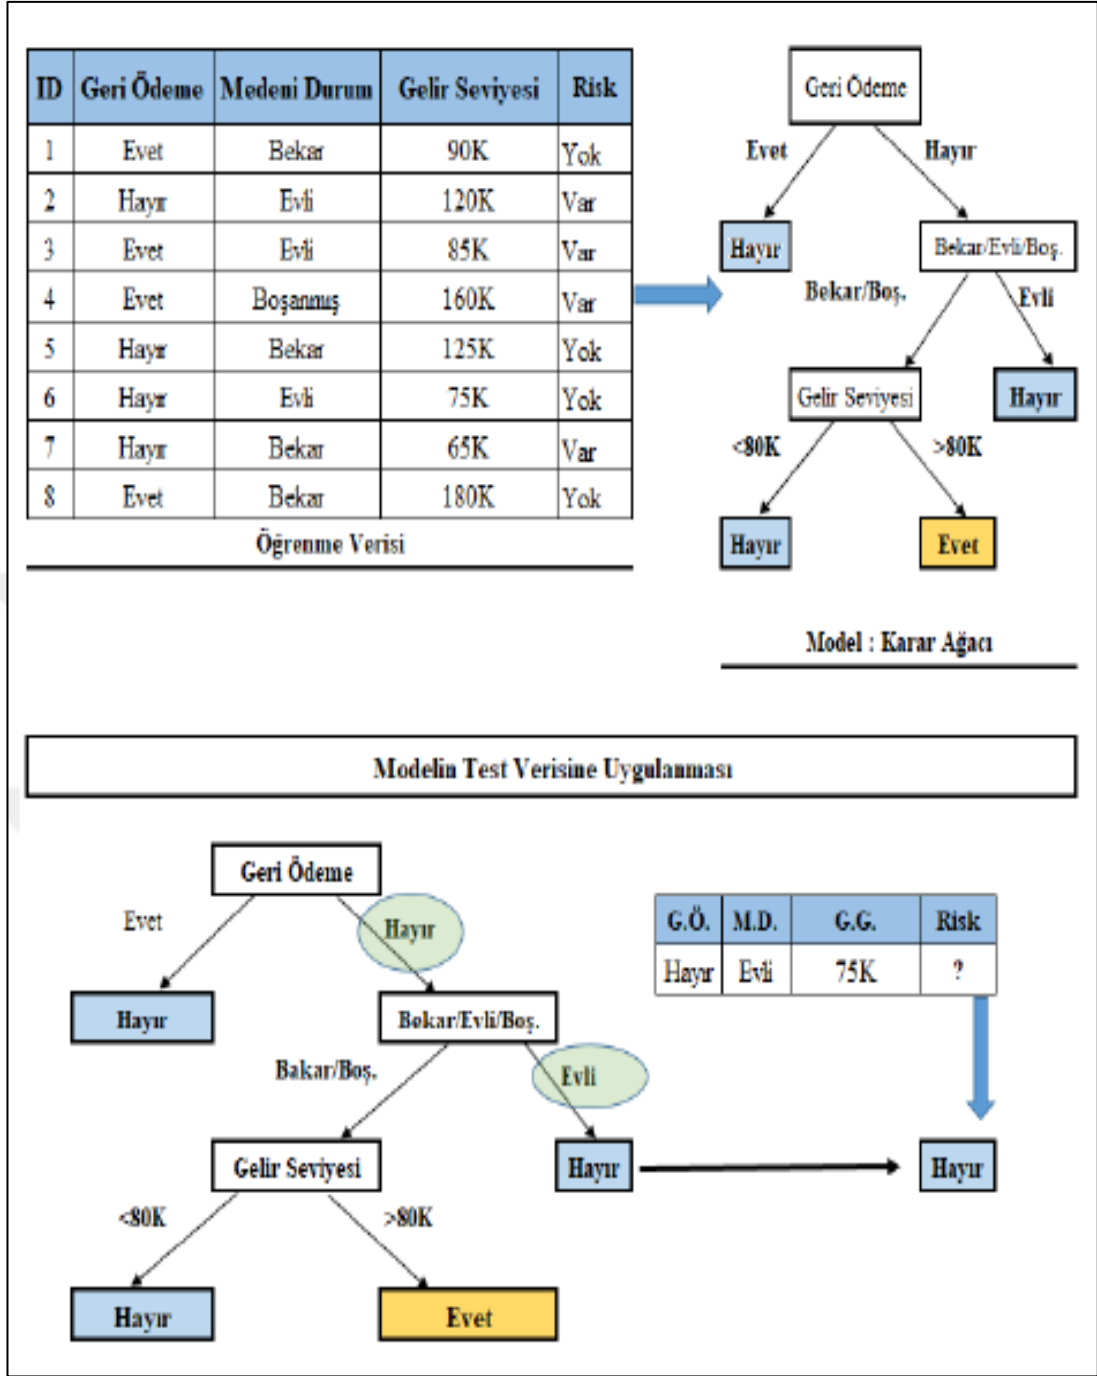
Şekil 2.2’de örnek bir karar ağacı gösterilmektedir. A_1, A_2, \dots, A_n şeklinde ifade edilenlerin her biri bir düğümü belirtmektedir. C_1, C_2, \dots, C_n sembolleri ise yaprakları ifade eder. Her bir yaprak sınıflandırma işleminde belirtilen sınıfları ifade eder.



Şekil 2.2. Karar ağacı örneği

Karar ağaçlarına dayalı olarak geliştirilmiş birçok algoritma mevcuttur. Yaygın olarak kullanılan karar ağacı algoritmaları ID3, C4.5, CART, SPRINT, C5 gibi algoritmalarlardır. Bu algoritmalar kök, düğüm, dallanma biçimleri veya uygulama esnasında izledikleri yol açısından birbirlerinden ayrılmaktadır.

Karar ağaçları uygulama teknikleri bakımından iki kısımdan oluşmaktadır. İlk kısımda karar ağacı oluşturulurken öğrenme işlemi yapılarak sınıflandırma yapılır. İkinci aşamada ise uygulanacak model geliştirilerek ağacın anlamsız dallarına budama işlemi gerçekleştirilir. Böylece model oluşturulur ve test edilir. Daha sonrasında yeni veriler model sayesinde sınıflandırılabilir. Şekil 2.3’te karar ağacı modelinin oluşturulması ve test verisine uygulanması örneklenmiştir.



Şekil 2.3. Karar ağacı oluşturulması ve test verisine uygulanması (Öğüt, 2018)

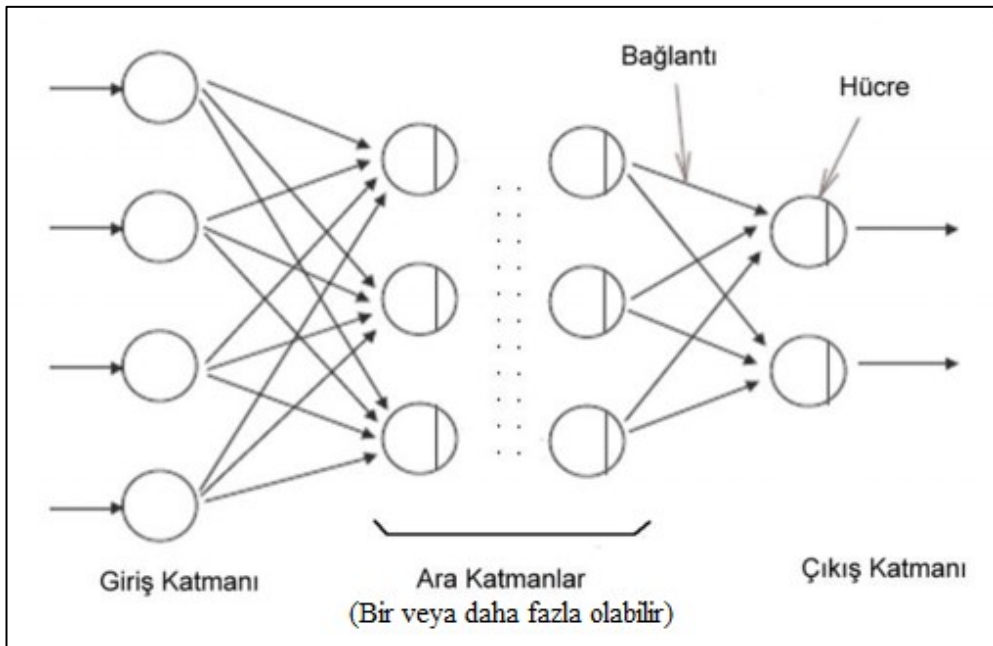
2.1.1.2. Yapay sinir ağları

Yapay sinir ağları insandaki sinir ağlarından esinlenerek geliştirilmiştir. İnsan beyninin çalışma prensiplerine dayandırılarak oluşturulmuş bir bilgi işleme sistemidir. Klasik problem çözme tekniklerinin aksine yapay sinir ağları çok sayıda problemin yer aldığı karmaşık problemleri çok hızlı bir şekilde

çözümleyebilmektedir. Biyolojik sinir sisteminden faydalanılarak oluşturulan yapay sinir ağları aynı anda birden çok probleme sonuç üretebilmektedir. Aynı zamanda farklı yapay sinir hücrelerinden birinde sorun olması durumunda diğerleri bundan etkilenmez.

Biyolojik sistemlerde öğrenme, nöronlar arasındaki sinaptik bağlantıların ayarlanması ile oluşturulur. İnsan yaşamı süresince tecrübeler edinir, bu tecrübelerin sinaptik bağlantıları etkilediği ve öğrenmenin bu şekilde geliştiği düşünülmektedir. Yapay sinir ağlarında bu ayarlamayı yapmak ve öğrenmeyi sağlamak için ağırlık fonksiyonları kullanılmaktadır, insanın deneme yanılma yoluyla öğrenmesi yapay sinir ağlarında yinelemeli eğitim sayesinde gerçekleştirilmektedir (Özçınar, 2006).

Bir yapay sinir ağı modelinde genel olarak üç katman vardır. Bunlar; giriş katmanı, gizli katman ve çıkış katmanıdır. Giriş katmanı modele girecek verileri içerir. Diğer bir deyişle bu katman dışarıdan girdileri alan nöronları içerir. Gizli katman verilerin işlendiği katmandır. Modelin karmaşıklığına göre bu katmanın sayısı çoğaltılabilir. Bu katmandaki nöron sayısı oldukça fazladır ve bu nöronlar diğer nöronlarla bağlantılı bir şekilde çalışır. Çıkış katmanı ise tüm gizli katmanlarda işlenen verilerin sonucunu oluşturan katmandır. Yapay sinir ağının genel yapısı Şekil 2.4'te gösterilmektedir.



Şekil 2.4. Yapay sinir ağlarının genel yapısı

“Yapay sinir ađları için farklı yapılar vardır ve bunların her biri verilen işleri yapmak için farklı yol ve öğrenme yöntemleri kullanırlar. Yapay sinir ađları, veri madenciliđi için çok kullanışlı bir yöntem olmasının yanında anlaşılmaz modeller de ortaya çıkardığı için uygulaması çok uzun zaman gerektirebilir. Bu duruma rağmen yapay sinir ađları; sınıflama, kümeleme ve tahmin amaçları ile kolaylıkla kullanılacak genel amaçlı ve güçlü araçlardır” (Gülçe, 2010).

2.1.1.3. Genetik algoritmalar

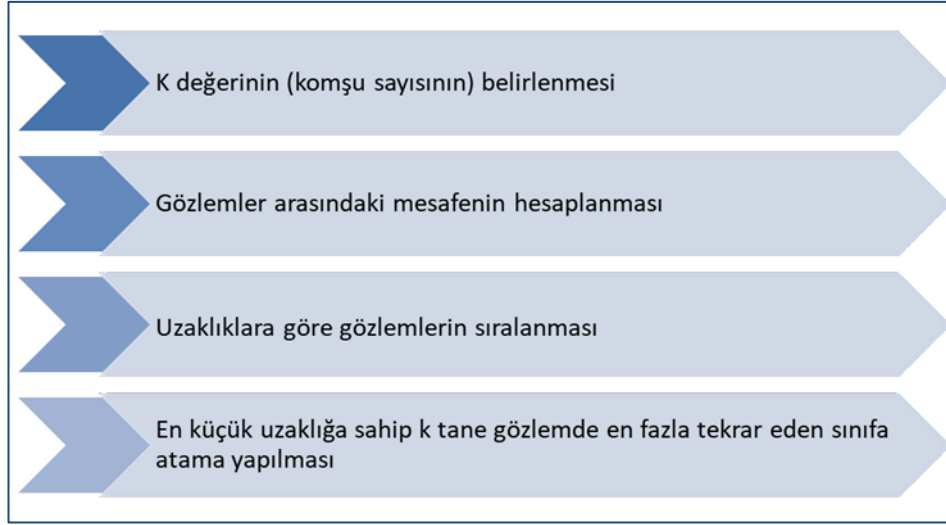
Genetik algoritmalar, biyoloji biliminden esinlenilerek geliştirilmiş makine öğrenimi yöntemlerinden birisidir (Ersöz, 2019). Genel olarak optimizasyon veya sınıflandırma amacıyla kullanılmaktadır. Doğadaki süreçlere benzer şekilde bir arama ve en iyileme yöntemidir. Genetik algoritma probleme yönelik çok sayıda çözüm oluşturur ve bunları çözüm kümesine yerleştirir. Daha sonra en güçlü olan genin hayatta kalmasını yani en iyi sonuca ulaşabilmeyi hedeflemektedir. Oluşturulan kümeye popülasyon adı verilir. Genetik algoritmalar yapay sinir ađlarıyla birlikte kullanılırlar.

Genetik algoritmalar birçok avantajına rağmen karmaşık problemlerin kodlanması açısından zorluk oluşturabilmektedir. Bunun yanı sıra en iyi sonucu verme garantisi de olmamaktadır.

2.1.1.4. K komşu yöntemi

K komşu yöntemi verideki kayıtların birbirlerine olan uzaklıklarını ve benzerliklerini değerlendirilmesiyle gerçekleşen sınıflandırma yöntemidir. Bu algoritmalar arasında en bilinen k-en yakın komşu algoritmasıdır. Öğrenme benzerlik tekniđiyle sağlanmaktadır. En yakın komşu yönteminde karar ağaçlarının tersine her bir özelliđe eşit ağırlık verilmektedir. Bu nedenden dolayı ilgisiz özelliklerin çok bulunması karmaşıklıđa sebep olabilmektedir.

Algoritma adımları Şekil 2.5’te gösterildiđi gibidir.



Şekil 2.5. k komşu yöntemi algoritmasının adımları

2.1.1.5. Bayes sınıflandırma algoritması

İstatistiksel bir sınıflama yöntemi olan bayes algoritması verilerin sonuca etkilerini olasılıksal olarak hesaplanmasını amaçlar. Sonuçlarının yorumlanması oldukça basit olmasından dolayı bayes algoritmasının kullanımı çok yaygındır. Algoritmanın temelinde Bayes Teoremi yer almaktadır. Bu teoride koşullu olasılıklar hesaplanmaktadır. Bayes teoremi, kendisi hakkında ön olasılık bilgisine sahip olduğumuz bir olay ya da hipotezle ilgili bize bir kanıt geldiğinde aynı hipotezle ilgili ön olasılık değerimizin nasıl değiştiğini açıklar (Köse, 2018). Bayes teoreminin denklemi denklem (2.1)’de verildiği gibidir.

$$P(H|E) = \frac{P(E|H)P(H)}{P(E)} = \frac{P(E|H)P(H)}{P(E|H)P(H) + P(E|H)P(H)} \quad (2.1)$$

Burada H ifadesi hipotezimizi, E ifadesi kanıtımızı ve P(H|E) ise kanıt verildiğinde hipotezin olasılığını göstermektedir.

“Bayes sınıflandırma, belirgin bir kural bulma yerine olasılıkları tahmin eden bir öğrenme sürecidir. Bu yaklaşımın avantajı, belli olasılıkları tahmin etme yöntemi tutarlı olduğunda ve veri kümesi büyük olduğunda sınıflandırıcı en küçük hataya ulaşacaktır” (Berry ve Browne, 2006:17).

2.1.2. Kümeleme analizi

Kümeleme analizi veri madenciliğinde kullanılan en önemli analizlerden biridir. Kümeleme analizi, çok sayıda verinin bulunduğu bir veri tabanında verileri değişkenlerden yararlanarak belirli özelliklerine göre gruplara yani kümelere ayırma işlemidir (Silahtaroglu, 2018). Burada gruplandırmalar yapılırken sınıflandırmadaki gibi sınıflar önceden belirli değildir. Kümelemede denetimsiz öğrenme anlayışı uygulanmaktadır. Denetimsiz öğrenme, sınıflar önceden belirli değilken veri tabanı incelenirken gruplandırma için kural çıkarma işlemidir. Başlangıçta her bir kayıt bir küme olarak ele alınır ve daha sonrasında birbirlerine benzer olanlar birleştirilerek yeni kümeler oluşturulur.

Kümeleme analizi benzer özelliklere sahip olan verilerin kümelerini bulmayı amaçlar. Bu kümelere göre veri setindeki nesnelere gruplandırır. Bu analizde verilerin gruplandırılmasında kümeleri bilgisayar programı belirleyebilir. Bunun yanı sıra kümelerin sahip olması gereken özelliklerini kullanıcı tarafından da programa bildirilebilir.

Kümeleme analizi pazarlama, ekonomi, psikoloji, istatistik, matematik, bilgisayar, telekomünikasyon gibi birbirinden farklı birçok alanda verileri tanımlama ve ayrıştırmada kullanılmaktadır.

2.1.3. Birliktelik kuralı analizi

Birliktelik analizi en basit tanımıyla veriler arasındaki ilişki ve örüntüleri analiz etmek olarak ifade edilmektedir. Giderek artan veri yığınları arasından ilişkileri bulmak kuruluşlar için oldukça güçleşmektedir. Bu nedenle doğru ve hızlı kararlar alabilmek için birliktelik kuralı analizinden faydalanmak gerekmektedir.

Birliktelik kuralları diğer veri madenciliği tekniklerinden oldukça farklıdır. Diğerleri veriyi tanımaya ya da model oluşturmaya yaramaktadır. Ancak birliktelik kuralı analizi veri tabanı içerisindeki belirli verinin diğer verilerle olan durumunu ve ilişkisini analiz etmektedir. Birliktelik analizi veri tabanındaki kayıtlar arasındaki çok önemli kuralları ve bilgileri ortaya çıkardığı için veri madenciliğinde önemli bir yere sahiptir.

Birliktelik analizi birçok alanda kullanılmaktadır. En yaygın kullanıma sahip olan ve literatürde ‘pazar sepeti analizi’ olarak isimlendirilen analiz türüdür. Bu çalışmalarda, bir ürün satın alındığında bu ürünün yanında hangi ürün veya ürünlerin de alındığı ve bu ürünler arasında nasıl bir ilişki olduğu incelenmektedir. Analiz veri setindeki tüm satış hareketleri incelenerek bütün birliktelikler arasında sık tekrarlanan birliktelikleri ortaya çıkarır. Birliktelik analizi bu ilişkiyi ve kuralı araştırmacıya sunar.

Pazar sepeti analizi sonucunda müşterinin bir ürünü satın aldığına başka hangi ürünleri de satın alabileceği hakkında olasılıklar meydana çıkmaktadır. Bu sayede işletmeci bu ilişkili ürünleri birbirine yakın konumlandırarak müşterilerin bu ürünlere daha kolay ulaşabilmelerini sağlayabilir ve aynı zamanda bu ürünlerin satışlarında artış elde edebilir.

2.1.3.1. Birliktelik kurallarının matematiksel modeli

Birliktelik kuralı modelinde $I = \{ I_1, I_2, I_3, \dots, I_m \}$ kümesine veri seti yada ürünler denir. T , ürünlerin hareketlerini ifade eder. D ise veri bütünlüğündeki tüm hareketleri tanımlar.

$X \Rightarrow I_j$, X , I 'nın bir alt kümesi ve I_j ise I içindeki herhangi bir elemandır ve bu eleman X içinde yer almamaktadır. $X \Rightarrow I_j$ kuralının T için uygun olduğunun söylenebilmesi için belli güven seviyesinden söz etmek gerekecektir. Yani, T içindeki tüm X 'lerin ne kadarının I_k 'yı sağladığı %c değeriyle ifade edilmelidir. Bu durumda, birliktelik kuralını $0 \leq c \leq 1$ güven seviyesiyle birlikte $X \Rightarrow I_j \mid c$ şeklinde ifade edebiliriz. Güven seviyesi, kuralın gücünü de belirtmektedir. (Silahtaroglu, 2016)

Birliktelik kuralı formülasyonu şu şekildedir:

$$X_1, X_2, \dots, X_m \Rightarrow Y_1, Y_2, \dots, Y_n$$

Burada X_i ve Y_j ile ifade edilmek istenen yapılan iş veya nesnelere. Bu kuralda $\{X_1, X_2, \dots, X_m\}$ meydana geldiğinde sıklıkla $\{Y_1, Y_2, \dots, Y_n\}$ işi veya nesnesinin de gerçekleştiğini tanımlar.

Birliktelik kuralı analizinde en çok kullanılmakta olan bazı ifadeleri şu şekilde sıralayabiliriz; destek, güven ve lift değeri.

Destek (support) değeri: Bir değer tüm gözlemler arasındaki görülme sıklığı olarak tanımlanır.

X için destek değeri denklem (2.2)'deki gibidir.

$$P(X) = \frac{N(X)}{n} \quad (2.2)$$

Burada n gözlem sayısını, N(X) ise X'in görülme sayısını ifade eder.

Güven (confidence) değeri: X değerini seçenlerin Y seçeneğini de seçme olasılığıdır ve denklem (2.3) nasıl hesaplandığını göstermektedir.

$$P(Y/X) = \frac{N(X,Y)}{N(X)} \text{ veya } P(Y/X) = \frac{P(X,Y)}{P(X)} \quad (2.3)$$

İlgi (lift) değeri: X ve Y'nin istatistiksel olarak bağımsız olması durumunda ne kadar birlikte geçtiklerini bulmayı sağlayan değerdir. Denklem (2.4)'de formülü verilmektedir.

$$K(X) = \frac{P(X/Y)}{P(X)} \quad (2.4)$$

2.1.3.2. Birliktelik kuralı analizinde kullanılan algoritmalar

Birliktelik kuralları analizinde ilişki kurallarının oluşturulmasının daha kolay olabilmesi için birçok algoritma geliştirilmiştir. Tüm algoritmalar aday kümeleri minimize etmeye ve veri setini hızlı bir şekilde tarayarak destek değerlerini hesaplamayı hedeflemektedir. Ancak aday kümelerinin oluşturulması, veri setinin taranma sıklığı ve veri yapılarının farklılıkları açısından birbirlerinden ayrılmaktadırlar. En çok kullanılan algoritma Apriori algoritmasıdır. Bu bölümde AIS, SETM, Apriori ve AprioriTid algoritmaları açıklanmaktadır.

AIS algoritması: AIS algoritması 1993 yılında Agrawal tarafından ortaya atılmıştır. Algoritma geniş nesne kümelerini oluşturmak için geliştirilmiştir. Veri tabanı içerisindeki nesnelere sıralamaya ve aralarında bir ilişki kurmayı amaçlamaktadır.

“Bu algoritmada, yalnızca bir öğeden kaynaklanan ilişkilendirme kuralları oluşturulur; yani, bu kuralların sonucunda yalnızca bir veri seti bulunur, örneğin $X \cap Y \Rightarrow Z$ gibi kurallar üretilebilir, ancak $X \Rightarrow Y \cap Z$ gibi kurallar üretmez” (Zerman, 2018).

Algoritma veri tabanını birçok defa tarar ve daha verimli bir hale getirmek için budama tekniği uygular. Algoritma geniş veri setleri oluşturabilmek için geliştirilmiştir.

Veri tabanındaki nesnelere A'dan Z'ye sıralama kısıtına sahiptir. AIS Algoritması birçok tarama yaparak geniş verileri ve sık tekrarlanan veri setlerini bulmaya çalışır.

Her işlemde bulunan geniş veriler aday veri seti oluşturmak amacıyla işaretlenir. Her bir işlem sonrası bir önceki taramada işaretlenen geniş veri setleri ile bu işlemdeki veriler arasındaki ortak nesne kümeleri belirlenir. Bu ortak nesne kümeleri işlemde kullanılan diğer verilerle birleştirilerek yeni veri setleri oluşturulur. Algoritma bu işlemler sırasında tahminleme ve budama tekniklerinden yararlanır. Bu sayede aday verilerden gereksiz olan kümelerin çıkartılması sağlanır. Bu aşamadan sonra her aday veri setinin destek değeri hesaplanır.

Hesaplanan destek setleri minimum güvene eşit veya daha büyük değerde ise bu veri setleri geniş veri setleri olarak seçilir. Bu geniş veri setleri bir sonraki tarama işleminde aday setlerin oluşturulması amacıyla kullanılır. Veritabanında daha fazla veri seti kalmayana kadar algoritma taramaya devam eder.

SETM algoritması: SETM algoritması büyük veri setlerinde birliktelik kuralı analiz işlemlerinin yapılabilmesi için SQL sorgulama diliyle işlem yapılmasını sağlar. Houtsuma ve Swami tarafından 1995 yılında geliştirilmiştir. Bu algoritmanın geliştirilmesindeki amaç problemin doğrudan veri tabanı işlemleri üzerinden de çözülebilmesini sağlamaktır.

Algoritmada her geniş veri seti, veri ismi ve bu ismi ayırt etmeye yarayan özellik numarası olmak üzere iki parametreye sahiptir. Bu numara TID (transaction identification) olarak kullanılır (Silahtaroglu, 2016).

SETM algoritması da AIS algoritmasında olduğu gibi veri tabanını birçok kez tarayarak işlemlerini gerçekleştirir. İlk taramada, verilerin destek değerlerine bakarak

veri tabanında geniş ve sık tekrarlayan veri seti olanları belirler. Bulunan geniş kümelerin arttırılmasıyla aday veri setlerini oluşturur.

SETM algoritması aday veri setleriyle yapılan işlemlerin TID bilgilerini saklı tutar. Aday veri setleri oluştururken ardışık olarak ifade edilen TID'ler ile aday veri setlerinin bir kopyası beraber bir şekilde algoritma tarafından kayıt edilir. Bu aşamadan sonra aday veri setleri isimlere göre sıralanır ve küçük veri setleri seçilerek silinir. Eğer bu işlemler esnasında veri tabanı TID numaralarına göre sıralanmışsa, bir sonraki işlemdeki geniş veri setleri TID'ye göre isimlerin sınıflandırılması ile bulunur. Veri tabanında birçok tarama daha yapılarak daha fazla geniş veri seti kalmayana kadar algoritma devam eder.

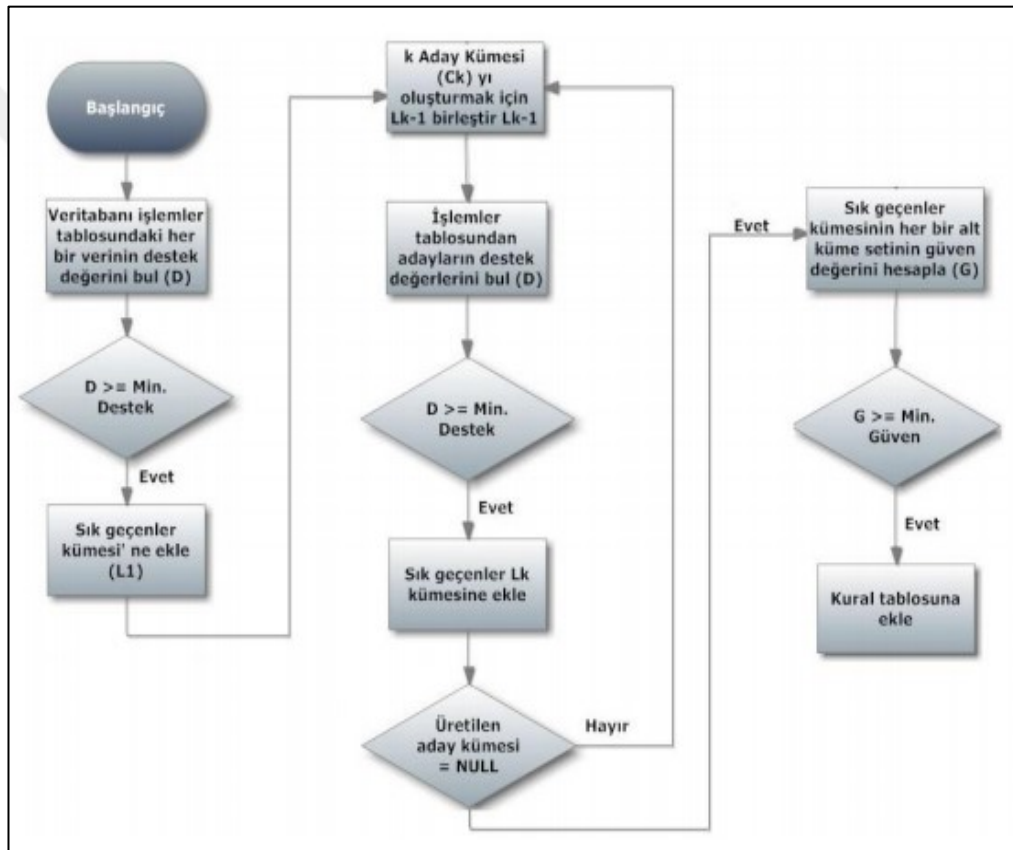
Her bir aday veri setinin bir TID numarasının bulunmasıyla bu kadar çok TID verilerinin büyük kayıt alanlarına ihtiyaç vardır. Bunun yanı sıra aday veri setinin destek değeri hesaplandıktan sonra tekrar sıralanması gerekecektir. Sonrasında destek değerini sağlamayanların elenmesi gerekmektedir. Bu dezavantajlar zaman açısından da kayıplara yol açabilmektedir.

Apriori algoritması: Apriori algoritması birliktelik kuralı analizlerinde en çok bilinen ve yaygın kullanıma sahip bir algoritmadır. Agrawal ve Srikant tarafından 1994'te geliştirilmiştir. Apriori algoritmasının ismi işlemlerin sürekli bir önceki aşamaya göre değerlendirilmesinden dolayı önceden anlamına gelen 'prior' kelimesinden gelmektedir (Özcan, 2014).

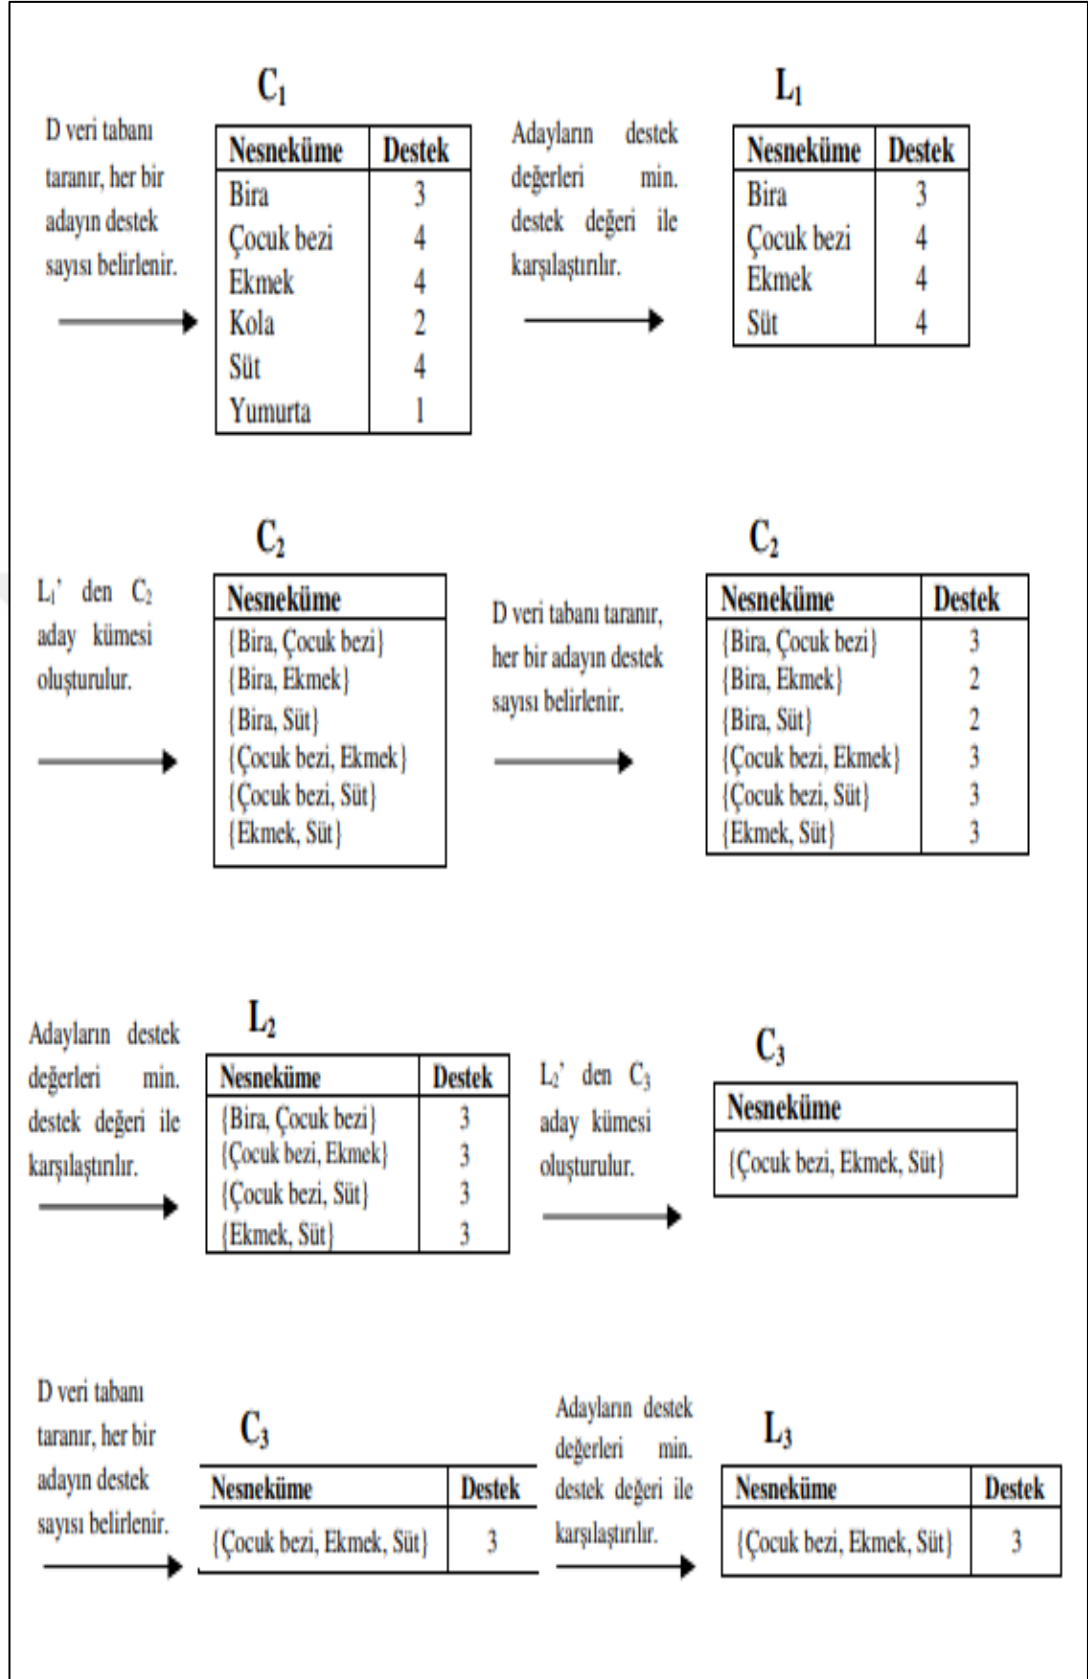
Apriori algoritması daha önceden geliştirilmiş olan AIS ve SETM algoritmalarından farklıdır. Diğerlerinde veriler okunurken aday veri setleri oluşturulmaktadır ve böylece küçük veri setleri de aday veri setleri arasına girmektedir. Bu işlemler bazen küçük veri setlerinin de gereksiz yere büyük veri setiymiş gibi sayılmasına ve işlem çokluğunun oluşmasına sebep olmaktadır. Ancak apriori algoritmasında aday veri setleri geniş olduğu tespit edilmiş yani destek değerinin uygun olduğu veri setleri üzerinden oluşturulmaktadır. Apriori algoritması geniş bir veri seti varsa bunun alt kümelerinin de geniş olabileceği hipotezini savunur. Bu sayede her bir veri için işlem yapmaz dolayısıyla zamandan ve kayıt alanından kazanç sağlar.

Algoritma ilk tarama işleminde her bir nesnenin destek değerini hesaplar ve başlangıçta belirlenen minimum destek seviyesine göre geniş olup olmadığına karar verir. Sonraki aşamalarda geniş olduğu belirlenen veri setleriyle işlemler devam eder. Algoritma daha geniş veri setleri bulunmayana kadar sürer. Her aşamada destek değerleri hesaplanır ve buna göre geniş veri setleri belirlenir.

Apriori algoritmasının anlaşılmasının daha kolay olması için Şekil 2.6'da örnek bir uygulama verilmiştir. Şekil 2.7'de ise algoritmaya ait akış diyagramı gösterilmektedir.



Şekil 2.6. Apriori algoritmasının akış diyagramı (Gülce, 2010)



Şekil 2.7. Apriori algoritması örnek uygulama (Ay, 2009)

AprioriTid algoritması: Algoritmalar destek deęerini hesaplamak için veri tabanını taramaktadır. Fakat Agrawal her adımda taramaya gerek olmayabileceęi düşüncesiyle Apriori algoritmasını tanımlarken AprioriTid algoritmasını da ortaya çıkarmıştır.

AprioriTid algoritması da aday nesne kümelerini tanımlayabilme amacıyla başlangıçta apriori-gen fonksiyonunu kullanır, ancak sonraki aşamalarda destek deęerini hesaplamak için veri tabanını taramamaktadır.

Apriori daha büyük verisetlerinde, AprioriTid ise daha küçük veri setlerinde çözüme başarılı ve hızlı bir şekilde ulaşmaya yatkındır (Aksoy, 2019).

2.2. Veri Madencilięi Yazılımları

Bu bölümde veri madencilięi uygulanırken faydalanılan uygulamalara dair bilgiler verilmektedir. En yaygın kullanılan yazılımlardan olan IBM SPSS Modeler, WEKA, Statistica Data Miner, RapidMiner gibi yazılımlar açıklanmaktadır.

2.2.1. IBM SPSS modeller

Veri madencilięi uygulamalarında kullanılmakta olan ve her adımı detaylı bir şekilde ele alan metodolojilerden biri CRISP-DM'dir. IBM SPSS Modeler (Clementine)'de bunu kullanan yazılımlardandır (Ersöz, 2019).

IBM SPSS Modeler veri madencilięi uygulamalarında hızlı bir şekilde modeli oluşturma ve uygulamaya olanak sağlamaktadır. Modeler, farklı farklı formatlarda olan veri tabanı dosyalarını deęiştirmeye gerek duymadan çekebilme ve kullanabilmektedir. Bunların içinde metin dosyaları, excel dosyaları, SQL ve SAS verileri vb. dosyalar mevcuttur.

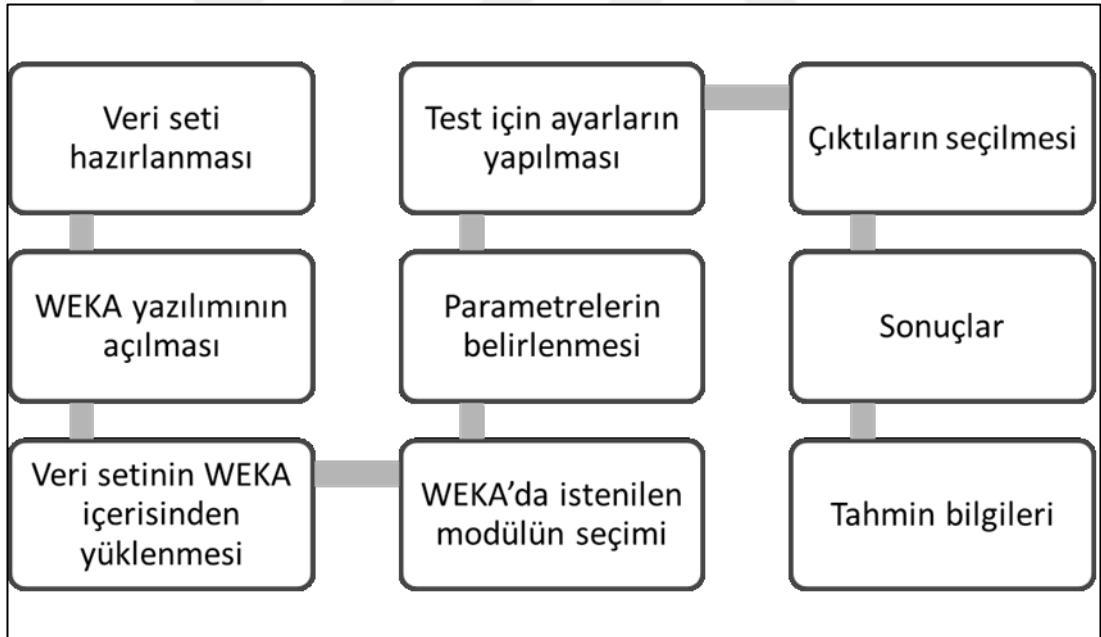
IBM SPSS Modeler tüm veri madencilięi yöntemleriyle çözüm sunabilmektedir. Bunlar; sınıflayıcı, kümeleyici ve birliktelik kurallarıdır. Algoritmaların hepsi yazılımda mevcuttur. Her alanda yapılmayı planlanan veri madencilięi uygulamalarına uyarlanabilir bir programdır. Ayrıca bu yazılım verilerin kalitesini deęerlendirebilmektedir. Bu özellięi büyük avantajlarından biridir.

2.2.2. WEKA

WEKA Yeni Zelanda'daki Waikato Üniversitesi tarafından geliştirilmiş bir yazılımdır. Makina öğrenimi tekniğiyle geliştirilen yazılım işlevsel bir grafik arabirimine sahip bir veri madenciliği programıdır. Veri ön işleme, sınıflandırma, regresyon, kümeleme, birliktelik kurallarını uygulama ve bunların sonuçlarını görselleştirebilen araçlar içerir. Algoritmalar veri kümesine doğrudan veya Java kodundan çağırılarak uygulanabilir (Ersöz, 2019).

WEKA'da veri işleme, regresyon ve gruplandırma gibi makine öğrenimi ve istatistiksel bilgiler hazır bulunmaktadır. Ayrıca içeriğinde bulunan görüntüleme araçları algoritmalar sonucu elde edilen bilgileri görsel olarak da ifade edebilmesini sağlamaktadır.

WEKA yazılımının işlem basamakları Şekil 2.8'de gösterilmektedir.



Şekil 2.8. WEKA işlem basamakları

2.2.3. Statistica data miner

“StatSoft”un sunduğu analitik yazılım ürünlerini ve çözümlerini içeren yazılım paketidir. Statistica Data Miner, çok kapsamlı bir prosedüre sahiptir. Veri analizi,

veri yönetimi, görüntüleme ve veri madenciliği tekniklerini hepsini bir arada sunmaktadır. Grafikselleştirme ara yüzü sayesinde kullanımı oldukça kolaydır.

Ölçeklenebilirlik özelliği ile boyut ve büyüklük açısından daha geniş veri kümelerini diğer programlardan daha hızlı işleyebilir, Visual Basic dilini temel alan güçlü özelleştirme araçları mevcuttur (Ay,2009).

2.2.4. RapidMiner

Amerika'daki Yale Üniversitesi tarafından Java dilini kullanarak ortaya çıkardığı bir programdır. Çok sayıda veriyi işler ve anlamlı bilgiler çıkarır. Sınıflama ve regresyon, karar ağaçları, bayes algoritması, kümeleme, birliktelik analizi ve ilişkilendirme kuralları için çok sayıda algoritma içerir. Bunların yanı sıra verileri ayırma, normalleştirme filtreleme gibi işlevleri de yerine getirmektedir. Genetik algoritma, yapay sinir ağları gibi algoritmaları da kolaylıkla uygulayabilmektedir. RapidMiner içerdiği bu özelliklerin sayısının çok olması ile analizciye rahatlık sağlamaktadır.

3. UYGULAMA

Bu bölümde çalışmaya konu olan uygulamanın tanımı ve sonuçları yer almaktadır. Uygulama kapsamında bir işletme ele alınmaktadır. İşletmenin deposunda bir iyileştirme çalışması amaçlanmaktadır. Depo incelendiğinde karmaşıklıklar gözlemlenmiştir. Aynı zamanda depo yerleşim planı bir düzene bağlı olarak değil depo çalışanın kararlarına göre gelişigüzel oluşturduğu da görülmüştür. Ayrıca bir ürünün birkaç yerde de bulunması gibi durumların söz konusu olduğu belirlenmiştir. Depo yerleşim planının oluşturulması gerektiği kararı alınmış ve bu nedenle doğru kararlar alınabilmesi için öncelikle satışların incelenmesi gerektiği düşünülmüştür. Hangi ürünlerin çok sattığı, hangi ürünlerin bir arada satıldığı ve ürünler arasındaki ilişkileri ortaya sunmak adına birliktelik kuralı analizi uygulanmıştır.

3.1. İşletme Tanıtımı

Çalışma seramik, kalebodur ve banyo malzemeleri satışı yapan bir kobinin satışları ile gerçekleştirilmiştir. İşletme bulunduğu bölgede köklü bir kuruluş olup uzun yıllardır geniş ürün yelpazesıyla müşterilerine hizmet vermektedir.

Firma satışını gerçekleştirdiği bir kısım çok çeşitli ürünlerde siparişe dayalı bir sistemle çalışmaktadır. Ancak en çok satılan ve sürekli elinde bulundurması gereken kalemler de oldukça fazladır. İşletme bu ürünleri stoklayabilmek için hemen yanında bulunan 1200 m²'lik bir depoya sahiptir.

Müşteri siparişi girildiğinde depo çalışanı istenilen ürünleri hazırlayarak araca yükleme işlemini uygulamaktadır. Bu işlem esnasında ürün boyutu ve sayısına bağlı olarak depoda bulunan transpalet ve forkliftten yararlanılmaktadır.

3.2. Problemin Tanımı

Günümüzde işletmelerin yönetim ve organizasyonlarını sürekli gerçekleşen değişim ve gelişmelere göre uyarlamaları gerekmektedir. Müşteri taleplerini karşılamak için sürekli kendilerini yenilemeye ve her zaman daha iyisini uygulamaya

çalışmaktadırlar. Bu gelişmeleri takip edip iyileştirme sürecine girmelerinde alacakları kararlar büyük önem taşımaktadır. Doğru kararların alınması zaman ve maliyet açısından hep firmaya avantaj sağlamaktadır. Bu doğrultuda artık günümüz işletmelerinin karar verme sistemlerini doğru oluşturmaları ve bilgisayar yazılımlarından da yararlanarak doğru analiz ve tespitlerde bulunmaları gerekmektedir.

Depo yönetimi ve depo düzenleme konusunda da önemli kararlar alınması her geçen gün daha fazla önem taşımaktadır. Doğru tasarlanmamış bir depo sistemi içerisinde sürece dair problemler ortaya çıkabilmektedir. Yapılan çalışmalarda göstermektedir ki depo tasarımı verimi artırmada oldukça büyük kazanımlar elde ettirmektedir.

Müşteri tarafından istenilen farklı ürün gruplarını bir arada barındıran siparişler hazırlanırken depo düzeni, ürünlerin depo ve raflarda ki konumları gibi faktörler siparişin hazırlanma sürecini doğrudan etkilemektedir. Öyle ki bu faktörler siparişin tamamlanması esnasında depo görevlisinin ürünleri toplarken katettiği mesafeyi ve harcadığı zamanı etkileyebilmektedir. Talep edilen ürünlerin doğru zamanlamayla müşteriye teslim edilmesi problem oluşturabilmektedir. Bu depo yönetimi problemine yönelik bir iyileştirme yapılmazsa ve depo çalışmasının kişisel kararlarına göre yöntemler uygulanırsa sorunlar ortaya çıkabilmektedir.

Sipariş hazırlanırken kat edilen fazla mesafe ve harcanan fazla zaman sipariş sürecinin ve çalışanın gün içinde ki verimini düşürmektedir. Bunun yanında forklift gerektiren işlemlerde enerji kaybı da söz konusu olmaktadır.

İşletmenin depo düzenlemesine bakıldığında kabaca bir düzenin olduğu fakat yeni ürünler geldikçe bu düzenin bozulmuş ve bir ürün çeşidinin birden fazla yerde olduğu bir durum söz konusu olduğu görülmektedir. Yeni ve doğru bir depo yerleşimi gerektiği aşikârdır. Bu düzenleme yapılırken işletmenin amacı depo içerisindeki ürünlerin konumlarını satışlardaki ilişkilerine göre oluşturmak ve böylece siparişler hazırlanırken oluşabilecek zaman, enerji ve müşteri memnuniyeti gibi etmenlerde kayıpları asgari düzeye indirmektedir. Bu bağlamda bu çalışmada depo düzenini iyileştirmek için alınacak kararların doğru ve hızlı olabilmesi için veri

madenciliğinden yararlanılarak satışlardaki birliktelik kurallarının analizler sonucu ortaya koyulması amaçlanmaktadır.

3.3. Algoritmanın Uygulanması

İşletmenin deposunda devamlı olarak bulundurduğu ürünlerini sınıflandırmak öncelikli aşamadır. Çalışma kapsamında ürünler incelenmiş ve sınıflandırılmıştır. Ürünler toplamda 20 gruba ayrılmıştır. Bu gruplandırma, seramiklerde ölçülerine bağlı olarak 30*60, 40*40, 60*120, 45*45, 15*60, 60*60, 25*75, 25*50 şeklinde belirlenmiştir. Diğer gruplar da; derz dolgu, yapıştırıcı, 3 cm'lik bordür, iç ve dış köşelikler, derz artışı, batarya, lavabo, aksesuar, WC taşı, klozet, duş teknesi ve duşakabin olarak sınıflandırılmıştır. Ürünler ve satış birimleri Tablo 3.1'de gösterilmektedir.

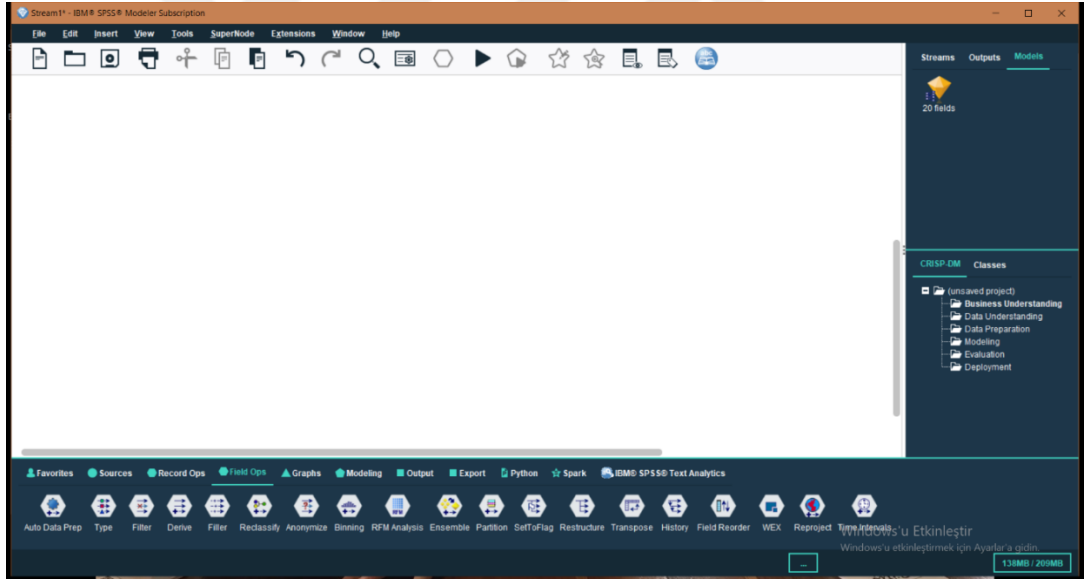
Tablo 3.1. Ürünler ve satış birimleri

Ürün Adı		Satış Birimi
Derz Dolgu		Kg
Yapıştırıcı		Kg
Seramikler	30*60	m^2
	40*40	m^2
	60*120	m^2
	45*45	m^2
	15*60	m^2
	60*60	m^2
	25*75	m^2
	25*50	m^2
Bordür		Adet
İç/Dış Köşelik		Adet
Derz Artışı		Kg
Batarya		Adet
Aksesuar		Adet
Lavabo		Adet
WC Taşı		Adet
Klozet		Adet
Duş Teknesi		Adet
Duşakabin		Adet

İşletme satışlarına ilişkin 2019 yılının ikinci yarısına ait siparişlerin bulunduğu yaklaşık 500 veri sisteme girilmiştir. Bu verilerdeki nesnelerin birbirleriyle olan ilişkilerinin incelenmesi ve bu sayede oluşturulan kurullarla depo düzenlenmesinde fayda sağlanabilecek bilgilerin edinilmesi amaçlanmıştır.

Çalışma konusu olan veri madenciliği probleminde birliktelik kurallarının oluşturulabilmesi için en yaygın olarak kullanılan apriori algoritması yöntemiyle çözüm aranmıştır. Algoritma, içeriğinde apriori modülünün bulunduğu IBM SPSS Modeler programı üzerinden çalıştırılmış ve çıkan sonuçlar değerlendirilmiştir.

IBM SPSS Modeler'ın ekranı Şekil 3.1'de verilmektedir. Eklenecek veri setinin dosyasına göre 'sources' sekmesinden türüne uygun sekme seçilip veriler çekilmektedir. Bu çalışmada Var.File data source seçilmiş ve veri seti sisteme çekilmiştir.



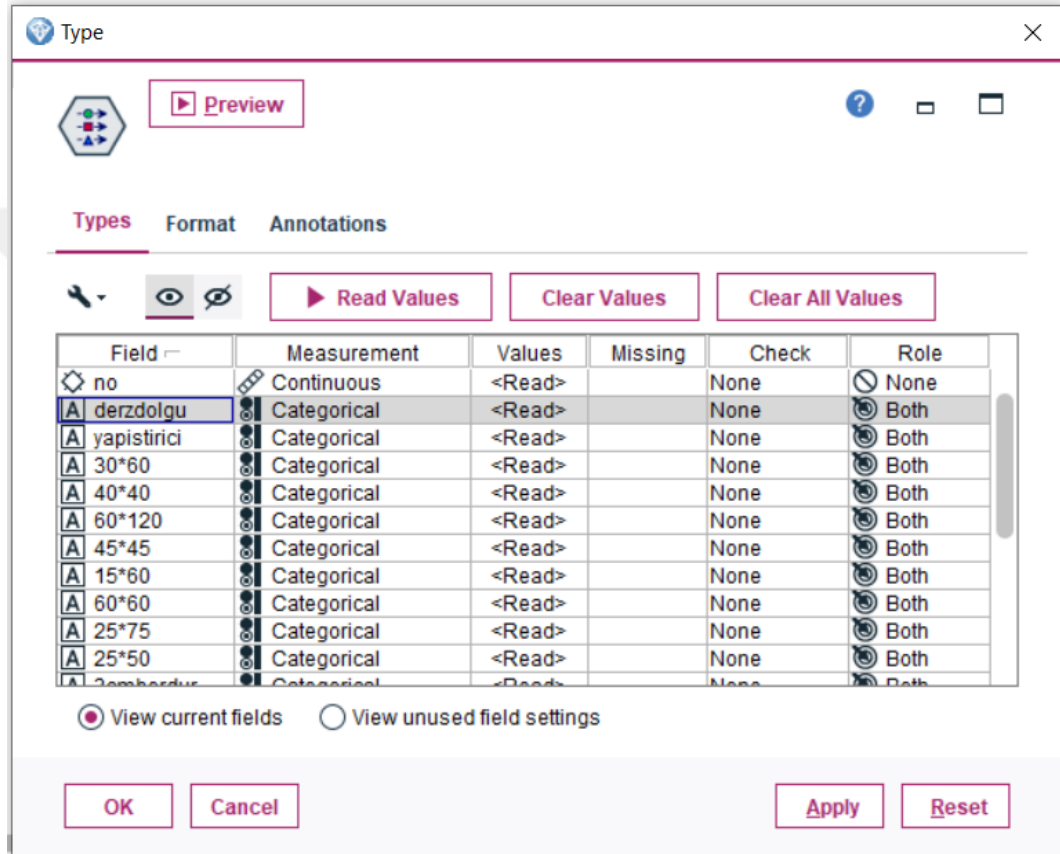
Şekil 3.1. IBM SPSS Modeler programı ana sayfası

Veri setinin tablo halinde oluşabilmesi için output menüsünden 'table' modülü seçilerek çalıştırılmaktadır. Veri setinin bir kısmının gösterildiği tablo Tablo 3.2'de verilmektedir. Burada sipariş numaraları ve müşterilerin o siparişte aldığı ürünler belirtilmektedir. T ifadesi müşterinin o ürünü aldığını F ifadesi ise ürünü almadığını belirtmektedir.

Tablo 3.2. Uygulamada kullanılan veri setinden bir kesit

no	derzdogul	yapistirici	30*60	40*40	60*120	45*45	15*60	60*60	25*75	25*50	8cmborduis	koşepari	derzartisi	batarya	aksesuar	lavabo	wctasi	klozet	dustekne	dusakabin
251	T	T	T	T	F	F	F	F	F	F	F	F	T	T	T	T	F	T	T	F
252	T	T	T	T	F	F	F	F	F	F	T	F	F	F	F	F	F	F	F	F
253	T	T	T	T	F	F	F	F	F	F	F	F	F	T	F	F	F	T	F	F
254	F	F	F	F	F	F	F	F	F	F	F	F	F	T	F	F	F	T	F	F
255	F	F	F	F	F	F	F	F	F	F	F	F	F	T	F	F	T	T	T	T
256	T	T	T	T	F	F	F	F	F	F	T	F	F	F	F	F	F	F	F	F
257	F	F	F	F	F	F	F	F	F	F	F	F	F	F	F	F	F	F	F	T
258	F	F	F	F	F	F	F	F	F	F	F	F	F	F	T	F	F	T	T	T
259	F	F	F	F	F	F	F	F	F	F	F	F	F	F	F	F	F	T	F	F
260	F	F	T	T	F	F	T	F	F	F	F	F	F	F	F	F	F	F	F	F
261	T	T	T	F	F	F	T	F	F	F	F	F	F	F	F	F	F	F	F	F
262	T	T	T	T	F	F	F	F	F	F	F	T	T	T	F	F	F	T	F	F
263	T	T	T	T	F	F	F	F	F	F	F	F	F	F	F	F	F	F	F	F
265	F	F	F	F	F	F	F	F	F	F	F	F	F	F	F	F	F	F	T	T
266	T	T	F	F	F	F	T	F	F	F	F	F	F	F	F	F	F	F	F	F
268	T	T	F	F	F	F	T	F	F	F	F	F	F	T	F	F	F	F	F	F
270	T	T	T	T	F	F	F	F	F	F	F	F	F	T	T	F	F	F	F	T
271	T	T	T	T	F	F	F	F	F	F	T	T	T	F	F	F	F	F	F	F
272	F	F	F	F	F	F	F	F	F	F	F	F	F	T	F	F	F	T	F	F
274	T	T	F	T	F	F	F	F	F	F	F	F	F	F	F	F	F	F	F	F
275	F	F	F	F	F	F	F	F	F	F	F	F	F	F	F	F	F	F	T	T
279	F	F	F	F	F	F	F	F	F	F	F	F	F	F	T	F	F	T	F	F
281	F	F	F	F	F	F	F	F	F	F	F	F	F	T	F	T	F	T	F	F
284	F	F	F	F	F	F	F	F	F	F	F	F	F	F	F	F	F	T	F	F
287	T	T	F	T	F	F	F	F	F	F	F	F	F	T	F	F	F	T	F	F
291	T	T	T	F	F	F	F	F	F	F	F	F	T	F	F	F	F	F	F	F
300	F	F	F	F	F	F	F	F	F	F	F	F	F	F	F	F	F	T	F	F
601	F	F	F	F	F	F	F	F	F	F	F	F	F	T	F	F	F	T	F	F

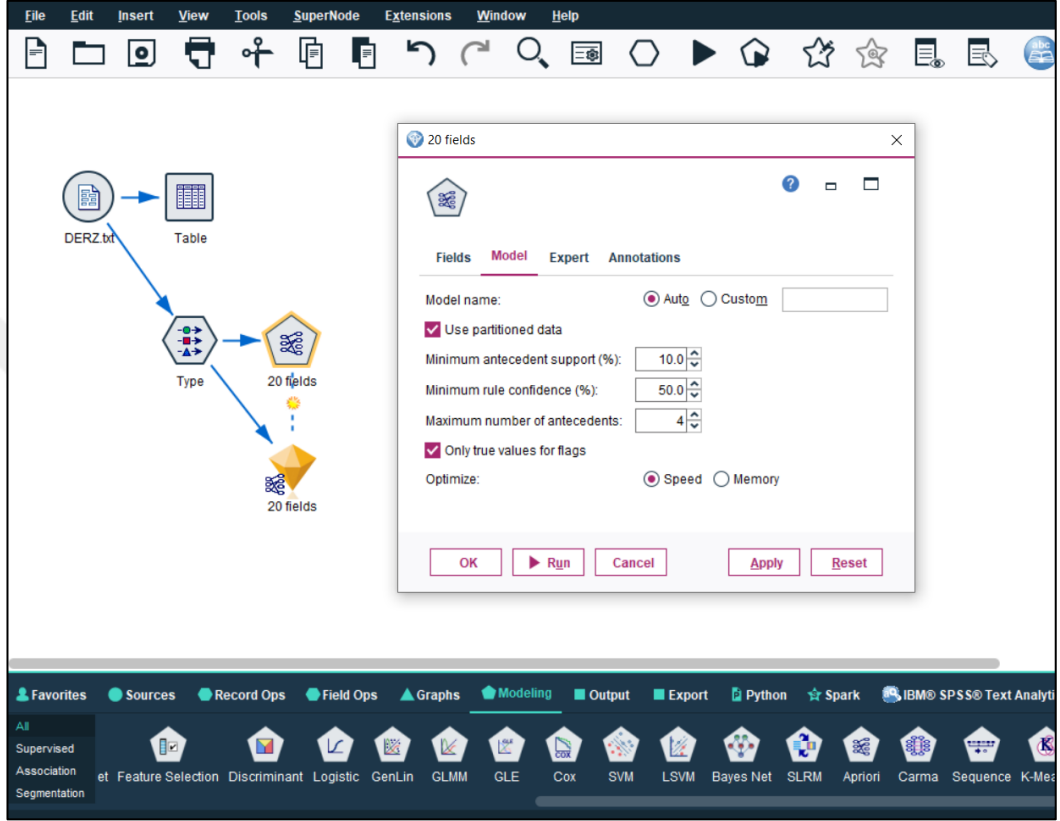
IBM SPSS Modeler programında veri setindeki değerlerin bağımlı veya bağımsız değişken olduğunu sisteme belirtmek gerekmektedir. Bu işlem menü içerisindeki ‘Type’ seçeneğiyle gerçekleştirilmektedir. Bu aşamada yapılan çalışma kapsamında analize etkisi olmayacağından sipariş numaralarını dikkate almamasını sisteme belirtmek adına bu bilgiler verilmiştir. Diğer verilerin hepsi için birbirlerine etkisi olabileceği bilgisi programa verilmiştir. Şekil 3.2’de bu işlemler belirtilmektedir.



Şekil 3.2. Type modülünde bağımlı ve bağımsız değişkenlerin atanması

Son olarak sistem üzerinde bulunan apriori modülünü seçilerek programın birliktelik kurallarını çıkarması sağlanmıştır. Apriori algoritmasının çalıştırılması için destek ve güven değerlerinin belirlenmesi gerekmektedir. Çalışma kapsamında farklı destek ve güven değerleriyle algoritma çözümlenmiştir. Uygulanan bu destek ve güven değerleri sırasıyla şu şekildedir; %10-%50, %10-%60, %20-%50 ve %15-%50. Bu çözümlenmelerin sonuçları Ek-A’da verilmektedir. Değerlendirmeler için uygun bulunan yani kapsamlı şekilde önemli birliktelikleri gösteren çözümlenmede destek değeri % 10 güven değeri ise % 50 olarak belirlenmiştir.

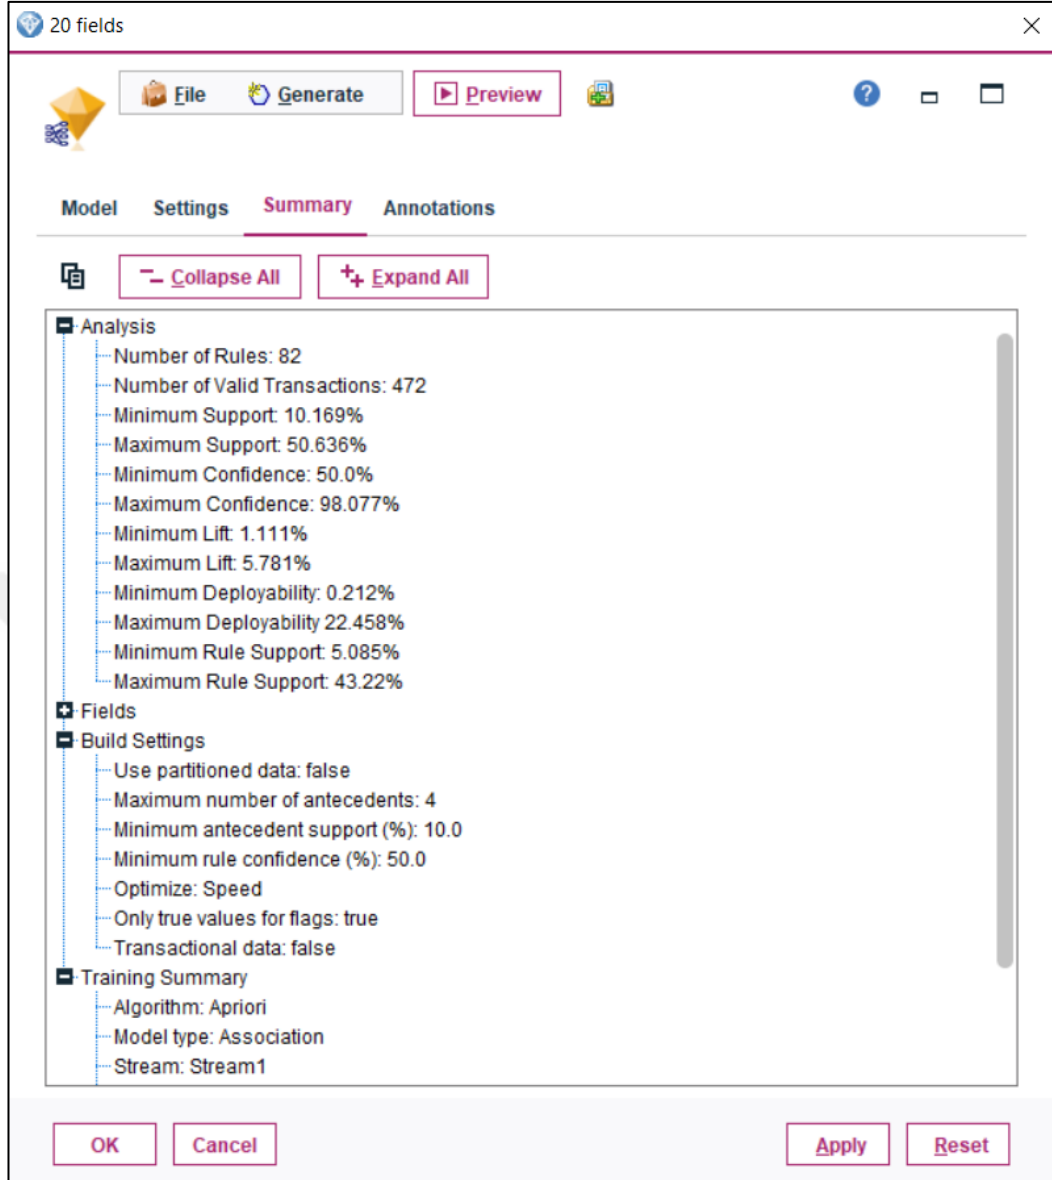
Bunun yanında sistemin ilişki kuracağı maksimum veri sayısı da 4 olarak girilmiştir. Veri sayısının 4 belirtilmesinin nedeni daha fazla sayıda ürünün birliktelik kurallarının çıkmamasıdır. Şekil 3.3’de apriori modülünde girilen değerler gösterilmektedir.



Şekil 3.3. Apriori modülünde destek ve güven değerlerinin belirtilmesi

3.4. Algoritma Sonuçları ve Değerlendirilmesi

IBM SPSS Modeler’in apriori algoritması sonucu çıkarılan kurallar EK-A Tablo A.1’de verilmektedir. Algoritma sonucu analizlerin özetini gösteren görsel ise Şekil 3.4’de verilmektedir. Programın sunduğu bu özet bilgilerde hangi algoritmanın kullanıldığı, uygulama modelinin tipi, belirlenen minimum destek ve güven değerleri hakkında bilgi verilmektedir. Bunların yanında algoritma sonucu oluşturulan birliktelik kurallarının sayısı, maksimum ve minimum destek, güven ve lift değerleri ve oluşturulan kurullarda bir arada bulunan verilerin maksimum sayısı ifade edilmektedir.



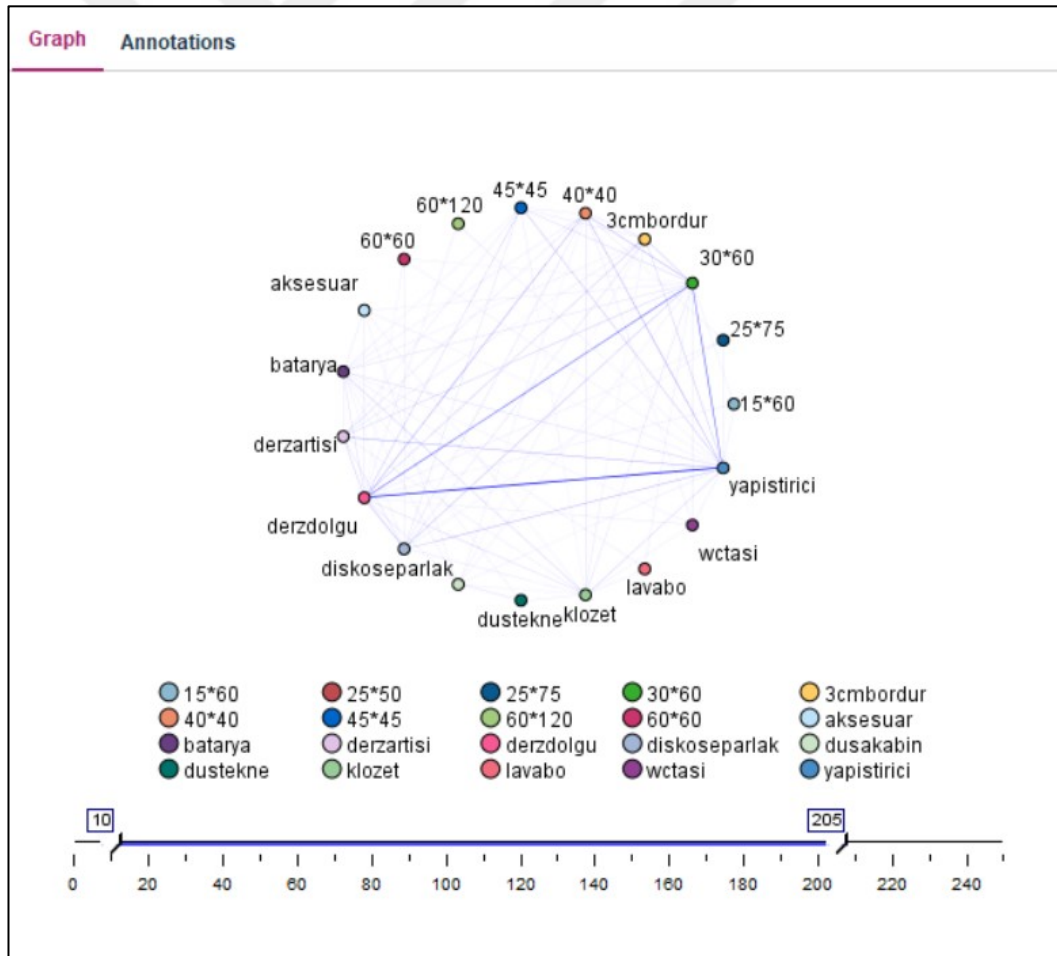
Şekil 3.4. Apriori algoritması sonucu elde edilen verilerin özeti

Program çıktıları değerlendirildiğinde en yüksek güven değerine sahip olan veri kombinasyonunun derz dolgu, yapıştırıcı, 30*60 ve 40*40'lık seramiklerin bir arada bulunduğu kombinasyon olduğu görülmüştür. Bu ürünlerin aynı anda satıldığı satışların toplam satışların % 11.02'si olduğu bulunmuştur. Bunun yanı sıra yapıştırıcı, 30*60 ve 40*40'lık seramiğin aynı anda satıldığı satışların % 98.08'inde derz dolgunun da satıldığı tespit edilmiştir. Bu dört ürünün de bulunduğu kurallardaki lift değerleri incelendiğinde hangi ürünlerin öncül olduğu konusunda çok kesin bir şey söylenemese de diğer üçünün alınması derz dolgusu için kesin bir öncül olarak ifade edilebilir.

Birliktelikler incelendiğinde 3 cm' lik bordürler, dış köşeler ve derz artısının da derz dolgusu ve yapıştırıcılar için öncül kurallar barındırdığı görülmüştür. Duşakabin ve duş teknesi arasındaki ilişki önceden de tahmin edilebilir düzeyde olması ile birlikte duşakabin alanların % 56.34'ünün duş teknesi de aldığı gözlemlenmiştir.

Tahmin edilmesi çok zor olan bir birlikteliğin de klozet ve batarya arasında olduğu gözlemlenmiştir. Klozet alan müşterilerin % 51.61'inin batarya da aldığı görülmüştür.

Algoritma sonucunda elde edilen veriler Şekil 3.5'de yer alan örümcek ağı grafiğinde gösterilmektedir. Burada ürünlerin aralarındaki ilişkiler ifade edilmektedir. Belirtilen çizgi ürünlerin birlikte buldukları satış sayısına göre farklılık göstermektedir. En çok bir arada alınan ürünlerin arasındaki çizgi en kalın olarak görülmektedir.



Şekil 3.5. Apriori algoritması sonucu ürünler arası ilişki grafiği

Analizler sonucu elde edilen bilgilere göre depo düzenlemesinde ürünlerin nerelerde yer alması gerektiğini şu şekilde özetlenebilir; en çok satılan kombinasyon, yani derz dolgu, yapıştırıcı, 30*60 ve 40*40, hem bir arada bulunmalı hem de deponun çıkış kapısına yakın bir yerde olmalıdır. Mevcut durumda derz dolgu ve yapıştırıcı bir arada olmasına rağmen seramiklere yakın konumlandırılmamaktadır. Bu dört ürünün birbirlerine yakın bulundurulması verimliliği arttıracak bir etken olacaktır.

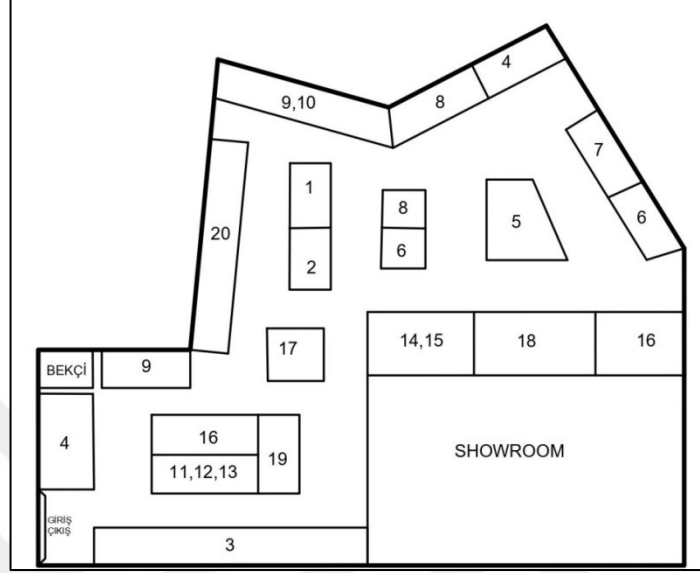
Ayrıca derz dolgunun bir öncülü olan derz artışı, bordür ve köşelikler de yine bu kısma yakın bir yerde konumlandırılmalıdır. Mevcut duruma bakıldığında derz artışı, bordür ve köşelikler bir arada ve derz dolgusuna yakın sayılabilir konumdadır. Ancak derz dolgusu seramiklere yakın konuma alındıktan sonra bu ürünlerin de yerlerini derz dolgusuna yakın tutmak amacıyla revize etmek, siparişleri hazırlama süresinin kısalmasına katkı sağlayacaktır.

Seramikler içerisinde en çok satılanların 30*60 ve 40*40 olması sebebiyle çıkışa yakın olması gerektiği gibi bu ürünlerden sonra en çok etkili satışı bulunan 45*45'lik seramikler de diğerlerine nazaran depo çıkışına daha yakın olmalıdır. Hali hazırda 30*60 ve 40*40'lık seramikler çıkışa yakın konumda ancak 45*45'lik seramikler depo içerisinde çıkışa uzak bir alanda yer almaktadır. Eğer yerleşim planında yeri çıkışa daha yakın konumlandırılırsa hareket tasarrufu ve zaman tasarrufu elde edilecektir.

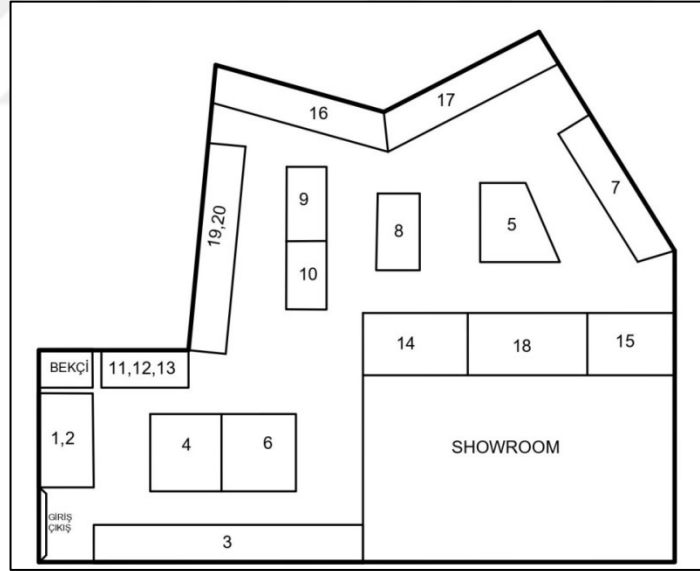
Klozet alanların yaklaşık % 52'sinin batarya aldığı göz önünde bulundurularak bu iki ürünün de konumlarının birbirlerine yakın olması gerekmektedir. Ayrıca klozet ve batarya alanların % 50-60'ı kadarı yapıştırıcı veya derz dolgu da almaktadır. Derz dolgu ve yapıştırıcıların çıkışa yakın konumda olması bu durumda sipariş hazırlama sürecine olumlu etki edecektir.

Duş teknelerinin ve duşakabinlerin yerleşim yeri de mevcut durumda depo içerisinde birbirlerine uzak konumdadır ancak aralarındaki ilişkinin % 56 gibi yüksek bir değerde olduğu görülmekte ve yakın konumlandırılması siparişin hazırlanmasında verimi arttıracaktır.

Firmanın mevcut durumdaki karmaşık yapıya sahip olan depo düzeni ve algoritma sonucu elde edilen birliktelik kuralları göz önünde bulundurularak önerilen depo düzenine ait görseller Şekil 3.6'da verilmektedir.



(a)



(b)

1. Derz dolgu	6. 45*45	11. Bordür	16. Lavabo
2. Yapıştırıcı	7. 15*60	12. Köşelik	17. WC taşı
3. 30*60	8. 60*60	13. Derz artışı	18. Klozet
4. 40*40	9. 25*75	14. Batarya	19. Duş teknesi
5. 60*120	10. 25*50	15. Aksesuar	20. Duşakabin

Şekil 3.6. Depo yerleşim düzeni

(a) İşletmenin mevcut düzeni (b) İşletme için önerilen depo düzeni

Önerilen bu depo düzeninde birlikte satılan ürünler bir arada bulundurulmuş ve bu sayede sipariş hazırlama süresinin azalması amaçlanmıştır. Önerilen bu yerleşim planı göz önünde bulundurularak veri setinden rasgele seçilmiş 10 sipariş ele alınmış ve sipariş toplama mesafeleri hesaplanmıştır. Mevcut yerleşim düzeninde ve önerilen yerleşim düzeninde sipariş toplama mesafeleri ölçülmüştür. Tablo 3.3'de bu ölçümler ve elde edilen kazanımlar ifade edilmektedir.

Tablo 3.3. Yerleşim düzenine göre sipariş toplama mesafeleri

Sipariş No	Sipariş İçeriği	Mevcut Yerleşim Düzeninde Toplama Mesafesi (m)	Önerilen Yerleşim Düzeninde Toplama Mesafesi (m)	Kazanım	Ortalama Kazanım
0251	1,2,3,4,13,14,15,16,18,19	142,80	148,80	-6,00	25,59
0256	1,2,3,4,11	104,90	30,40	74,50	
0630	2,4,14,18,20	111,70	111,60	0,10	
0923	14,19,20	96,30	85,70	10,60	
1605	1,2,3,4,5,10,19,20	135,90	111,20	24,70	
1687	1,2	99,20	22,20	77,00	
1758	1,2,4,9,12,13,18	140,70	117,40	23,30	
1911	3,4	26,00	22,00	4,00	
2011	14,19,20	87,00	77,70	9,30	
2157	3,6,11,12,13	90,00	51,60	38,40	

Tabloda da görüldüğü üzere yerleşim planı birliktelik kurallarına göre tekrar düzenlendiğinde sipariş hazırlık sürecinde kat edilen mesafede ortalama 25,59 m kadar kazanç sağlanacaktır. Dolayısıyla forklift ve transpalet kullanımında enerji ve hareket tasarrufu sağlanacaktır.

Literatürde bulunan çalışmalarda da görüldüğü gibi aralarında ilişki bulunan ürünleri depo yerleşim düzenlemesi esnasında birbirlerine yakın konumlandırmak verimi arttıracak önemli bir etkidir. Sipariş oluşturulduktan sonraki ürünlerin hazırlanma safhasının süresi doğru konumlandırma sayesinde azalacaktır. Ayrıca bu aşamada gerek forklift ile hazırlanması gereken siparişte harcanan enerji gerekse depo görevlisinin transpaletlerle veya taşıma yoluyla hazırlayacağı siparişlerdeki iş yükü minimum düzeye indirilecektir.

4. SONUÇLAR VE ÖNERİLER

Hızla gelişen teknoloji sayesinde rekabete ayak uydurabilmek adına doğru kararların alınabilmesi için kurum ve kuruluşlar tarafından veri madenciliği uygulanabilmesi büyük önem taşımaktadır. Günümüzde sürekli artan verilerin depolanabilmesi ve yorumlanabilmesi için veri madenciliği tekniklerinden faydalanmak gerekmektedir. Çünkü veri setlerinin büyüklüğü analizci tarafından değerlendirilemeyecek kadar fazladır.

Bu çalışma kapsamında öncelikle veri madenciliği tanımları, uygulama alanları, veri madenciliği yöntemleri ve kullanılan yazılımlar hakkında bilgi verilmektedir. Sonrasında uygulama kısmında bir işletmedeki depo düzeni incelenmiştir. İşletmenin plansız bir depo düzeninin olduğu ve gelen yeni ürünlerin gelişigüzel yerleştirilmesiyle halihazırda plansız olan depoda ilave karmaşıklıklar oluştuğu gözlemlenmiştir. Bu nedenle verimliliği arttırmak amacıyla yeni bir depo düzeni oluşturulması gerektiğine karar verilmiştir. Depo yerleşim planı hazırlanırken ürünlerin konumlarının satış ilişkilerine göre düzenlenmesi uygun görülmüştür. Bu sayede zaman ve enerji tasarrufuyla beraber müşteri memnuniyetini sağlamak amaçlanmıştır. Bu nedenle oluşturulacak yeni yerleşim düzenlenmesinde doğru kararlar alınabilmesi için veri madenciliğinde birliktelik kuralı analizinden faydalanılmıştır. En yaygın kullanıma sahip olan Apriori algoritması aracılığıyla ürünler arasındaki ilişkilerin analizi yapılmış ve birliktelik kuralları ortaya konulmuştur. Sonuç olarak çıkan kuralların tamamı yorumlanmış ve önemli birliktelikler şu şekilde belirtilmiştir;

- Derz dolgu, yapıştırıcı, 30*60 ve 40*40'lık seramikler arasında oldukça yüksek oranda birliktelik gözlemlenmiştir. Bu ürünler bir arada ve çıkışa yakın konumlandırılmalıdır.
- Derz artışı, köşelikler ve bordürler ilişki analizine göre derz dolgusu için bir öncül olduğu görülmüştür. Bu nedenle bu ürünler derz dolgusuna yakın konumda bulundurulmalıdır.

- Klozet alan müşterilerin çoğunun batarya ürünlerini de aldığı gözlemlenmiştir. Bu ürünlerin yan yana veya yakın konumlandırılması fayda sağlayacaktır.
- Klozet ve bataryanın bir arada bulunduğu siparişlerin çoğunda derz dolgu ve yapıştırıcı da olduğu tespit edilmiştir. Derz dolgu ve yapıştırıcının çıkışa yakın konumlanması bu ürün birlikteliği olan siparişlerin hazırlanma sürecinin verimliliğinde olumlu etkisi olacaktır.
- Duş tekneleri ve duşakabinler arasında da yüksek bir birliktelik olduğu bilgisi algoritma sonucunda elde edilmiştir. Birbirlerine uzak olan bu ürünlerin de konumları, depo yerleşim düzeni oluşturulurken birliktelikleri göz önüne alınarak tekrar düzenlenmelidir.

Bu yorumlar sayesinde depo yerleşim planında ürünlerin hangilerinin birbirlerine yakın olması ve hangilerinin çıkışa yakın konumda olması gerektiğinin daha yararlı olacağı belirtilmiştir. Elde edilen analiz sonuçlarına dayanılarak oluşturulabilecek örnek bir yerleşim düzeni verilmiştir. Bu önerilen örnek düzene göre sipariş toplama mesafeleri ölçülmüş ve ortalama 25,59 m'lik bir kazanım elde edilmiştir.

Yapılan bu çalışma sonucunda elde edilen bilgiler oldukça önemlidir. Bu bilgiler ışığında işletmenin depo yerleşim planlaması yapılabilir. Bu sayede sipariş hazırlama safhasında hem zamandan hem hareketten tasarruf sağlanabilir. Sipariş süresinin kısılması müşteriler tarafından olumlu karşılanacağı gibi depo içerisindeki araçların da daha az ve verimli kullanılması ile maliyet açısından işletmeye fayda sağlayacaktır. Ayrıca ileriki çalışmalarda da sipariş oluşturulduğunda hazırlanma safhasını depo görevlisinin kararlarına bırakmak yerine bu konuda da gezgin satıcı problemi tekniği uygulanarak işletme sistemi iyileştirilebilir.

KAYNAKLAR

Ay D., Veri Madenciliği ve Apriori Algoritması İle Süpermarket Analizi, Yüksek Lisans Tezi, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Sakarya, 245339.

Akbulut S., Veri Madenciliği Teknikleri ile Bir Kozmetik Markasının Ayrılan Müşteri Analizi ve Müşteri Segmentasyonu, Yüksek Lisans Tezi, Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Ankara, 2006, 180239.

Aksoy A., Pazarlama ve müşteri ilişkileri yönetiminde veri madenciliği uygulamaları: Pazar sepet analizinde apriori algoritmasının uygulanması, Yüksek Lisans Tezi, İstanbul Aydın Üniversitesi, Lisansüstü Eğitim Enstitüsü, İşletme Anabilim Dalı, İstanbul, 2019, 607708.

Albayrak M., Bilimsel araştırmalarda veri madenciliği kullanımı, *International Journal of Social Sciences and Education Research*, 2017, **3**(3), 751-760.

Altunkaynak B., *Veri madenciliği yöntemleri ve R uygulamaları; Kavramlar-Modeller-Algoritmalar*, Seçkin Yayıncılık, Ankara, 2017.

Ayberkin D., Özen Ü., Apriori algoritmasının kullanılmasına yönelik bir yazılım tasarımı ve uygulaması: işkur verilerinin değerlendirilmesi üzerine bir örnek çalışma, *Journal of Business In The Digital Age*, 2019, **2**(2), 95-102.

Baskak M., Karakış İ., Dağıtım Merkezi Depolarına İlişkin Hiyerarşik Depo Tasarım Metodolojisi Ve Konvansiyonel/otomatik Depo Karar Problemine İlişkin Analitik Bir Model, Doktora Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı, İstanbul, 2014.

Berry M.W., Browne M., *Lecture Notes in Data Mining*, World Scientific, London, 2006.

Budak V.Ö., Kartal E., Gülseçen S., Site-içi aramalar ve apriori algoritması kullanılarak web sitesi ziyaretçilerinin ihtiyaç tespitine yönelik bir örnek olay incelemesi, *Bilişim Teknolojileri Dergisi*, 2018, **11**(2), 211-222.

Cox I., Lewis R., Ransing R., Laszczewski H., Berni G., Application of Neural Computing in Basic Oxygen Steelmaking, *Journal of Materials Processing Technology*, 2002, **120**(1-3), 310-315.

Çalışkan S. K., Soğukpınar İ., KxKNN: K-Means ve K En Yakın Komşu Yöntemleri ile Ağlarda Nüfuz Tespiti, *2. Ağ ve Bilgi Güvenliği Sempozyumu*, Girne, 16-18 Mayıs 2008.

De Koster R., Le-Duc T., Jan Roodbergen K., Design and control of warehouse order picking: A literature review, *European Journal of Operational Research*, 2007, **182**(2), 481-501.

Dođan B., Erol B., Buldu A., Sigortacılık Sektöründe Müşteri İlişkileri Yönetimi İçin Birliktelik Kuralı Kullanılması, *Marmara Fen Bilimleri Dergisi*, 2014, **3**, 105- 114.

Dođan O., Türkiye’de Veri Madenciliđi Konusunda Yapılan Lisansüstü Tezler Üzerine Bir Araştırma, *Gazi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 2017, **19**(3), 929-951.

Dümrek N.C., Hızlı tüketim sektöründe tüketici davranışlarının birliktelik kurallarına göre incelenmesi ve sepet analizi, Yüksek Lisans Tezi, Bahçeşehir Üniversitesi, Sosyal Bilimler Enstitüsü, İstanbul, 2018, 512615.

Ersöz F., *Veri Madenciliđi Teknikleri ve Uygulamaları*, 3. Basım, Seçkin Yayınevi, Ankara, 2019.

Facca F., Lanzi P., Mining interesting knowledge from weblogs: a survey, *Data & Knowledge Engineering*, 2005, **53**(3), 225-241.

Gedleç Ş., Çok boyutlu birliktelik kuralları analizi ve işletme uygulaması, Yüksek Lisans Tezi, Marmara Üniversitesi, Sosyal Bilimler Enstitüsü, Ekonometri Anabilim Dalı, İstanbul, 2019, 550670.

Gemici B., Veri Madenciliđi ve Bir Uygulaması, Yüksek Lisans Tezi, Dokuz Eylül Üniversitesi, Sosyal Bilimler Enstitüsü, İzmir, 2012, 351031.

Güler E.R., Enerji tüketimi verileri üzerinde akan veri madenciliđi uygulaması, Yüksek Lisans Tezi, Gazi Üniversitesi, Bilişim Enstitüsü, Bilişim Sistemleri Anabilim Dalı, Ankara, 2019, 611125.

Gülce A.C., Veri Madenciliđinde Apriori Algoritması ve Apriori Algoritmasının Farklı Veri Kümelerinde Uygulanması, Yüksek Lisans Tezi, Trakya Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliđi Anabilim Dalı, Edirne, 2010, 269275.

Gülçe G., Veri Ambarı ve Veri Madenciliđi Teknikleri Kullanılarak Öğrenci Karar Destek Sistemi Oluşturma, Yüksek lisans tezi, Pamukkale Üniversitesi, Fen bilimleri enstitüsü, Denizli, 2010, 275300.

Gürcanok O.T., E-ticaret satış verileri üzerinde bir veri bilimi vaka çalışması, Yüksek Lisans Tezi, Maltepe Üniversitesi, Bilgisayar Mühendisliđi Anabilim Dalı, İstanbul, 2020, 610911.

Hong G., Park S., Jang D., Rho H., An Effective Supplier Selection Method For Constructing A Competitive Supply Relationship, *Expert Systems with Applications*, 2005, **28**(4), 629-639.

Hopbağlı F., Tedarik zincirinde ve lojistik süreçlerinde depo tasarımı ve depo yönetimi: Kozmetik sektöründe bir uygulama, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliđi Anabilim Dalı, İstanbul, 2009, 251946.

Houtsuma M., Swami A., Set-Oriented Data Mining In Relational Databases, *Data&Knowledge Engineering*, 1995, **17**(3), 245-262.

Işık E., Depo yerleşimi problemi için çok kriterli karar verme yaklaşımları: Bir otomotiv işletmesi uygulaması, Yüksek Lisans Tezi, Çukurova Üniversitesi, Fen Bilimleri Enstitüsü, Adana, 2019, 545348.

Kalıkov A., Veri Madenciliği ve Bir E-Ticaret Uygulaması, Yüksek Lisans Tezi, Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Ankara, 2006, 180400.

Keleş A. E., Kaya M., Duvar İnşa Edilmesinde Verimliliği Etkileyen Faktörlerin Apriori Veri Madenciliği Yöntemi Kullanılarak Analizi, *XVI. Akademik Bilişim Konferansı*, Mersin, 5-7 Şubat 2014.

Kılınç Y., Mining Association Rules For Quality Related Data In An Electronics Company, Yüksek Lisans Tezi, Ortadoğu Teknik Üniversitesi, Ankara, 2009, 237591.

Köse İ., *Veri madenciliği teori uygulama ve felsefesi*, 1. basım, Papatya Yayıncılık Eğitim, İstanbul, 2018.

Köse Y., Değerli müşterilerde ürün kategorileri arasındaki satış ilişkilerinin veri madenciliği yöntemlerinden birliktelik kuralları ve kümeleme analizi ile belirlenmesi ve ulusal bir perakendecide örnek uygulama, Yüksek Lisans Tezi, Selçuk Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme Anabilim Dalı, Konya, 2015, 391883.

Lee T., Chiu C., Chou Y., Lu C., Mining the customer credit using classification and regression tree and multivariate adaptive regression splines, *Computational Statistics & Data Analysis*, 2006, **50**(4), 1113-1130.

Lian J., Lai M., Lin Q., Yao F., Application of data mining and process knowledge discovery in sheet metal assembly dimensional variation diagnosis, *Journal Of Materials Processing Technology*, 2002, **129**(1-3), 315-320.

Lin F., McClean S., A data mining approach to the prediction of corporate failure, *Knowledge-Based Systems*, 10.1007/978-1-4471-0275-5_7.

Önüt S., Tuzkaya U.R., Doğaç B., A particle swarm optimization algorithm for the multiple-level warehouse layout design problem, *Computer & Industrial Engineering*, 2008, **54**(4), 783-799.

Özcan C., Veri Madenciliğinin Güvenlik Uygulama Alanları ve Veri Madenciliği ile Sahtekârlık Analizi, Yüksek Lisans Tezi, İstanbul Bilgi Üniversitesi, Sosyal Bilimler Enstitüsü, İstanbul, 2014, 380714.

Özçakır F. C., Çamurcu A. Y., Birliktelik Kuralı Yöntemi İçin Bir Veri Madenciliği Yazılımı Tasarımı ve Uygulaması, *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi*, 2007, **12**(6), 21-37.

Özçınar H., KPSS sonuçlarının veri madenciliği yöntemleriyle tahmin edilmesi, Yüksek Lisans Tezi, Pamukkale Üniversitesi, Fen Bilimleri Enstitüsü, Denizli, 2006, 180572.

Sağın A.N., Veri madenciliği algoritmaları ile birliktelik kurallarının belirlenmesi: Perakende sektöründe bir uygulama, Yüksek Lisans Tezi, İstanbul Ticaret Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı, İstanbul, 2018, 526928.

Sargın K., Etkin depo yönetimi ve depo planlamasında bilişim sistemleri uygulaması, Yüksek Lisans Tezi, Yaşar Üniversitesi, Sosyal Bilimler Enstitüsü, İzmir, 2017, 477402.

Savaş, S., Topaloğlu, N. ve Yılmaz, M., Veri Madenciliği Ve Türkiye'deki Uygulama Örnekleri, *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi*, 2012, **11**(21), 1-23.

Sebik N.B., Bülbül H.İ., Veri madenciliği modellerinin akciğer kanseri veri seti üzerinde başarılarının incelenmesi, *TÜBAV Bilim Dergisi*, 2018, **11**(3), 1-7.

Seyrek İ.H., Ata H.A., Veri zarflama analizi ve veri madenciliği ile mevduat bankalarında etkinlik ölçümü, *BDDK Bankacılık ve Finansal Piyasalar Dergisi*, 2010, **4**(2), 67-84.

Silahtaroglu G., *Veri madenciliği kavram ve algoritmaları*, 3. Basım, Papatya Yayıncılık, İstanbul, 2016.

Şener B., Envanter sınıflandırma tabanlı depo içi yerleşim planlaması ve bir uygulama, Yüksek Lisans Tezi, Hava Harp Okulu, Havacılık ve Uzay Teknolojileri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı, 2015, 397136.

Şenocak M., Kozmetik sektöründe bir depo tasarımı, Yüksek Lisans Tezi, Maltepe Üniversitesi, Sosyal Bilimler Enstitüsü, Uluslararası ticaret ve Lojistik Yönetimi Anabilim Dalı, İstanbul, 2014, 370356.

Taş Y., Birliktelik kuralları madenciliği ve bir uygulama, Yüksek Lisans Tezi, Cumhuriyet Üniversitesi, Sosyal Bilimler Enstitüsü, Yönetim Bilişim Sistemleri Anabilim Dalı, Sivas, 2018, 494114.

Toktaş Palut P., Okçuoğlu F., Depo tasarımı ve yerleşimi: Bir gerçek hayat uygulaması, *Beykent Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, 2019, **12**(2), 14-22.

Tuna G., Tunçel G., Depo yönetiminde sipariş toplama sistemleri: Bir literatür araştırması, *Dokuz Eylül Üniversitesi Mühendislik Bilimleri Dergisi*, 2012, **14**(42), 15-31.

URL-1: <https://www.oracle.com/tr/database/what-is-a-data-warehouse/>, (Ziyaret Tarihi: 27 Nisan 2020)

URL-2: http://auzefkitap.istanbul.edu.tr/kitap/sivilhava_ao/depotasarimiveyonetimi.pdf, (Ziyaret Tarihi: 14 Temmuz 2020)

Yavaş G., Using A Data Mining Approach For The Prediction of User Movements in Mobile Environments, Yüksek Lisans Tezi, Bilkent University, Institute of Engineering and Science,2003, 139268.

Yener F., Veri madenciliği ve optimizasyon teknikleri kullanılarak bir depo tasarımı: Perakende sektöründe uygulanması, Yüksek Lisans Tezi, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı, Sakarya, 2014, 379558.

Yıldırım P., Birant D., Bulut bilişimde veri madenciliği tekniklerinin uygulanması: Bir literatür taraması, *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 2018, **24**(2), 336-343.

Zerman M., Birliktelik kuralı algoritmaları ile büyük veriler üzerinde anlitik analizler: havaalanı örneği, Yüksek Lisans Tezi, Haliç Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul, 2018, 522749.



EKLER

EK-A

Tablo A.1. Algoritma sonuçları – Güven %10 Destek %50

Consequent	Antecedent	Support (%)	Confidence (%)	Lift
Derz dolgu	40*40 30*60 Yapıştırıcı	11.017	98.077	1.937
Derz dolgu	derz artısı 30*60 Yapıştırıcı	10.593	96.0	1.896
Derz dolgu	40*40 Yapıştırıcı	17.373	95.122	1.879
Derz dolgu	derz artısı Yapıştırıcı	16.525	94.872	1.874
Yapıştırıcı	derz artısı 30*60 derz dolgu	10.805	94.118	1.859
Yapıştırıcı	40*40 derz dolgu	17.585	93.976	1.856
Yapıştırıcı	derz artısı derz dolgu	16.737	93.671	1.85
Yapıştırıcı	3cm bordür derz dolgu	11.864	91.071	1.799
Derz dolgu	derz artısı 30*60	11.864	91.071	1.799
Yapıştırıcı	40*40 30*60 derz dolgu	11.864	91.071	1.799
Yapıştırıcı	dış köşe 30*60 derz dolgu	11.017	90.385	1.785
Derz dolgu	30*60 Yapıştırıcı	28.178	90.226	1.782
Derz dolgu	derz artısı	18.644	89.773	1.773
Derz dolgu	3cm bordür Yapıştırıcı	12.076	89.474	1.767
Yapıştırıcı	45*45 derz dolgu	11.864	89.286	1.763
Yapıştırıcı	derz artısı 30*60	11.864	89.286	1.763
Yapıştırıcı	derz artısı	18.644	88.636	1.75

Tablo A.1. (Devam) Algoritma sonuçları – Güven %10 Destek %50

Consequent	Antecedent	Support (%)	Confidence (%)	Lift
Yapıştırıcı	30*60 derz dolgu	29.025	87.591	1.73
Yapıştırıcı	dış köşe derz dolgu	16.525	87.179	1.722
Derz dolgu	dış köşe Yapıştırıcı	16.525	87.179	1.722
Derz dolgu	dış köşe 30*60 Yapıştırıcı	11.441	87.037	1.719
Yapıştırıcı	dış köşe 30*60	13.347	85.714	1.693
Yapıştırıcı	derz dolgu	50.636	85.356	1.686
Derz dolgu	Yapıştırıcı	50.636	85.356	1.686
Derz dolgu	3cm bordür 30*60	11.017	84.615	1.671
Yapıştırıcı	3cm bordür 30*60	11.017	84.615	1.671
Yapıştırıcı	3cm bordür	14.619	82.609	1.631
Derz dolgu	dış köşe 30*60	13.347	82.54	1.64
Derz dolgu	dış köşe	20.127	82.105	1.621
Yapıştırıcı	dış köşe	20.127	82.105	1.621
Derz dolgu	3cm bordür	14.619	81.159	1.603
30*60	3cm bordür derz dolgu Yapıştırıcı	10.805	80.392	1.926
30*60	3cm bordür derz dolgu	11.864	78.751	1.883
Derz dolgu	45*45 Yapıştırıcı	13.559	78.125	1.543
30*60	3cm bordür Yapıştırıcı	12.076	77.193	1.849
Yapıştırıcı	45*45	17.797	76.19	1.505
Derz dolgu	40*40	23.305	75.455	1.49
30*60	3cm bordür	14.619	75.362	1.806
Yapıştırıcı	40*40	23.305	74.545	1.472
Derz dolgu	40*40 30*60	16.102	73.684	1.455

Tablo A.1. (Devam) Algoritma sonuçları – Güven %10 Destek %50

Consequent	Antecedent	Support (%)	Confidence (%)	Lift
Derz dolgu	30*60	41.737	69.543	1.373
30*60	dış köşe Yapıştırıcı	16.525	69.231	1.659
30*60	dış köşe derz dolgu Yapıştırıcı	14.407	69.118	1.656
30*60	40*40	23.305	69.091	1.655
Yapıştırıcı	40*40 30*60	16.102	68.421	1.351
Yapıştırıcı	30*60	41.737	67.513	1.333
30*60	40*40 derz dolgu	17.585	67.47	1.617
Yapıştırıcı	45*45 30*60	10.381	67.347	1.33
Derz dolgu	45*45	17.797	66.667	1.317
30*60	dış köşe derz dolgu	16.525	66.667	1.597
30*60	dış köşe	20.127	66.316	1.589
30*60	40*40 derz dolgu Yapıştırıcı	16.525	65.385	1.567
Derz dolgu	45*45 30*60	10.381	65.306	1.29
30*60	derz artışı derz dolgu Yapıştırıcı	15.678	64.865	1.554
30*60	derz artışı derz dolgu	16.737	64.557	1.547
30*60	derz artışı Yapıştırıcı	16.525	64.103	1.536
30*60	derz artışı	18.644	63.636	1.525
30*60	40*40 Yapıştırıcı	17.373	63.415	1.519
Yapıştırıcı	Klozet Batarya	10.169	60.417	1.193
40*40	3cm bordür 30*60	11.017	59.615	2.558

Tablo A.1. (Devam) Algoritma sonuçları – Güven %10 Destek %50

Consequent	Antecedent	Support (%)	Confidence (%)	Lift
30*60	derz dolgu Yapıştırıcı	43.22	58.824	1.409
40*40	3cm bordür derz dolgu Yapıştırıcı	10.805	58.824	2.524
30*60	45*45	17.797	58.333	1.398
30*60	derz dolgu	50.636	57.322	1.373
30*60	45*45 derz dolgu	11.864	57.143	1.369
40*40	3cm bordür derz dolgu	11.864	57.143	2.452
Duş tekne	Duşakabin	15.042	56.338	5.781
Derz dolgu	Klozet Batarya	10.169	56.25	1.111
30*60	45*45 derz dolgu Yapıştırıcı	10.593	56.0	1.342
30*60	Yapıştırıcı	50.636	55.649	1.333
40*40	3cm bordür Yapıştırıcı	12.076	54.386	2.334
Dış köşe	derz artışı 30*60	11.864	53.571	2.662
Dış köşe	derz artışı 30*60 derz dolgu	10.805	52.941	2.63
3cm bordür	40*40 30*60 Yapıştırıcı	11.017	51.923	3.552
Derz artışı	dış köşe 30*60 derz dolgu	11.017	51.923	2.785
Batarya	Klozet	19.703	51.613	2.511
30*60	45*45 Yapıştırıcı	13.559	51.562	1.235

Tablo A.1. (Devam) Algoritma sonuçları – Güven %10 Destek %50

Consequent	Antecedent	Support (%)	Confidence (%)	Lift
3cm bordür	40*40 30*60 derz dolgu Yapıştırıcı	10.805	50.98	3.487
40*40	3cm bordür	14.619	50.725	2.177
3cm bordür	40*40 30*60 derz dolgu	11.864	50.0	3.42
Dış köşe	derz artışı 30*60 Yapıştırıcı	10.593	50.0	2.484
Dış köşe	derz artışı 30*60 derz dolgu Yapıştırıcı	10.169	50.0	2.484

Tablo A.2. Algoritma sonuçları – Güven %10 Destek %60

Consequent	Antecedent	Support (%)	Confidence (%)
Derz dolgu	40*40 30*60 Yapistirici	11.017	98.077
Derz dolgu	derz artısı 30*60 Yapistirici	10.593	96.0
Derz dolgu	40*40 Yapistirici	17.373	95.122
Derz dolgu	derz artısı Yapistirici	16.525	94.872
yapistirici	derz artısı 30*60 Derz dolgu	10.805	94.118
yapistirici	40*40 Derz dolgu	17.585	93.976
yapistirici	derz artısı Derz dolgu	16.737	93.671
yapistirici	3 cm bordür Derz dolgu	11.864	91.071
Derz dolgu	derz artısı 30*60	11.864	91.071
yapistirici	40*40 30*60 Derz dolgu	11.864	91.071
Yapistirici	dış köşe 30*60 Derz dolgu	11.017	90.385
Derz dolgu	30*60 Yapistirici	28.178	90.226
Derz dolgu	Derz artısı	18.644	89.773
Derz dolgu	3cm bordür Yapistirici	12.076	89.474
Yapistirici	45*45 Derz dolgu	11.864	89.286
Yapistirici	derz artısı 30*60	11.864	89.286

Tablo A.2. (Devam) Algoritma sonuçları – Güven %10 Destek %60

Consequent	Antecedent	Support (%)	Confidence (%)
yapistirici	Derzartisi	18.644	88.636
yapistirici	30*60 Derz dolgu	29.025	87.591
yapistirici	dış köşe Derz dolgu	16.525	87.179
derz dolgu	dış köşe Yapistirici	16.525	87.179
derz dolgu	dış köşe 30*60 Yapistirici	11.441	87.037
yapistirici	dış köşe 30*60	13.347	85.714
yapistirici	Derz dolgu	50.636	85.356
derz dolgu	Yapistirici	50.636	85.356
derz dolgu	3 cm bordür 30*60	11.017	84.615
yapistirici	3 cm bordür 30*60	11.017	84.615
yapistirici	3cm bordür	14.619	82.609
derz dolgu	dış köşe 30*60	13.347	82.54
derz dolgu	Diskoseparlak	20.127	82.105
yapistirici	Diskoseparlak	20.127	82.105
derz dolgu	3 cm bordür	14.619	81.159
30*60	3 cm bordür derz dolgusu Yapistirici	10.805	80.392
30*60	3 cm bordür Derz dolgu	11.864	78.571
derz dolgu	45*45 Yapistirici	13.559	78.125
30*60	3 cm bordür Yapistirici	12.076	77.193
yapistirici	45*45	17.797	76.19
derz dolgu	40*40	23.305	75.455
30*60	3 cm bordür	14.619	75.362
yapistirici	40*40	23.305	74.545
derz dolgu	40*40 30*60	16.102	73.684

Tablo A.2. (Devam) Algoritma sonuçları – Güven %10 Destek %60

Consequent	Antecedent	Support (%)	Confidence (%)
Derzdolgu	30*60	41.737	69.543
30*60	dış köşe Yapistirici	16.525	69.231
30*60	dış köşe derz dolgu Yapistirici	14.407	69.118
30*60	40*40	23.305	69.091
Yapistirici	40*40 30*60	16.102	68.421
Yapistirici	30*60	41.737	67.513
30*60	40*40 derz dolgu	17.585	67.47
Yapistirici	45*45 30*60	10.381	67.347
Derzdolgu	45*45	17.797	66.667
30*60	dış köşe derz dolgu	16.525	66.667
30*60	diskoseparlak	20.127	66.316
30*60	40*40 derz dolgu yapistirici	16.525	65.385
Derzdolgu	45*45 30*60	10.381	65.306
30*60	derz artısı derz dolgu yapistirici	15.678	64.865
30*60	derz artısı derzdolgu	16.737	64.557
30*60	derz artısı yapistirici	16.525	64.103
30*60	derzartisi	18.644	63.636
30*60	40*40 yapistirici	17.373	63.415
Yapistirici	klozet batarya	10.169	60.417

Tablo A.3. Algoritma sonuçları – Güven %20 Destek %50

Consequent	Antecedent	Support %	Confidence %
derzdolgu	30*60 Yapistirici	28.178	90.226
yapistirici	30*60 derz dolgu	29.025	87.591
yapistirici	derz dolgu	50.636	85.356
derzdolgu	Yapistirici	50.636	85.356
derzdolgu	dış koşe	20.127	82.105
yapistirici	dış koşe	20.127	82.105
derzdolgu	40*40	23.305	75.455
yapistirici	40*40	23.305	74.545
derzdolgu	30*60	41.737	69.543
30*60	40*40	23.305	69.091
yapistirici	30*60	41.737	67.513
30*60	dış koşe	20.127	66.316
30*60	derz dolgu Yapistirici	43.22	58.824
30*60	derz dolgu	50.636	57.322
30*60	Yapistirici	50.636	55.649

Tablo A.4. Algoritma sonuçları – Güven %15 Destek %50

Consequent	Antecedent	Support %	Confidence %
Derz dolgu	40*40 yapistirici	17.373	95.122
Derz dolgu	derz artisi yapistirici	16.525	94.872
Yapistirici	40*40 derz dolgu	17.585	93.976
Yapistirici	derz artisi derz dolgu	16.737	93.671
Derz dolgu	30*60 yapistirici	28.178	90.226
Derz dolgu	derzartisi	18.644	89.773
Yapistirici	derzartisi	18.644	88.636
Yapistirici	30*60 derz dolgu	29.025	87.591
Yapistirici	dış köşe derz dolgu	16.525	87.179
Derz dolgu	dış köşe yapistirici	16.525	87.179
Yapistirici	derz dolgu	50.636	85.356
Derz dolgu	yapistirici	50.636	85.356
Derz dolgu	diskoseparlak	20.127	82.105
Yapistirici	diskoseparlak	20.127	82.105
Yapistirici	45*45	17.797	76.19
Derz dolgu	40*40	23.305	75.455
Yapistirici	40*40	23.305	74.545
Derz dolgu	40*40 30*60	16.102	73.684
Derz dolgu	30*60	41.737	69.543
30*60	dış köşe yapistirici	16.525	69.231
30*60	40*40	23.305	69.091
Yapistirici	40*40 30*60	16.102	68.421

Tablo A.4. (Devam) Algoritma sonuçları – Güven %15 Destek %50

Consequent	Antecedent	Support (%)	Confidence (%)
yapistirici	30*60	41.737	67.513
30*60	40*40 derz dolgu	17.585	67.47
derzdolgu	45*45	17.797	66.667
30*60	dış köşe Derzdolgu	16.525	66.667
30*60	Diskoseparlak	20.127	66.316
30*60	40*40 derz dolgu Yapistirici	16.525	65.385
30*60	derz artısı derz dolgu Yapistirici	15.678	64.865
30*60	derz artısı derz dolgu	16.737	64.557
30*60	derz artısı Yapistirici	16.525	64.103
30*60	Derzartisi	18.644	63.636
30*60	40*40 Yapistirici	17.373	63.415
30*60	derz dolgu Yapistirici	43.22	58.824
30*60	45*45	17.797	58.333
30*60	Derzdolgu	50.636	57.322
dustekne	Dusakabin	15.042	56.338
30*60	Yapistirici	50.636	55.649
batarya	Klozet	19.703	51.613

KİŞİSEL YAYIN VE ESERLER

Öztopuz Eren R., Alkan A., Bulanık Hedef Programlama İle Enerji Üretim Optimizasyonu / Energy Production Optimization With Fuzzy Goal Programming, *5th International Conference on Multidisciplinary Sciences (ICOMUS)*, Türkiye, 28-30 Mayıs 2020.



ÖZGEÇMİŞ

İlk ve orta öğrenimini burada, lise öğrenimini ise İstanbul'da tamamladı. 2013 yılında girdiği Kocaeli Üniversitesi Mühendislik Fakültesi Endüstri Mühendisliği Bölümü'nden 2017 yılında mezun oldu. Aynı yıl Kocaeli Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı'nda Yüksek Lisans eğitimine başladı.

