T.C.
İSTANBUL ÜNİVERSİTESİ
SOSYAL BİLİMLERİ ENSTİTÜSÜ
İŞLETME ANABİLİM DALI
SAYISAL YÖNTEMLER BİLİM DALI

DOKTORA TEZİ

TERSİNE LOJİSTİK SÜRECİNDE BİR OPTİMİZASYON ÇALIŞMASI

AYŞE NUR ADIGÜZEL TÜYLÜ
2502120286

TEZ DANIŞMANI
PROF. DR. ERGÜN EROĞLU

İstanbul – 2017

T.C.
İSTANBUL ÜNİVERSİTESİ
SOSYAL BİLİMLERİ ENSTİTÜSÜ
İŞLETME ANABİLİM DALI
SAYISAL YÖNTEMLER BİLİM DALI

DOKTORA TEZİ

TERSİNE LOJİSTİK SÜRECİNDE BİR OPTİMİZASYON ÇALIŞMASI

AYŞE NUR ADIGÜZEL TÜYLÜ
2502120286

TEZ DANIŞMANI
PROF. DR. ERGÜN EROĞLU

İstanbul – 2017

T.C.
İSTANBUL ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ

DOKTORA
TEZ ONAYI

Adı ve Soyadı	:	AYŞE NUR ADIGÜZEL TÜYLÜ	**Numarası**	:	2502120286
Anabilim Dalı / Anasanat Dalı / Programı	:	SAYISAL YÖNTEMLER	**Danışmanı**	:	PROF.DR. ERGÜN EROĞLU
Tez Savunma Tarihi	:	01.12.2017	**Saati**	:	11:00
Tez Başlığı	:	TERSİNE LOJİSTİK SÜRECİNDE BİR OPTİMİZASYON ÇALIŞMASI			

TEZ SAVUNMA SINAVI, İÜ Lisansüstü Eğitim-Öğretim Yönetmeliği'nin 50. Maddesi uyarınca yapılmış, sorulan sorulara alınan cevaplar sonunda adayın tezinin KABULÜNE OYBİRLİĞİ / ~~OYÇOKLUĞUYLA~~ karar verilmiştir.

JÜRİ ÜYESİ	İMZA	KANAATİ (KABUL / RED / DÜZELTME)
1-PROF.DR. ERGÜN EROĞLU		Kabul
2-PROF.DR. MEHPARE TİMOR		Kabul
3- PROF. DR. ALP BARAY		Kabul
4- PROF.DR. SELİM ZAİM		Kabul
5- DOÇ. DR. SONA MARDİKYAN		Kabul

YEDEK JÜRİ ÜYESİ	İMZA	KANAATİ (KABUL / RED / DÜZELTME)
1- PROF. DR. ŞAKİR ESNAF		
2- PROF. DR. NİZAMETTİN BAYYURT		

ÖZ

TERSİNE LOJİSTİK SÜRECİNDE BİR OPTİMİZASYON ÇALIŞMASI

Ayşe Nur ADIGÜZEL TÜYLÜ

Satış tahmini, stok planlama ve dağıtım gibi faaliyetlerde yapılan hatalar nedeni ile birçok tekstil ürünü tersine lojistik ağına girmektedir. Kaynak kullanımını ve maliyeti en başta azaltmak için doğru sayıda üretimin yanı sıra bu ürünlerin doğru şubelere doğru sayıda, renkte, bedende ve modelde gönderilmesi, nakliyesinin ve stok planlamasının doğru bir şekilde yapılması gerekmektedir. Çok parametreli ve çok değişkenli problemlerde matematiksel model kurmanın zorluğu nedeniyle istatistiksel yöntemler, yapay zeka yöntemleri ve makine öğrenme yöntemleri kullanılmaktadır. Genel olarak tüm bu faaliyetler zaman serisine dayalı talep tahminleri baz alınarak yapılır, fakat moda ve tüketicilerin çok çabuk değişen istekleri nedeniyle talep tahminleri ile gerçekleşen talepler arasında önemli farklılıklar doğmaktadır. Son dönemde yapılan çalışmalar gösteriyor ki bu şekilde karmaşık yapılı büyük veri setlerinde yapay zeka ve makine öğrenme yöntemleri diğer tahmin yöntemlerine göre doğruluğu daha yüksek sonuçlar vermektedir.

Bu çalışmada diğer çalışmalardan faklı olarak Tersine Lojistikte ürün iade oranlarının ilk defa Makine Öğrenme ve Bileşik Makine Öğrenme yöntemleri ile tahmin edilmesi söz konusudur. Bu doğrultuda müşterilerin tercihleri ile birlikte satışa çıkan ürünlerin iadeleri ve nedenleri üzerinde yoğunlaşılıp iadelerin daha doğru bir şekilde tahmin edilmesi amaçlanmaktadır. Bu şekilde, analizler sonucunda elde edilen tüketici bilgileri şubelere doğru beden, renk ve modelde ürünlerin gitmesi, gereksiz üretim, nakliye ve depolama faaliyetlerinden kaçınılması, maliyetin, kaynak kullanımının ve çevre kirliliğinin azaltılması konularında daha doğru planlama yapılmasını

sağlayabilir. Ayrıca yapılan ürün iade oranlarının tahmin edilmesinde kullanılabilecek parametrelerin belirlenmesi ile de literatüre katkı sağlanması da çalışmanın temel amaçlarından biridir.

Makine Öğrenme tekniklerinden fonksiyonel algoritmalardan Doğrusal Regresyon (Linear Regression) ve Destek Vektör Regresyonu (Support Vector Regression), karar ağacı algoritmalarından M5P, kural tabanlı algoritmalardan M5Rules ve Karar Tablosu (Decision Table) algoritmaları en iyi sonuç verirken, Bileşik Makine Öğrenme tekniklerinden Stacking, Voting, Bagging ve Random Sub Space yöntemleri ile iyi sonuçlar elde edilmiştir. Elde edilen sonuçlar karşılaştırmalı olarak verilmiş, %83,89 değerinde korelasyon katsayısına ulaşılmıştır.

Anahtar Kelimeler: Tersine Lojistik, Ürün İadesi Oran Tahmini, Makine Öğrenme, Bileşik Makine Öğrenme

ABSTRACT

AN OPTIMIZATION STUDY IN REVERSE LOGISTICS PROCESS

Ayşe Nur ADIGÜZEL TÜYLÜ

Many textile products are in reverse logistics network due to mistakes made in activities such as sales forecasting, inventory planning and distribution. In order to reduce resource usage and cost at first step, in addition to producing the correct quantity, these products must be sent to branches, in correct properties (amount, color, size and model) and transportation planning and stock planning should be done correctly. Statistical methods, artificial intelligence and machine learning methods are used because of the difficulty of establishing mathematical models in multi-parameter and multi-variable problems. In general, all these activities are based on demand forecasts by time series, but there are important differences between these demand predictions and the actual demands because of fashion and consumers' requests change very quickly. Artificial intelligence and machine learning methods provide faster and more accurate results in complex data sets.

The difference of this study from other studies is to estimate the product return rates in Reverse Logistics with Machine Learning and Compound Machine Learning methods. In this direction, it is aimed to predict the claims accurately by concentrating on the customers' preferences, their reasons and the replies of the products which are sold to the customers. Thus, the consumer information obtained as a result of these analyzes can provide us with more accurate planning in terms of avoiding unnecessary production, transportation and storage activities and sending the products with the correct properties (amount, color, size and model) to the branches. Machine Learning and Ensemble Machine Learning Methods are used to estimate the rates of product return. In addition, contributing to the literature with determining the parameters that can be used in estimating the product return rates is one of the main objectives of the study.

Best results of this study are obtained with Linear Regression and Support Vector Regression from the functional algorithms of machine learning techniques, M5P from decision tree algorithms of machine learning techniques, M5Rules and Decision Table based on rules algorithms of machine learning techniques and Stacking, Voting, Bagging and Random Sub Space algorithms of ensemble machine learning techniques. The results obtained are given comparatively and the correlation coefficient value is reached to 83.89%.

Keywords: Reverse Logisitcs, Forcasting Rate of Return Product, Machine Learning, Ensemble Machine Learning

ÖNSÖZ

"Tersine Lojistik Sürecinde Bir Optimizasyon Çalışması" adlı tez çalışmamın yürütülmesinde ve sonuçlandırılmasında yardım ve desteğini esirgemeyen, çalışmamın her adımında bilgisini ve desteğini sunan ve beni yönlendiren değerli danışman hocam Sayın Prof. Dr. Ergün EROĞLU'na teşekkürlerimi sunarım.

Ayrıca analizler konusunda önerileriyle araştırmanın gelişmesine yol gösteren, fikirleriyle bana yön veren ve destek olan değerli hocam Sayın Yrd. Doç. Dr. Ersin NAMLI'ya teşekkürlerimi sunarım.

Her konuda olduğu gibi eğitim hayatımda da beni destekleyen rahmetli babam Zahit ADIGÜZEL'e, hayatımda yapmak istediklerim ve aldığım kararlar konusunda aynı fikirde olmasalar da desteklerini esirgemeyen ve dualarını eksik etmeyen canım annem Teslime ADIGÜZEL'e ve ağabeyim Hakan ADIGÜZEL'e, bu zorlu süreçte ve bundan sonra yanımda olduğu için huzur ve güven duyduğum sevgili eşim Serkan TÜYLÜ'ye, bana en büyük moral ve motivasyonu sağlayan, sonuna kadar bana güç veren ve bu süreçten en az benim kadar etkilenen canım oğlum Bozok Kağan TÜYLÜ'ye başta sevgi, saygı ve minnetimi sunar, en derin duygularımla teşekkür ederim.

Ayrıca iyi ve kötü günlerimde beni yalnız bırakmayan, her konuda destek olmaya çalışan, değerli vakitlerini bu çalışmaya katkı sağlamak için harcayan kıymetli arkadaşlarıma ve çalışmamda yardımcı olamasalar da desteklerini ve sevgilerini her zaman hissettiren sevgili geniş aileme ve tüm sevdiklerime teşekkür ederim.

Aralık, 2017 Ayşe Nur ADIGÜZEL TÜYLÜ

İÇİNDEKİLER

Sayfa No

ÖZ ..... **iv**
ABSTRACT ..... **vi**
ÖNSÖZ ..... **viii**
İÇİNDEKİLER ..... **ix**
ŞEKİLLER LİSTESİ ..... **xii**
TABLOLAR LİSTESİ ..... **xv**
SİMGELER VE KISALTMALAR LİSTESİ ..... **xvii**
GİRİŞ **1**

BİRİNCİ BÖLÜM
TERSİNE LOJİSTİK

1.1. TERSİNE LOJİSTİĞİN TANIMI **6**
1.2. TERSİNE LOJİSTİĞİN ÖNEMİ **12**
1.3. KAVRAM VE KAPSAM **17**
1.4. İLERİ LOJİSTİK VE TERSİNE LOJİSTİK ARASINDAKİ FARKLAR **24**
1.5. TERSİNE LOJİSTİĞİN UYGULANMA NEDENLERİ **29**
1.6. TERSİNE LOJİSTİK LİTERATÜR TARAMASI **31**
1.7. TERSİNE LOJİSTİK AKIŞ ÜRÜNLERİ **47**
1.8. TERSİNE LOJİSTİKTE ÜRÜN DÖNÜŞLERİ **50**
1.9. TERSİNE LOJİSTİK FAALİYETLERİ **56**
1.9.1. Tersine Lojistikte Talep Tahmini *64*
1.10. TERSİNE LOJİSTİK FAALİYETLERİNİN UYGULANMASINDA KARŞILAŞILAN SORUNLAR **66**

İKİNCİ BÖLÜM
VERİ MADENCİLİĞİ

2.1. VERİ MADENCİLİĞİNİN TANIMI **75**
2.2. VERİ MADENCİLİĞİNİN TARİHSEL GELİŞİMİ **77**
2.3. VERİ MADENCİLİĞİ SÜRECİ **79**

2.4. VERİ MADENCİLİĞİNDE KULLANILAN MODELLER.....80
2.5. VERİ MADENCİLİĞİNİN SAĞLADIĞI YARARLAR 80
2.6. VERİ MADENCİLİĞİ SÜRECİNİ ETKİLEYEN KRİTİK NOKTALAR.....82

ÜÇÜNCÜ BÖLÜM

MAKİNE ÖĞRENME

3.1. MAKİNE ÖĞRENMENİN TARİHSEL GELİŞİMİ.....90
3.2. SINIFLANDIRMA.....90
3.2.1. Bayes Ağları Algoritmaları.....91
3.2.2. Tembel (Lazy) Algoritmalar.....92
3.2.3. Kural Tabanlı Algoritmalar.....93
3.2.4. Karar Ağacı Algoritmaları.....94
3.2.5. Sınıflandırmada Kullanılan Fonksiyonlar 96
3.2.6. Bileşik Makine Algoritmaları.....97
3.3. MAKİNE ÖĞRENME ALGORİTMALARI İLE İLGİLİ LİTERATÜR ÇALIŞMASI 99
3.4. BİLEŞİK MAKİNE ÖĞRENME 108

DÖRDÜNCÜ BÖLÜM

MALZEME VE YÖNTEM

4.1. WEKA 112
4.2. KULLANILAN ALGORİTMALAR.....113
4.2.1. Destek Vektör Makineleri Algoritması.....113
4.2.2. Random Subspace Algoritması 116
4.2.3. Stacking Algoritması 117
4.2.4. Voting (Oylama) Algoritması.....119
4.2.5. Bagging Algoritması 120
4.2.6. Doğrusal Regresyon Algoritması.....121
4.2.7. Destek Vektör Regresyonu Algoritması 122
4.2.8. Karar Tablosu Algoritması 122
4.2.9. M5P Algoritması 123
4.2.10. M5Rules Algoritması.....126
4.2.11. Performans Ölçümleri.....127

4.3. VERİ ANALİZİ.....128

BEŞİNCİ BÖLÜM

BULGULAR

5.1. VAKA ÇALIŞMASI 137

5.2. SONUÇLARIN DEĞERLENDİRİLMESİ.....139

TARTIŞMA VE SONUÇ..... 173

KAYNAKLAR 176

EKLER..... 191

ÖZGEÇMİŞ..... 230

ŞEKİLLER LİSTESİ

Sayfa No

Şekil 1.1: İleri ve tersine lojistik süreçlerinde temel akış (Agrawal, 2015: 78). 7

Şekil 1.2: Tersine lojistik süreci (Gupta, 2013: 5).....11

Şekil 1.3: Ürün yaşam döngüsü aşamalarında malzeme ve bilgi akışı (Gupta, 2013: 205). ..12

Şekil 1.4: Tersine lojistik konuları (Gupta, 2013: 6).....19

Şekil 1.5: Tersine lojistiğin boyutları (Steven, 2004: 169).....20

Şekil 1.6: Tersine lojistik ve yeşil lojistiğin karşılaştırılması (Rogers ve Tibben–lembke, 2001: 131).....22

Şekil 1.7: Yeşil tedarik zinciri yönetimi literatürünün sınıflandırılması (Srivastava, 2008: 537).....23

Şekil 1.8: Tersine dağıtım sistemi (Fleischmann, 1997: 5). 25

Şekil 1.9: Tedarik zincirinde kazanım seçenekleri piramidi (Brito ve Dekker, 2002: 16). 13

Şekil 1.10: Tersine lojistik hiyerarşisi (Carter ve Ellram, 1998: 92).....14

Şekil 1.11: Ömrü tükenmiş ürünün üretim hattına geri dönmesi (Gupta, 2013: 128). 55

Şekil 1.12: Tersine lojistikte temel faaliyetler ve akışlar (Lau ve Wang, 2009: 449). 56

Şekil 1.13: Temel lojistik faaliyetler (Çekerol, 2013: 37).....64

Şekil 1.14: Talep tahmin yöntemleri. 65

Şekil 1.15: Geri dönüşüm sürecinin sınıflandırılması (Steven, 2004: 171).....66

Şekil 2.1: Veri madenciliği yöntemleri (Garcia v.d., 2015:4). 74

Şekil 2.2: Bilgi keşfi süreci (Bharati ve Ramageri, 2010: 301).....76

Şekil 2.3: Veri madenciliği stratejileri (Akkuş, Erişim Tarihi: 28.10.2017). 82

Şekil 3.1: Bileşik sınıflandırma makine öğrenme modelinin yapısı (Hsieh, 2012: 2842)....108

Şekil 4.1: WEKA'da temel işlem adımları (Evren, Erişim Tarihi: 28.10.2017).....113

Şekil 4.2: İki farklı veri sınıfının doğrusal olarak ayrılması (Namlı, 2012: 60).....114

Şekil 4.3: Doğrusal olarak ayrılamayan verilerin sınıflandırılması (Namlı, 2012: 62). 115

Şekil 4.4: Stacking Yöntemi (Koptur, Erişim Tarihi: 29.10.2017). 118

Şekil 4.5: Stacking Yönteminde Tahminleyicilerin Eğitimi (Koptur, Erişim Tarihi: 29.10.2017). 119

Şekil 4.6: Voting Yöntemi (Koptur, Erişim Tarihi: 29.10.2017). 119

Şekil 4.7: Voting Yönteminde Tek Bir Eğitim Seti ile farklı sınıflandırma algoritmalarının eğitilmesi (Koptur, Erişim Tarihi: 29.10.2017). 120

Şekil 4.8: Bagging Yöntemi (Koptur, Erişim Tarihi: 29.10.2017). 121

Şekil 4.9: M5P Yöntemi (Zhan, 2011: 1551-1552). 126

Şekil 4.10: Toplam iade oranı 130

Şekil 4.11: Sektörlere göre lojistik maliyetleri (Uğur, 2007; 82). 131

Şekil 4.12: İade oranının beden özelliğine göre dağılımı. 132

Şekil 4.13: İade oranının renge göre dağılımı. 133

Şekil 4.14: Renk ve bedene göre iade oranı yoğunluğu. 133

Şekil 4.15: İade oranının mağaza segmentine göre dağılımı. 134

Şekil 5.1: Metodoloji 138

Şekil 5.2: Makine Öğrenme algoritmalarıyla elde edilen sonuçların korelasyon katsayıları 151

Şekil 5.3: Makine Öğrenme algoritmalarıyla elde edilen sonuçların ortalama mutlak hataları 152

Şekil 5.4: Makine Öğrenme algoritmalarıyla elde edilen sonuçların ortalama karesel hatalarının karekökleri 152

Şekil 5.5: Makine Öğrenme algoritmalarıyla elde edilen sonuçların bağıl mutlak hataları .153

Şekil 5.6: Makine Öğrenme algoritmalarıyla elde edilen sonuçların karesel bağıl mutlak hatalarının karekökleri 153

Şekil 5.7: Makine Öğrenme algoritmalarıyla elde edilen sonuçların model kurma süreleri 154

Şekil 5.8: Bileşik Makine Öğrenme algoritması Voting ile elde edilen sonuçların korelasyon katsayıları 156

Şekil 5.9: Bileşik Makine Öğrenme algoritması Voting ile elde edilen sonuçların ortalama mutlak hataları 157

Şekil 5.10: Bileşik Makine Öğrenme algoritması Voting elde edilen sonuçların ortalama karesel hatalarının karekökleri 158

Şekil 5.11: Bileşik Makine Öğrenme algoritması Voting ile elde edilen sonuçların bağıl mutlak hataları 159

Şekil 5.12: Bileşik Makine Öğrenme algoritması Voting ile elde edilen sonuçların karesel bağıl mutlak hatalarının karekökleri 160

Şekil 5.13: Bileşik Makine Öğrenme algoritması Voting ile elde edilen sonuçların model kurma süreleri 161

Şekil 5.14: Bileşik Makine Öğrenme algoritmaları RandomSubSpace ve Bagging ile elde edilen sonuçların korelasyon katsayıları 162

Şekil 5.15: Bileşik Makine Öğrenme algoritmaları RandomSubSpace ve Bagging ile elde edilen sonuçların ortalama mutlak hataları 163

Şekil 5.16: Bileşik Makine Öğrenme algoritmaları RandomSubSpace ve Bagging ile elde edilen sonuçların ortalama karesel hatalarının karekökleri 164

Şekil 5.17: Bileşik Makine Öğrenme algoritmaları RandonSubSpace ve Bagging ile elde edilen sonuçların bağıl mutlak hataları 164

Şekil 5.18: Bileşik Makine Öğrenme algoritmaları RandomSubSpace ve Bagging ile elde edilen sonuçların karesel bağıl mutlak hatalarının karekökleri 165

Şekil 5.19: Bileşik Makine Öğrenme algoritmaları RandomSubSpace ve Bagging ile elde edilen sonuçların model kurma süreleri 165

Şekil 5.20: Bileşik Makine Öğrenme algoritması Stacking ile elde edilen sonuçların korelasyon katsayıları 167

Şekil 5.21: Bileşik Makine Öğrenme algoritması Stacking ile elde edilen sonuçların ortalama mutlak hataları 168

Şekil 5.22: Bileşik Makine Öğrenme algoritması Stacking elde edilen sonuçların ortalama karesel hatalarının karekökleri 169

Şekil 5.23: Bileşik Makine Öğrenme algoritması Stacking ile elde edilen sonuçların bağıl mutlak hataları 169

Şekil 5.24: Bileşik Makine Öğrenme algoritması Stacking ile elde edilen sonuçların karesel bağıl mutlak hatalarının karekökleri 170

Şekil 5.25: Bileşik Makine Öğrenme algoritması Stacking ile elde edilen sonuçların model kurma süreleri 170

TABLOLAR LİSTESİ

Sayfa No

Tablo 1.1: Tersine akışdaki ürünlerin türüne ve kaynağına göre karakterizasyonu (Rogers ve Tibben–lembke, 2001: 134).....21

Tablo 1.2: Genel tersine lojistik faaliyetleri (Rogers ve Tibben–lembke, 2001: 133).....21

Tablo 1.3: İleri ve tersine lojistik arasındaki farkların kısaca özeti (Tibben-Lembke ve Rogers, 2002: 276).....26

Tablo 4.1: Beden bazlı iade oranı. 132

Tablo 4.2: Renk bazlı iade oranı. 132

Tablo 4.3: Renk ve bedene göre iade oranları.....133

Tablo 4.4: Mağaza segmentine göre iade oranı.....134

Tablo 4.5: Mağazanın lokasyon tipine göre iade oranı. 134

Tablo 4.6: Mağazanın bulunduğu bölgenin sıcaklığına göre iade oranları. 135

Tablo 4.7: Mağaza bazında iade oranları. 136

Tablo 5.1: Basit makine öğrenme algoritmalarından elde edilen sonuçlar (%80 Eğitim-%20 Test Seti).....140

Tablo 5.2: Bileşik makine yöntemi olan random sub-space algoritmalarından elde edilen sonuçlar (%80 Eğitim-%20 Test Seti) 141

Tablo 5.3: Bileşik makine yöntemi olan bagging algoritmalarından elde edilen sonuçlar (%80 Eğitim-%20 Test Seti) 142

Tablo 5.4: Bileşik makine yöntemi olan voting algoritmalarından elde edilen sonuçlar (%80 Eğitim-%20 Test Seti) 143

Tablo 5.5: Bileşik makine yöntemi olan stacking algoritmalarından elde edilen sonuçlar (%80 Eğitim-%20 Test Seti) 144

Tablo 5.6: Basit makine öğrenme algoritmalarından elde edilen sonuçlar (%90 Eğitim-%10 Test Seti).....146

Tablo 5.7: Bileşik makine yöntemi olan random sub-space algoritmalarından elde edilen sonuçlar (%90 Eğitim-%10 Test Seti) 147

Tablo 5.8: Bileşik makine yöntemi olan bagging algoritmalarından elde edilen sonuçlar (%90 Eğitim-%10 Test Seti) 148

Tablo 5.9: Bileşik makine yöntemi olan voting algoritmalarından elde edilen sonuçlar (%90 Eğitim-%10 Test Seti) 149

Tablo 5.10: Bileşik makine yöntemi olan stacking algoritmalarından elde edilen sonuçlar (%90 Eğitim-%10 Test Seti).....150

Tablo 5.11: Makine Öğrenme yöntemlerinin performans ölçümleri 151

Tablo 5.12: Bileşik Makine Öğrenme yöntemlerinin performans ölçümleri (Vote).....155

Tablo 5.13: Bileşik Makine Öğrenme yöntemlerinin performans ölçümleri (RSS ve Bagging) 162

Tablo 5.14: Bileşik Makine Öğrenme yöntemlerinin performans ölçümleri (Stacking) 166

Tablo 5.15: Elde edilen sonuçlardan en iyi 15 değerin korelasyon katsayısı bakımından sıralanması. 171

Tablo 5.16: Elde edilen en iyi 15 değerin normalize edilmiş ortalama hata değerlerine göre sıralaması. 172

SİMGELER VE KISALTMALAR LİSTESİ

Simgeler	Açıklamalar
$\Longrightarrow$	: İse
$\wedge$	: Ve
$\vee$	: Veya
$\forall$	: Her
$\in$	: Elemanı
$\notin$	: Elemanı değil
%	: Yüzde
$=$	: Eşit
$\neq$	: Eşit değil
$<$	: Küçük
$>$	: Büyük
$\leq$	: Küçük eşit
$\geq$	: Büyük eşit
$\|\boldsymbol{x}\|$	: x'in mutlak değeri
$\sum$	: Toplam sembolü
$\left[\boldsymbol{c_{ij}}\right]_{\boldsymbol{N\times N}}$	: c_{ij} elemanlarından oluşan $N \times N$ boyutlu matris gösterimi
$[\boldsymbol{t_i}]_{\boldsymbol{N}}$	: t_i elemanlarından oluşan N boyutlu vektör gösterimi

Kısaltmalar	Açıklamalar
ABC	**:** Yapay Arı Kolonisi
ABD	**:** Amerika Birleşik Devletleri
ANN	**:** Artificial Neural Network (Yapay Sinir Ağları)
BMÖ	**:** Bileşik Makine Öğrenme
DT	**:** Decision Table (Karar Tablosu)
DVM	**:** Destek Vektör Makinesi
E	**:** Evet
EKKDVM	**:** En Küçük Kareler Destek Vektör Makinesi
EKKDVR	**:** En Küçük Kareler Destek Vektör Regresyonu
EKK-DVS	**:** En Küçük Kareler Destek Vektör Sınıflandırması
ENN	**:** Düzenlenmiş En Yakın Komşu
EPSO	**:** Gelişmiş Parçacık Sürü Optimizasyonu
GA	**:** Genetik Algoritmalar (Genetic Algorithm)
GSYİH	**:** Gayri Safi Yurt İçi Hasıla
H	**:** Hayır
IBL	**:** Instance Based Learning (Örneğe Dayalı Öğrenme)
ID3	**:** Iterative Dichotomiser 3 (İteratif İkileştirici 3)
IDTM	**:** Inducer of Decision Table Majority (Kara tablosu Çoğunluğunun Oluşturucusu)
kNN	**:** k En Yakın Komşu
LR	**:** Linear Regression (Doğrusal Regresyon)
LS-SVM	**:** En Küçük Kareler Destek Vektör Makineleri
MAE	**:** Ortalama Mutlak Hata
MKS	**:** Model Kurma Süresi
ML	**:** Machine Learning (Makine Öğrenme)
MÖ	**:** Makine Öğrenme
R	**:** Korelasyon Katsayısı
RAE	**:** Ortalama Bağıl Hata
RMSE	**:** Ortalama Hata Kareleri Kökü
RRSE	**:** Ortalama Bağıl Hata Kareleri kökü
RSS	**:** Random Sub Space (Rasgele Alt Uzay)
SD	**:** Standart Sapma
SDR	**:** Standart Sapma Azaltma
SMO	**:** Support Vector Machines (Destek Vektör Makineleri)
SMOreg	**:** Support Vector Regression (Destek Vektör Regresyonu)
SVM	**:** Support Vector Machines (Destek Vektör Makineleri)
SVR	**:** Support Vector Regression (Destek Vektör Regresyonu
Sn	**:** Saniye
WEKA	**:** Bilgi Analizi için Waikato Ortamı
WWW	**:** World Wide Web (Dünya Çapında Ağ)
YSA	**:** Yapay Sinir Ağları (Artificial Neural Networks)
0-R	**:** Zero Rule (0 Kural)
1-R	**:** One Rule (1 Kural)

GİRİŞ

Asırlardır insanoğlu bir şeyler elde edebilmek için doğal kaynakları kullanıp sonrasını düşünmeden tahrip etmektedir. Bu tahribatın yanı sıra atıkların da uygun şekilde yok edilmeyip bilinçsiz bir şekilde doğaya terk edilmesi çevre kirliliğine ve ekolojik dengenin bozulmasına neden olmaktadır. Dünyamız her ne kadar kendini yenileyebiliyor olsa da insanoğlunun doğaya müdahalesi ve doğal kaynakları tüketim hızı nedeniyle kaynaklarımız yavaş yavaş tükenmektedir.

Son yıllarda sıkça tartışılan ve çözüm bulunmaya çalışılan en önemli konulardan biri; insan yaşamını ve insanoğlunun geleceğini tehdit eden olaylar, nedenleri ve önlemek için neler yapılabileceğidir. Küresel ısınma ve bunun sonucunda ortaya çıkan iklim değişiklikleri, bitki ve hayvan popülasyonlarının giderek azalması ve yok olması ile nüfus artışı, bazı doğal kaynakların kendini yenileyemeyecek derecede tahrip edilmesi ya da tükenmeye yakın olması sonucunda geleceğimiz şimdiden alarm vermektedir. Geç de olsa bunun bilincine varan insanoğlu elimizde kalan bu kısıtlı kaynakları en verimli şekilde kullanmak için yeni yollar ve yöntemler aramaktadır. Doğaya zarar vermeyecek ya da zararı en aza indirecek şekilde üretim yapmak, ürünlerin yeniden kullanılabilirliğini ya da hammadde olarak yeniden üretime girmesini sağlamak, atıklardan en iyi şekilde yararlanıp kullanılabilir kısmını ayırıp üretime katkı sağlamak, kullanılamayan ve doğaya zararlı kısmının ise en iyi şekilde toplanıp yok edilmesini veya saklanmasını sağlamak, en önemlisi de üretim aşamasında doğru planlama yapıp gereksiz üretimi ve kaynak israfını önlemek bunlardan başlıcalarıdır. Günümüzde yasal olarak da kaynakların verimli kullanımı ve atıkların uygun şekilde yok edilmesi kısmi de olsa zorunludur. Ayrıca gün geçtikçe, bilinçlenen tüketici de ürün ve hizmet tercihlerinde kaynaklarını uygun kullanan üreticinin yanında olma eğilimi göstermektedir. Tersine lojistik ise bu çabalar sonucunda ortaya çıkan bir kavramdır.

Atıkların uygun şekilde toplanması ve yok edilmesi, geri dönüşümü olan atıkların toplanması ve geri dönüştürülmesi, ürünlerin yeniden üretimi, tamir-bakımı, değer kazanımı vb. gibi işlemler için toplanması ve işlenmesi gibi faaliyetlerin işletmeye ek maliyet getirdiği bir gerçektir. Fakat kaynakların verimli kullanılmasıyla elde edilen malzeme ve mali kazanç, gereksiz üretim ve bilinçsiz tüketim nedeniyle oluşan kayıpların azaltılması veya ortadan kaldırılması ile firmaların kendilerini çevreye duyarlı bir firma olarak göstererek prestijlerini yükseltmelerinin firmaya sağladığı katkının büyüklüğü, yasal zorunluluklar ve müşteri memnuniyeti firmaların tersine lojistik faaliyetlerinin önemini anlayıp, bu konudaki çalışmalara ağırlık vermeye başlamasına sebep olmaktadır. Günümüz pazarında diğer firmalarla rekabet edip ayakta kalabilmek için maliyetleri düşürecek, üretim verimliliğini etkileyecek her konuda olduğu gibi tersine lojistik faaliyetlerinde de başarılı olmak gerekmektedir.

Ayrıca günümüzde e-ticaretin (elektronik ticaret) pazara getirdiği canlılıktan pay edinebilmek için müşteri memnuniyeti ve ürün kalitesi başta olmak üzere bu yeni pazar anlayışına uyum sağlamak gerekmektedir. E-ticarette müşteri memnuniyeti sağlayabilmek için kaliteli ve çeşitli ürünlerin pazara sunulmasının yanı sıra müşterilerin beğenmedikleri ya da istedikleri özellikleri karşılamayan ürünleri sorunsuz iade edebilmeleri de gerekmektedir. Bu, firmanın güvenilirliğini arttırarak firmaya rekabet avantajı sağlamaktadır.

Piyasada varlığını sürdürebilmenin en temel şartlarından biri müşteri memnuniyetini sağlamaktır. Sürekli değişen moda algısı ve her gün gelişen teknoloji ile de bu memnuniyeti sağlamak oldukça zordur. Farklı bir ürünün, rengin, modelin vb. moda olması ile müşterinin ürüne duyduğu ilgi bir anda değişip başka bir ürüne kayabilmektedir. Ya da müşterinin aldığı ürünün yeni teknoloji ile daha iyi donanımlı bir üst modeli piyasaya sürülmüş olabilmektedir. Müşteri beğenisindeki bu değişim ve satış tahmini, stok yönetimi, lojistik gibi faaliyetlerin planlanmasında yapılan hatalar sonucu henüz ürün yaşam ömrünü tamamlamamış ürünler bir şekilde pazardaki yerini kaybedip yeniden değer kazanıp pazardaki yerlerini alabilmek için tersine lojistik ağına girmektedir. Bu sayede hammadde ya da yedek parça olarak işe yarar, çalışır, zarar görmemiş, hatta belki de yeni durumda sayılabilecek ürünlere atık olmak yerine

firma ve ülke sermayesine de büyük katkısı olacak şekilde değer kazandırılmaktadır. Ama yapılaması gereken en doğru şey kaynak kullanımını en başta azaltmak için faaliyetleri doğru şekilde planlamaktır.

Bu konuda tersine lojistik faaliyetlerinden elde edilen bilgilerden faydalanmak gerekmektedir. Müşterilerden veya mağazalardan merkeze yapılan ürün iadelerinden elde edilen bilgilerle daha doğru planlamalar yapılabilmektedir. Örneğin; üretiminin doğru tahmin edilemediği ürünler, müşterilerin tercihleri, bu tercihlerin lokasyona bağlı değişimi, satış ve pazarlama planlamasının doğruluğu, her mağazaya gönderilen ürün sayısının ve ürün özelliklerinin doğruluğu, satış stratejilerinin sonuçları gibi planlamaya bağlı faaliyetler iade edilen ürünler hakkındaki bilgilerin analizi ile daha doğru bir şekilde yapılabilmektedir.

Ürün iadelerinde problem yapısını karmaşıklaştıran can alıcı nokta belirsizliktir. İade edilecek ürünlerin miktarının ve iade sebebine bağlı olarak kalitesinin belirsiz olması nedeniyle yapılacak planlamalar yapılan tahminlere dayanmaktadır. Yapılan tahminlerin doğruluğu ne kadar yüksek olursa oluşacak tersine lojistik faaliyetleri ve bu faaliyetlerin neden olduğu maliyetler de o kadar azalmaktadır. Son dönemde yapılan çalışmalar göstermektedir ki bu şekilde karmaşık yapılı büyük veri setlerinde yapay zeka ve makine öğrenme yöntemleri diğer tahmin yöntemlerine göre doğruluğu daha yüksek sonuçlar vermektedir.

Bu çalışma ile amaçlanan Makine Öğrenme ve Bileşik Makine Öğrenme yöntemleri kullanılarak satış noktasının ve ürünün özelliklerinin ürünün iadesine etkisininin tespit edilmesi, mağazalardan merkeze yapılan ürün iadelerinin oranlarının daha doğru bir şekilde tahmin edilmesi, bu sayede oluşacak tersine lojistik faaliyetlerinin ve gereksiz kaynak kullanımının en başta azaltılması ile bu faaliyetlerin neden olduğu maliyetlerin, çevre kirliliğinin ve atığın da azaltılmasıdır.

Literatürde perakende sektörü için iade oranlarının tahmin edilmesine yönelik çalışmaların eksikliği görülmektedir. Çalışmanın bu yönüyle literatüre katkı sağlaması amaçlanmaktadır. Makine Öğrenme ve Bileşik Makine Öğrenme yöntemleri ile Tersine Lojistikte ürün iade oranlarının tahmin edilmesi konusunda yapılan ilk çalışma

olması bakımından bu çalışma literatürdeki diğer çalışmalardan farklıdır. Ayrıca ürün iade oranlarının tahmin edilmesinde kullanılabilecek parametrelerin yapılan detaylı bir çalışma sonucu belirlenmesi ile de hem literatüre yenilik ve katkı sağlanması hem de uzman görüşleri de alınarak tüm tekstil sektöründe kullanılabilecek bilgiler elde edilmesi çalışmanın temel amaçlarındandır.

Bu amaçlar doğrultusunda dünya çapında faaliyet gösteren bir tekstil firmasının mağaza ve müşteri iade verileri üzerinde çalışabilmek için öncelikle iş analistleri ve mağaza personeli ile görüşülerek ürün iadesini etkileyen ürün ve mağaza ile ilgili parametrelerin neler olabileceğine yönelik bilgi toplanmıştır. Veri analizi, deneme-yanılma, parametre seçim algoritmaları ile yapılan ayrıntılı bir çalışma sonucu ürün iade modeli için kullanılabilecek girdi parametreleri belirlenmiştir.

Ürün iadelerinin daha detaylı incelenebilmesi için çok büyük miktardaki ürün havuzundan ürün yelpazesi geniş, iade oran aralığı tutarlı, eksik ve aşırı uç verilere sahip olmayan belirli bir ürün grubu seçilmiştir. Bu ürün grubu için mağazanın merkeze geri gönderdiği ürün adedi ile merkezden mağazaya gönderilen ürün adedi oranlanarak mağazalar bazında tüm ürünler için ürün iade oranları hesaplanmıştır.

Bu veri setinin %80'i eğitilerek %20'si test edilecek şekilde ve veri setinin %90'ı eğitilerek, %10'u test edilecek şekilde Makine Öğrenme ve Bileşik Makine Öğrenme yöntemleri ile ürün iade oranları tahmin edilmiştir.

Makine Öğrenme tekniklerinden fonksiyonel algoritmalardan Doğrusal Regresyon (Linear Regression) ve Destek Vektör Regresyonu (Support Vector Regression), karar ağacı algoritmalarından M5P, kural tabanlı algoritmalardan M5Rules ve Karar Tablosu (Decision Table) algoritmaları en iyi sonuç verirken, Bileşik Makine Öğrenme tekniklerinden Stacking, Voting, Bagging ve Random Sub Space yöntemleri ile iyi sonuçlar elde edilmiştir. Elde edilen sonuçlar karşılaştırmalı olarak verilmiş, korelasyon katsayısı bakımından incelendiğinde Stacking M5Rules (M5P+M5Rules+SMOreg) %90-10 algoritması ile %83,89 değerinde en iyi tahmin oranına ulaşılmış, korelasyon katsayısının yanı sıra hata ölçümleri de göz önünde

bulundurulularak Vote (M5P+M5Rules) %90-10 algoritması ile 0,249 ortalama hata değerinde en iyi tahmin performansına ulaşmıştır.

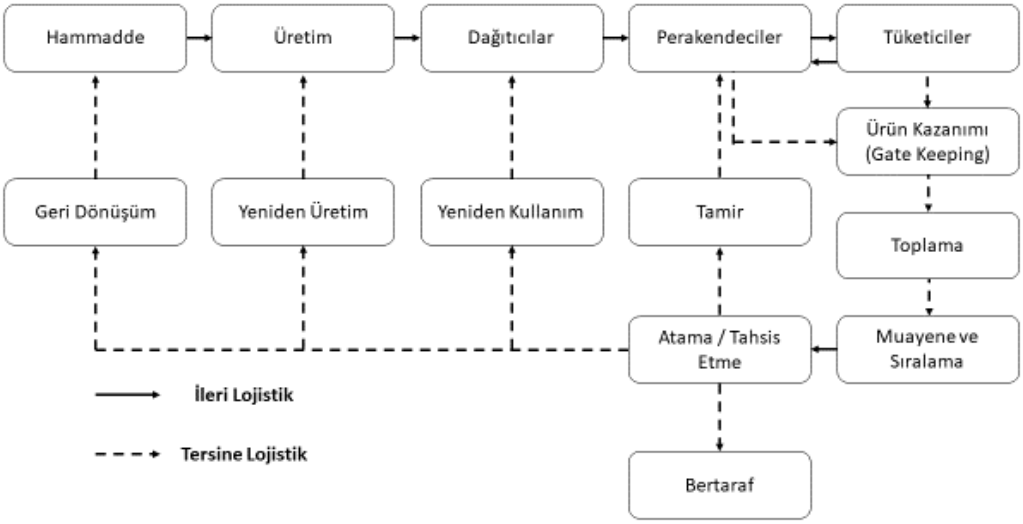
1. TERSİNE LOJİSTİK

Çok uzun bir geçmişe sahip olmayan tersine lojistik kavramının aslında en baştan beri lojistik kavramının içinde bir yerinin olduğu görülmektedir. Öneminin anlaşılması, hatta ileri lojistik faaliyetleri kadar tersine lojistik faaliyetlerine de ağırlık verilmesi son birkaç yıl içinde yapılan çalışmalara dayanmaktadır. Hatta Dünya'nın şimdiki durumu ve gelecekte olabilecekler düşünülerek tersine lojistiğin önemi giderek daha çok anlaşılmakta ve tersine lojistik faaliyetleri için yapılan çalışmalar artmaktadır.

1.1.TERSİNE LOJİSTİĞİN TANIMI

Tersine lojistik kavramı literatürde çeşitli şekillerde tanımlanmaktadır:

Tersine lojistik; herhangi bir hammadde, yarı mamul veya ürünün tedarikçiden başlayarak üretici, dağıtıcı ve son olarak tüketiciye doğru akış sürecini oluşturan ileri lojistiğin herhangi bir aşamasında kalite yetersizliği, hasarlı veya yanlış teslimat, stok fazlalığı gibi herhangi bir nedenden dolayı yeniden üretim, geri kazanım, yok etme veya kaynakları etkin şekilde kullanmak üzere hammadde, yarı mamul, stok fazlası ürünün ters yönde akışı ile tüketicinin kullanımından sonra ürünlerin iadesi, yeniden satışı, yeniden paketlenip satışa sunulması, geri çağırılması, bakımı, tamiri, ikincil pazarda satışı, ürünlerin yeniden kullanımı, parçaların kısmi kullanımı, geri dönüşümü ve katma değeri kalmayan veya zararlı atıkların bertarafı işlemlerini ve bu oluşan tersine akışı yönetmek için yeniden tasarlanmış tedarik zincirini içermektedir. En basit haliyle tersine lojistik sürecindeki ileri ve tersine akışlar Şekil 1.1'de görülmektedir.



Şekil 1.1: İleri ve tersine lojistik süreçlerinde temel akış (Agrawal, 2015: 78).

Tersine Lojistik kavramı uzun zaman önceye denk gelse de, ters kanallar veya tersine akış gibi terimler, yetmişli yılların bilimsel literatüründe Guiltinan ve Nwokoye (1974), Ginter ve Starling (1978) gibi çalışmalarda geri dönüşüm ile ilişkili olarak görülmektedir (De Brito ve Dekker, 2002: 2).

Tersine lojistiğin ilk tanımlamalardan biri de 1981'de Lambert ve Stock tarafından yapılmıştır. Bu çalışmada tersine lojistik "tek yönlü bir cadde üzerinde yanlış yolda ilerlemek" olarak tanımlanmıştır. Bu tanım, 1986'da Murphy ve 1989'da Murphy ve Poist tarafından "bir tüketiciden dağıtım kanalındaki bir üreticiye doğru hareket" olarak tanımlanan tersine lojistik tanımına benzemektedir. 1980'li yıllar boyunca, ters lojistik kapsamı, malzemenin birincil akışa karşı müşteriden üreticiye doğru hareketi ile sınırlı kalmıştır (Rogers ve Tibben-Lembke, 2001: 129).

1998'de Stock, tersine lojistiği "ürün iadeleri, kaynak azaltma, geri dönüşüm, malzeme ikame etme, materyallerin yeniden kullanımı, atıkların bertaraf edilmesi, onarım ve yeniden üretilmesinde lojistiğin rolü" olarak tanımlanmıştır. Bu, 1992 yılında Stock tarafından verilen tanıma ve 1993'te Kopicki ve diğerleri tarafından verilen tanıma benzemektedir. Carter ve Ellram, Journal of Business Logistics dergisinde 1998'de yayınlanan bir makalede, "şirketlerin ürünlerin geri dönüştürülmesi, yeniden

kullanılması ve kullanılan materyal miktarının azaltılması yoluyla daha çevre dostu olabilmesi" olarak adlandırılan benzer bir tanım benimsemiştir (Rogers ve Tibben-Lembke, 2001: 129-130).

Lojistik Yönetimi Konseyi (CLM), 1990'ların başında Tersine Lojistik'in ilk bilinen tanımını yayınlanmıştır: “Bu terim genellikle geri dönüşüm, atık bertarafı ve tehlikeli maddelerin yönetimi konularındaki lojistik rolünü belirtmek için kullanılmaktadır; daha geniş bir bakış açısıyla tersine lojistik kaynakların azaltılması, geri dönüştürülmesi, yerine konması, malzemelerin tekrar kullanılması ve bertaraf edilmesinde yürütülen lojistik faaliyetlerle ilgili olan herşeyi kapsamaktadır (De Brito ve Dekker, 2002: 2).

RevLog (1998) Tersine Lojistik Avrupa Çalışma Grubu, tersine lojistik için şu tanımlamayı ortaya koymaktadır: "Hammaddelerin, süreç içi envanterin ve nihai ürünlerin, bir imalat, dağıtım veya kullanım noktasından bir iyileştirme veya uygun şekilde elden çıkarma noktasına kadar akışını planlama, uygulama ve kontrol etme sürecidir” (De Brito ve Dekker 2002: 3).

Amerika Tersine Lojistik Yürütme Konseyi tersine lojistiği; "hammadde, süreç içi envanter, tamamlanmış mallar ve bunlarla ilgili bilgilerin yeniden değer elde etmesi veya uygun şekilde elden çıkartılması amacıyla tüketim noktasından menşe noktasına kadar olan akışını verimli, uygun maliyetli planlama, uygulama ve kontrol etme süreci" olarak tanımlanmaktadır (Govindan ve Soleimani, 2017: 371). Yani bu tersine akış süreci hem perakendecileri hem de üreticileri ilgilendiren bir konudur.

Rogers ve Tibben-Lembke, Lojistik Yönetimi Konseyi tarafından yapılan tanıma benzer bir tanım yapmıştır: “Hammadde, süreç içi envanter ve nihai ürünlerin yeniden fiyatlandırılması, değer kazanımı ya da yok edilmesi amacıyla tüketim noktasından üretim noktasına kadar etkili, düşük maliyetli akışının planlanması, uygulanması ve kontrol edilmesi sürecidir (Rogers ve Tibben-Lembke, 2001: 130).

Fleischmann vd.’ne göre, tersine lojistik kullanıcı tarafından kullanılmış üründen, bir piyasada yeniden kullanılabilen ürüne kadar olan tüm lojistik faaliyetleri kapsamaktadır. Buna göre kullanılan ürünlerin son kullanıcıdan üreticiye doğru

fiziksel olarak tersine naklini ve böylece dağıtım planlama yönlerini içerir. Bir sonraki adım, iade edilen ürünlerin üreticisi tarafından tekrar kullanılabilir ürünlere dönüştürülmesidir (Fleischmann vd., 1997: 2).

Tedarik zincirinin kritik bir alanı tersine lojistiktir. Tersine lojistik, ürünü değer kazanımı veya uygun şekilde elden çıkarmak için tüketim noktasından üretim noktasına taşıma sürecidir. Tersine lojistik, tipik olarak ürünlerin ve ambalajların müşterilerden veya depolardan distribütörlere veya üreticilere geri gönderilmesine ilişkin malzemelerinin akışıyla ilgili konularla ilgilidir. Bir perakendeci bir ürünü satamazsa veya bir müşteri bir ürünü iade etmişse, perakendeciye ürünü iade etmesi talimatı verilebilir. Tersine lojistik sistemi, bu ürünlerin başka yere satılacağı (perakendeci) ya da daha yüksek bir değer elde etmek için işlem göreceği başka bir yere (merkezi iade işleme tesisi) getirilmesi için tasarlanmıştır (Tibben-Lembke, 1998: 54)

Dowlatshahi'ye göre ise " tersine lojistik, mümkün olan geri dönüşüm, yeniden imalat veya imha için tüketim noktasından üretim noktasına kadar ürünlerin veya parçaların akışını yöneten sistematik bir süreçtir" (Dowlatshahi, 2005: 3455).

"Tersine lojistik, son kullanıcı tarafından ihtiyaç duyulmayan ürünlerden, pazarda tekrar kullanılabilecek ürünlere kadar bütün şebeke tasarımı, bilgi akışı, taşıma, stok, depolama, malzeme yönetimi ve paketleme gibi lojistik faaliyetleridir" (Dinç vd., 2008: 327).

Yapılan bir diğer tanım da : "Zaman içinde farklı tür ve hacimlerde dinamik bir değer kazandıran bir ürünün tüm yaşam döngüsü boyunca değer yaratmayı en üst düzeye çıkaracak bir sistemin tasarımı, kontrolü ve uygulanmasıdır" (Govindan ve Soleimani, 2017: 372).

"Tersine lojistik, müşteriler tarafından ömrünün sona ermesi [EOL], onarım, kira bitimi ve garanti gibi herhangi bir nedenle geri gönderilen ürünlerin geri alınması için gereken tüm faaliyetleri kapsamaktadır" (Gupta, 2013: 19).

“Tersine lojistik, değeri kazanımı veya uygun bir şekilde elden çıkarılması amacıyla nihai malların varış yerlerine taşınması sürecidir. Tersine lojistik bir başka deyişle; varlıkların birincil kullanım kanallarından değerini en yükseğe çıkaracak şekilde ikincil bir kanala ulaştırılmasıdır” (Greve ve Davis, 2012: 1).

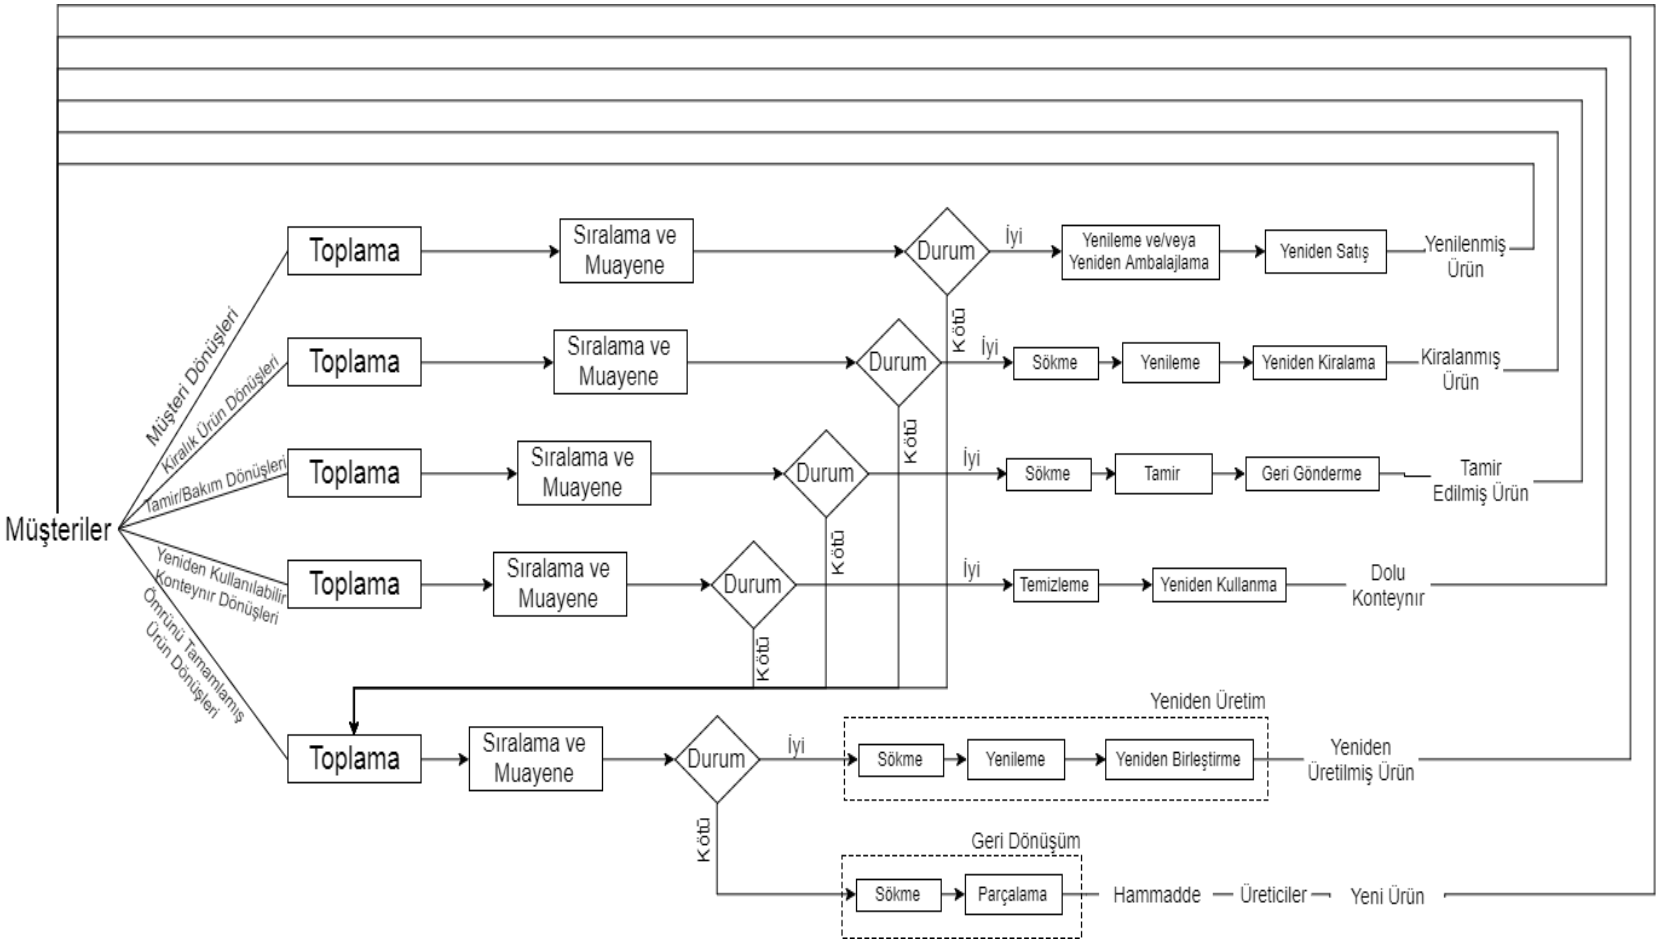
“Tersine lojistik, tersine dağıtım işlemleri de dahil olmak üzere, ürünlerin üretimi, ambalajlanması ve kullanımı konularında yönetilmesi, işlenmesi, tehlikeli veya tehlikeli olmayan atığın azaltılması ve bertaraf edilmesine ilişkin tüm faaliyetleri kapsamaktadır” (Steven, 2004: 164).

“Tedarikçiden üreticiye ve perakendeciden tüketiciye doğru ilerleyen malların tersine akışı; kullanılan ürünleri, ambalajlama materyalleri, üretim hurdası ve diğer kalıntıları yeniden kullanılabilecekleri, yeniden imal edilebilecekleri, geri dönüştürülebilecekleri veya uygun şekilde yok edilebilecekleri yerlere getirmek için toplama ve gerekli tüm mal akışı ve bilgileri ile ilgilidir” (Steven, 2004: 164).

“Tüm bunlara paralel olarak tersine lojistik, yaşam evresini tamamlamış çeşitli ürün veya malzemelerin tekrar kullanıma kazandırılması, çevreye zararının en aza indirilmesi ve doğal kaynakların korunması amacıyla tüketim noktasından üretim noktasına doğru tersine akışıdır” (Dirik, 2012: 53).

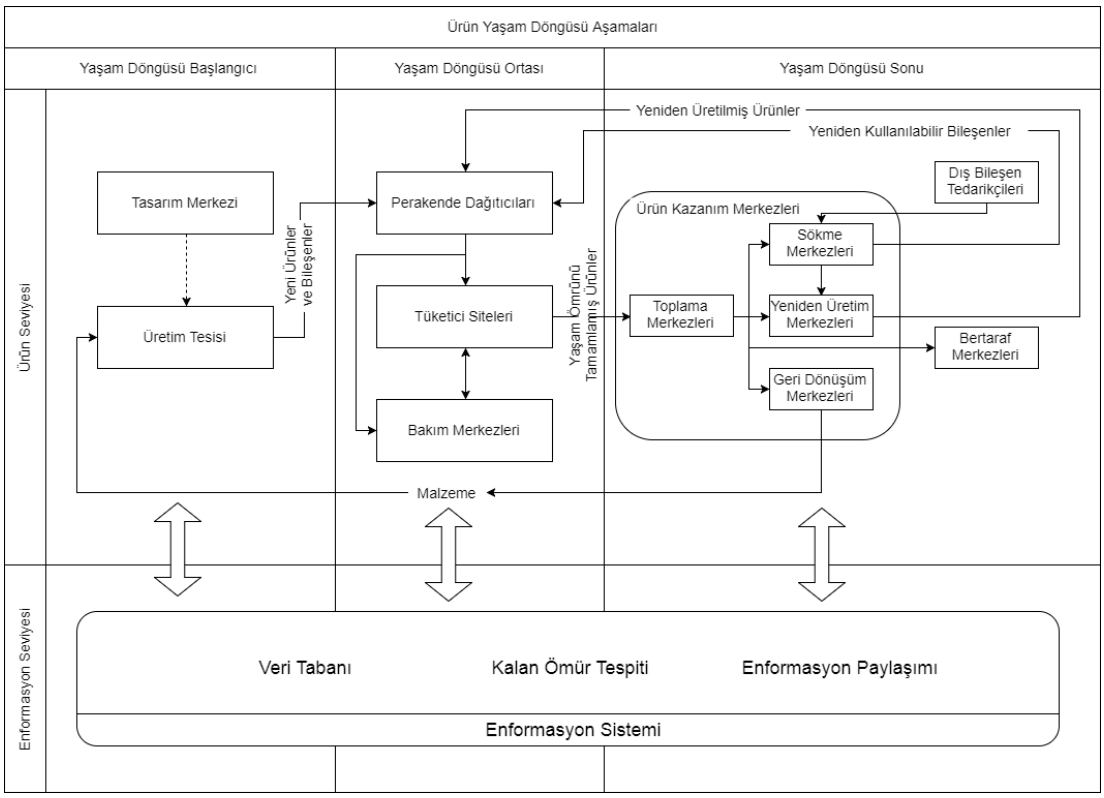
“Tersine lojistik anlayışı adından da anlaşılacağı üzere, alışılmış lojistik faaliyetlerde şekillenmiş olan ve klasik anlamda kabul gören talebe dayalı üretilen mal ve hizmetin satıcıya ya da nihai tüketiciye ulaştırılması değildir, aksine nihai tüketiciden daha önce işletme ya da başka işletmeler tarafından sunulmuş olan mamullerin geri toplanması ve üreticiye geri döndürülmesi sürecidir” (Çekerol, 2013: 14) bu tanımlar altında tersine lojistik sürecinin daha detaylı bir gösterimi Şekil 1.2’de sunulmaktadır.

Bir ürün birçok sebeple farklı aşamalarda, örneğin üretim aşamasındaki ürünün bir sebeple geri dönüşü veya dağıtım aşamasındaki ürünün bir sebeple tüketiciye ulaştırılmadan geri dönüşü olabileceği gibi ürün tüketiciye ulaştıktan sonra geri dönüşü ile de tersine lojistik ağına girebilir.



Şekil 1.2: Tersine lojistik süreci (Gupta, 2013: 5).

Tersine lojistik hakkında yapılan her tanım birbirinden biraz da olsa farklılık gösterse de genel olarak tüketiciden üreticiye dönen kullanılmış ürün üzerinde odaklanılmıştır. Fakat tersine lojistiğin sadece tüketici dönüşlerini değil üretim ve dağıtım aşamasındaki dönüşleri, süreç içi envanterleri ve tüm bu süreç hakkındaki bilgileri de içerdiği unutulmamalıdır. Ürün yaşam döngüsünde yer alan bu malzeme ve bilgi akışı Şekil 1.3'te görülmektedir.

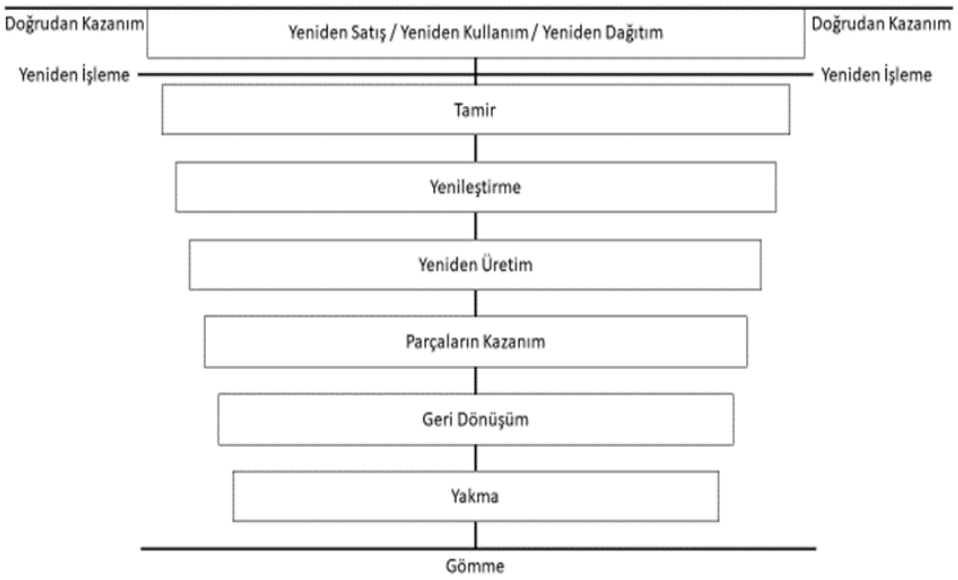


Şekil 1.3: Ürün yaşam döngüsü aşamalarında malzeme ve bilgi akışı (Gupta, 2013: 205).

1.2.TERSİNE LOJİSTİĞİN ÖNEMİ

Ekonomik sistemin girdi tarafında artan dünya nüfusu ve artan müşteri talepleri sonucu sınırlı ve bazı durumlarda tükenmek üzere olan doğal kaynaklara yönelik gereksinimlerin artması, çıktı tarafında ise depolama alanlarına sığmayacak derecede artan atığın yok edilmesi problemi ile karşı karşıya kalmaktayız. Ekonomik sistemin ekosistemdeki doğal döngüyü taklit ettiği kapalı döngü sistemleri kurulmaya çalışılması ile bu durumu biraz da olsa rahatlatan bir çözüm getirilmiştir. Bu kapalı

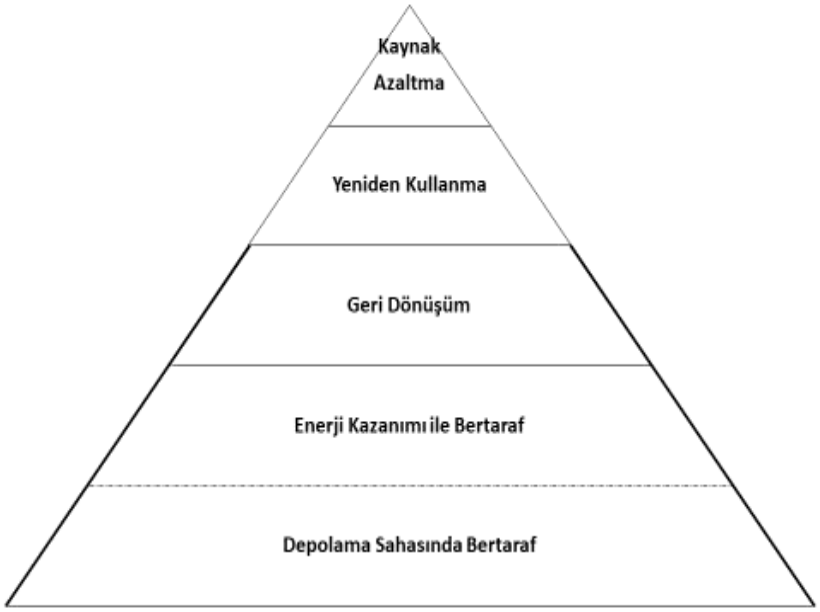
döngüleri oluşturmak içinse tersine lojistik faaliyetlerinin gerçekleştirilmesi gerekmektedir. Bu sistemlerde kullanılmış ürünlerin atık olarak yok edilmeden önce doğal kaynaklardan elde edilen malzeme yerine kullanılıp kullanılmayacağı değerlendirilmektedir. Ekonomik sürece döndürülemeyecek, herhangi bir değeri kalmamış ürünlere bu sürecin sonunda atık gözü ile bakılmaktadır. Üretimde girdi olarak diğer ekonomik süreçlerin çıktıları kullanıldığından hammadde ve malzeme ihtiyacı azalırken, üretim süresi ve enerji kullanımı da düşmektedir. Daha az atık oluştuğu için daha az atık depolama alanına ihtiyaç duyulmakta, daha az atık depolama olacağı için atık depolama maliyetleri de azalmakta, daha az zararlı atık oluşmakta ve çevreye daha az zarar verilmektedir. Sonuç olarak, tersine lojistik ile maliyetler azaltılırken ekolojik ve ekonomik verimlilik de artmaktadır (Steven, 2004: 166-167).



Şekil 1.4: Tedarik zincirinde kazanım seçenekleri piramidi (Brito ve Dekker, 2002: 16).

Şekil 1.4'te tersine lojistik ile ürün geri kazanımı sonucu elde edilen değeri gösteren kazanım hiyerarşisi gösterilmektedir. En yüksek değer ürünün yeniden satış, yeniden kullanım veya yeniden dağıtım gibi doğrudan geri kazanımı ile elde edilirken, ürünün çöp olarak yakma veya gömme gibi yöntemlerle bertaraf edilmesinin ekonomik olarak kazanç yerine kayba yol açtığı görülmektedir. Şekil 1.5'te gösterilmiş tersine lojistik hiyerarşisinde ise geri kazanılan ürünler ekonomik değil miktar olarak sıralanmaktadır. Piramidin tepesindeki ekonomik ve ekolojik katkı sağlayabilecek kaynak azaltımı hacmi çok azken, piramidin en alt katına indikçe bertaraf edilen ürün

hacminin arttığı, bertaraf işlemlerinden de depolama sahasında bertarafın en çok hacme sahip olduğu görülmektedir.



Şekil 1.5: Tersine lojistik hiyerarşisi (Carter ve Ellram, 1998: 92).

Tersine lojistiğe olan ilginin artması için birçok sebep mevcuttur. Tersine lojistiğin ortaya çıkışı temelde doğal kaynakların yok olması, çevre kirlenmesi, küresel ısınma ve atık depolama alanlarının dolması gibi kaygılarından ortaya çıksa da firmalar ve ülke sermayesi için ekolojik olduğu kadar ekonomik öneme sahip olduğu da zamanla anlaşılmıştır. Firmalar ürettikleri ürünler için tersine lojistik faaliyetlerini yalnızca yasal ve sosyal sorumluluk haline gelmesi sebebiyle değil, tersine lojistik ağına girmiş ürünlerden yeniden kullanma, değer kazanımı, yeniden imalat, geri dönüşüm gibi farklı ürün kurtarma yollarıyla ekonomik değer elde etme amacıyla da yerine getirmektedir. Yeniden ürün üretmek yerine kullanılmış ürünlerin veya zaten pazarda bulunan ama atıl durumda olan satılmamış stok fazlası ürünlerin farklı ürün yenileme ve değer kazanımı yöntemleri ile yeniden kullanılabilir hale getirilip pazara sunulması daha az kaynak tüketimine sebep olacağı için üreticiler tersine lojistiği ekonomik kazanç olarak daha net görmektedir.

Rogers ve Tibben-Lembke 2001'deki çalışmalarında tersine lojistiğin ABD lojistik maliyetlerinin önemli bir bölümünü oluşturduğunu ve lojistik maliyetlerinin ABD

ekonomisinin yaklaşık % 9,9'u olduğunu tahmin etmişlerdir. Araştırmada incelenen firmalar için ters lojistik faaliyetleri toplam lojistik faaliyetlerinin % 4'ünü oluşturmuştur. Ayrıca araştırmada yapıldığı dönem için tersine lojistik maliyetlerinin toplam ABD GSYİH'sının % 0,5'i olduğu tahmin edilmiştir (Rogers ve Tibben-Lembke, 2001: 134).

Ekonomideki tersine lojistik faaliyetinin toplam miktarı büyüktür ve halen giderek artmakta olduğu açıktır. Tersine lojistik faaliyetinin kesin miktarının belirlenmesi zordur, çünkü çoğu şirket tersine lojistik maliyetlerini dikkatle izlememektedir. Belirli endüstrilerde, tersine lojistik faaliyetleri firma için kritik olabilir. Tersine lojistiğin boyutu, kapsamı ve etkisi sektör ve kanal konumu ile dağıtım kanalı türüne göre değişmektedir. Genel olarak, ürünün değeri büyük olduğunda veya geri dönüş oranı çok yüksek olduğunda dönüş süreçlerini iyileştirmek için daha fazla çaba harcanmaktadır (Rogers ve Tibben-Lembke, 2001: 135). Firmalar bulundukları koşullara uyum sağlamak ve değişimlere hızlıca ayak uydurmak için tersine lojistik faaliyetlerini geliştirmeli ve planlamalarını uzun dönemli ve stratejik olarak yapmalıdırlar.

Güney Florida Üniversitesi'nden Dr. James Stock tarafından hazırlanan bir tebliğe göre, ABD'li tüketiciler yılda dünyadaki GSYİH'nın '% 66'sından daha fazla dolar değeri olan ürünü geri göndermektedir. Tüketici kârının muazzam hacmine ek olarak, 2009'da Tüketici Koruma Kurumu tarafından 495 adet zorunlu ürün geri çağrısı, Gıda İlaç İdaresi tarafından 295 adet ilaç geri çağrısı ve tahmini 800 adet üreticinin isteğe bağlı çağrısı gerçekleşmiştir (Greve ve Davis, 2012: XVIII).

Tersine lojistikteki malların çoğu yok edilmekte, bazıları yenilenmekte veya yeniden üretmekte, bazıları önümüzdeki sezon yeniden pazara giriş için tutulmakta ve yaklaşık yarısı ikincil perakende pazarında satılmaktadır. Dale S. Rogers (Rutgers Üniversitesi Tedarik Zinciri Yönetimi ve Pazarlama Bilimleri Bölümü profesörü ve daha önce Reno'daki Nevada Üniversitesi'ndeki Lojistik Yönetimi Merkezi Direktörü) tarafından yürütülen bir araştırmaya göre, ikincil piyasaya aktarılan ürünlerin değerleri 329 milyar dolar veya ABD Gayri Safi Yurtiçi Hâsıla'nın (GSYİH) % 2,28'ine denk gelmektedir. Çoğu şirket için, tersine lojistik göz ardı edilmekte ve ihmal edilmektedir.

Açıkçası tersine lojistik büyük bir maddi değerdir ve bir müşteriye mal üreten, gönderen veya satan herhangi bir şirketin her yönden tersine lojistikten büyük oranda etkilendiği gibi tedarikçiler, müşteriler, ortaklar, hizmet sağlayıcıları, çevre, şirket kazançları ve hissedarlar da bir şekilde tersine lojistik sürecinden etkilenmektedir. Birçok şirket, yalnızca tersine lojistik yeteneklerini geliştirmeye odaklanarak rekabet avantajı sağlamakta ve net kazançlarını % 5 veya daha fazla oranda artırma fırsatı bulmaktadır (Greve ve Davis, 2012: XVIII).

Tersine lojistik ağı faaliyetlerinin son aşaması olan imha faaliyetlerinde, yeniden kullanılamayacak durumda olan ürünlerin yeraltına gömülerek ortadan kaldırılmasına ilişkin maliyetler de giderek artmaktadır. (ABD'de bir tonluk çöpü yok etmenin maliyeti 33,70 dolar seviyesine yaklaşırken yakılarak yok edilmesinin maliyeti ise ton başına yaklaşık 59,07 dolara yaklaşmaktadır. Artan maliyetler, iş çevrelerinde kalıcı çözüm beklentisini artırmaktadır) Metal hurda, atık kâğıt, cam atıklar vb. ürünlerin geri alınması, yok edilmesine kıyasla daha avantajlı bulunmaktadır. Son yıllarda artan çevre bilinci ve paralelinde artan kaygılar, yeniden kullanıma olan ilgiyi artırmaktadır. Ürün geri alımının en belirgin örneği, otomotiv endüstrisinde yaşanmaktadır. ABD'de camın %20'si, kâğıt ürünlerinin %30'u ve alüminyum kutuların %61'i geri dönüştürülürken 10 milyon araba ve kamyonun her yıl %95'i geri dönüşüme girmekte ve bu araçların %75'i yeniden kullanım için geri kazandırılabilmektedir. (Çekerol, 2013 :23).

Tersine lojistik faaliyetlerinin önemini kabul etse bile çoğu firma tersine lojistiğin gerçekte ne kadar çok katkısının olabileceğinin farkında değildir. Bu nedenle olumsuz maliyetlerin nasıl olumlu maliyetlere dönüştürülebileceğini görmekte zorlanmaktadırlar. Çünkü tersine lojistik faaliyetleri için kaynak, zaman ve para kullanımı istenmediği için sürecin iyileştirilebileceği görmezden gelinmektedir. Müşteri memnuniyetinin önemini bilmelerine rağmen iade ve kullanım ömrü bitmiş ürünleri geri toplama konusunda çoğu şirket gönülsüz davranmaktadır, ürünlerin geri dönüşüne önem veren az sayıda firmanın birçoğu da tersine lojistik faaliyetlerinde tecrübe sahibi olmadıkları için işe nereden ve nasıl başlayacağını bilememektedir. Yeni kurulacak bir sistem için bu tecrübeye sahip olmak önemlidir, çünkü verilecek

doğru kararların maliyetleri azaltma, yanlış kararların da gereksiz maliyetlere neden olma ihtimali yüksektir. Örneğin atık toplama merkezleri için yer seçimi önemli bir karar problemidir. Bu tesislerin firmanın üretim tesislerine olan mesafesi kadar müşterilere, atık depolama alanlarına ve ikincil pazarlara olan mesafeleri de zaman ve maliyet açısından önemlidir.

Firmalar için tersine lojistiğin önem kazanmasında sadece maliyet avantajı sağlaması rol oynamaz, yasal zorunlulukların, müşteri memnuniyetinin ve sosyal sorumluluğun da rolü büyüktür.

Tersine lojistik faaliyetlerinin firmalar için önemli olduğuna değinmenin yanında bu faaliyetler gerçekleştirilirken alınacak kararların da firmayı etkileyen önemli kararlar olduğunun altını çizmek gerekmektedir. Ürünlerin geri kazanımı için ürünlerin kullanıcılardan tesislere taşınması ve buradan da yeniden pazara sunulması için yerleşim yerlerinin tespiti, tesisler ve her bir tesis arasında taşınacak miktarlar alınması gereken önemli kararlardır. Stratejik kararlar üst yönetim, taktik kararlar orta seviye yönetim ve operasyonel kararlar ise alt seviye yönetim tarafından verilmektedir. Bu önemli kararlar uygulama durumlarına ve sürelerine göre dönemsel olarak şu şekilde gruplanmıştır (Ayvaz, 2013: 14-15):

- Uzun vadedeki kararlar: Fabrika yer seçimi, tesis tasarımı ve fabrika yerleşim düzeni, kapasite planlama
- Orta vadedeki kararlar: Kullanılacak teknolojik ve enformasyon sistemleri, işletmelerin entegre edilmesi
- Kısa vadedeki kararlar: Stok planlama, araç rotalama, yeniden imalat çizelgelemeleri

1.3.KAVRAM VE KAPSAM

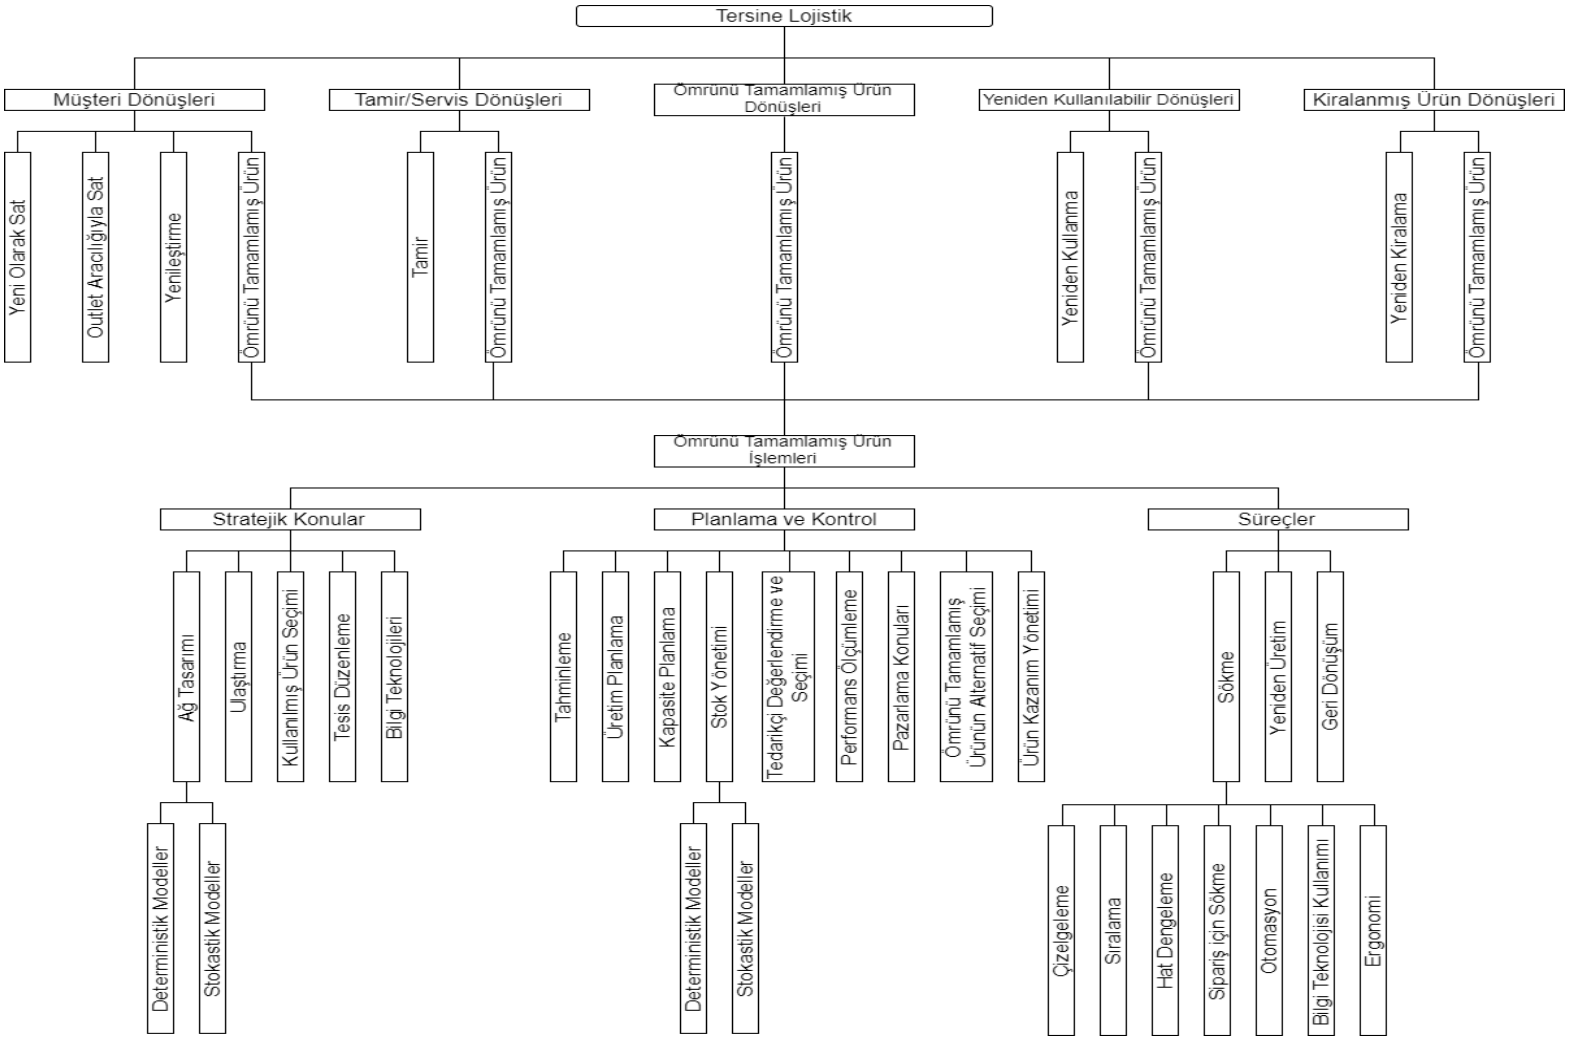
Tersine lojistik kavramının ortaya çıkışı ile ilgili net bir tarih vermek zordur. Uygulama olarak çok eskiden beri ticaret, lojistik, üretim vb. alanları ile iç içe olsa da "tersine lojistik" kavramı olarak literatüre son yarım yüzyılda girmiştir.

Tersine lojistik kavramı, dünya nüfusunun artmasının karşısında hammadde miktarının azalmasından dolayı, hammadde yerine kullanılacak malzemeleri geri

dönüşüm ile elde etme ihtiyacından doğmuştur. 1970'lere kadar, çevresel olaylar veya sürdürülebilir kalkınma endişe verici boyutlarda olmamıştır. Takip eden on yılda çevresel kirlenme endişe verici durumlara ulaşınca bu durum akademisyenler, politikacılar, medya ve konuyla ilgilenen diğer toplum kesimlerinin dikkatini çekmiştir (Çekerol, 2013: 14).

Bunun yanında çevresel kaygılar, ekonomik nedenler, yasalar, kurumsal ve sosyal sorumluluk, sürdürülebilir gelişme, doğal kaynakların korunması, daha az malzeme tüketimi gibi nedenlerden dolayı geri kazanım faaliyetleri önem kazanmıştır. Bu durum ürünlerin yeniden kazanımı için, kullanılmış ve iyileştirilmiş ürünlerin akışına imkan veren uygun lojistik yapıların oluşturulması ihtiyacını da beraberinde getirmiştir (Dirik, 2012: 55). Tersine lojistik kavramı Şekil 1.6 incelendiğinde daha iyi anlaşılmaktadır.

Ürün ve malzemelerin hammadde, yarı mamul, parça veya farklı bir ürün olarak yeniden kullanılması insan yaşamında yer edinmiş bir durumdur. En basitinden evlerimizde anne, baba, nine ve dedelerimizin eskiyen eşyaları atmak yerine çok farklı şekillerde değerlendirdiğini görmüşüzdür. Ninemizin eskiyen bir kilimden çantalar yapması, annemizin eskiyen kumaş veya giysilerden yeni örtüler veya giysiler dikmesi, dedemizin eski dolabı bahçe masasına çevirmesi ya da babamızın eskiyen kabloların sağlam kısımlarını birleştirerek işe yarar çalışan kablolar yapması buna verebileceğimiz çok tanıdık örneklerdir. Bu durum üretim yapan firmalar için de geçerlidir. Geri dönen bir ürünü atık olarak görmeden önce ekonomik ve ekolojik açılardan en yüksek katkıyı elde edebilmek için; herhangi bir işlemden geçmeden, tamir-bakım yapılarak veya değer kazandıran bir işlem görerek yeniden kullanılıp kullanılamayacağı, ürünün herhangi bir parçasının yeniden kullanılmak için işe yarayıp yaramadığı, ürünün tamamının veya parçalarının geri dönüşüm ile hammaddeye dönüştürülüp dönüştürülemeyeceği göz önünde bulundurulmakta ve üründen en iyi şekilde yararlanılmaya çalışılmaktadır. Tüm bu değerlendirmeler sonucunda hiçbir şekilde işe yaramayan kısımlar atık olarak görülmekte ve en uygun şekilde bertaraf edilmektedir. Örnek vermek gerekirse elektronik eşyalar ve mobilyalarda "eskiyi getir yeniyi götür" kampanyaları, çocukluğumuzda plastik veya



Şekil 1.6: Tersine lojistik konuları (Gupta, 2013: 6).

cam şişelerde satılan içeceklerin depozitolu satışı, yeni taşıt alırken eski taşıtlarla takas edilerek eski taşıtın değerinin yeni taşıtın fiyatından düşürülmesi, kağıt firmalarının ağaç kesmek yerine kağıtların geri dönüşümü ile doğaya verilen zararın azaltılmasına yönelik bilgilendirme çalışmaları ve bilinen çok eski mesleklerden biri olan hurdacılık ile üreticiler ürünlerinin geri dönüşünü sağlamaktadırlar. Burada yasal, kurumsal ve sosyal sorumlulukları altında bir çok belediyenin de geri dönüşümü olan cam, plastik, kağıt veya metal malzemeden üretilmiş ürün veya ambalajları toplamaya yönelik faaliyetlerinin ülke ekonomisine ve temiz bir çevre oluşumuna katkısını belirtmek gerekmektedir.

Tersine lojistiğin ürün dönüş türüne, zamana, ürünün göreceği işlem türüne ve tersine lojistiğin uygulanma nedenlerine göre boyutları Şekil 1.7'de görülmektedir.



Şekil 1.7: Tersine lojistiğin boyutları (Steven, 2004: 169).

Tersine lojistikte ürün geri dönüşü için ürünler ve ambalajlar olmak üzere iki ayrı geri dönüş üzerinde yoğunlaşılmaktadır. Tablo 1.1'de geri dönüş kaynağına göre ürün ve ambalajların gruplandırılması verilmiştir.

Katı atık kontrolüyle ilgili yasa gereği ambalajlarında plastik, pet şişe, polietilen, polistiren malzeme kullanan üretici firmalar bunların en az %30'unu geri toplamak durumundadır. Oluşturulan lojistik ağları da tersine lojistik süreçlerini içermeyip atıklar çoğunlukla çöp müteahhitleri tarafından toplanmaktadır (Çekerol, 2013: 15).

Tablo 1.1: Tersine akışdaki ürünlerin türüne ve kaynağına göre karakterizasyonu (Rogers ve Tibben–lembke, 2001: 134).

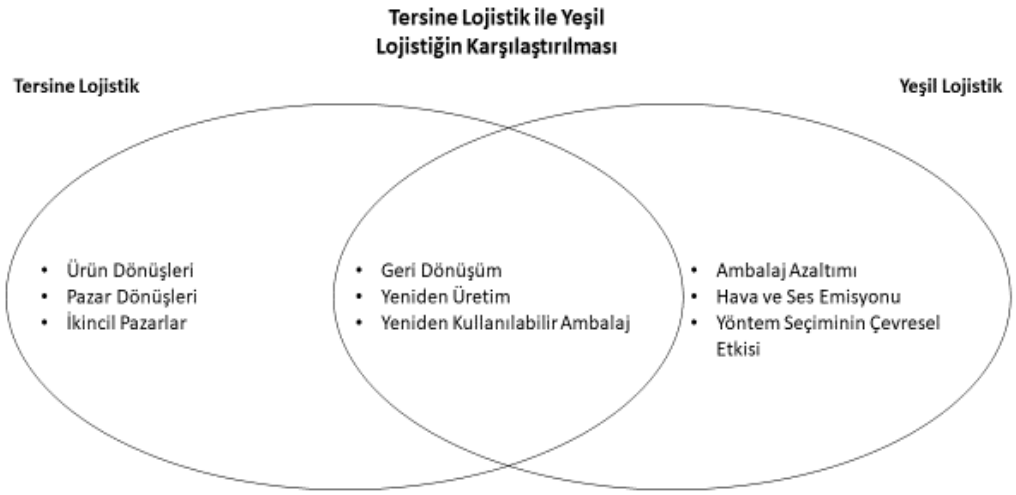
	Tedarik Zinciri Ortakları	Son Tüketiciler
Ürün	Stok dengeleme dönüşleri Pazar dönüşleri Sezonluk/ömrü tükenmiş ürünler	Kusurlu/istenmeyen ürünler Garanti dönüşleri Geri çağırmalar Çevresel bertaraf sorunları
Ambalaj	Yeniden kullanılabilir toplayıcılar Çok aşamalı taşıma Bertaraf gereksinimleri	Yeniden kullanım Geri dönüşüm Bertaraf kısıtları

Tablo 1.2'de ise geri dönen ürün ve ambalajlar için tersine lojistik faaliyetleri belirtilmiştir.

Tablo 1.2: Genel tersine lojistik faaliyetleri (Rogers ve Tibben–lembke, 2001: 133).

Malzeme	Tersine Lojistik Aktiviteleri
Ürün	Tedarikçiye dönüş Yeniden satış Outlet yoluyla satış Hurda Yenileştirme Tamir Yeniden üretim Geri kazanılan malzemeler Geri dönüşüm Hibe Katı atık depolama sahası
Ambalaj	Yeniden kullanım Yenileştirme Geri kazanılan malzemeler Geri dönüşüm Hurda Katı atık depolama sahası

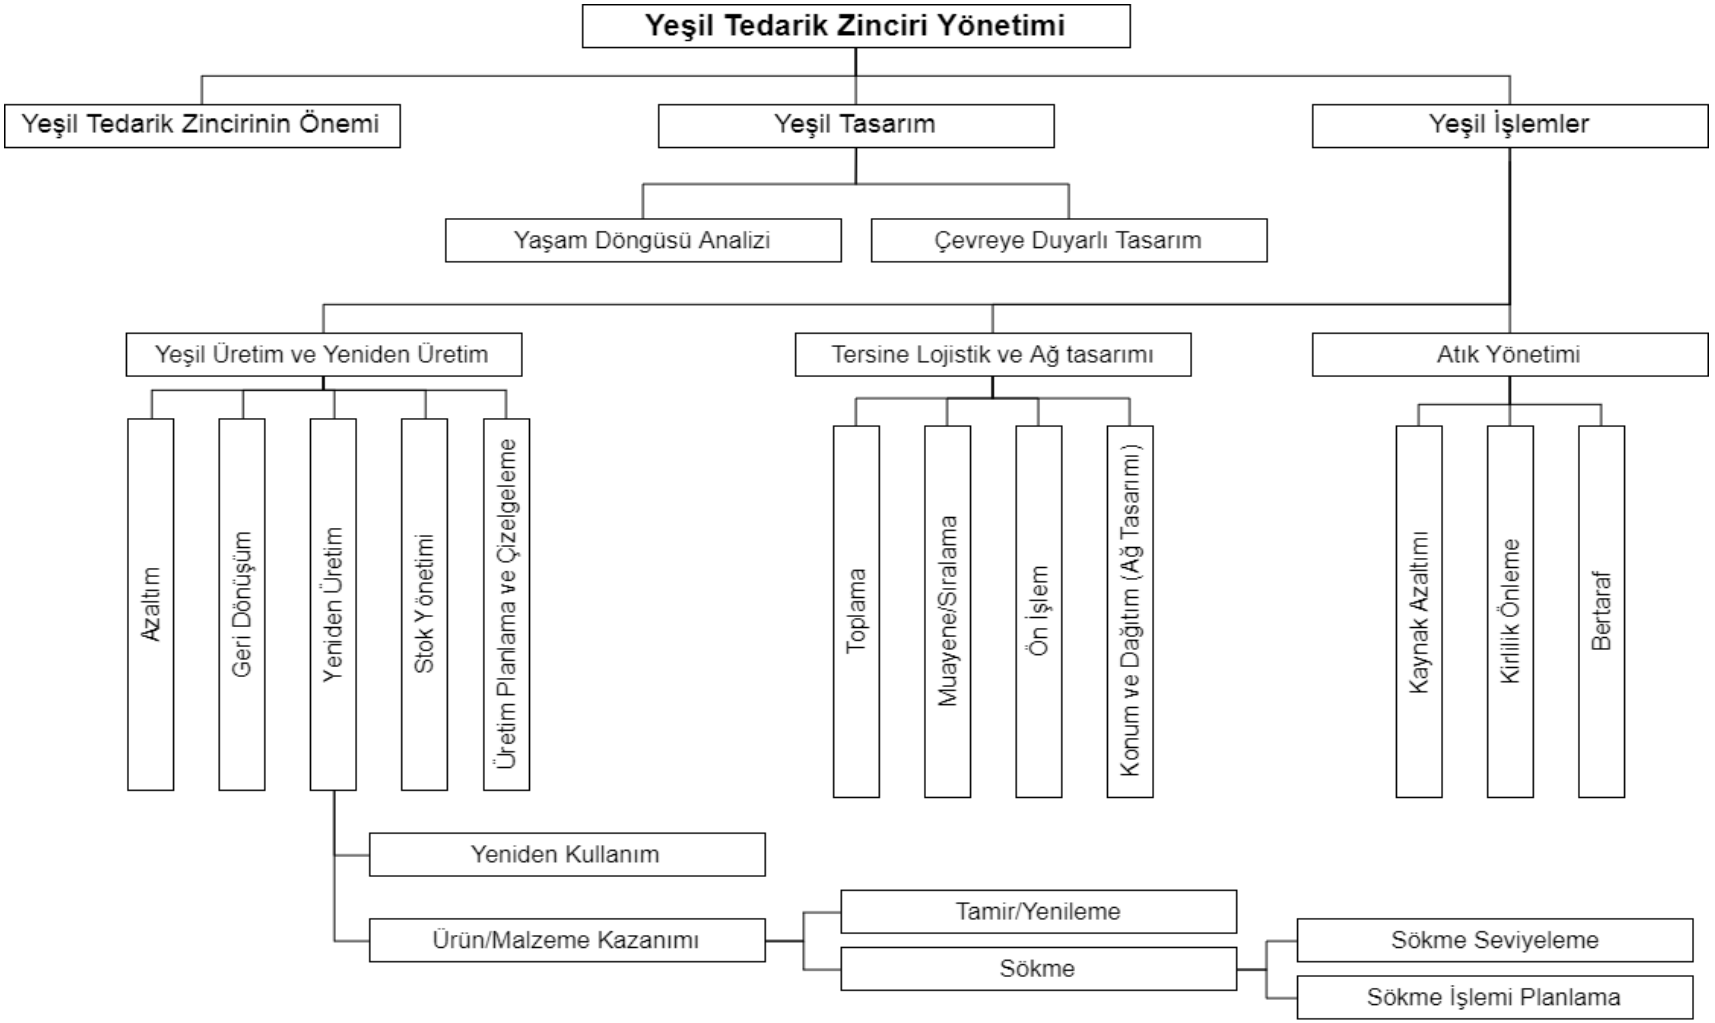
Tersine lojistik kavramının ortaya çıkışından bu yana bu kavram sanki geri dönüşüm veya atık yönetimi kavramlarıyla aynı manadaymış gibi birbirlerinin yerine kullanılmasına rağmen aralarında anlam ve kapsam bakımından büyük farklılıklar vardır. Geri dönüşüm, ürünlerin yapıldığı yeniden kullanıma uygun malzemelerin toplanması, ayrıştırılması, sterilizasyonu, depolanması, uygun işlem göreceği yerlere taşınması gibi sadece geri dönüşüm sürecini kapsayan işlemlerdir. Atık yönetimi ise, artık ekonomik bir değeri kalmamış, yeniden üretime kazandırılamayacak durumdaki ürünlerin toplanması, atık sahalarına taşınması, yakma, gömme, sterilizasyon, press gibi uygun bir atık saklama ve depolama yöntemi ile uygun şekilde bertaraf edilmesi faaliyetlerini kapsamaktadır.



Şekil 1.8: Tersine lojistik ve yeşil lojistiğin karşılaştırılması (Rogers ve Tibben–lembke, 2001: 131).

Tersine lojistik geri dönüşüm ve atık yönetimi ile birlikte iade yönetimi, satış sonrası hizmetler, tamir - bakım, saha çalışmaları, ürünlerin yenilenmesi - değer kazanımı, taşıma, geri çağırma, yeniden paketleme, yeniden kullanım, konu ile ilgili politikalar ve sözleşmeler ile tüm bu süreçlerle ilgili bilgilerin toplanması ve aktarımını kapsayan çok daha geniş bir kavramdır.

Ayrıca tersine lojistik kavramı, tersine tedarik zinciri ve yeşil lojistik kavramları ile de karıştırılmamalıdır. Tersine lojistiğin ve yeşil lojistiğin karşılaştırılması Şekil 1.8'de



Şekil 1.9: Yeşil tedarik zinciri yönetimi literatürünün sınıflandırılması (Srivastava, 2008: 537).

gösterilmiştir. Yeşil lojistik, ileri lojistik faaliyetlerine odaklanarak ekolojik dengeyi korumak için çevreye zarar vermeyen ürünler üretmeyi, doğal kaynakların tüketimini, kullanılan enerjiyi, tehlikeli atıkların imhasını ve açığa çıkan her türlü kirliliği azaltmayı amaçlarken, tersine lojistiğin çevreyi korumanın yanında atık miktarını azaltma, doğal kaynakları verimli kullanma, ekonomik katkı sağlamak gibi birçok amacı vardır. Tersine lojistiğin yeşil tedarik zincirindeki yeri Şekil 1.9'da gösterilmiştir.

Literatürde "tersine lojistik" ve "tersine tedarik zinciri" terimlerini birbirinin yerine kullanan çalışmalar bulunmakla birlikte, aralarında küçük bir fark vardır. Tersine lojistik çoğunlukla nakliye, üretim planlaması ve envanter yönetimi ile uğraşırken, tersine tedarik zinciri, kanal ortakları arasında eşgüdüm ve işbirliği gibi ek unsurları içeren geniş bir odak noktası bulmaktadır. Başka bir deyişle, tersine lojistik tersine tedarik zincirinin unsurlarından biridir (Gupta, 2013: 1-2).

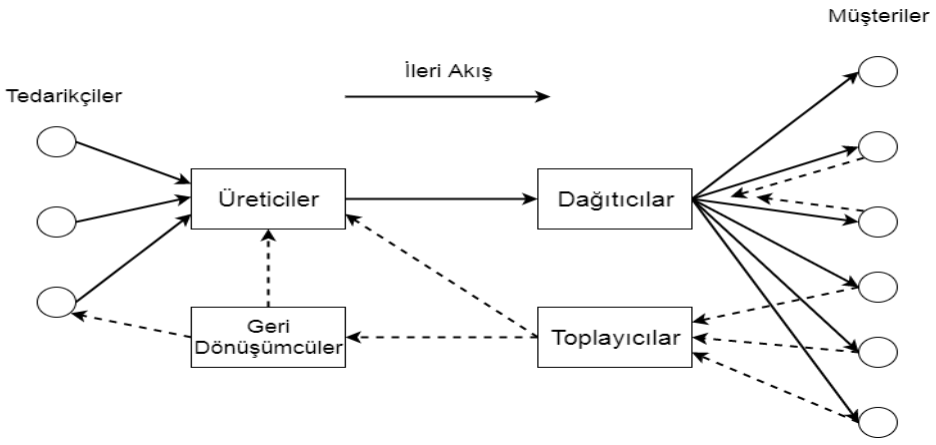
1.4.İLERİ LOJİSTİK VE TERSİNE LOJİSTİK ARASINDAKİ FARKLAR

Lojistik kelimesi eskiden ileri lojistik ile aynı manada kullanılırken günümüzde aslında olduğu manada, yani ileri lojistiği ve tersine lojistiği içine alan bir kavram olarak ortaya konmaktadır. Tersine lojistik, ileri lojistiğin işlem olarak tamamen tersi, yani ters olarak birebir yansıması gibi düşünülmemelidir. İçerdikleri işlemler ve özellikleri birbirinden bazı durumlarda kısmen bazı durumlarda tamamen farklılık gösterebilir. İleri lojistiği tedarik, üretim ve dağıtım lojistiği olarak alt kavramlara ayırırsak; üretim öncesi üretim için gerekli hammadde ve malzemelerin planlama, sipariş ve tedariği olarak tedarik lojistiğinden, üretim esnasındaki tüm planlama, taşıma ve depolama faaliyetlerini içeren üretim lojistiğinden ve depolardaki ürünlerin satıcılara ve tüketicilere ulaştırılmasını sağlayan dağıtım lojistiğinden bahsetmek gerekmektedir. Tersine lojistik ise tüketiciden itibaren geriye doğru tüm aşamalarda meydana gelen ürün geri dönüşü ile ilgilenmektedir. Bu geri dönüş kullanıp ömrü bittikten sonra olacağı gibi, ürünün kullanım esnasında ya da ürün hiç kullanılmadan da gerçekleşebilir.

Bu sebeple tersine lojistik ağ yapısı birçok alanda belirsizlik içermesi ve daha fazla birimin yer aldığı bir ağ olması nedeniyle çok daha karmaşıktır. Bu belirsizlik ve

karmaşık ağ yapısı tersine lojistiği ileri lojistikten ayıran en temel özelliktir. Tersine lojistik ağında ileri lojistik birimlerine ek olarak, toplama, ayırma, geri dönüşüm, bertaraf etme ve tamir-bakım merkezleri ile ikincil pazarlar da yer almaktadır. Ayrıca ileri lojistikte kalite, miktar ve zaman faktörleri belirli olduğundan süreç kontrolü ve planlaması da tersine lojistiğe kıyasla daha kolaydır. Hangi ürünün, ne zaman, nereden, nasıl bir durumda, ne kadar geri dönüşünün olacağı, nasıl bir işlem görmesi gerektiği bilinmediğinden tersine lojistik ağının tasarımı da belirsizlikler üzerine kurulmuş hassas ve maliyetli bir yapıdır. Bu yapının kurulması için önemli miktarda yatırımlar söz konusudur. Bu yüzden her adımda bir karar verilmeden önce dikkatlice plan yapılmalı ve değerlendirilmelidir.

Lojistik Yönetim Konseyi tarafından yapılan bir çalışmaya göre; tersine lojistiği etkileyen üç önemli konu vardır: Şebekenin yapısı, malzeme akışının planlanması ile malzemenin yönlendirilmesi ve sınıflandırılması. İleri lojistikte talep akışı yönlendirmekte, tersine lojistikte ürünün miktarı, zamanı ve durumu hakkında büyük belirsizlik yaratan tedarik akışı yönlendirmektedir. Tersine dağıtım, orijinal ileriye dağıtım ile aynı kanalını, ayrı bir tersine kanalı veya her ikisini birden kullanabilir. İleri ve tersine kanalların bütünleştirilmesi, tersine dağıtımda önemli bir konudur (Dinç vd. 2008: 329). Tersine dağıtım sistemi Şekil 1.10'da gösterilmektedir.



Şekil 1.10: Tersine dağıtım sistemi (Fleischmann, 1997: 5).

Aşağıdaki Tablo 1.3'te Tibben-Lembke ve Rogers tarafından ileri ve tersine lojistiğin kısaca karşılaştırılması verilmiştir (Tibben-Lembke ve Rogers, 2002: 276) :

Tablo 1.3: İleri ve tersine lojistik arasındaki farkların kısaca özeti (Tibben-Lembke ve Rogers, 2002: 276).

İleri Lojistik	**Tersine Lojistik**
Nispeten tahmini daha basit	Tahmin etmek daha zor
Birden çoklu ulaşıma	Çokludan tekli ulaşıma
Ürün ssabit kaliteye sahip	Ürün kalitesi sabit değil
Ürün sabit paketlemeye sahip	Ürün ambalajı sıklıkla hasarlı
Hedef / rota net	Hedef / rota belirsiz
Standart kanal	İstisna tahrikli
Atma seçenekleri temiz	Düzensizlik net değil
Nispeten sabit fiyatlandırma	Birçok faktöre bağlı fiyatlandırma
Hızın önemi vardır	Hız çoğunlukla bir öncelik olarak görülmez
İleriye dönük dağıtım maliyetleri muhasebe sistemleri tarafından yakından izlenir	Tersine akış maliyetleri daha az doğrudan izlenebilir
Tutarlı envanter yönetimi	Stok yönetimi tutarlı değil
Ürün ömrü yönetilebilir	Ürün yaşam döngüsü sorunları daha karmaşık
Taraflar arasındaki anlaşma basit	Müzakereler ilave hususlarla karmaşıktır.
Bilinen pazarlama yöntemleri	Birkaç faktörle karmaşık pazarlama
Ürünü izlemek için hazır olan gerçek zamanlı bilgiler	İşlemin görünürlüğü daha az şeffaftır

Bu karşılaştırmayı daha detaylı bir şekilde açıklayacak olursak;

- İleri lojistik yeni ürünlerin satış için dağıtımını kapsadığı için firmalar açısından birincil öneme sahiptir. Tersine lojistik ise yeniden üretim ve geri dönüşüm ile ilgilenen şirketler için önceliğe sahiptir.
- İleri lojistikte kalite, zaman ve miktar gibi ürün ve sipariş özellikleri belirli ve planlı olduğu için doğrudan talep tahmini yöntemleri uygulanabilir. Belirsizlik durumu talebin doğru bir şekilde tahminini de oldukça zor kılmaktadır. Geri dönen her ürün için miktar, zaman ve kalite gibi özellikler farklıdır. Bu nedenle tersine lojistikte talebi doğru tahmin etmek çok zor bir işlemdir.

- Dağıtım kanalı ileri lojistikte bir merkezden birçok dağıtım merkezine doğru iken, tersine lojistikte birçok tüketici veya toplama merkezinden bir üreticiye veya bir ürün iyileştirme merkezine doğrudur.
- İleri lojistikte çekme sistemi kullanılırken, tersine lojistikte ürünün durumu ve göreceği işleme göre hem çekme hem itme sistemi kullanılabilir.
- İleri lojistikte aynı ürünler belli kalite standartlarına uymak için sıkı kalite kontrollerinden geçmiş ve sabit kaliteye sahiptir. Tersine lojistikte ürün kullanım durumuna göre hasar görmüş parçası değiştirilmiş, eksik parçalı olabileceği için farklı kalite özelliğinde olabilirler. Bunun sonucu olarak inceleme, ayrıştırma, parça işleme gibi tersine lojistik faaliyetleri uzun sürmektedir. Tekrar kullanım için parça verimliliğinin ve hangi işlemlerin yapılması gerektiğinin önceden tahmin edilmesi zordur.
- İleri lojistikte tüm ürünler yenidir ve ürünleri korumak ve tanımlamak amacıyla belirli standartlara göre ambalajlanmışken, tersine lojistikte ürün ambalajı çok nadiren hasarsızdır, genellikle hasarlıdır ya da yoktur. Bu nedenle ürünlerin tanımlanması ve taşınması tersine lojistikte daha zordur.
- İleri lojistikte iletim ve dağıtım kanalları belli olduğu için belirli bir hedef/rota vardır. Tersine lojistikte ise farklı toplama kanalları mevcut olduğu için belirli bir hedef/rota yoktur.
- İleri lojistikte asıl hedef bir ürünü bir müşteriye satmaktır. Tersine lojistikte ise ürünün durumuna göre tamir, bakım, yeniden üretim, geri dönüşüm gibi farklı kararlar alınabilir. Ayrıca ileri lojistikte amaç minimum maliyet ve maksimum kazanç iken, tersine lojistikte maliyet minimizasyonu ve kar maksimizasyonu kadar yasal zorunluluklar ve sosyal sorumluluklar da önemlidir.
- İleri lojistikte sabit kanallar mevcutken, tersine lojistikte değişken kanallar mevcuttur.
- İleri lojistikte ürün başına maliyet belirliyken ve ürüne göre sabit fiyatlandırma yapılırken, tersine lojistikte fiyatlandırma ve ürün başına maliyet geri dönen ürünle ilgili birçok faktöre bağlıdır.
- Rekabet ortamının olduğu ürün pazarında müşterilere istediklerinde ürünü sunabilmek ve müşteriyi kaybetmemek için firmanın rakiplerinden daha hızlı

olması gerekir, yani ileri lojistikte hız ürün pazarında can alıcı roldedir. Tersine lojistikte iade edilen ürünleri genellikle firma topladığı ve bu konuda rekabet ortamı olmadığı için herhangi bir müşteri kaybı ya da stok kaybı durumu söz konusu değildir, dolayısıyla da hızın tersine lojistik için genellikle bir önceliği yoktur.

- İleriye dönük dağıtım maliyetleri net olduğu için muhasebe sistemleri ileri lojistik faaliyetlerindeki maliyetleri yakından izleyebilecek şekilde tasarlanmıştır. Tersine lojistikte farklı faaliyetler ve farklı maliyetler ortaya çıkabileceği için tersine akış maliyetleri daha az doğrudan izlenebilir.
- İleri lojistik sistemlerinde arz ve talep tahmin edilebilir veya belirli olduğu için stok yönetimi etkin ve tutarlıdır. Tersine lojistikte ise arz, talep ve ürün getirileri belirsiz olduğu için birçok stok modeli uygulanamaz, bu nedenler ise stok yönetimini tutarsız ve karmaşık yapmaktadır.
- Ürün yaşam döngüsü hem ürün tasarımı, üretimi, dağıtımı ve satışı gibi ileri lojistik faaliyetlerini içerirken, hem de kullanım sonrası faaliyetleri kapsayan tersine lojistik aşamalarını içermektedir. İleri lojistikte ürün ömrü belirli ve yönetilebilirken, tersine lojistikte ürün yaşam döngüsü daha karmaşık olduğu için ürün ömrü dikkate alınmamaktadır.
- İleri lojistikte taraflar arasındaki anlaşma basit ve kolaydır. Tersine lojistikte ise ürünlerin bir standarda sahip olmaması, ürün miktarı, arz ve fiyatların belirsizliği taraflar arasında iş birliğinin karmaşık ve zor olmasına neden olmaktadır.
- İleri lojistikte bilinen pazarlama yöntemleri kullanılırken, tersine lojistikte pazarlama birçok faktörden etkilendiği için daha karmaşıktır.
- İleri lojistikte ürün akışını izlemek için bilgi sistemleri mevcuttur ve bu sistemlerde hazır olan gerçek zamanlı bilgiler kullanıldığı için her şey şeffaftır ve ürünü izlemek kolaydır, tersine lojistikte ise genellikle bilgi sistemleri için yatırım yapılmamakta ve mevcut bilgi sistemlerinde de tersine lojistik süreçleri yer almamaktadır. Tersine lojistik süreçleri hakkında daha az bilgi mevcut olduğu için daha az şeffaflık vardır ve ürünü izlemek bu nedenle daha zordur.

1.5.TERSİNE LOJİSTİĞİN UYGULANMA NEDENLERİ

Firmalar genellikle ekonomik getirisi olan faaliyetlerde bulunmayı tercih etmektedir. Firmaların bilinçli olarak maliyeti azaltıp karı arttırmayı amaçlaması dışında, yasal zorunlulukların üreticileri ürettikleri üründen ürün ömrü boyunca sorumlu tutması ya da çevre bilincinin arttığı günümüzde müşterilerin üretimin doğaya daha az zarar verecek şekilde yapıldığı firmalara yönelmesinden doğan toplumsal baskı nedeniyle tersine lojistiğe yöneldikleri de söylenebilir. Tersine lojistiğin uygulama sebeplerini şu başlıklar altında özetlersek:

1. Ekonomik nedenler
2. Çevresel sorumluluk ve pazarlama nedenleri
3. Yasal zorunluluklar
4. Bilgi gizliliği

1. Ekonomik nedenler

Tersine lojistiğin ekonomik olarak uygulanma nedenleri direkt ve dolaylı nedenler olarak ikiye ayrılmaktadır. Direkt olarak firmaya ekonomik etkisi üretim maliyetlerini düşürme, üretim için gerekli hammadde ve malzemeyi azaltması, gerekli yedek parçaların elde edilmesi, değer kazanımı ile ürünlerin yeniden kullanımını sağlama veya bertaraf maliyetlerini azaltma olarak sayılabilir. Ayrıca tersine lojistik faaliyetleri, kullanılmış ürünlerden yeniden ürün üretiminin maliyetinin sıfırdan yeni ürün üretmeye göre daha az olduğunu göstermektedir.

Herhangi bir nakit veya hemen beklenen kar olmadan bile, bir organizasyon pazarlama, rekabet ve stratejik nedenlerle tersine lojistik ile daha fazla ilgilenebilir. Tersine lojistiğin ekonomik anlamda dolaylı etkisi ise başta firmaya sağlayacağı prestij ve yeşil imaj olmak üzere, müşteri ve tedarikçi ilişkisini geliştirerek müşteri memnuniyetini arttırma, pazar payını koruma ve gelecekte yürürlüğe girecek yasalara uyum sağlama olarak sayılabilir. Yeşil imaja sahip olmak, özellikle toplumun çevresel bilincinin bir bütün olarak artması nedeniyle müşteri ilişkileri stratejisinin bir parçası olabilir. Öte yandan, bir firma uzun vadede yaklaşan mevzuat ve yeni yasalar gibi bazı koşulları öngörebilir. Firmalar kendilerine avantaj sağlamak için gelecekte yürürlüğe

girecek yasalara hazırlıklı olmak için stratejik bir adım olarak iyileşme sürecine katılabilir. Ya da rekabet ortamındaki bir şirket, diğer şirketlerin teknolojilerini almasını engellemek veya piyasaya girmelerini engellemek için kendini iyileşme sürecine girebilir. Lastik üreten bir firmanın müşterilerin masraflarını düşürmek için müşterilere yamalama ya da tekrar kaplama olanakları sunması tersine lojistiğin dolaylı olarak ekonomik katkısına örnek olarak gösterilebilir (De Brito ve Dekker, 2002: 6).

2. Çevresel sorumluluk ve pazarlama nedenleri

Gün geçtikçe müşterilerin çevre bilinci artmakta ve istedikleri ürünlerin beklenen özelliklerde, kaliteli olmalarının yanında hem üretimlerinde hem de kullanım sonunda çevreye en az zarar verecek özellikte olmalarını istemektedirler. Bu durum önemli bir konu haline gelmekte ve firmaların imajını ve pazardaki yerini etkilemektedir. Çevreye duyarlılığın artmasıyla firmalar pazardaki konumlarını korumak hatta pazar paylarını genişletmek için tersine lojistikle yakından ilgilenmektedir. Çevresel imajını sağlamak için firmalar çevre dostu üretim yapmakta, ürettikleri ürünlerinin tüm yaşam döngüsü boyunca sorumluluğunu almakta, kullanılan ürünlerine geri dönüşüm, yeniden üretim gibi yollarla değer kazandırmaktadır. Tersine lojistiğin rekabet avantajı sağlayan tek özelliği çevre dostu ürünler üretmesi değildir; tüketicilere aldıkları ürünle ilgili satış sonrası tamir-bakım, bozuk ürünün değişimi ya da para iadesi gibi faaliyetlerle güven vermek de firmaya rekabet avantajı sağlamaktadır. Tersine lojistiğin firmaya sağladığı direkt ve dolaylı ekonomik katkılardan ve sağladığı rekabet avantajlarından daha önce kısımda bahsedilmiştir.

3. Yasal zorunluluklar

Bazı durumlarda firmaların tersine lojistiği kullanma nedenleri tercih etmeleri değil, yasal olarak zorunlu olmalarıdır. Çevre politikaları ile ilgili yasalar firmaları yaptıkları üretim faaliyetlerinden ve ürettikleri ürünlerden sorumlu tutmaktadır. Bu yasal sorumluluklar firmaların sattıkları ürünleri geri almalarını ve kullanılan ürünleri geri kazanmalarını sağlamak için tersine lojistik faaliyetlerini yerine getirmelerini gerektirmektedir. Bu şekilde müşteri haklarını korurken çevreyi de korumak için

firmalara sorumluluk yüklenmiş olur. Çoğu ülkede firmalar ürettikleri ürünleri belirli bir oranda geri toplamak zorundadırlar.

Genel olarak bu yasal düzenlemeler, ürünlerin yaşam döngülerinin sonunda toplanması, yeniden kullanımı, atık yönetimi ve bununla ilgili sorumlulukların üreticilere yüklenmesi, atık miktarının azaltılması, ürün ya da malzeme geri dönüşüm oranlarının artırılması yönünde olmaktadır. Ülkemizdeki yasal düzenlemelerden bazıları şu şekildedir: Tıbbi Atıkların Kontrolü Yönetmeliği, Ömrünü Tamamlamış Lastiklerin Kontrolü yönetmeliği, Katı Atıkların Kontrolü yönetmeliği, Bitkisel Atık Yağların Kontrolü Yönetmeliği, Atık Pil ve Akümülatörlerin Kontrolü Yönetmeliği, Ambalaj Atıklarının Kontrolü Yönetmeliği, Tehlikeli Atıkların Kontrolü Yönetmeliği vs. (Ayvaz, 2013: 17).

4. Bilgi gizliliği

Bahsettiğimiz diğer üç neden en temel neden olmakla birlikte firmaların piyasadaki rekabet avantajlarını kaybetmemek için ürünleri ve üretimleri ile ilgili bilgileri korumak, kurum dışına sızdırmamak amacıyla kendi ürünlerinin tersine lojistiğini de kendilerinin yapmayı istemeleridir.

Ayrıca günümüzde üretilen ürünlerin eskiden üretilen ürünlere kıyasla ürün ömürlerinin daha az olması, modalarının çabuk geçmesi, insanların sürekli yeni teknoloji istemeleri ve elektronik ticaretin perakende sektöründe hızla yayılması, müşterilerin kolay alışveriş ve ürün çeşitliliği sebebiyle elektronik ticareti tercih eder duruma gelmesi de tersine lojistiğin uygulanmasını zorunlu kılan sebeplerdendir.

1.6.TERSİNE LOJİSTİK LİTERATÜR TARAMASI

Tersine Lojistik ile ilgili ilk tanımlar Lambert ve Stock (1981) tarafından yapılmışken, Lojistik Yönetim Konseyi (CSCMP) ise tersine lojistikle ilgili bilinen ilk tanımını 1990'lı yıllarda yapmıştır. Böylece Tersine lojistik kavramı ortaya çıkmış ve bu konudaki çalışmalar yapılmaya başlanmıştır.

Fleischmann vd. (1997) tersine lojistiği üç ana alana, yani dağıtım planlaması, stok kontrolü ve üretim planlamasına göre alt bölümlere ayırmıştır. Bunların her biri için,

ortaya çıkan yeniden kullanım çabalarının etkilerini tartışılmış, bazı önerilen matematiksel modeller gözden geçirilmiştir.

Carter ve Ellram (1998) literatürü gözden geçirip lojistik personelinin tersine lojistikteki rolü hakkında geniş bir bakış açısı geliştirmiş ve rehberlik etmeye yardımcı olması için teorik olarak temel alınmış, ancak pragmatik olarak yönlendirilmiş bir çerçeve sunmuşlardır.

Tibben-Lembke (1998) tersine lojistiğin malın toplam maliyeti üzerindeki etkisini araştırmış, detaylı olarak atıkların, geri dönüşümün, elden çıkarma ve iade edilen malların maliyetlerinin toplam maliyete etkisini incelemiştir.

Fleischmann vd. (2000) kullanılan ürünlerin geri kazanımında kullanıcılardan üreticilere doğru ürünlerin iletilmesi için etkili ve uygun bir şekilde lojistik yapıların kurulmasını amaçlayan lojistik ağlarının tasarımını araştırmışlardır. Bunun için farklı endüstrilerdeki ürün geri kazanımındaki lojistik ağı tasarımı çalışmalarını incelemişlerdir. Ayrıca farklı ürün geri dönüşümü ağlarının sınıflandırılması üzerine bir şema türetmişlerdir.

Fleischmann (2001) kapalı döngü tedarik zincirinin özel durumu için lojistik ağı tasarımını ele alınmış, bir ürün kurtarma girişimi lojistik uygulamasına karar verirken şirketlerin karşılaştıkları önemli konuları vurgulamıştır. Özellikle, geleneksel 'ileri' tedarik zincirleri için lojistik ağı tasarımıyla olan farklılıkları belirtmiş, ayrıca spesifik tedarik zinciri bağlamları ile lojistik ağı yapıları arasındaki stratejik uygunluğu incelemiş, sonuçları niceliksel bir analizle desteklenmiştir.

Rogers ve Tibben-Lembke (2001) ABD'deki tersine lojistik faaliyetinin kapsamını belirlemek amacıyla tersine lojistikle ilgili ekonomik ve tedarik zinciri konularına odaklanmış, tersine lojistiği tanımlamış, tersine lojistik çalışmalarını ve iyi tersine lojistik çalışmalarının uygulanmasına ilişkin engelleri tanımlamış ayrıca yeşil konular kısaca tartışılmıştır.

De Brito ve Dekker (2002) tersine lojistik kavramlarını tanımlayıp tersine lojistik için "neden-ne-nasıl" temelli bir anlayış çerçevesi çizmişlerdir. Bu yolla, geri dönüş

sebepleri tiplerini, ürünleri, süreçleri ve aktörleri sınıflandıran tersine lojistik için itici güçler ortaya koymuş, tersine lojistik için bir karar çerçevesi oluşturmuş ve uzun, orta, kısa vadeli kararlara göre stratejik-taktik-operasyonel kararlar sunmuşlardır.

Marx-Gomez vd. (2002) hurdaya ayrılan ürünlerin geri dönüş değerleri (miktar ve zaman) için genişletilmiş bir tahmin yöntemi sunmuş, ilgili etki faktörleri ve ürün yaşam döngüsü verilerine dayanan bir model sunmuşlardır. Değerlendirme ve kullanılabilirlik için fotokopi makineleri ile ilgili bir vaka çalışması simüle edilmiş, belirli bir planlama döneminde dönüşün öngörülmesi için bir bulanık çıkarım sisteminin tasarımı ve dönüş değerlerinin zamanla öngörülmesi için bir nevro-bulanık sistem tasarlanmıştır.

Tibben-Lembke ve Rogers (2002) ürünün tersine akışına odaklanarak, bir perakende ortamında ileri ve geri lojistiği karşılaştırıp lojistik sistemlerinin ileri ve geri akışları arasındaki birçok farklılığı sunmuştur. Tersine akışta ürünü yeniden üreten veya yenileyebilecek tersine akışlı firma açısından sorunlar değerlendirilmiştir.

Jayaraman vd. (2003) tersine lojistik için bir matematiksel programlama modeli önermiş, önerilen modelin karmaşıklığı nedeniyle, bu problem için sezgisel bir çözüm yöntemi sunmuşlardır.

Toktay (2003) tersine lojistikte stok yönetimi ve toplam maliyeti etkileyen ürün geri dönüşlerinin zaman periyotlarını ve geri dönen ürün miktarını tahmin etmenin önemini vurgulamaya çalışmış ve konuyu daha iyi açıklamak için KODAK tek kullanımlık fotoğraf makineleri ile örnek bir çalışma yapmıştır. Ayrıca tahmin yöntemlerinde zaman serileri analizi dışında kullanılan Saf tahmin, dağıtılmış gecikme bayesian çıkarım modeli ve Beklenti Maksimizasyonu algoritması modellerinden de bahsedip karşılaştırma yapmıştır.

Gonza-‘lez Torre vd. (2004) farklı Avrupa ülkelerinde gıda ve içecek sektörüne ait şişeleme ve ambalajlama firmaları, bunların şişe-kavanoz üreten tedarikçileri ile müşteriler arasındaki ilişkilerdeki farklılıkları analiz etmişler ve tersine lojistik faaliyetlerine karşılık gelen uygulamaları incelemişlerdir.

Richey vd. (2004) çalışmalarında literatüre kısa bir bakış sunmuş ve biçimsel hipotezler geliştirmiştir. Konunun daha iyi anlaşılmasına yardımcı olmak için otomobil endüstrisinde tersine lojistik uygulamaları üzerine yapılan bir araştırmanın sonuçlarını değerlendirmiş, araştırma metodolojisi tartışılarak sonuçlara ve yönetsel etkilere değinilmiştir.

Peralta ve Fontanos (2005) çalışmalarında televizyon, buzdolabı, klima, çamaşır makinesi ve radyoya odaklanarak Filipinler'deki e-atık miktarını tahmin etmeyi amaçlamışlardır. Ulusal İstatistik Ofisi'ne (NSO) ait veriler kullanılarak, her elektronik cihaz türü için matematik denklemler, kullanılan elektronik cihazların sayısı, mevcut kullanım ömrü yönetimi uygulamaları, kullanıma hazır yıllar ve tüketicilerin elden çıkarma davranışları gibi diğer faktörleri içeren basit bir ömür sonu modeli türetmişlerdir.

Prahinski ve Kocabasoglu (2005) tersine tedarik zincirindeki literatürü gözden geçirmiş ve 10 araştırma önerisi geliştirmişlerdir.

Gonza´lez-Torre ve Adenso-Dı´az (2006) cam malzemesini kullanan ambalaj ve şişeleme şirketlerini, tedarikçilerle ve müşterilerle olan ilişkileri, çevre talepleri açısından incelemişlerdir. Çalışma, tüketici alışkanlıkları ve geri dönüşüm açısından çok farklı özelliklere sahip iki ülke olan İspanya ve Belçika'da elde edilen sonuçlarla karşılaştırılmıştır.

Ravi ve Shankar (2006) bir Hint kağıt üretim şirketinin vaka incelemesini sunmuş, tersine lojistik uygulamalarının Hint kağıt üretim şirketinde yeni bir safhada olduğu gözlemlenmiştir.

Srivastava ve Srivastava (2006) belirli ürün kategorileri için getiri tahminine odaklanarak tersine lojistikte ürün getirilerini yönetmek için bir çerçeve sunmayı amaçlamışlar, bunun için kavramsal bir model geliştirip literatürden ve endüstri uygulamalardan alınan entegre bir modelleme çerçevesi geliştirmişlerdir. Ortaya koydukları modelde ürün sahipliği verileri, ürünlerin ortalama yaşam döngüsü, geçmiş satışlar, öngörülen talep ve geri dönüş akışlarını tahmin etmek için çevresel politika önlemlerinin muhtemel etkisi kullanılmış, önemli parametrelerin tahmin edilmesi için

84 paydaşla gayriresmi görüşmeler yapılmış, çözüm için yazılım paketleri, ayrıştırma yöntemleri ve buluşsal yöntemler kullanılmıştır.

Wu ve Cheng (2006) Çin, Hong Kong ve Tayvan arasındaki yayıncılık sektöründeki tersine lojistik özelliklerini karşılaştırmışlardır. Bu çalışma Çin, Tayvan ve Hong Kong'daki yayıncılık endüstrisindeki ters lojistik zorluklarını anlamak için EIQ (sipariş, öğeler ve miktar girişi) analizini uygulayan ilk ampirik çalışma olmuştur.

Bernon ve Cullen (2007) tersine lojistik ile ilgili bir literatürün geliştirilmesine katkıda bulunmayı amaçlamış ve entegre tedarik zinciri yaklaşımının kullanılması ile varlık geri kazanımı değerlerini maksimize ederken tersine lojistik operasyonlarının maliyetini düşürmek için önemli fırsatlar sağladığını savunmuşlardır.

Biehl vd. (2007) bir halı tersine lojistik tedarik zincirini taklit edip sistem tasarım faktörlerinin etkisini ve tersine lojistik sisteminin operasyonel performansını etkileyen çevresel faktörleri analiz etmek için tasarlanmış bir deney kullanmışlardır. Öncelikle, çeşitli ağ tasarım parametrelerinin göreli önemi tespit etmişler, verimli bir tersine lojistik sisteminin tasarlanması durumunda bile geri dönüşüm oranlarının yaklaşık on yılda karşılanamayacağını göstermişlerdir.

Bulut ve Deran (2007), tersine lojistiğin şirketlerin maliyetleri üzerindeki etkilerini incelemiş, ürünlerin direk yok edilmesi ile ortaya çıkan maliyet ile ürünlerin yeniden kullanımı, geri dönüşümü, kısmi kullanımı veya kısmi geri dönüşümüyle sağlanan maliyetteki azalışlara veya ek gelirlere dikkat çekmişlerdir.

Hanafi vd. (2007) Avustralya'daki çeşitli yerlerde cep telefonu dönüşlerini tahmin etmek için Bulanık Renkli Petri Net tahmin modelinin bir uygulamasını sunmuşlardır.

Jayaraman ve Luo (2007) tersine lojistik faaliyetlerinin (yeniden kullanım, onarım, yenileme, geri dönüşüm, yeniden üretim veya iade edilen ürünlerin yeniden tasarımı) endüstriler için kapalı çevrimli bir sistemi içerdiğini tanımlayan bir değer zinciri stratejisi sunmuşlardır. Tanımlanan bu değer zincirinin, ürün iadelerini ele alan üreticiler veya perakendeciler için genel iş stratejisinin bir parçası olması gerektiğini vurgulamışlardır.

Kumar ve Craig (2007) Dell Firması için yirmi yıllık kapalı döngü tedarik zincirinin kapsamlı bir analizini sunmuşlardır.

Linton vd. (2007) yaptıkları çalışmada operasyon yönetimi ile kesişen sürdürülebilir kalkınma alanında mevcut eğilimlerin, araştırma fırsatlarının ve sunduğu zorlukların daha iyi anlaşılması için bir arka plan sağlamayı amaçlamışlardır.

Liu ve Fang (2007) tersine lojistik alanındaki teorik çalışmaların mühendislik uygulamalarının gerisinde kaldığını düşünüp tersine lojistikte çağrışım, unsurlar, sınıflandırma, temel özellikler ve araştırma içeriğinin ayrıntılı olarak ele alındığı kavramsal katman, etkinleştirme tekniklerinin olduğu etkinleştirme katmanı ve temel özelliklerin olduğu destek katmanından oluşan üç katmanlı bir çerçeve ileri sürmüşlerdir.

Nakıboğlu (2007) tersine lojistik ile ilgili tanımsal ve teorik yapıda bir literatür incelemesi yapmış, tersine lojistiğin içerdiği süreçleri, bazı önemli yasal düzenlemeleri tanımlamış ve mevcut uygulamalar ile eğilimler hakkında bilgi vermiştir. Tersine lojistiğin işleyişini, sebeplerini, işletmelere sunduğu faydaları ve konu ile ilgili yasal düzenlemeleri dünyadaki uygulama örnekleri ile ele almıştır.

Rubio vd. (2007) yaptıkları çalışmada, 1995-2005 döneminde en ilgili dergilerde yayınlanan tersine lojistik konulu bir veri tabanı oluşturup üretim ve işletme yönetimi alanında yayınlanan tersine lojistik konularındaki makalelerin temel özelliklerini tanımlamayı ve analiz etmeyi amaçlamışlardır. Bunun için tersine lojistik konusundaki araştırmaların ilk on yılını, neler yapıldığını ve nerede, kimin tarafından yapıldığını incelemişlerdir.

Dinç, Erol ve Yüceer (2008)'in yaptıkları çalışmada tersine lojistik ile ileriye lojistiği bir yenileme şebekesinde birleştiren yeni bir tersine dağıtım modeli kurulmuştur. Model, ileriye ve tersine lojistiği iki aşamalı, kapasite kısıtlı, stok taşımalı, tesislerin açılma, ürünlerin üretim, taşıma, toplama, atma ve işlem maliyetlerini de içeren yeni bir model için küçük bir örnek tasarlanmış ve çözümü sunulmuştur.

Gülsün, Tuzkaya ve Bildik (2008), makalelerinde bir yeniden kullanımlı konteyner (veya geri dönüşümlü ambalajlama) sistemi bir simülasyon modeli oluşturulmuş, öncelikle model yapısının ayrıntılı açıklaması verilmiş, elde edilen sonuçlar değerlendirilmiş ve farklı kombinasyonların müşteri memnuniyetini farklı şekillerde etkileyeceği gösterilmiştir.

Özgün Demirel ve Gökçen (2008) tersine lojistik ağı tasarımı ve modellenmesi konusunda yapılmış olan çalışmalar incelemiş, genel özellikleri analiz edilmeye çalışılmış, ileri ve tersine akışı bağımsız ya da bütünleşik olarak modellemeleri, amaç fonksiyonu yapıları, örnek olay içerip içermemeleri gibi farklı özellikleri dikkate alınarak sınıflandırmış ve temel özellikleri analiz etmeye çalışmıştır.

Srivastava (2008) literatürdeki girdileri ve 84 paydaşla gayri resmi görüşmeleri, maliyet açısından etkin ve verimli tersine lojistik ağında tesislerin aynı anda konumsal olarak tahsis edilmesi için kavramsal bir model geliştirmek için kullanmıştır. Önerilen tersine lojistik ağı, maliyetleri ve operasyonları ortaya koyup çeşitli stratejik, operasyonel ve müşteri hizmetleri kısıtlamaları altında birkaç ürün kategorisi için orijinal ekipman üreticileri tarafından kurulan toplama merkezleri ve iki tür yeniden işleme tesisinden oluşturulmuştur. Çalışmada, betimsel modellemeyi metodolojik düzeyde optimizasyon teknikleriyle birleştiren bütünsel bir kavramsal çerçeve sunulmuş, ayrıca, kavramsal modelle deneyler yaparak, topolojik düzeyde ağ yapılandırması ve tasarımı için ayrıntılı çözümler sunulmuştur.

Akçalı vd. (2009) araştırmalarını sadece ters kanalları yönetmek için bir altyapı oluşturmakla ilgilenen tersine tedarik zinciri ağı tasarımı ve kapalı döngü tedarik zinciri ağı tasarımı olmak üzere odaklanan iki ana bölüm halinde düzenlemişlerdir. Yayınlanmış literatürün eleştirel bir incelemesini yaparak gelecekteki araştırmalar için potansiyel alanları tanımlamışlardır.

Efendigil vd. (2009) çalışmalarında bulanık talebi eksik bilgi ile yönetmek için yapay sinir ağlarının ve uyarlamalı ağ tabanlı bulanık çıkarım sisteminin karşılaştırılmasını içeren yapay zeka yaklaşımları ile modellenen yeni bir öngörü mekanizması önermeyi amaçlamış, nöral teknikler yoluyla çok seviyeli bir tedarik zinciri yapısındaki belirsiz

müşteri taleplerine ilişkin karşılaştırmalı bir tahmin metodolojisi sunmuşlardır. Önerdikleri yaklaşımın talep tahmini konusundaki etkinliğini, İstanbul'da dayanıklı tüketim malları endüstrisinde aktif olan bir şirketten gelen gerçek dünya verilerini kullanarak göstermişlerdir.

Lau ve Wang (2009) Çin'de tersine lojistik uygulamalarını etkileyen dışsal ve içsel faktörlerin sistematik bir analizini sunmuşlardır. Elektronik şirket web sitelerinden toplanan bilgiler, doğrudan gözlem ve Çin'de dört büyük elektronik ürün üreticisi ile derinlemesine görüşmelerle bir vaka çalışması yaklaşımı benimsemişlerdir. Literatürdeki teoriler ile Çin'deki modeller ve gerçek uygulamalar arasındaki boşlukları belirlemek için literatürle karşılaştırma yapılmışlardır

Pokharel ve Mutha (2009) makalelerinde çeşitli web tabanlı arama motorlarını, kitapları ve konferans süreçlerini kullanarak tersine lojistiktiğin kullanılmış ürünlerin toplanması, işlenmesi ve sonrasında işleme çıktılarına, yani geri dönüştürülmüş malzemeler, yedek parçalar, yeniden üretilmiş ürünler ve atık maddelerin bertaraf edilmesine kadar tüm yönlerine odaklanarak araştırma ve uygulamalardaki gelişmeyi incelemişlerdir.

Stock ve Mulki (2009) üreticilerin, tüm toplayıcıların/distribütörlerin ve perakendecilerin ürün iadesi işlemlerinde toplanan ampirik verileri kullanarak ticaret sektöründe neyin yer aldığının daha iyi anlaşılmasını kolaylaştırmayı ve tersine lojistik uygulamaları ile ilgili bazı ölçütler sağlamayı amaçlamışlardır. Çeşitli yayınlanmış makalelerde önerilmiş ancak test edilmemiş birçok hipotezi inceleyip bu hipotezlerin test edilmesinin, ürün iadelerinin önem derecesini, geri kazanılan değerin ürün kurtarma çabalarını haklı gösterecek kadar yüksek olup olmadığını ve ürün iade sürecinin çeşitli aşamalarında harcanan kaynaklar gibi sorulara cevap bulmasına yardımcı olup olmayacağını incelemişlerdir.

Xiaofeng ve Tijun (2009) tersine lojistik ile iade edilen ürün miktarını tahmin etmek için, dalga fonksiyonuna dayalı yeni bir model önerilmişlerdir. Bu modelin doğruluğunun geri dönen ürünlerin miktarını bariz periyotlarla tahmin ettiği için daha

iyi olduğunu savunup, modelin fizibilitesini ve üstünlüğünü, hata analizi ve diğer modellerle karşılaştırma analizi için açıklayıcı bir örnekle doğrulamışlardır

Yu vd. (2010) çalışmalarında lojistik model ve malzeme akış analizini kullanarak eski kişisel bilgisayarların global üretimini öngörerek gelişmekte olan bölgelerde üretilen eski kişisel bilgisayarların hacminin 2016-2018 yılları arasında ve 2030 yılına kadar nasıl bir artış göstereceğini tahmin etmeyi amaçlamışlardır.

Bernon vd. (2011) perakendede tersine lojistik operasyonlarını yönetmek için hem uygulayıcılara hem de akademisyenlere, kilit yönetim konularını daha iyi anlamak için yardımcı olmak üzere tasarlanmış kavramsal bir çerçeve sunmayı amaçlamışlardır. Çalışmayı İngiltere perakende sektörü bağlamında gerçekleştirmişlerdir. Çerçevenin kabulünün, geri gönderilen ürünlerin hacminin azaltılmasında, tersine lojistik operasyonel maliyetlerinin düşürülmesinde ve ürün varlıklarının geri kazanım değerlerinin artırılmasında uygulayıcılara yardımcı olacağını ileri sürmüşlerdir.

Lambert vd. (2011) önerdikleri çerçevede tersine lojistik sisteminin üç hiyerarşik seviyeye (stratejik, taktiksel ve operasyonel) ayırmışlardır. Önerdikleri kavramsal modelle deneme yaparak, üç seviye de gelişimi boyunca farklı endüstriyel sektörlerde üç gerçek dünya vaka incelemesi ile test edilmiştir.

Rathore vd. (2011) Hindistan'da kullanıcılar bağlamında yeniden üretimin resmi bir etkinlik olarak kurulma fırsatını araştırmış ve yeniden üretilen ürünlerin Hint tüketicileri tarafından kabul edilip edilemeyeceği ve Hindistan piyasasına nasıl gireceği ile ilgili temel soruları yanıtlamışlardır.

Şengül (2011) çalışmasında tersine lojistik kavramını, kapsamını, önemini ve bazı önemli yasal düzenlemeleri tanımlanmış ve tersine lojistik ağı tasarımını ele alınmıştır.

Clottey vd. (2012) çalışmalarında, aynı zamanda üreticiye de hizmet eden bir üretici düşünmüş ve kullanılan ürünlerin geri dönüş dağılımını belirlemek için genel bir tahmin yaklaşımı geliştirmiş ve aynı zamanda üretim planlaması ve kontrolünü mümkün kılacak bir envanter modeliyle bütünleştirmişlerdir.

Gilanlı, Altuğ ve Oğuzhan (2012) çalışmalarında, Türkiye'de henüz çok yeni olan tersine lojistik kavramı üzerinde durmuş, Trakya Bölgesi'nde faaliyet gösteren bazı işletmelerin tersine lojistik uygulayıp uygulamadıklarını, uygulayanların uygulama nedenlerini ve uygulama aşamasında yaşadıkları sorunları incelemişlerdir.

Govindan vd. (2012) lastik endüstrisindeki bir şirketin, n olası tedarikçilerinden bir ortak olarak bir üçüncü taraf ters lojistik sağlayıcısını nasıl seçebileceğini gösteren bir vaka çalışması ortaya koymuşlardır. Kavramsal modeli geliştirdikten sonra, çalışmayla ilişkili nitelikleri ve alt özellikleri literatür taraması ve şirketten uzmanların girişi yardımı ile tanımlamışlardır.

Karaçay (2012), makalesinde tersine lojistik sitemi, kavramlar ve sitemin işleyişini ele alınmış; eskiden beri yapılan depozito ve geri dönüşüm uygulamalarının, tersine lojistikte bilinçli bir şekilde planlı ve tüm süreçlerde bu "tersine akışı" destekleyecek şekilde düzenli olması ile ortaya çıkan verimlilik, maliyette azalma, çevreci bir etikete sahip olma gibi sonuçlarını ortaya koymuştur.

Potdar ve Rogers (2012) çalışmalarında aşırı nokta yaklaşımı ve merkezi eğilim yaklaşımı olmak üzere iki yaklaşımın bir araya getirilmesiyle neden kod temelli öngörme yöntemini kullanarak ürün geri dönüşlerini tahmin etmeyi amaçlamışlardır.

Rogers vd. (2012) tersine lojistik süreçlerini iyileştirmek, etkinliği ve verimliliği maksimize etmek ve gerçek dünyadaki tersine lojistik problemlerini çözmeye yardımcı olmak için modelleme tekniklerinin nasıl kullanılabileceğini açıklamış; ürün satan firmalara hitap edebilecek özel tersine lojistik süreçlerine odaklanarak bir modelleme tekniği geliştirilmiştir.

Shih vd. (2012) çalışmalarında, geri dönüşüm endüstrilerine bir teşvik olarak geri dönüşüm ve onarım ücretlerini ayarlamak için Analitik Ağ Süreci'ni uygulanarak Tayvan'daki yazıcıların satış hacmini tahmin etmeye çalışmıştır. Ayrıca tahmin uygulamalarında kullanımlarını basitleştirmek için, Analitik Hiyerarşi Süreci ve Analitik Ağ Süreci'nin karakteristik güçlü yönlerini tartışmıştır.

Uslu ve Akçadağ (2012) ilaç sektöründeki lojistik sürecin uygulamada incelenmesi ve tersine lojistik ve iyi dağıtım uygulamalarının lojistik sürecine etkisini belirlemeyi amaçlamış. ilaç sektöründeki firmaların faaliyetleri sırasında dağıtım ve tersine lojistik faaliyetlerine verdikleri değeri vurgulamıştır.

Ayvaz vd. (2013) belirsizlikler altında tersine lojistik ağ tasarımı ile ilgili literatür hakkında detaylı bir inceleme yapılmış, literatür taraması neticesinde belirsizlikler altında stokastik tersine lojistik ağ tasarım konusu ile ilgili boşluklar ortaya konulmaya çalışılmıştır.

Benedito ve Corominas (2013) getirilerin satılan ürünlerin faydalı ömürlerine ve ömrünü tamamlamış ürünün geri alınma ihtimaline bağlı olduğu satışa bağlı dönüş modellerini anlatmış, en uygun üretim politikasını elde etmek için bir Markov karar problemi oluşturmuşlardır. Tanımladıkları modelin kullanımını göstermek için sayısal bir örnek verilmiş, optimal politikanın kolayca elde edildiği yerde, yaklaşık bir Markov karar modeli tanımlamışlardır.

Hall vd. (2013) çalışmalarında savunma sanayiinde çalışan 84 tersine lojistik uzmanına niteliksel veri toplamak için açık uçlu sorular sormuşlardır. Tersine lojistik süreçleri için amaçları, zorlukları ve metrikleri çıkarmak ve kategorize etmek için bir içerik analizi yöntemi kullanmışlardır. Tersine lojistik ölçümlerini hedeflerle uyumlu hale getirerek ve tersine lojistik uygulayıcılarının karşılaştığı zorlukları çözmeyi amaçlamışlardır.

Kara vd. (2013) çalışmalarında bir tersine lojistik ağ yapılanması içerisinde yer alan özel toplama merkezlerinin nerelerde olması gerektiğini matematiksel bir problem olarak ele alarak yer tespiti yapmş, tersine lojistik ağını kurabilmek için gerekli olan ön koşullar arasında yer alan özel toplama merkezlerinin Türkiye'nin coğrafik koşulları ve karayolları dağılımı göz önünde bulundurularak mesafe (maliyet) minimizasyonu amaç fonksiyonu ile karma tam sayılı doğrusal programlama modelini kurmuştur. Model Microsoft Excel Solver programında çalıştırılarak maliyet minimize edilmiş ve açılacak özel toplama merkezlerinin nerelerde açılması gerektiği incelenmiştir.

Krapp vd. (2013a) kapalı döngülü tedarik zincirlerinde ürün iadelerini öngörmek için genel bir tahmin yaklaşımı sağlamayı amaçlamış, Bayes tahmin tekniklerine dayanan bir yaklaşım sunmuşlardır. Literatürdeki yaklaşımlardan daha az kısıtlama ile ürün getirilerini tahmin etmeye izin veren bu yaklaşımın, sayısal bir örnek ile bir Poisson dağılımından alınan geri dönüş sürelerini kullanarak uygulandığını göstermiştir.

Krapp vd. (2013b) ürün iadeleri için genel bir tahmin çerçevesi geliştirmiş, literatürden daha iyi bir sonuç elde etmek için uyarlanabilir bir Bayesci yaklaşım ve Kalman filtresi kavramlarının kombinasyonunu önermişlerdir. Buna ek olarak, tahmin doğruluğu ile eklenen ekonomik katma değer arasında bir bağlantı oluşturmuşlardır.

Organ vd. (2013) Denizli'de ömrünü tamamlamış lastiklerin geri kazanımı için tersine lojistik ağ tasarımı planlamış ve karma tamsayılı doğrusal programlama kullanılarak ömrünü tamamlamış lastik geri kazanımı için tersine lojistik ağ modelini tasarlayıp giderler ile gelir arasındaki farkı en küçükleyecek ürün akışını sağlamak için problemi modellemiştir. Her senaryo için toplama bölgelerinden toplanacak ömrünü tamamlamış atık lastik miktarı, taşıma maliyeti, geçici depo açma maliyeti ve elleçleme maliyetleri belirlenmiş, 6 farklı senaryo için oluşturulan model LINGO optimizasyon programıyla çözülmüş, her senaryo için en uygun depo ve geri kazanım tesisi, kapasite ve konumu belirlenmiştir.

Agrawal vd. (2014) miktar ve zaman açısından geri dönüşüm için şirkete ürün getirilerinin tahmini için bir model geliştirmeyi amaçlamış, ürün geri dönüşleri öngörme modelinin geliştirilmesi için Grafik Değerlendirme ve İnceleme Tekniği uygulamışlardır. Bu modeli doğrulamak için bir Hint mobil imalat şirketi örneğini tartışıp olasılıklar ve ürün ömrü döngüsü üzerine veri toplamak için şirket tarafından yapılan anket ve önceki araştırmanın bulgularını kullanmışlardır. Bu modeli, müşteriden satılan ürünlerin olası tüm akışlarını yeniden kullanıma, depolamaya veya geri dönüşümden veya düzenli depolama alanlarına kadar düşünerek geliştirmişlerdir. Böylece ilk kez bu tür gerçek hayat akışı göz önüne alınmış ve ürünlerin getirilerinin tahmini için Grafik Değerlendirme ve İnceleme Tekniği uygulanmıştır.

Kumar vd. (2014a) geri dönüş ürünlerinin belirsizliklerinin önemli boşluğuyla ilgilenmek için kendi açık döngü tedarik zincirine sahip olan iade ürünlerinin tahmin edilmesini amaçlamışlardır. Kapalı çevrim tedarik zinciri tasarımı ve planlama problemiyle baş etmek için entegre iki fazlı metodoloji geliştirmiş; ilk aşamada, geri dönüş ürün miktarlarının belirsizliklerini gidermek ve öngörülen getiri oranlarını belirlemek için Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi sunmuş, ikinci aşamada ise önerilen çok katmanlı, çok ürünlü, çok dönemli, kapalı döngü tedarik zinciri ağını optimize etmişlerdir. Önerdikleri yöntemin performansını sayısal bir örnek kullanarak 25 dönem içinde değerlendirmişlerdir.

Kumar vd. (2014b) çalışmalarıyla tedarik zinciri yöneticilerinin, kurumsal sosyal sorumluluk temelinde bir tedarikçinin seçimini vurgulayan ana meseleyi belirlemelerine yardımcı olmayı amaçlamış, yorumlayıcı yapısal modelleme yaklaşımı kullanılarak doğrulanmış Hindistan'ın güney kesiminde yer alan havai fişek sanayiine hitap eden bir model önermişlerdir.

Narayana vd. (2014) Güney Hindistan'ın Kerala kentinde bulunan bir ilaç tedarik zincirine ait paydaşlardan elde edilen veriler ile bir ilaç tedarik zincirinde yer alan çok sayıda paydaşın farklı bakış açılarını ortaya koyan bir katılımcı süreci göstermiş, bir ilaç tedarik zincirinde tersine lojistik süreçlerini etkileyen faktörlerin karmaşık etkileşiminin sistematik bir analizini sunmuşlardır. Hint ilaç endüstrisinde tersine lojistik ile ilgili karmaşıklıkları analiz etmek için metodolojinin niteliksel aşamaları ile sınırlı bir sistem düşünce ve modelleme yöntemlerine dayanan bütünsel bir yaklaşım oluşturmuş, bu sistem modelini geliştirmek için katılımcı bir grup model oluşturma süreci kullanmışlardır. Modelde; ilaçların piyasaya akışını hafifleterek geri dönüşlerden kaçınma, kalite ve performans yönetimi için altyapı geliştirme, tedarik zincirinde yer alan ana paydaşlar arasında dengeli bir risk paylaşımından oluşan üç stratejik müdahale yer almıştır. Bu doğrultuda tersine lojistik ağı tasarımı ile geri dönüş yönetiminde kilit faaliyetler arasında kuvvetli bir bağlantı olduğunu ortaya koymuşlardır.

Temur vd. (2014) tersine lojistik ağındaki geri dönüş sürecinden kaynaklanan belirsizlikleri giderebilmek için geri dönüş miktarının doğru olarak tahminini

tasarlamak için bulanık bir uzman sistem geliştirmiş, öncelikle ürünlerin geri dönüşünü etkileyen en önemli faktörler tanımlanmış, daha sonra diğerleriyle eşdoğrusallık gösteren faktörler, boyut fazlalık analizini kullanarak elimine etmişlerdir. Seçilen faktörlerin verilerini bulanık uzman sistemle eğitip alternatif şehirlerin geri dönüş miktarları tahmin etmeye çalışmışlardır. Bu çalışmaları bulanık uzman sistemi kullanarak alternatif tahmin yapmayı amaçlayan ilk çalışmadır. Ayrıca, sistemin tahminlemede kullandığı kapsamlı bir faktör listesi tanımlamış ve geri dönüş sürecinde önemli bir etkisi olan faktörleri ortaya çıkarmak, geri kalanını ortadan kaldırmak için bir boyutlu fazlalık analizi geliştirmişlerdir.

Subramanian vd. (2014) çalışmalardında Çin imalat sektöründe bir ürünün ömrünü bitirdikten sonraki tersine lojistik faktörlerini anlamayı ve öncelik vermeyi amaçlamışlardır. İmalat sanayinde beş farklı sanayide birden fazla vaka çalışması yapmış ve Çin imalat sektöründe başarılı tersine lojistik uygulaması için yönetim faktörlerine öncelik vermek için analitik hiyerarşi süreci (AHP) uygulamışlardır.

Wang vd. (2014) lityum-iyon pil ile ilgili yaptıkları çalışmada geri dönüşüm tesislerinin verimliliğini analiz etmek için bir optimizasyon modeli geliştirmiş ve uygulamışlardır. Lityum-iyon pil teknolojilerinin tahminleri, geri kazanılması, beklenen malzemelerin piyasa fiyatları ve üç ortak pil türü için malzeme kompozisyonunu dikkate almış, buna ek olarak, bu kullanımdan kaldırılan lityum iyon pilleri için yaşam ömrü yönetimi ve göreceli politika oluşturmayı teşvik etmeye yardımcı olmayı amaçlayan ABD'deki bazı şirketlerden elde edilen bilgilerle bir vaka çalışması oluşturmuşlardır.

Vlachos (2014) firma performansını etkileyen tersine lojistik faktörlerini incelemeyi amaçlamış, tersine lojistik faktörlerini firma stratejisi, firmanın kaynak tabanlı görünümü, ilişkisel teori ve kurumsal teori olmak üzere üç araştırma akışı altında incelemiştir. Firma performansını karlılık, maliyet, yenilikçilik, algılanan rekabet avantajı ve algılanan müşteri memnuniyetini dikkate alarak ölçmüştür.

Govindan vd. (2015) Ocak 2007 ile Mart 2013 arasında yayınlanan bilimsel dergilerdeki tersine lojistik ve kapalı çevrim tedarik zinciri ile ilgili toplam 382 makale

seçmiş ve gözden geçirmişlerdir. Ayrıca bu makaleleri analiz etmiş ve geçmiş araştırmalarda yararlı bir temel oluşturacak şekilde sınıflandırmışlardır.

Agrawal vd. (2015) akademisyenler, araştırmacılar ve uygulayıcılar tarafından tersine lojistiğin daha iyi anlaşılması ve gelecek araştırmalar için rehberlik etmesi amacıyla literatürü gözden geçirmiş toplam 242 yayınlanmış makale seçmiş, kategorize etmiş, analiz etmiş ve literatürdeki boşluklar gelecekteki araştırma fırsatları için önerilmek üzere tanımlamışlardır.

Bazan vd. (2016) ilişkili süreçlerin ana özelliklerinin sistematik olarak analiz edilmesi için, ekonomik sipariş / üretim miktarı ve müşterek ekonomik lot boyutu ayarlarına dayanan tersine lojistik envanter sistemlerinin modellenmesi ile ilgili literatürü gözden geçirmişlerdir. Literatürü incelemiş ve karşılaşılan belirli sorunlara ve modelleme varsayımlarına göre sınıflandırılmış ve çevresel etkileri olan tersine lojistik envanter modelleri için açıklayıcı bir örnek sunmuşlardır.

Cannella vd. (2016) çalışmalarında kapalı döngülü tedarik zincirlerinde stok ve dinamik akışları incelemişler, bazı tersine lojistik faktörlerinin (geri dönüşümü, geri dönüştürülmüş ürünlerin geri dönüş oranı, ters sipariş politikası ve tedarik zinciri katmanlarının yeniden üretilmesi) arasındaki faktörleri analiz etmişlerdir. İlgili çalışmaların sistematik bir literatür taraması yapılmış, matematik yaklaşımı ve deney tasarımı benimseyerek operasyonel ve kapalı döngülü bir tedarik zincirinin analizini gerçekleştirmişlerdir.

Gonçalves ve Silva (2016) Portekizli şirketlerin bakış açısını kavram, iade ve çevre açısından incelemek ve karakterize etmek için farklı boyut ve endüstriyel sektörlerden 10 Portekizli şirkete yarı yapılandırılmış görüşmeler uygulamışlardır. Ürün iadesi stratejileri yeniden kullanımına, hurda veya geri dönüşüm endüstrilerine satışa; çevre stratejileri, yüklerin ambalajlanmasında yeniden kullanılmalarına, büyük şirketlerde geri dönüşüme, planlama güzergâhları ve geri dönüştürülmüş materyallerin kullanımı ve tekrar kullanılabilir ambalajlamasına yönlendirilmesi olarak ortaya konulmuştur.

Han ve Cueto (2016) makalelerinde firmaların geri dönüşlerini yönetmek, tersine lojistik programlarını resmileştirmelerine yardımcı olmak, tersine lojistik süreçlerini

daha iyi kontrol altına alacak şekilde yazılı kurallar ve standart prosedürlerle biçimlendirmek için talimatlar sunan bir biçimlendirme programı uygulamasına yardımcı olan orijinal bir teorik çerçeve önermişlerdir. Önerdikleri çerçevede, geri dönüş ürünlerin toplanmasından sıralama ve işleme süreçlerine kadar, tersine lojistik sürecindeki tüm aşamaları kapsarken, kurulan teorik model mevcut çalışmalara ve literatür kaynaklarına göre önerilmiştir.

Jalil vd. (2016) tersine lojistik söyleminde evsel atık geri dönüşüm sistemleri ile evde geri dönüşüm davranışları arasında birbiriyle ilişkili bir etkileşim olduğunu ileri sürmüşlerdir.

Kumar ve Gupta (2016) tersine lojistik için bir genel bakış sunmayı ve bir endüstri sektöründe ekonomik olarak verimli ürün ömrü geri dönüşümü ve geri dönüşüm uygulamasının nasıl yönetileceği konusunda bilgi sağlamayı amaçlamıştır.

Morgan vd. (2016) işletmelerin tersine lojistik yetkinliği üzerinde işbirliği ve bilgi teknolojisinin etkisini araştırmayı amaçlamış, bunun için tedarik zinciri ilişkileri ile ilgili çalışanlara bir anket uygulayıp katılımcılardan gelen 267 deneysel kanıtı yapısal eşitlik modellemesi ile analiz etmişlerdir. Bu araştırmada tersine lojistik yetkinliğinin ilerlemesinde işbirliğinin etkisi üzerinde ılımlı bir etki yaratarak bilgi teknolojisini tanıtmışlardır. Firmanın kaynak temelli teorisi uygulaması aracılığıyla tersine lojistik yetkinliğinin geliştirilmesi için teorik sonuçları içeren bu araştırma, ağırlıklı olarak ABD firmalarının seçilen araştırma soruları ve örneklemiyle sınırlı kalmıştır.

Singh vd. (2016) tedarik zincirinde kullanılan otomobil alternatörlerinin toplanması ve geri dönüşümü için tersine lojistikte yakıt tüketimini en düşük seviyeye indirmek için optimize edilmiş yeni bir model geliştirmiş, hem ekonomik hem de çevresel avantajı aynı anda verecek bir modelin eleştirel olarak incelenmesi ve geliştirilmesini amaçlamıştır. Çalışmalarında tedarik zinciri ile ilgili problemlerin çözümü için Genetik Algoritma teknikleri kullanılmış, çevresel tüketimin azaltılması için ise Yeşil Lojistik modeli kullanılmış, araştırma Yeşil Lojistik ve Genetik Algoritma hakkında vaka analizi tabanlı bir yaklaşımla özetlenmiştir.

Stephens vd. (2016) "Sürdürülebilir Tedarik Zinciri" başlıklı 105 akademik dergi makalesini inceleyip sayısal içerik analizinin bulgularını sunarken 'sürdürülebilirlik' ve ‘sürdürülebilir tedarik zinciri’ kavramlarının daha iyi anlaşılmasını amaçlamıştır.

Centobelli vd. (2017) iki akademik veri tabanı kullanılarak ve 1960-2014 yıllarını kapsayacak şekilde literatürdeki gelişmeleri analiz etmiş, uygun araştırma sorularını seçmek için ise lojistik hizmet sağlayıcılarının hizmet sektöründeki çevresel sürdürülebilirlik konusunda sistematik bir gözden geçirme sunmuşlardır. Makalede, yeşil girişimlerin sınıflandırılması, yeşil girişimlerin lojistik hizmet sağlayıcıların performansı üzerindeki etkisi, sürdürülebilirlik performansının değerlendirilmesi, çevresel sürdürülebilirlik girişimlerinin benimsenmesini etkileyen faktörler, sürdürülebilir tedarik zinciri ve yeşil girişimlere destek veren bilgi ve iletişim teknolojileri müşteri perspektifine ilişkin altı temel literatür boşluğu vurgulamış, bu boşluklardan başlayarak konuyla ilgili muhtemel ortaya çıkan soruşturma alanlarını temsil eden sekiz araştırma sorusu tespit etmişlerdir.

Esposito vd. (2017) makalelerinde posta ağlarında yürütülen ön işleme ve toplama faaliyetlerinin yürütülmesi ve maliyetleri ile ekonomiye etkisini incelemişlerdir.

Govindan ve Soleimani (2017) geçmiş çalışmaların sistematik bir görünümünü ve yapılacak çalışmalar için uygun bir vizyonu sağlamak amacıyla Journal of Cleaner Production'da 31 Aralık 2014 tarihine kadar yayınlanan toplam 83 adet makaleyi incelemiş, kategorilere ayırmış ve değerlendirmişlerdir.

1.7.TERSİNE LOJİSTİK AKIŞ ÜRÜNLERİ

Tersine lojistik; satılmayıp raf ömrünü tamamladığı veya stokta gereksiz yer kapladığı için iade edilen ürünler, kullanılmış ama yeniden kullanılabilecek ürünler, onarılabilecek düzeyde arızası olan ürünler, ürün yaşam ömrünü tamamlamış ama değer kazanımı olabilecek ürünler, geri dönüşümü olan ürünlerle ve çevreyi kirleten zehirli veya tehlikeli atıklar ile ilgilenmektedir. Bu ürünleri şu şekilde gruplamak mümkündür (De Brito ve Dekker, 2002: 12-13):

- Gıda maddeleri: Bu ürünlerin kullanım ömrü kısa olduğu için tüketiciye ulaşmadan son kullanma tarihi gelebilir. Bu ürünler bozulma durumlarına göre

ayrılıp iyi durumda olanlar hayvanlar için gıda maddesi olarak kullanılmaktadır, zehirleyecek ya da zarar verecek derecede bozulmuş olanlar ise atık olduğu için bertaraf edilmektedir.

- Kamu malları: Binalar, altyapı kanalları, köprüler, yollar gibi kamu malları çok uzun yıllar kullanılır ve bu süre boyunca yenileme, parça değişikliği veya onarım ile yaşam ömürleri uzatılmaktadır. Bu kamu malları ürün yaşam ömrünü tamamladıklarında ise yıkılmakta, geri dönüşümü olabilecek molozlar ayrılmakta, kalan atıklar ise atık sahalarında depolanmaktadır.
- Tüketici eşyaları: Beyaz eşyalar, mobilyalar, küçük ev aletleri gibi tüketici eşyaları teknolojinin hızla ilerlemesi, modanın sürekli değişmesi ve ürünlerin kısa ömürlü olması sebebi ile büyük miktarda tersine akışa sahip olan ürünlerdir. Çok fazla üretim olduğu için geri dönüşümüne önem verilmesi gereken bir ürün grubudur. Müşteriler yeni, daha teknolojik, daha modern ve öncekinden farklı özelliklerde ürünler tercih ettikleri için bu ürünlerde yeniden üretim işlemleri pek tercih edilmez, tamir işlemleri ise genellikle garanti kapsamında olan ürünler için tercih edilmektedir. Müşterilerin bu ürünleri kullanılabilir durumdayken yenileme eğilimleri de ikinci el piyasasının hacminin neden bu kadar geniş olduğunu açıklamaktadır.
- Endüstriyel ve profesyonel ekipmanlar: Bu ürünler tüketici ürünlerinden daha pahalı ve kullanılabilir parçalara sahiptir. Parçalar ve alt montaj parçaları çekme ve yerine yenisini koyma ya da parça tamiri gibi işlemlerde ortaya çıkmaktadır. Yüksek teknoloji ürünlerinin parçaları ve alt montaj parçaları tekrar tekrar kullanılabilir. Yapılan araştırmalarda da geri gönderilen bu parça ya da ürünlerin %35'ine yakın miktarının bozuk olmama durumunda olduğu tespit edilmiştir. Özellikle leasing ürünlerinde, uçak motorlarında, fotokopi makinelerinde ve lastiklerde yeniden üretimle geri kazanım çok yaygın olarak kullanılmaktadır.
- Nakliye araçları: Karayolu, denizyolu ve havayolu taşımacılığında kullanılan nakliye araçlarının üretiminin zorluğu, maliyetli oluşu ve üretimlerinde değerli metallerin kullanılması sebepleri ile yeniden üretimi, yedek parça kazanımı, değer kazanımı ve geri dönüşümüne önem verilmektedir.

- Maden cevherleri, petrol ve kimyasallar: Maden cevherleri kıymetli metalleri, doğal taşları ve mineralleri kapsamaktadır. Kıymetli metaller eritilip yeniden üretilebilirler. Ayrıca maden cevherlerinin ocaklardan çıkarılması esnasında istenilen cevherle birlikte az miktarda da olsa artık olarak başka cevherler ve mineraller de birlikte çıkarılmaktadır. Bu artıklar bazı işlemlerden geçirilerek içerisindeki cevherler çıkarılabilir ama bu işlem öncesi çıkarılacak cevherin değeri işlem maliyeti ile kıyaslanmaktadır. Eğer işlem yapmaya değecek değerde görülürse bu cevher artıktan çıkarılır, değersiz görülürse atık barajlarında depolanmaktadır. Eğer daha sonra bu cevher kıymetlenirse atık barajından bu artık tekrar işlem görmek için çıkarılabilir. Benzin buharının geri kazanımı dışında petrol ürünlerin yeniden üretimi zordur, genellikle kullanımlarında tamamen tüketilmektedir. Kimyasallar çevreye zarar veren zehirli atıklar olduğu için ger kazanımı zorunludur.
- Askeri teçhizatlar: Bu ürünlerin üretiminde olduğu gibi yeniden üretimi, parça kazanımı ve değer kazanımı işlemleri de devlet kontrolü altında yapılmalıdır. Bu ürünler için geri dönüşüm faaliyetleri yaygın olmamakla beraber sınırlı düzeydedir.
- Tıbbi ürünler: İlaçlar kullanım ömürleri bittiğinde veya geri çağırma işlemlerinden sonra uygun bir şekilde bertaraf edilmektedir. Medikal ürünlerin kullanımı ise ürüne ve kullanıldığı alana göre değişmektedir. Tekerlekli sandalye ve sedye gibi ürünler iş gördükleri sürece kullanılırken, operasyonlarda kullanılan araç gereçler sterilizasyon işleminden sonra yeniden kullanılabilir. Bazı ürünler ise sağlık sebepleri ve sterilizasyon işlemleri için uygun olmamalarından dolayı yeniden kullanılmayıp atılmaktadır. Tehlikeli atık sınıfına giren tıbbi atıklar hastalık yayabileceği ya da zehirli madde içerebileceği için özel yöntemlerle bertaraf edilmektedir.
- Tekstil ürünleri: Kumaş üretiminde meydana gelen kusurlu ürünler ve üretim artıkları genellikle pamuğa çevrilirken iplik artıklarından genellik yine iplik üretimi yapılmaktadır. Kullanılmış giysiler ve ev tekstil ürünlerinin eskimemiş ve iyi kullanılmış olmalarına göre ikinci el piyasasında satılması ise günümüzde uygulanmaya başlayan bir faaliyettir. Ayrıca yardım ve geri

dönüşüm amaçlı eski kıyafet toplama kampanyaları da birçok bölgede yaygınlaşmaktadır. Kullanılamayacak durumda olan giysiler ise kumaşının cinsine göre pamuk, elyaf ya da iplik üretiminde kullanılmaktadır.

- Paketleme ve dağıtım malzemeleri: Kutu, koli, sandık, palet, konteyner gibi paketleme ve dağıtım malzemeleri herhangi bir geri kazanım işlemi görmeden tekrar tekrar kullanılabilir. Bu ürünler ileri lojistik akışında işlevlerini gördükleri yerlerden tersine lojistik akışıyla toplanıp yeniden ileri lojistik akışına girerler. Bu ürünlerin tekrar tekrar kullanımı için geri dönüşü firmalara önemli derecede ekonomik katkı sağlamaktadır.
- Diğer materyaller: Kağıt, cam, plastik, metal ve hurda ürünler yeniden kullanım ve geri dönüşüm işlemleri ile geri kazanılan, ekonomik açıdan önemli yere sahip ürünlerdir. Geri kazanımları yerel yönetimlerin toplama işlemini yapmasıyla gerçekleşmektedir.

Bu ürünler farklı özelliklere sahip olduklarından bu ürünlere uygulanan tersine lojistik faaliyetleri de birbirinden farklı olabilir.

1.8.TERSİNE LOJİSTİKTE ÜRÜN DÖNÜŞLERİ

Kullanımı bitmiş ve atılacak ürünlerin, kullanılmış ama kullanılabilir ürünlerin, kullanılmadan iade edilmiş hasarlı ürünlerin, kullanılmadan iade edilmiş hasarsız ürünlerin, satışı yapılmadan hasar görmüş ürünlerin, satışı yapılmadan iade edilmiş veya geri çağırılmış hasarsız ürünlerin tersine lojistik ağına girip geri dönmelerinin birçok nedeni vardır. Geri gönderilen ürünler genellikle kırık, bozuk, ambalajı hasarlı, işlevini yitirmiş, kalitesiz, modası geçmiş, müşteri beklentisini tam karşılamayan, artık ihtiyaç duyulmayan, hatalı teslimat, piyasadaki fiyat farklılığı, geri çağırma veya satılamayıp stokta yer tutan ürünlerdir. Ürünlerin tedarik zincirinde iade edildikleri yere göre geri dönüş sebepleri üç gruba ayrılmaktadır. Bu sebepler;

- üretim dönüşleri,
- dağıtım dönüşleri,
- müşteri dönüşleridir.

1. Üretim Dönüşleri: Ürettim esnasında oluşan kalitesiz, hatalı veya artık ürünlerin, yarı mamullerin, hammaddelerin ve malzemelerin geri kazanılmasını sağlamak

için üretim aşamasına geri alınması üretim dönüşleridir. Yeniden üretim hattına girip yeniden işlem gören bu ürünlerle artık hammadde ve malzemeler atık olma yerine üretim girmiş, bu şekilde atıkların azaltılmasına, çevre kirliliğinin azaltılmasına, maliyetlerin azaltılmasına ve ekonomik katkı sağlanmasına sebep olmuştur. Üretim geri dönüşlerinin temel sebepleri şu şekilde özetlenebilir:

- İhtiyaç duyulmayan ürün
  - Hammadde veya üretim fazlalığı
  - Üretim artıkları
- Hatalı ürün
  - Kalite kontrolde başarısız olmuş ürünler

2. Dağıtım dönüşleri: Ürünlerin dağıtım aşamasında ortaya çıkan tüm geri dönüşler dağıtım dönüşleridir. Geri dönen bu ürünlere; teslimatı yanlış yapılmış ürün, dağıtımda hasar görmüş ürün, kullanım süresi dolmuş ürün, satılmayıp stok fazlası olmuş ürün, mevsimsel satış dönemi bitmiş ürün, taşıyıcı araçlar örnek olarak verilebilir.

Perakendeciden ana firmaya ya da tedarikçiye doğru olan ticari dönüşlerde taraflar arasında başlangıçta yapılan sözleşme ile perakendecinin hasarlı, kullanım süresi dolmuş, sezonu geçmiş vb. ürünleri tedarikçisine geri iade etme hakkı vardır. Bu şekilde ürünlerin ticari geri dönüş miktarları fazladır. Ticari dönüşlerde genellikle kullanılmış ürünler değil kullanılmamış yeni ürünler söz konusudur.

Stok düzenleme; antrepo, depo ve mağazalardan birinden stok fazlalığı, mevsimsel düzenleme veya stokta yer açma sebepleri ile stok dağıtımı yapılması sonucu stokların yeniden düzenlenmesi işlemidir.

Fonksiyonel geri dönüşler, dağıtım aşamasında kullanılan, dağıtım sonrası tekrar faaliyet göstermek için geri dönen taşıyıcı, konteyner, palet, gibi araçların dönüşünü ifade etmektedir. Bu geri dönüşler kullanım ömrünü tamamlama, hasar veya tamirat gibi işlemleri değil de araçların yaptıkları iş gereği sıra ile ileri ve tersine akış yönünde faaliyet göstermelerini ifade etmektedir. Bu nedenle

geri döndüklerinde herhangi bir yenileyici, değer kazandırıcı işleme ihtiyaç görmeden taşıma işlemlerine yardımcı olmak için tekrar tekrar kullanılabilirler.

Ürün geri çağırmaları ise tüketicinin kullanımında olan ve satış için perakendecide olan ürünlerin üretici veya tedarikçi tarafından genellikle hatalı üretim, güvenlik ve sağlık nedeniyle geri çağırılmasıdır. Satış için perakendecide olan ürünlerin geri çağırılması ise dağıtım geri dönüşlerine girmektedir.

Dağıtım dönüşleri şu şekilde özetlenebilir:

- Ticari geri dönüşler
  - Yanlış teslimat
  - Hasarlı veya eksik teslimat
  - Kullanım süresi dolan ürünler
  - Sezonu bitmiş ürünler
  - Perakendecide satılmamış stok fazlası ürünler
- Stok düzenlemeleri
  - Stok fazlalığı
  - Yeni ürün için yer açma
  - Antreponun stoklarının düzenlenmesi
- Fonksiyonel Dönüşler
  - Taşıyıcılar
  - İstifleyiciler
  - Koruyucu paketler
  - Ambalajlar
- Ürün geri çağırmaları
  - Satış için perakendecide olan ürünlerin geri çağırılması

3. Müşteri Dönüşleri: Müşteriye ulaşan ürünün herhangi bir sebepten dolayı müşteri tarafından iade edilmesi ürünün müşteri tarafından dönüşünü ifade etmektedir. Müşteriden perakendeciye, ana firmaya ya da tedarikçiye doğru olan bu ticari dönüşler; para iadesini, garanti kapsamında ürün geri dönüşünü, tamir-

bakım hizmetleri için ürün geri dönüşünü, kullanılmış ürün dönüşünü, ömrünü tamamlamış ürünlerin dönüşünü kapsamaktadır.

Ürün geri dönüşleri için tüketici geri dönüşleri yüksek bir oran tutmaktadır. Tüm tüketici geri dönüşleri yaklaşık olarak tüm perakende geri dönüşlerinin %60'ına tekabül etmektedir (Çekerol, 2013: 15)

Para iadesi garantisi verilmiş ürünler için tüketicinin belirli bir süre içerisinde ürünü iade edip parasını geri alma veya yerine yeni bir ürün alma hakkı vardır.

Garanti ise tüketicilere hatalı, kalitesiz, söz verilen özelliklere sahip olmayan veya bozulan ürünlerini üreticiye veya tedarikçiye değiştirilmesi veya ücretsiz tamir edilmesi için geri gönderme hakkı sağlamaktadır. Garanti hizmetinin sağladığı bu yasal haklar tüketici haklarını korur ve müşteri memnuniyetini sağlamaktadır.

Servis hizmetlerinin üründe meydana gelen bozulmaların garanti kapsamına girmediği durumlarda müşteriye ücret karşılığı sunduğu tamir ve bakımının hizmetlerini kapsamaktadır. Servis hizmeti esnasında ürünün tamir, bakım, parça değişikliği gibi nedenlerle geri dönüşü söz konusudur.

Kullanılmış ürün dönüşleri; kiralama ürünleri, yeniden kullanılabilir ürünleri veya ikinci el olarak ürünün satışını kapsamaktadır.

Ömrünü tamamlamış ürünler ise yeniden kullanılamayacak şekilde tahrip olmuş, işlevini yitirmiş, değeri kalmamış ürünlerdir. Bu ürünler değer kazanımı için üretici firmalar veya geri dönüşüm faaliyetlerini yürüten firmalar tarafından toplanmaktadır.

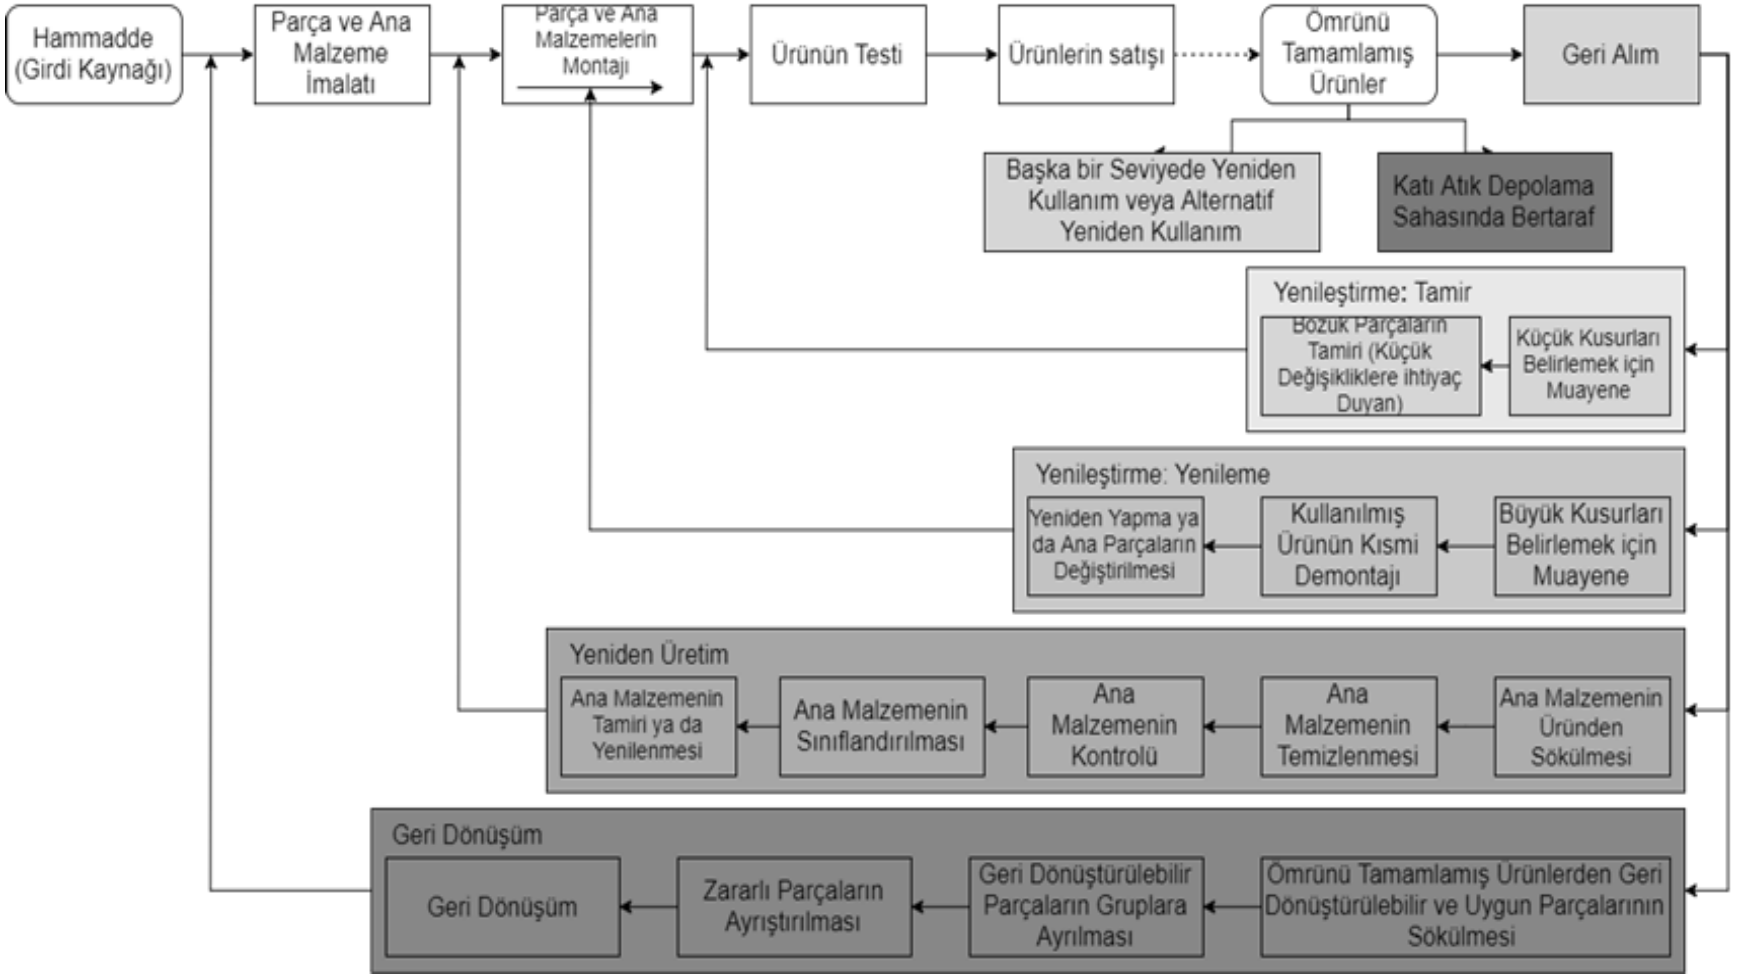
Müşterilere ulaşmış ve kullanımda olan ürünler de üretici veya tedarikçi tarafından üretim hatası, güvenlik veya sağlık konusunda risk taşıması sebepleri ile geri çağırılabilir.

Müşteri dönüşleri şu şekilde özetlenebilir:

- Garanti kapsamında dönüşler
  - Para iadesi garantisi
  - Bozulan ürünün garanti kapsamında tamiri veya değiştirilmesi
- Servis hizmetleri
  - Tamir
  - Bakım
  - Yedek parça
- Kullanılmış ürün dönüşleri
  - Kiralama
  - Yeniden kullanım
  - İkinci el satış
- Ömrünü tamamlamış ürün dönüşleri
  - Yenilenebilir ürün dönüşleri
  - Yedek parça olarak kullanılabilecek ürün dönüşleri
  - Hammadde ve malzeme değeri olan ürün dönüşleri
  - Zararlı veya zehirli madde taşıyan ürün dönüşleri

Şekil 1.11'de ömrünü tamamlamış ürünlerin üretim hattına geri dönüşü görülmektedir.

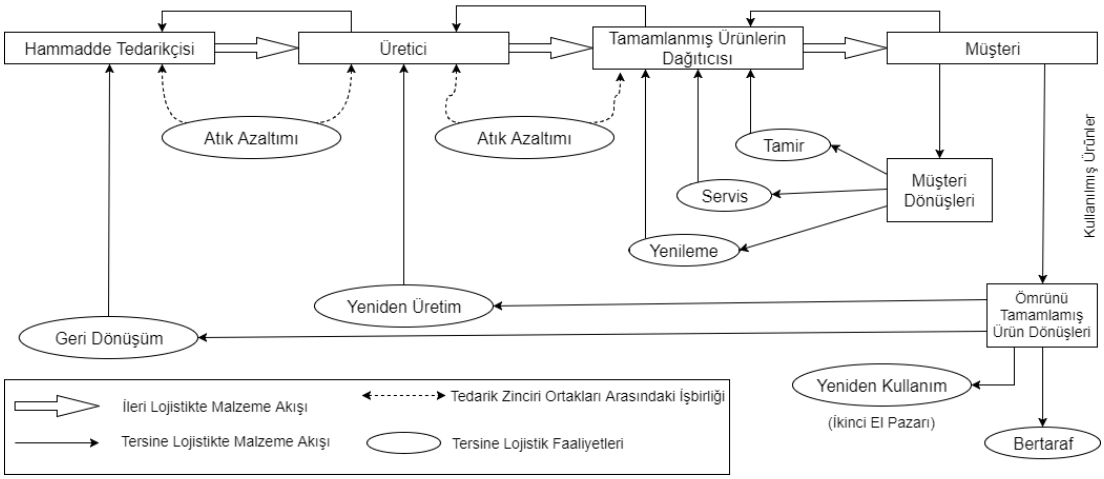
Firmaların tersine lojistik faaliyetlerinde bulunup yukarıda açıklanan bu ürün dönüşlerini kabul etme sebepleri sadece ürünlerin hatalı ya da hasarlı olması veya müşterinin beklentilerini karşılamaması gibi yasal zorunluluklardan ya da müşteri memnuniyetini sağlama çabalarından kaynaklanmamaktadır. Artık firmalar bu ürün geri dönüşlerinin tersine lojistik faaliyetleri sonucunda sağladıkları maliyet azaltımından doğan kar, çevresel sorumluluklarını yerine getirme, ürünlerin yeniden üretim hattına girip değer kazanması, müşteri ilişkilerini geliştirme gibi faydalarının ve rekabet avantajlarının farkına varmaktadırlar.



Şekil 1.11: Ömrü tükenmiş ürünün üretim hattına geri dönmesi (Gupta, 2013: 128).

1.9.TERSİNE LOJİSTİK FAALİYETLERİ

Tersine lojistik süreçleri birçok yazar tarafından farklı perspektiflerle açıklanmıştır. Kullanılmış veya iade edilen ürünler, satın alındıktan veya tüketiciden döndükten sonra toplanır ve farklı sınıflara ayrılmak üzere denetlenmekte ve ayrıştırılmaktadır. Bir sonraki adım ya değer kazanımı ya da atma kararına bağlı olarak ürünleri onarım, yeniden imalat, geri dönüşüm, yeniden kullanma veya imha etme amacıyla elden çıkarmaktır. Anahtar işlemler, ürün edinimi, toplanması, denetimi/sınıflandırılması ve yerleştirilmesi olarak aşağıdaki bölümde tanımlanmaktadır (Agrawal vd., 2015: 77). Tersine lojistik işlemi ayrıca demontaj, yeniden imalat, tedarik zinciri planlaması, koordinasyon, stok kontrolü ve satış sonrası hizmetleri içermektedir (Pokharel, 2009: 178). Bu işlemlerden herhangi birinin gerçekleştirilmediği durumlarda kullanılmış ürünler yakılarak ya da gömülerek uygun bir şekilde yok edilmektedir (Şengül, 2011: 38). Tersine lojistikteki temel faaliyetler ve akış Şekil 1.12'de gösterilmiştir.



Şekil 1.12: Tersine lojistikte temel faaliyetler ve akışlar (Lau ve Wang, 2009: 449).

Temel tersine lojistik faaliyetleri aşağıda açıklanmaktadır:

Toplama: Kullanılmış ürünlerin toplanması potansiyel olarak kapalı çevrim tedarik zincirinin toplam maliyetinin önemli bir bölümünü oluşturmaktadır. Çok sayıda düşük hacimli akışın taşınması, toplama işlemini pahalı bir operasyon haline getirme eğilimindedir. Şirketler, ulaşım maliyetlerini düşürmek için çeşitli yöntemlere başvurmaktadır. Her şeyden önce, dağıtımla benzer şekilde, en pahalı faaliyetlerin

bazıları kısmen müşterilere kaydırılabilir. Aktif olarak mal toplamak yerine, bir şirket, müşterilerin kullandığı ürünleri teslim edebileceği bazı atık toplama noktaları kurabilir. Kamuya açık cam, metal, plastik veya kağıt toplama kutuları ve perakende satış mağazalarında teslim edilen tüketici elektroniği örnek olarak verilebilir. Bu strateji nakliye oranını düşürürken, ek depolama alanı gerektirmektedir. Bu yaklaşım nispeten küçük, düşük değerli tüketici ürünleri ile sınırlı olabilir. Diğer bir yöntem ise, toplama ile diğer ulaşım akışlarını birleştirmektir. Özellikle, dağıtım ve toplama faaliyetlerinin birleştirilmesinde sinerji olabilir. 'İleri' ve 'ters' mal akışlarının bu birleşimi, ters kanalın daha az zaman baskısı içerebileceği gerçeği ile kolaylaştırılmıştır. Dolayısıyla akışlar daha sonra toplama işlemi eklenerek ileriye dönük olarak planlanabilir. Öte yandan, dağıtımı ve toplamayı verimli bir şekilde birleştirmek, her iki akışın aynı rotayı izlemesini gerektirir ve bu da her zaman uygun olmayabilir. Boş toner kartuşlarının ve yeniden kullanılabilir kameraların hızlı posta yoluyla taşınması, bazı ağ aşamalarını atladığından dolayı toplama faaliyeti için daha iyi bir seçenek olarak görülen örnekleri göstermektedir. Aynı şey dönüş kanalında hızın önemli olduğu durumlarda da geçerlidir (Fleischmann, 2001: 4).

Kumar ve Putnam 2008'de yaptıkları bir çalışmada, üreticilerin doğrudan müşterilerden, üreticilerin perakendeciler aracılığıyla veya üreticilerin üçüncü parti lojistik aracılığıyla toplama yaptığı üç toplama yönteminden bahsetmiştir. Webster ve Mitra 2007'de yaptıkları çalışmada, ürün iadelerinde "kontrol derecesi" ile ayırt edilen toplama için iki alternatif geri alma yöntemi üzerinde yoğunlaşmıştır. Birinci yöntem, üreticinin geri dönüşler üzerinde kontrol sahibi olmadığı toplu geri alma işlemidir; ikinci yöntem, üreticiye tam kontrol imkanı sağlayan bireysel tahsilattır. Toplama yönteminin seçimi, maliyet yapısı ve toplama miktarı kararlarına bağlıdır. Toplama merkezlerinin ve ilgili parametrelerin kararı, operasyonel etkinliği için tersine lojistik tasarımında önemli ölçüde yer almaktadır (Agrawal vd., 2015: 78).

Genel olarak, toplama, kullanılmış ürünlerin geri kazanım için tüketicilerden toplanması veya satın alınması, nakliyesi ve depolamanması faaliyetlerini içermektedir. Toplama faaliyetinin bir dereceye kadar yasalarla dayatılabileceği

unutulmamalıdır (örneğin, Almanya'daki ambalajlama materyali, Hollanda'daki beyaz ve kahverengi eşyalar) (Liu ve Fang, 2007: 1181).

Taşıma (Nakliye): Taşıma, kapalı çevrim zincirinin genel çevresel performansında önemli bir faktördür. Bu nedenle, birçok ürünün iyileştirme girişiminde, en azından pazarlama için önemli bir rol oynayan 'yeşil' argümanlarla çatışmaların önlenmesi, aşırı taşıma faaliyetini önlemenin başka bir nedeni olabilir (Fleischmann, 2001: 3).

Taşıma, lojistiğin operasyonel alanı olup, ürün, hammadde, yarımamul veya hizmetlerin fiziksel olarak hareketini, yani bir noktadan başka bir noktaya taşınmasını kapsamaktadır. Taşımanın görevi; hammaddeleri tedarik noktasından üretim noktasına, ürünleri ise üretim noktasından tüketim noktalarına istenen miktarda, planlanan süre içinde ve makul bir maliyetle göndermektir. Taşıma faaliyetleri üç şekilde karşılanabilir. Birincisi, işletmenin kendi araç filosunun olmasıdır. İkincisi, uzun süreliğine uzman nakliye firmaları ile anlaşma yöntemidir. Üçüncüsü, çeşitli lojistik şirketlerinden hizmet almaktır. Taşıma, karayolu, havayolu, denizyolu, demiryolu ve boru hattı taşımacılığı olmak üzere beş ana başlık alında toplanmaktadır. Her bir taşıma şeklinin kendine özgü avantaj ve dezavantajları vardır. Taşıma şekillerinin karşılaştırılmasında maliyet, tutarlılık, hız, elverişlilik, kapasite, ağırlık/mesafe açısından ekonomikliği ve enerji verimliliği gibi özellikler kullanılmaktadır (Uslu ve Akçadağ, 2012: 151).

Depolama: Depolama tesisleri, üretim hatlarının desteklenmesi için yarı mamullerin hazırlanması; hammadde ve yedek parçaların saklanması, stokların ikmali; üretim tesislerinden gelen ürünlerin muhafazası için kullanılan alanlardır. Depolar, ürünlerin hammadde aşamasından üretim ortamına, oradan da tüketim merkezlerine dağıtımına kadar olan bütün bir faaliyetler dizisinin gerçekleştirilmesinde stratejik rol oynayan ara noktalardır. Geleneksel yönetim anlayışında depolar sadece ürünlerin saklandığı yer olarak algılanırken, entegre lojistik sistemlerinde, depo yönetimi aynı zamanda teknolojik gelişmelerin sağladığı imkanlar sayesinde, modern stok kontrol yönetim biçimleri ile birlikte kullanılan özel bir sektör haline gelmiştir. Depolama beklenmedik zamanda ve istenen miktarlardaki talebin karşılanmasına olanak sağlamaktadır. Teknolojinin gelişmesi ile geleneksel depolar yerini dağıtım merkezlerine bırakmıştır.

Dağıtım merkezlerinde, ürünlerin saklanması dışında, sipariş alma-işleme, yollama, envanter kontrolü ve faturalama vb. pek çok işlev gerçekleştirilebilmektedir. Bu bakımdan depolar, değişik üretici ve satıcılardan alınan siparişlerin toplanıp gruplandırılmasını, ürünlerin geçiş noktalarındaki akışını ekonomik biçimde sağlamaktadır. Üretim için yeni, yeniden üretilmiş ve ikame edilebilir parçaları işleme ve tersine lojistikte kullanılan parça, yeni parça, yedek parça, bitmiş ürün stoklarının ele alınması tersine lojistik için önemli bir konudur. Ürünlerin kısa mesafede depoya toplanması, taşınması, saklanması, tasniflenmesi ve müşteri taleplerine göre ayrıştırılıp birleştirilmesi gibi elleçleme faaliyetleri de depolama sistemleri içindeki önemli faaliyetlerden biridir. Elleçleme süresince gerekli olan işçilik maliyetleri ve elleçleme için gerekli olan makine - ekipman için yapılan harcamalar toplam lojistik maliyetleri içinde önemli bir yer tutmaktadır (Uslu ve Akçadağ, 2012: 152).

Muayene ve sınıflandırma: Ağdaki muayene ve sınıflandırma işlemlerinin yeri, ortaya çıkan mal akışı üzerinde önemli bir etkiye sahiptir. Bu aşamadan sonra, tek tek ürünler uygun bir kurtarma seçeneğine ve dolayısıyla coğrafi bir varış noktasına atanabilir. Temel olarak, bu aşamada ulaştırma ve yatırım maliyetleri arasında bir denge söz konusudur. Kademeli ürünler doğrudan ilgili kurtarma işlemine gönderilebildiğinden akış kanallarında toplanan ürünleri erken dönemde muayene etmek, toplam taşıma mesafesini en aza indirebilir. Özellikle, yeniden kullanılamaz maddeleri geri dönüşümsüz hurdadan ayırarak gereksiz nakliye önlenebilir. Bu sebeple tüketiciye ya da geri dönen ürün sağlayıcılarına yakın yerlerde toplama merkezleri kurulur ve toplama işleminden sonra geri dönen ürünler geri kazanım işlemleri için üretici firmaya taşınmadan önce muayene ve sınıflandırma işlemlerinden geçmektedir. Öte yandan, pahalı test ekipmanı ve kalifiye işgücü ihtiyacı, muayene ve sınıflandırma işlemlerini merkezileştirmek için birer neden olabilir. Bu merkezileşmenin yasal kısıtlamalarla sınırlandırılabileceğini belirtmek gerekmektedir. Öte yandan, bilgi ve iletişim teknolojilerindeki son gelişmeler "yerel" testlerin maliyetinin düşürülmesine yardımcı olabilir. Son olarak, muayene etme çabası ile toplama stratejileri arasındaki takasa dikkat edilmelidir. Toplama işlevinin bir bölümünü müşteriye kaydırmak taşıma maliyetini en aza indirmeye yardımcı olabilir; fakat bu durumda muayene ve sınıflandırma maliyetlerini artırma eğiliminde olan farklı ürünleri ayrı tutmak zor

olabilir. Alternatif olarak, bireysel toplama işlemi, geri kazanılabilir öğeleri hurda kaynağından ayırmak için fırsatlar sunabilir ve böylece daha sonra kanalda sıralama gereksinimini azaltmaktadır (Fleischmann, 2001: 4).

Ayrıştırma: Sınıflandırılan ürünler, kullanılabilir durumdaki parçaların alınarak iyileştirilmesi ya da çalışır durumda olmayan parçaların yenileriyle değiştirilmesi, ürüne teknolojik yeniliklerin ilave edilmesi gibi nedenlerle ayrıştırma işlemine tabi tutulmaktadır (Demirel, 2008: 905)

Demontaj: Demontaj, kullanılan ürünlerin bozunumunu ve durumunu analiz etmek, bileşenlerin ömrünü değerlendirmek için ürünlerin sökülmesi işlemidir (Pokharel, 2009: 178). Başka bir tanımla demontaj, bir üründen bileşenlerin veya modüllerin tahribatsız olarak ayrılmasıdır. Belirli bir ürünün demontajı genellikle birçok farklı yoldan gerçekleşebilir. Bunlar, genellikle demontaj birimi işlem dizileri olarak ifade edilmektedir. Demontaj sıralaması, tüm olası ayrıştırma dizilerinin grafiksel olarak temsil edilmesiyle ve sezgisel, metasezgisel veya matematiksel programlama yoluyla bu kümedeki en iyi dizinin seçilmesi ile ilgilidir. Genellikle, maksimum kar, tehlikeli maddelerin zorunlu olarak geri kazanılması gibi çevresel ve teknik kriterler kümesine tabi tutulmayı amaçlamaktadır. Her bir bileşen veya modülün hasar derecesi farklı olduğundan onları incelemek / test etmek için özel araçlara ihtiyacımız vardır. Test sonucuna göre, kurtarma seçenekleri hakkında karar verebiliriz (Liu ve Fang, 2007: 1181).

Ürün kazanımı: Ürün kazanımı, daha sonraki işlem için son kullanıcılardan dönen kullanılmış ürünlerin, bileşenlerin veya materyallerin edinilmesi işlemidir. Ürün dönüşleri zaman, miktar ve kalite bakımından belirsiz olduğu için, bu ürünlerin kazanımı tersine lojistiğin başarısı için önemlidir. Perakendeciler tarafından genellikle sisteme girmesine izin verilen veya sorunları çözüldükten sonra kullanıcıya geri verilen ürünlerin tanımlanması için yapılan bir dizi uygulama "kapı tutma- gate keeping" olarak tanımlanmaktadır. Örneğin, tüketici ürünü perakendeciye döndürdüğünde perakendeci, ürünün daha fazla kazanım işlemine tabi tutulması veya tüketiciye geri verilmesi gerekip gerekmediğine karar vermermektedir. Bu karar verme eylemi "kapı tutma – gate keeping"dir (Agrawal vd., 2015: 78).

Yeniden kullanma veya doğrudan geri kazanım: Yeniden kullanma, geri dönen ürünün yeniden ambalajladıktan veya tamir edildikten sonra yeniden kullanılmasıdır (Liu ve Fang, 2007: 1181). Doğrudan geri kazanım ise, ürünlerin herhangi bir işlem görmeden tekrar satışa sunulmasıdır.

Yeniden İmalat: Yeniden imalat, kullanılan ürünleri, yeni ürünlerinki kadar titiz kalite standartlarına getirmektir. Kullanılmış ürünler tamamen sökülür ve tüm bileşenler kapsamlı olarak denetlenmektedir. Aşınmış parçalar yeniden imalat ekipmanları ile işlenmektedir (Liu ve Fang, 2007: 1181). Genellikle, yeniden işleme aşaması, ters lojistik ağı içinde en yüksek yatırımları gerektirmektedir. Özel imalat veya geri dönüşüm ekipmanının maliyeti, tüm zincirin ekonomik olarak yaşayabilirliğini büyük ölçüde etkilemektedir. Çoğu durumda, yeniden işleme aşamasında yüksek yatırım maliyetleri, yüksek işlem hacimlerinin karlı olmasını gerektirmektedir. Geri kazanılan ürünler için sadece yeterli bir satış hacmi değil, aynı zamanda yeterli miktarda geri kazanılabilir kaynak sağlanmalıdır. Kapalı döngü zinciri, yeniden işleme aşamasını tasarlayan orijinal ekipman üreticisi tarafından yönetilirse, kısmen ürün kurtarma işlemlerinin orijinal imalat prosesine entegre edilmesi ekonomik olabilir. Entegrasyon, paylaşılan yerler, işgücü hatta üretim hatlarıyla ilgilidir. Benzer şekilde ulaştırma ekonomisi 'yeni' ile 'geri kazanılan' ürünler arasında farklılık gösterebilir. Dahası, çoğu durumda entegrasyonun örgütsel karmaşıklığa önemli ölçüde katkıda bulunduğu göz ardı edilmemelidir (Fleischmann, 2001: 5).

Ürün yenileştirme: Ürün yenileştirme, kullanılmış ürünü, standart bir kalite düzeyine getirmek için yapılan, ürünün kalitesini arttırıp ömrünü uzatan işlemlerdir. Kullanılmış ürün, demontaj işlemi ile parçalarına ayrıldıktan sonra önemli parçalar kontrol edilmekte ve gerekiyorsa uygun parçalarla değiştirilmektedir. Bazen ürün yenileme sürecinde eski parçalar, teknik olarak daha iyi olan parçalarla değiştirilmektedir. Uçaklar, yenileştirme sürecinden geçen ürünlere örnek verilebilir (Bulut ve Deran, 2008: 334).

Ürün yamyamlaştırma: Ürün yamyamlaştırma, kullanılmış ürün ya da bileşenden, kullanılabilir sınırlı bir dizi parçanın başka ürün veya bileşenlerin tamir, yenilenme

veya yeniden üretiminde yeniden kullanılması amacıyla geri alınmasıdır (Bulut ve Deran, 2008: 334).

Geri dönüşüm: Geri dönüşüm, geri dönen ürünlerin malzemelerinin kalitesi yüksekse bu malzemelerin yeni ürün üretmek için yeniden kullanımıdır.

Tamir ve satış sonrası servis: Tamir, geri dönmüş ve kullanılmış ürünü yeniden çalışır ya da kullanılabilir hale getirmek için kırılmış veya bozulmuş parçaların değiştirilmesi ya da işlevini yerine getirebilecek hale getirilmesi işlemidir. Tamir edilmiş ürünün kalitesi genellikle yeni ürün kalitesine göre biraz daha düşüktür (Bulut ve Deran, 2008: 333). Tamir ve satış sonrası hizmet sunma özelliği, bir şirketin ürününü pazarlama becerisini de geliştirebilir (Pokharel, 2009: 178).

Elden çıkarma ve bertaraf etme: Ekonomik ya da teknik nedenlerle yeniden kullanılamayan ürünler yeniden kullanıldığında bir değer yaratmayan ya da yeniden kullanılabilir duruma getirilmesi için gereken kazanım faaliyetlerine kıyasla ürünün işlemeye değer olmayan ürünler, yeniden kazanım işlemlerine uygun olmadığı için muayene ve sınıflandırma aşamasında atık olarak ayrılıp elden çıkarılmaktadır. Bu atıkların toprağa gömme, atık sahalarında depolama, yakma gibi işlemlerle imha edilmesi de bertaraf işlemidir (Şengül, 2011: 418).

Ambalajlama: Ambalajlama tüm lojistik süreç içerisinde ürünlerin fiziki durumunun ve özelliğinin korunmasını sağlayacak, ulaştırma şekli ve ürünün özelliği dikkate alınarak gerçekleştirilen önemli bir lojistik unsurudur (Uslu ve Akçadağ, 2012: 152).

Yeniden dağıtım: Tıpkı ileri lojistik gibi iyileşmiş ürünler de tersine lojistikte toptancıya / perakendeciye veya tüketiciye dağıtılmalıdır. Yeniden dağıtım, var olan ileri lojistik ağlarını kullanabileceği gibi, yeniden dağıtım için yeni bir ağ da kurulabilir. Yeniden dağıtım ağını seçme, işletmelerin mevcut durumuna bağlıdır (Liu ve Fang, 2007: 1181). Yeniden dağıtım aşamasının tasarımı, geleneksel dağıtım ağına çok benzemektedir. Yeniden dağıtımda yönetsel karmaşıklığa neden olan şey, bütünleşme meselesidir. Örneğin, firma araç yüklemesini arttırmak için toplama ve yeniden dağıtmayı birleştirme yöntemi seçilebilir (Fleischmann, 2001: 5). Yeniden dağıtım stratejilerinin oluşturulmasında piyasadan toplanabilecek atık miktarları

önemli bir unsurdur. Bu nedenle miktarla ilgili gözden geçirilmesi gereken değişken unsular aşağıda belirtilmiştir (Şengül, 2011: 418):

- Belli bir zaman diliminde toplanabilen ürün miktarı, cinsi, ürün miktarındaki değişiklik,
- Çöplerin veya atık kaynaklarının sayısı, miktarı,
- Kaynakların bölgesel dağılımı,
- Yardımcı nakliye araçlarının kullanımı,
- Toplanan malların değişik kullanım alanlarının varlığı,
- Kaynakların çöp toplama merkezlerine olan ortalama uzaklığıdır.

Yeniden satış: geri kazanılan ürünlerin birincil veya ikincil pazarlarda ürünlere değer eklenerek ya da eklenmeden ekonomiye yeniden kazandırılması yeniden satışa sunulması çalışmalarını kapsamaktadır (Çekerol, 2013: 19).

Tersine lojistiğin firma için başarılı ve faydalı bir uygulama olabilmesi için bu temel faaliyetlerin dışında talep tahmini, bilgi yönetimi, koordinasyon gibi faaliyetlerin öneminin anlaşılması ve geliştirilmesi gerekmektedir.

Koordinasyon: Geri dönen ürünlerin hızlı bir şekilde düzenlenmesine ve yeniden imalatı planlamaya yardımcı olmak için tersine lojistikte iletişimin rolü önemlidir. Bilgi destek sistemlerinin kullanılması koordinasyonun sağlanmasına yardımcı olur (Pokharel, 2009: 178).

Bilgi Yönetimi: Günümüzde lojistik faaliyetleri bilişim sistemlerinden ayrı olarak düşünülememektedir. Tüm lojistik sürecinin sağlıklı şekilde işleyebilmesi ve doğru bilgi akışının gerçekleşmesi için bilgi yönetiminin sağlanması gerekmektedir. Doğru bilginin iletilmesinde ise sipariş işleme birincil önem taşımaktadır. Günümüzde internet bağlantısı ile alınan müşteri siparişleri hem daha az maliyetli, hem daha hızlıdır (Uslu ve Akçadağ, 2012: 152).

Talep Yönetimi ve Talep Tahmini: Talep edilen ürünü, istenen miktarda, istenen kalite ve çeşitlerde, planlanan zamanda, doğru fiyatla ve doğru yerde karşılama gücü ve esnekliği etkin talep yönetimiyle sağlanabilir. Bu nedenle talep yönetimi, talebi

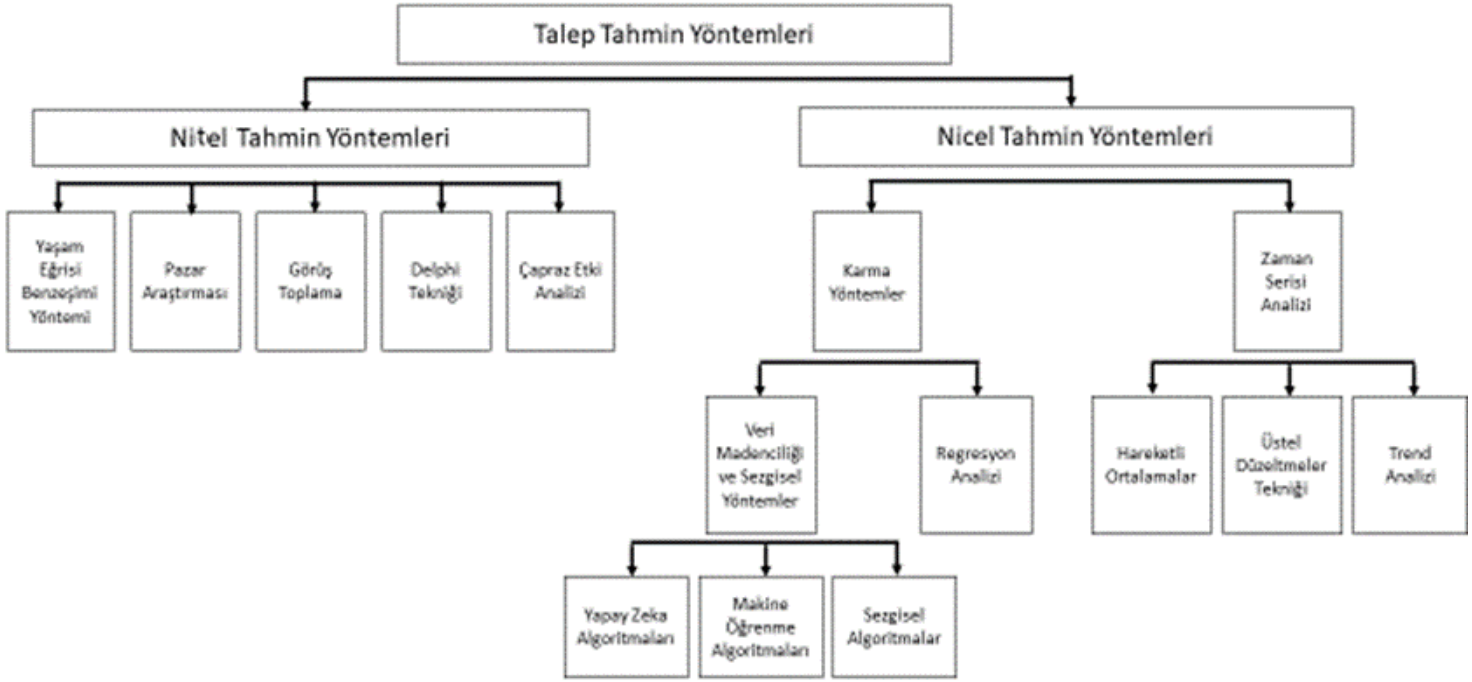
maksimum düzeyde karşılarken gecikme süresini, giderleri, maliyeti ve stok düzeyini en küçüklenmeyi amaçlamaktadır (Uslu ve Akçadağ, 2012: 152). Şekil 1.13'te başlıca talep tahmin yöntemleri gösterilmiştir.



Şekil 1.13: Temel lojistik faaliyetler (Çekerol, 2013: 37).

1.9.1. Tersine Lojistikte Talep Tahmini

Tersine lojistiğin karşılaştığı en büyük engel talepteki belirsizliktir. Geri dönen ürünlerin kalite bakımından durumu, miktarı, geri dönüş zamanı gibi özelliklerinin önceden tahmin edilmesi çok zordur. Şekil 1.13'te ise tersine lojistiğin en temel faaliyetleri gösterilmektedir. Talep tahmini olarak bahsedilen aslında ürün iadelerinin ve tersine akışa giren ürün geri dönüşlerinin tahminidir. Talep tahmini yöntemleri ise Şekil 1.14'te görülmektedir. Ayrıca tüketici veya perakendeciler tarafından iade edilen ürünler, stok fazlalığı oluşturduğu için üreticiler ve yöneticiler tarafından büyük bir problem olarak görülmektedir. Tersine lojistik veya iadeler, bir organizasyonun tedarik zincirinde sıklıkla gözden kaçan önemli bir bağlantıdır. İade edilen ürünler için doğru bir şekilde talep tahmini yapmak firmaya üretim, dağıtım, stok gibi birçok temel alanda stratejik fayda sağlamaktadır. Şekil 1.15'te geri dönen ürünlerin malzeme türüne, geri dönen ürünün kaynağına, ürünün tersine lojistik faaliyetleri sonrası durumuna ve kazanım seviyesine göre gruplandırılması görülmektedir.



Şekil 1.14: Talep tahmin yöntemleri.



Şekil 1.15: Geri dönüşüm sürecinin sınıflandırılması (Steven, 2004: 171).

1.10. TERSİNE LOJİSTİK FAALİYETLERİNİN UYGULANMASINDA KARŞILAŞILAN SORUNLAR

Bir firmanın "ürün geri dönüş faaliyetleri" sırasında müşterileri ile etkili bir şekilde iletişim kurma; geri çağırılan ve iade edilen varlıkları işleme; tüm ticaret ortaklarıyla adil ve doğru bir şekilde anlaşma; geri dönüş sürecini maddi olarak hesaba katma; ve varlığın son durumunu sorumlu bir şekilde yönetme yeteneği müşteri memnuniyetini, ticari itibarı, satışları, kazancı, kamuoyu ve hissedar değerini olumlu yönde etkilemektedir (Greve ve Davis, 2012: 2). Tersine lojistiğin firmaya sağladığı bu yararlara rağmen birçok engel firmaları tersine lojistik uygulamasından alıkoymaktadır. Bunlar hem firma içi hem de firma dışı engeller olabilmektedir. En önemli firma içi engel bilinç eksikliğidir; üst yönetimin firma çalışanlarına tersine lojistiği tanıtma konusundaki eksiliği, stratejik planlama eksikliği, finansal kısıtlar, çalışanların değişimden hoşlanmamaları ya da ekonomik konularda eğitimli ve deneyimli olmamalarıdır (Rogers and Tibben-Lembke, 2001: 143-144).

Tüccarlar, geri dönüşlerden bahsetmekten hoşlanmamakta ve operasyon yöneticileri bunu sadece kendi yollarından çekilmesi gereken bir engel olarak görmektedir. Tedarik zinciri yöneticileri geri dönüşleri, önceliklerine ve ileri lojistik sorumluluklarına az veya hiç yararı olmayan istenmeyen bir sorun olarak görmektedir. Yöneticiler, tersine lojistik tartışmaları başlatıldığında genellikle iki şekilden biriyle

tepki vermektedir. İlk ve en yaygın tepki, tersine lojistiği "sadece ürünün geri dönmesi" ve müşteriye para iadesi olarak basitleştirmektir. Tersine lojistik konularına eğilim içinde olduğunuz ikinci tür yürütme tepkisi "çok karmaşık" olduğuna dair umutsuz kabullenmedir. Tersine lojistik konusunda umutsuzluğa düşüren düşünceler şunlardır (Greve ve Davis, 2012: 2-6):

- Tersine lojistik karmaşık bir yapıya sahiptir.
- Tersine lojistik departman sınırlarını aşmaktadır.
- Tersine lojistik üzerinde yoğunlaşmaya yönelik az sayıda veya hiç iç kaynak mevcut değildir.
- Genelde tersine lojistikten sorumlu tek bir yönetici yoktur.
- Firmanın ürün dönüşleri ile ilgilenecek ve bu dönüşlerdeki gizli karları bulacak bir sorumlu bulmak oldukça zordur. Genellikle kimse tersine lojistikten sorumlu olmayı gönüllü kabul etmemektedir.
- Ürünlerin geri dönmeleri iyi bir şey değildir.
- Tedarik zinciri yöneticilerinin çoğuna göre ürün geri dönüşleri depo operasyonlarının düzensiz olmasına neden olmaktadır.
- Tersine lojistiğin firma üzerindeki etkisi açık bir şekilde anlaşılamamaktadır.
- Tedarik zinciri yöneticilerinin tersine lojistik alanında ne kadar iyi performans gösterdiği genellikle ölçülemediği için performans karşılığı da ücret olarak ödenmemektedir.

Tersine lojistik ekonomik, ekolojik, imaj ve rekabet üstünlüğü avantajlarına rağmen bir çok sınırlama ile de karşı karşıyadır. Tersine lojistiğin uygulanmasını zorlaştıran sınırlamalar kısaca şöyledir:

- Son tüketiciden dönen kullanılmış ürünlerin durumu, miktarları ve malzeme özellikleri belirsizdir. Kalite denetimleri zordur.
- Bu çeşitlilik sebebi ile ürün akışları da çeşitlilik göstermektedir. Toplama ve nakliye işlemleri karmaşık bir ağ yapısına sahiptir.
- Çok sayıda müşteriden düşük hacimde ürün dönüşü olmaktadır.

- Ürünlerin geri alımı müşterilerden olduğu için belirli bir pazar mevcut değildir ve ürün dönüşleri için birçok akış oluşmaktadır.
- Geri dönüşü olan ürünlerin hızlı bir şekilde yenileme veya geri kazanım işlemlerinin yapılması gerekmektedir.
- Geri dönüşlerle yenilenen ürünler, sağlam yedek parçalar, geri dönüşüme uygun malzemelerin kullanımı ve satışı için yeni pazarlar gerekmektedir.
- Talep belirsizliği nedeni ile geri dönen ürünler için kullanılacak toplama ve taşıma araçlarının, depolama ve işlem görme tesislerinin kapasiteleri de bu belirsizlikler nedeni ile esnek olmalıdır.
- Birçok departmanın birlikte çalışması ve etkili bir şekilde iletişim kurabilmeleri gerekmektedir.
- Bilgi teknolojileri ileri lojistik faaliyetleri için kullanılmaktadır ve tersine lojistik faaliyetlerinin tam bilgileri sistemlere ya hiç ya da düzenli olarak işlenmemektedir.
- Firmalar, politikalarında ve stratejik planlarında tersine lojistiğe ilişkin bir hedef ya da politika belirlememekte ya da yeterli önemi vermemektedir.

Ayrıca tersine lojistik aşağıdaki sınırlamalarla da karşı karşıyadır (Steven, 2004: 167-168):

- Ekonomik açıdan tersine lojistik faaliyetlerinden kaynaklanan ek maliyetler, giriş tarafındaki malzeme ve enerjinin azaltılmasından elde edilen tasarruflardan ve çıkış tarafındaki atıktan daha yüksek değilse, bu durumda geri dönüşüm yalnızca karlı olmaktadır.
- Geri dönüşümün teknik olarak sınırlaması, çoğu durumda ürünlerin veya malzemelerin tamamen yeniden kullanılmasının imkansız olmasıdır. Genellikle her malzemenin kalitesi birincil malzeme eklenmedikçe her geri dönüşüm sürecinde bozulmaktadır. Bu etkiye (örneğin kağıt geri dönüşümünde olduğu gibi) kayıp dönüşüm denmektedir.
- Ekolojik bakış açısından, geri dönüşüm ile önlenebilen olumsuz çevresel etkiler, geri dönüşümü gerçekleştirmek için gereken tersine lojistik süreçlerinin sonuçlarından daha önemli olmalıdır. Bu etkilerin ölçülmesi zor olsa da, son

zamanlarda Almanya'da yapılan çalışmalar, küçük plastik nesnelerin malzeme geri dönüşümünün genel bir etkisi olmadığını göstermektedir.

- Son olarak, geri dönüştürülmüş ürünler, potansiyel kullanıcılarının görüşüne göre genellikle zihinsel engellerle karşılaşılmaktadır. Geri dönüştürülmüş ürünlerin, birincil kaynaklardan yapılan ürünlerden daha düşük bir kaliteye sahip olduğu düşünülmekte ve bu nedenle geri dönüştürülmüş malzeme ile yapılan ürünlerin yeni ürünlerle aynı fiyata satın almak istenilmediği varsayılmaktadır.

Tersine lojistik sürecinde tüketicide karşılaşılan sorunları ve ürünlerin tüketiciden veya perakendeciden geri dönüş nedenleri şu şekilde özetlenebilir (Wu ve Cheng, 2006: 512):

- Belirsiz ürün pazarı konumu
- Kalite sorunu
- Tasarım sorunları
- Yanlış tahmin
- Mantıksız fiyatlandırma
- Yavaş bilgi akışı
- Eksik pazarlama desteği
- Zayıf satış fonksiyonu
- Kötü mağaza tanıtımı
- Zayıf lojistik desteği
- Zayıf ulaşım desteği
- Geri dönüş sıklığı, miktarı ve öğeleri üzerinde kontrol eksikliği
- Küçük sipariş miktarı nedeniyle ciddi geri sipariş ve geç teslimat
- Dönüş işleminin uzun süren döngüsü
- Küçük miktarlarda çok çeşitli ürün geri dönüşü
- Sabit iade periyodundan dolayı çok miktarda iade edilmiş ürün
- En çok satanlar için satış döneminde getirilerde belirgin bir artış
- Nakit akışı sorunu
- Ürün karmasının uygunsuz seçimi
- İade listesi ile gerçek öğeler ve miktarlar arasındaki tutarsızlık

- Uzun dağıtım kanalı
- Promosyonun sonunda çok sayıda geri dönüş ile sonuçlanan sıklıkla yapılan promosyon faaliyetleri
- Farklı coğrafi bölgeler arasında farklı tüketici tercihleri
- Nakliye düzenlemesinde zorluk yaşanması nedeniyle yüksek nakliye masrafları
- Stok alma ve stoklama faaliyetlerinde katı bir disiplin eksikliği
- Çok fazla distribütör olması

2. VERİ MADENCİLİĞİ

Her gün çok miktarda veri toplanan bir dünyada yaşıyoruz ve bu sebeple çağımız bilgi çağı olarak adlandırılmaktadır. Başlangıçta, bilgisayarların ve seri dijital depolama araçlarının ortaya çıkmasıyla birlikte, bu bilgi birikimiyle sıralama yapmaya yardımcı olmak için bilgisayarların gücüne güvenerek her türlü veriyi toplamaya ve saklamaya başlanmıştır. Bu bilgi çağında, bilgisayarlar, uydular gibi teknolojiler sayesinde bilginin bize güç ve başarı getireceğine inandığımız için, muazzam miktarda veri toplamaktayız. Bu tür verilerin analiz edilmesi önemli bir ihtiyaç halini almıştır. Büyük miktarda veriler iş, toplum, bilim, mühendislik, tıp ve günlük hayattaki diğer her yönüyle her gün bilgisayar ağlarımıza, Dünya Çapında Ağ'a (WWW) ve çeşitli veri depolama aygıtlarına dökülmektedir. Ne yazık ki, farklı yapılarda depolanan bu büyük veri koleksiyonları çok hızlı bir şekilde ezici olmaktadır. Mevcut veri hacmindeki bu patlayıcı büyüme, toplumumuzun bilgisayarlaştırılmasının ve güçlü veri toplama ve depolama araçlarının hızlı bir şekilde geliştirilmesinin bir sonucudur. Muazzam miktarda veriden gelen değerli bilgileri otomatik olarak ortaya çıkarmak ve bu verileri organize bilgi haline dönüştürmek için güçlü ve çok yönlü araçlar gereklidir. Bu ilk kargaşa, yapılandırılmış veritabanlarının ve veritabanı yönetim sistemlerinin yaratılmasına yol açmıştır. Verimli veritabanı yönetim sistemleri, büyük bir veri kümesini yönetmek için ve özellikle belirli bir bilginin gerektiğinde geniş bir koleksiyonda etkin ve verimli bir şekilde alınması için çok önemli bir varlıktır. Veri madenciliği, geniş bir veri koleksiyonunu bilgiye dönüştürmektedir. Bir arama motoru (ör. Google), her gün yüz milyonlarca sorgu almaktadır. Bir arama motoru, zamanla kullanıcılar tarafından toplanan bu tür büyük bir sorgu koleksiyonunda bulunan bazı kalıpları, tek tek veri öğelerini, genellikle tek başına okurken elde edemediğiniz paha biçilemez orijinal ve yararlı bilgiyi bulabilmektedir (Zaïane, 1999: 1), (Han vd., 2011: 20).

Veritabanı yönetim sistemlerinin yaygınlaşması, her türlü bilginin toplanmasına katkıda bulunmaktadır. Basit nümerik ölçümlerden ve metin belgelerinden, mekansal veriler, çoklu ortam kanalları ve köprü metin belgeleri gibi daha karmaşık bilgilere kadar sayısız veri toplanmaktadır. Bugün, ticaret işlemlerinden bilimsel verilere, uydu

resimlerine, metin raporlarına ve askeri istihbarata kadar ele alacağımızdan çok daha fazla bilgiye sahip olmaktayız. Veri elde etmek, artık karar vermede yeterli olmamaktadır. Çok sayıda veri koleksiyonuyla karşı karşıya olmak, daha iyi yönetim tercihleri yapılabilmesi için yeni ihtiyaçlara gerek duymaktadır. Bu ihtiyaçlar, verilerin otomatik özetlenmesi, saklanan bilgilerin "özü"nün çıkartılması ve ham verilerdeki kalıpların bulunmasıdır (Zaïane, 1999: 1).

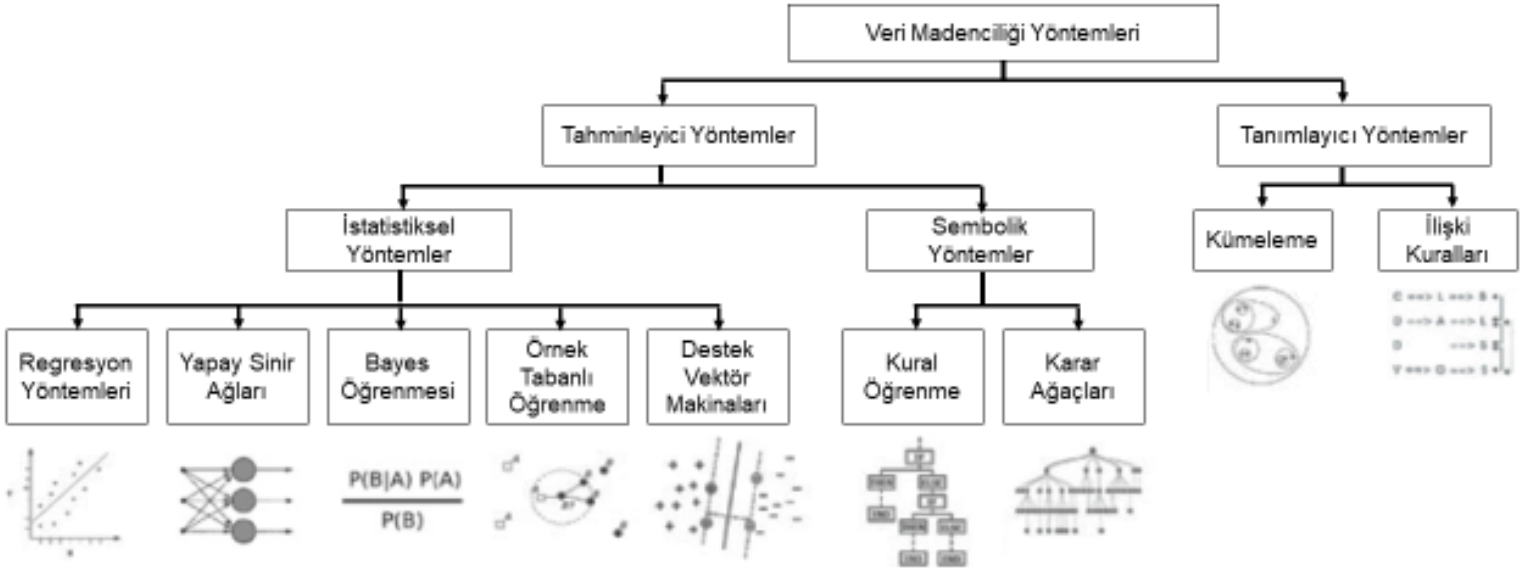
Dünya çapında işletmeler, satış işlemleri, hisse ticareti kayıtları, ürün açıklamaları, satış promosyonları, şirket profilleri, şirket performansı ve müşteri geri bildirimleri de dahil olmak üzere devasa veri setleri üretmektedir. Örneğin, Wal-Mart gibi büyük mağazalar, dünyanın dört bir yanındaki binlerce şubede haftada yüzlerce milyon işlem gerçekleştirmektedir. Bilimsel ve mühendislik uygulamaları, uzaktan algılama, süreç ölçümleme, bilimsel deneyler, sistem performansı, mühendislik gözlemleri ve çevre gözetimi gibi sürekli bir biçimde yüksek düzeyde petabayt veri üretmektedir. Küresel omurga telekomünikasyon şebekeleri her gün onlarca petabayt veri trafiğini taşımaktadır. Tıp ve sağlık endüstrisi, tıbbi kayıtlar, hasta izleme ve tıbbi görüntüleme yöntemleriyle muazzam miktarda veri üretmektedir. Arama motorları tarafından desteklenen milyarlarca web araması her gün onlarca petabayt veriyi işlemektedr. Topluluklar ve sosyal medya, dijital resimler, videolar, bloglar, web toplulukları ve çeşitli sosyal ağlar üreten giderek daha önemli veri kaynakları haline gelmektedir. Büyük miktarda veri üreten kaynakların listesi sonsuzdur. Alan genç, dinamik ve umut vericidir. Veri madenciliği, veri çağından gelen bilgi çağına doğru yolculuğumuza büyük adımlar atmıştır ve devam edecektir (Han vd.,2011: 675).

Pek çok başarılı şirket, akıllı karar verme için veri madenciliği uygulamaktadır. Veri madenciliği, müşteri ilişkileri yönetimini geliştirmeye ve yatırımın getirisini tahmin etmeye yardımcı olabilecek işletme verilerinden bilgi külçelerinin çıkarılmasına olanak tanımaktadır. Veri madenciliği, gelişmiş analitik teknikler kullanarak kurumların ham verilerini değerli bilgilere dönüştürmelerini ve böylelikle kritik bir rekabet avantajı elde etmelerini sağlamaktadır (Fernandez, 2010: 1).

Veri; sayılar, metinler, sesler ve görüntülerdir. Veri tabanı; sistematik erişim imkanı olan, yönetilebilir, güncellenebilir, taşınabilir, aralarında tanımlı ilişkiler bulunabilen

verilerdir. Bilgi ise; öğrenerek, deneyerek, araştırarak elde edilen, karar almaya yardımcı olan her türlü sonuçtur. Veri ile değil, bilgi ile çalışma avantajı her alanda, verilen kararların doğruluğu, kararı veren kişinin yeteneklerine ve deneyimine olduğu kadar sahip olduğu bilginin yeterliliğine de bağlıdır. Bu nedenle artık "bilgi", mal ve hizmetin yanında üçüncü üretim faktörü olarak değerlendirilmektedir. Veri madenciliği, özellikle kar ve pazar payı elde edebilmek için yoğun rekabetin yaşandığı pazarlama alanında ön plana çıkmaktadır. Veriyi hızlı toplayan ve bilgiye dönüştürerek hızlı kullanan firmalar rekabetçi avantaj elde etmektedir. Hangi müşteri, hangi ürünü, ne zaman satın alabilir, kimler tedarikçilerinden vazgeçmekte ve bu tür müşterileri geri kazanmak için neler yapılmakta, ürünün değerini yitirmesine hangi değişkenler neden olmakta, vb. soruların cevapları veri yığınlarında gizlidir ve cevapları bulabilmek için veri madenciliği çözümleri gereklidir. Veri madenciliği teknikleri kullanarak; maliyetleri azaltmak, gelirleri artırmak, verimliliği artırmak, yeni fırsatları ortaya çıkarmak, yeni keşifler yapmak, emek yoğun faaliyetleri otomatikleştirmek, sahtekarlıkları belirlemek ve müşteri deneyimini geliştirmek mümkündür. Bu şekilde yönetim kalitesini artıran kurumlar aynı zamanda toplumsal refah düzeyimizin artmasını ve toplumsal düzeninin korunmasını sağlamaktadır (Argüden ve Erşahin, 2008: 16-17).

Günümüzde kullanılan tüm veri madenciliği yöntemleri; bilgisayar mühendisliği, istatistiksel hesaplama ve veritabanı araştırmalarındaki ilerlemelerden gelişmiştir. Veri madenciliği yöntemleri ile istatistiksel ve grafiksel teknikler geliştirilmektedir. Daha önceleri otomatik veri madenciliği araçlarının, tahmine dayalı istatistiksel analistlerin model oluşturması gereğini ortadan kaldıracağı düşünülmüştür. Ancak, bir analistin sağladığı değer otomatikleştirilemez. Model sonuçlarını değerlendirmek ve model tahminlerinin makul olduğunu doğrulamak için analistlere ihtiyaç duyulmaktadır. Veri madenciliği yazılımı, ilişkili ve ilişkisiz korelasyon arasındaki farkı tanımaya yönelik insan deneyimi ve sezgisinden yoksun olduğu için, analistler hala büyük talep görmektedir (Fernandez, 2010: 6).



Şekil 2.1: Veri madenciliği yöntemleri (Garcia v.d., 2015:4).

2.1.VERİ MADENCİLİĞİNİN TANIMI

Veri madenciliği hakkında çeşitli kaynaklarda birçok tanım bulunmaktadır. Bu tanımlamalardan ve açıklamalardan bazıları aşağıda verilmiştir:

Veri madenciliğinin en yaygın kabul gören tanımlarından birisi "verilerin modellerinin keşfedilmesi"dir. Başlangıçta, veri madenciliği veya veri tarama, veriler tarafından desteklenmeyen bilgileri çıkarma girişimlerini ifade eden basit bir terimken, günümüzde istatistikçiler veri madenciliğini "istatistiksel bir modelin oluşturulması, yani görünür verilerin çizildiği altta yatan bir dağılım" olarak görmektedirler (Leskovec vd., 2014:1).

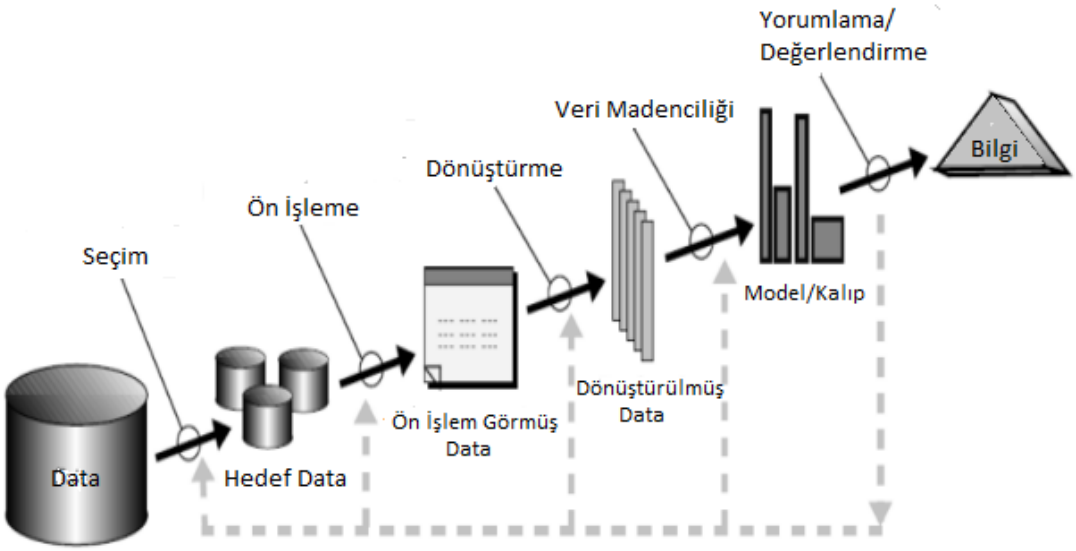
Dosyalarda, veritabanlarında ve diğer depolarda gerekmese de saklanan çok miktarda veriden karar vermede yardımcı olabilecek ilginç bilgilerin çıkarılması, bu bilgilerin analiz edilmesi ve hatta yorumlanması için güçlü araçlar geliştirmek gittikçe önem kazanmaktadır. "Veri madenciliği, veritabanlarındaki verilerden örtük, daha önce bilinmeyen ve potansiyel olarak yararlı bilginin çıkarımı" olarak tanımlanabilir. Veri madenciliği ve veritabanlarında bilgi keşfi sıklıkla eşanlamlı olarak değerlendirilir, aslında veri madenciliği bilgi keşfi sürecinin bir parçasıdır (Zaïane, 1999: 3).

"Veri madenciliği, büyük veritabanlarından daha önce bilinmeyen ve potansiyel olarak yararlı bilgileri ayıklamak için büyük bir potansiyele sahip güçlü bir bilgi teknolojisi aracıdır." Veri madenciliği ham verilerdeki ilişkileri ve modelleri bulma sürecini otomatikleştirir ve otomatik karar destek sistemi veya karar vericiler tarafından değerlendirilebilen sonuçlar sağlamaktadır (Fernandez, 2010: 1)

"Veri madenciliği, kapsamlı, anlaşılır ve tahmin edici modellerin yanı sıra anlaşılır, ilginç ve yeni kalıpları keşfetme sürecidir." Veri madenciliği, büyük verilerden temel bilgiler ve bilgi edinme olanağı sağlayan çekirdek algoritmaları içermektedir. Bu, veritabanı sistemleri, istatistik, makine öğrenme, örüntüleme ve görüntü tanıma gibi tekniklerden yararlanarak bu disiplinleri birleştiren disiplinler arası bir alandır. Aslında, veri madenciliği, veri çıkarma, veri temizleme, veri füzyonu, veri azaltma ve özellik oluşturma gibi işlem öncesi görevlerin yanı sıra model ve model yorumlama, hipotez onayı ve üretimi, vb gibi işlem sonrası adımları içeren daha geniş bir bilgi keşfi

sürecinin parçasıdır. Bu bilgi keşfi ve veri madenciliği süreci oldukça yineleyici ve etkileşimli olma eğilimindedir (Zaki vd., 2014: 1, 26-27).

“Veri madenciliği, veritabanlarında bilgi keşfi olarak bilinen daha genel bir süreçte atılmış bir adım” olarak tanımlanmıştır. Veritabanlarında bilgi keşfi tarafından edinilen "bilgi" ilginç, önemsiz, açık olmayan, daha önce bilinmeyen ve potansiyel olarak yararlı olmalıdır. “Veritabanlarında bilgi keşfi, çok sayıdaki veri kümesini "faydalı bilgiler için" aramak isteyenlere yardımcı olmak için tasarlanmış çok aşamalı bir süreçtir.” Veritabanlarında bilgi keşfinde yardımın akıllı ve otomatik olması beklenir ve süreç kendiliğinden etkileşimli ve iteratiftir (Izenman, 2008: 8). Veriden bilgi edinme süreci Şekil 2.2’de görülmetedir.



Şekil 2.2: Bilgi keşfi süreci (Bharati ve Ramageri, 2010: 301).

Veri madenciliği tekniği “büyük veri tabanlarından gizli bilgilerin, önceden tahmin edilemeyen örüntülerin ve yeni kuralların keşfedilmesi” olarak tanımlanabilir. Veri madenciliği, veritabanlarında bilgi keşfi sürecinin en önemli aşamasıdır (Gürsoy, 2012: 3).

“Veri madenciliği büyük miktarda veri içinden gelecekle ilgili tahmin yapmamızı sağlayacak ilişki ve kuralların aranmasıdır. Veri madenciliği, büyük hacimli veri yığınları içerisinden karar alabilmek için potansiyel olarak faydalı olabilecek, uygulanabilir ve anlamlı bilgilerin çıkarılmasına verilen addır.” Mevcut problemleri çözmek, kritik kararları almak veya geleceğe yönelik tahminleri yapmak için gerekli olan bilgileri elde etmeye yarayan bir araçtır. Ortaya çıkarılması hedeflenen bilgiler; üstü kapalı, çok net olmayan, önceden bilinmeyen, daha önce keşfedilmemiş ancak potansiyel olarak kullanışlı anlamlı ve kritik bilgilerdir. Özetle, veri madenciliği veriden bilgi üreterek, ortalama kararlar yerine özgün kararlar verilmesini destekleyen, satışları, kârlılığı, yenilikçiliği ve kaynak kullanımında etkinliği artıran önemli bir yönetim aracıdır (Argüden ve Erşahin, 2008: 10).

Amerikan Pazarlama Birliği, veri madenciliğini şu şekilde tanımlamıştır, “Verilerin, yeni ve potansiyel olarak yararlı bilgi bulma amaçlı analiz sürecidir. Bu süreç bulunması zor örüntülerin ortaya çıkarılması için matematiksel araçların kullanımını içermektedir.” Gartner tarafından verilen bir diğer tanım ise şöyledir, “Veri depolarında saklanan büyük miktarda veri üzerinden eleme ile anlamlı korelasyonlar, örüntüler ve trendler keşfetme sürecidir. Veri madenciliği, örüntü tanıma teknolojilerinin yanı sıra matematiksel ve istatistiksel teknikleri kullanmaktadır” (Akküçük, 2011: 17).

2.2.VERİ MADENCİLİĞİNİN TARİHSEL GELİŞİMİ

Veri madenciliği, bilgi teknolojisinin doğal gelişiminin bir sonucu olarak görülebilir. Veri madenciliği kavramı 1960’lı yıllarda ortaya çıkmıştır. O zamandan bu zamana, veritabanı ve bilgi teknolojisi, ilkel dosya işleme sistemlerinden karmaşık ve güçlü veritabanı sistemlerine sistematik bir şekilde gelişmiştir. 1970'lerden beri veritabanı sistemlerinde araştırma ve geliştirme, hiyerarşik ve ağ veritabanı sistemlerinden ilişkisel veritabanı sistemlerine, veri modelleme araçlarına, endeksleme ve erişim yöntemlerine geçmiştir. Buna ek olarak, kullanıcılar, sorgu dilleri, kullanıcı arabirimleri, sorgu optimizasyonu ve işlem yönetimi aracılığıyla uygun ve esnek veri erişimi elde etmişlerdir. Veritabanı yönetim sistemleri kurulduktan sonra, veritabanı teknolojisi ileri veri analizi ve web tabanlı veritabanları için ileri veri tabanı sistemleri,

veri ambarı ve veri madenciliği geliştirmeye yönelmiştir. Gelişmiş veritabanı sistemleri 1980'lerin ortalarından itibaren araştırmaların hızlanması sonucunda ortaya çıkmıştır. Bu sistemler, genişletilmiş ilişkisel, nesne yönelimli, nesne ilişkisel ve tümdengelim modeller gibi yeni ve güçlü veri modellerini içermektedir. Verilerin dağıtımı, çeşitlendirilmesi ve paylaşımı ile ilgili konular kapsamlı olarak incelenmiştir. Gelişmiş veri analizi 1980'lerin sonlarından itibaren başlamıştır. Bilgisayar donanımı teknolojisinin son otuz yıldaki istikrarlı ve göz kamaştıran ilerlemesi, güçlü ve uygun fiyatlı bilgisayarların, veri toplama ekipmanlarının ve depolama ortamlarının geniş tedarik edilmesine yol açmıştır. Bu teknoloji, veri tabanı ve bilgi endüstrisine büyük bir destek sağlamış ve işlem yönetimi, bilgi alımı ve veri analizi için çok sayıda veri tabanı ve bilgi havuzunun kullanılmasını sağlamıştır. Ortaya çıkan bu veri havuz mimarisi veri ambarıdır. Bu, yönetime karar vermeyi kolaylaştırmak için tek bir sitede birleştirilmiş bir şema altında organize edilen çok sayıda heterojen veri kaynağının bir havuzudur. Veri ambarı teknolojisi, veri temizleme, veri entegrasyonu ve çevrimiçi analitik işleme içermektedir; diğer bir deyişle, özetleme, birleştirme ve toplama gibi işlevselliği olan analiz tekniklerinin yanı sıra bilgileri farklı açılardan görüntüleme olanağı da vardır. Çevrimiçi analitik işleme araçları çok boyutlu analiz ve karar vermeyi desteklese de, örneğin veri sınıflandırma, kümeleme, aykırı değer / anormallik saptama ve zaman içindeki verilerdeki değişikliklerin karakterizasyonu gibi veri madenciliği araçları derinlemesine analiz için gereklidir. Veritabanları ve veri ambarlarından sonra büyük miktarda veri birikmiştir. 1990'lı yıllarda, World Wide Web ve web tabanlı veritabanları (ör. XML veritabanları) ortaya çıkmaya başlamıştır. İlk defa bu yıllarda geleneksel yöntemlerden farklı olarak veri madenciliği kavramından bahsedilmeye başlanmıştır (Han vd., 2011: 18).

Yirminci yüzyılda, Fisher, Neyman, Pearson, Wald, Savage, de Finetti ve diğerleri, istatistiklerin çıkarım teorilerinin inşa edildiği çeşitli rakip matematiksel çerçeveler (sıklıkçı, Bayesci, fiüküel, karar teorisi, vb.) sağlamıştır (Izenman, 2008: 6).

Günümüzde rekabet ortamında hızlı ve güvenli bilgi ihtiyacını karşılayabilmek ve maksimum kazancı sağlayacak kararı vermek firmalar için çok büyük önem arz etmekte ve bunun için veri madenciliği çalışmalarına yoğunlaşılmaktadır.

2.3.VERİ MADENCİLİĞİ SÜRECİ

Kurumlar ellerindeki verileri değerlendirerek, faydalı bilgiler elde etmeyi hedeflemektedir. İş uygulamaya geldiğinde ise yaptıkları tek şey veri toplamakta kalmaktadır. Ancak veri madenciliği veri toplamak değildir ve sadece veri toplayarak faydalı bilgi elde edilememektedir. Veri madenciliği süreci, en basit şekilde veri seçiminden, yeni bilgi elde etmeye kadar tekrar eden bir döngüyü oluşturan birkaç temel adımdan oluşmaktadır:

1. Veri Seçmek: Veri madenciliğinin uygulanacağı çalışma için kullanılacak verilere karar verilen ve bu verilerin veri havuzundan alındığı aşamadır.
2. Veri Temizlemek: Farklı kaynaklardan alınan verilerin birleştirilmesi, gürültünün giderilmesi, potansiyel aşırıkların tanımlanması, hatalı verilerin çıkarılması, eksik verilerin atanması ile seçilmiş verilerin kullanılabilir hale getirilmesi aşamasıdır.
3. Veriyi ön işleme koymak: Bu aşamada, genellikle heterojen olan çoklu veri kaynakları ortak bir kaynakta birleştirilmekte, veri dönüşümlerine karar verilmekte, zamana bağlı bilgi izlenmektedir.
4. Veri dönüşümü: Seçilen verilerin içeriği değiştirilmeden madencilik prosedürü için uygun şekle dönüştürüldüğü bir evredir.
5. Veri madenciliği: İşlenmiş verilerden potansiyel olarak anlamlı ve yararlı desenleri çıkarmak için akıllı tekniklerin (veri azaltma, boyut azaltma algoritmaları, modelleri belirleme, tahminleme, çıkarım modelleri) uygulandığı önemli adımdır.
6. Model değerlendirmesi: Bu aşamada, bilgileri temsil eden, analizin amacına uygun tanımlayıcı veya tahmin edici yöntemlere karar verilmektedir.
7. Algoritmanın Belirlenmesi: Seçilen modele uygun veri madenciliği algoritmasının seçilmesidir.
8. Bilgiye Ulaşmak: Veri madenciliği sonuçlarından elde edilen anlamlı bilginin yorumlanması ve değerlendirilmesidir. Bu önemli adım, kullanıcıların veri madenciliği sonuçlarını anlamasına ve yorumlamasına yardımcı olmak için görselleştirme tekniklerini kullanmaktadır.

Bu adımlardan bazıları bir araya getirilebilir.

2.4.VERİ MADENCİLİĞİNDE KULLANILAN MODELLER

Veri madenciliğinde modelin amacına göre "tanımlayıcı veya tahmin edici model" kullanılmaktadır. Bu modeller şöyle tanımlanmıştır (Gürsoy, 2012: 5):

- Tanımlayıcı modeller: Tanımlayıcı modellerde amaç, karar vermeye rehberlik etmede kullanılabilecek mevcut verilerdeki örüntülerin tanımlanmasını sağlamaktır. Tanımlayıcı modeller, İlişki analizi ve Kümeleme analizi olmak üzere iki grupta incelenmektedir. Birliktelik Kuralları ile Ardışık Zamanlı Örüntüler ilişki analizi kapsamında yer almaktadır.
- Tahmin edici modeller: Tahmin edici modellerde sonuçları bilinen verilerden hareket edilerek bir model geliştirilmesi ve kurulan bu modelden yararlanılarak, sonuçları bilinmeyen veri kümeleri için sonuç değerlerinin tahmin edilmesi amaçlanmaktadır.

Şekil 2.1'de de görüldüğü gibi Tahmin Edici Modeller, Sembolik Yöntemler ve İstatistiksel Yöntemler olmak üzere iki ana başlık altında incelenmektedir. Karar Ağaçları ve Kural Öğrenme sembolik yöntemlerdendir. Sınıflandırma Teknikleri de İstatistiksel Yöntemlerin alt dalıdır. Yapay Sinir Ağları, Destek Vektör Makinaları, Regresyon Analizi, Bayes Öğrenmesi ve Örneğe Dayakı Öğrenme algoritmaları bunlardan en yaygın olarak kullanılan algoritmalardır.

Veri madenciliğinde, tanımlama boyutu, makine öğrenmenin ana hedefini oluşturan tahminleme boyutundan daha önemlidir (Izenman, 2008: 8).

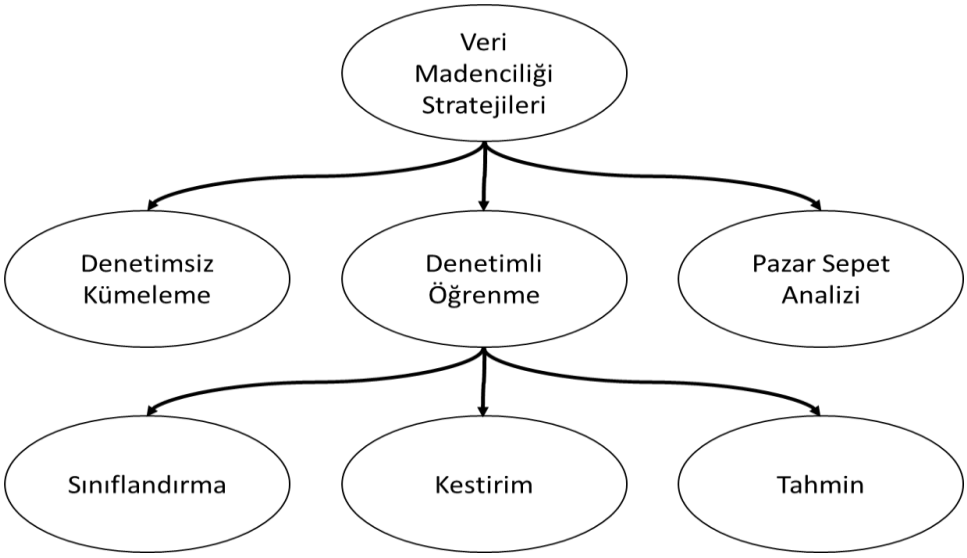
2.5.VERİ MADENCİLİĞİNİN SAĞLADIĞI YARARLAR

Veri madenciliğini etkili şekilde kullanan firmalar çok büyük kazançlar sağlayabilmekte, müşterilerin satın alma kalıpları ve davranışları hakkındaki verileri tam olarak kullanabilmekte ve sahteciliği azaltmak, kaynak kullanımını tahmin etmek, müşteri kazanım oranını artırmak ve müşteri memnuniyetini sağlamak için müşterilerin eğilimlerini daha iyi anlayabilmektedir. Ayrıca firmalar, veri madenciliğinin başarılı bir şekilde uygulanmasından sonra, veritabanları arasında gezinebilmekte ve daha önce gizli olan kalıpları tespit edebilmektedir. Örneğin,

genellikle birlikte satın alınmış, görünüşte ilgisiz ürünleri tanımlamak için perakende satış verilerinin analizi ile satın alma davranışlarını anlamamızı sağlayan modeller elde edilebilmektedir. Diğer kalıp bulma sorunları, hileli kredi kartı işlemlerini tespit etmek ve veri girişi anahtarlama hatalarını temsil edebilecek anormal verileri tanımlamaktır. Başarılı veri madenciliğinin sağladığı başlıca faydalar özetle şu şekildedir (Fernandez, 2010: 4):

- Muazzam büyüklükteki veri setleri ile çalışma imkanı sağlamak,
- Bilgisayar ve hesaplama güvenliği ile otomatik veri işleme kolaylığı sağlamak,
- Dinamik ve etkileşimli veri görselleştirme teknikleri kullanarak elde edilen bilgilerin anlaşılır olmasını sağlamak,
- Müşteri kazanımı ve kalıcılığını arttırmak,
- Sahtekarlıkları ortaya çıkarmak ve azaltmak (belirli bir işlemin bir kişinin etkinliğinin normal aralığından uzak olup olmadığını belirlemek ve doğrulama için o işlemi işaretlemek),
- Üretim kalitesini arttırmak ve üretimdeki üretim kayıplarını en aza indirmek,
- Satışı arttırmak (müşterilere, düzenli bir kredi kartına kıyasla altın kredi kartı gibi daha yüksek bir hizmet veya ürün düzeyi sunmak) ve çapraz satış yapmak (daha önce satın aldıklarına dayalı olarak müşterilere daha fazla ürün satmak),
- Pazar-sepet analizine dayalı kombinasyonlarda (belirli bir zamanda hangi ürün kombinasyonlarının satın alındığını belirleyerek) ürün ve hizmetleri satmak,
- Tüketicinin davranışları belirlenerek yeni ürün ve pazarlama stratejileri geliştirmek,
- Yapılacak bir kampanyaya tüketicilerin vereceği tepkiyi tahmin etmek,
- Pazar analizi ile tüketicinin pazarlanacak yeni bir ürüne karşı davranışını tahmin etmektir.

Veri madenciliği stratejileri Şekil 2.3'te de görüldüğü gibi pazar analizi, kümeleme ve öğrenerek sınıflandırma, kestirim, tahmin konularında bize fayda sağlamaktadır.



Şekil 2.3: Veri madenciliği stratejileri (Akkuş, Erişim Tarihi: 28.10.2017).

2.6.VERİ MADENCİLİĞİ SÜRECİNİ ETKİLEYEN KRİTİK NOKTALAR

Büyük veri setlerinin işlenmesi zordur. Veri setleri büyüdükçe, mevcut birçok algoritma dramatik bir şekilde yavaşlama, hatta durma noktasına gelme eğilimindedir. Veri madenciliğinde, sorunun boyutu veya karmaşıklığı ne olursa olsun algoritmaların iyi performans özelliklerine sahip olmaları gerekmektedir. Yani ölçeklenebilir olmalıdırlar. Ölçeklenebilirlik tanımında genel kabul gören bir tanım yoktur, ancak bu özelliğin ne anlama geldiğiyle ilgili genel fikir şudur: Ölçeklenebilirlik, sorunun karmaşıklığı arttığında algoritmanın verimli ve doğru kalabilme kabiliyetidir. En iyi senaryo, ölçeklenebilirliğin doğrusal olmasıdır. Veri madenciliğinin bir amacı, büyük veri kümelerinin istatistiksel analizi için ölçeklenebilir algoritmalar kütüphanesi oluşturmaktır. Veriler zaman vasıtasıyla toplandığında (ör. Perakende işlemleri, borsa işlemleri, hasta kayıtları, hava durumu kayıtları) örnekleme mantıklı olmayabilir. Gözlemlerin zaman sıralaması, veriyi üreten olguyu anlamak için önemlidir ve gözlemleri birbiriyle yüksek oranda ilişkili olabileceği zamandan bağımsız olarak değerlendirmek önyargılı sonuçlar sağlayabilmektedir (Izenman, 2008: 5-6).

Günümüzde piyasada bulunan veri madenciliği çözümlerinin çoğu bugün ya iyi entegre ve ölçeklenebilir değildir ya da bir veya iki modelleme tekniği veya

algoritması ile sınırlıdır. Veri madenciliği sorunu, veri miktarı ve iş problemlerinin karmaşıklığı arttıkça daha da artmaktadır. Veritabanının veri madenciliğinden farklı amaçlar için tasarlanması normaldir, bu nedenle öğrenme görevini kolaylaştıracak özellikler veya nitelikler mevcut değildir. Veri madenciliği çözümleri, modelleme için ham verileri sağlayan veritabanlarına bağımlıdır ve bu, veritabanlarının dinamik, eksik, gürültülü ve geniş olma eğiliminde olması nedeniyle sorunlara neden olmaktadır. Veri tabanları genellikle hatalarla kirlenir, dolayısıyla içerdikleri verilerin tamamen doğru olduğu varsayılamaz. Subjektif veya ölçüm kararlarına dayanan özellikler, bazı örneklerin yanlış sınıflandırılabileceği şekilde hatalara neden olabilmektedir. Özniteliklerdeki veya sınıf bilgisindeki hatalar gürültü olarak bilinmektedir. Mümkün olduğunca, üretilen kuralların genel doğruluğu etkilediğinden, sınıflandırma bilgilerinden gürültüyü ortadan kaldırmak amaçlanmaktadır. Bu nedenle, eksiksiz bir veri madenciliği çözümü sağlayan bir yazılım sisteminin benimsenmesi, rekabet ortamında çok önemlidir (Fernandez, 2010: 10).

3. MAKİNE ÖĞRENME

Bilgisayar teknolojisindeki gelişim sayesinde büyük miktarda veriyi depolayıp işlemekle birlikte, bir bilgisayar ağı üzerinden fiziksel olarak uzaktaki bilgisayarlara da erişim sağlayabilmekteyiz. Artık çoğu veri toplama cihazı dijital ve güvenilir verileri kaydedebilir. Örneğin, milyonlarca müşteriye binlerce mal satan yüzlerce mağazaya sahip bir süpermarket zincirinin satış noktası terminalleri, her bir işlemin tarih, müşteri tanımlama kodu, satın alınan mallar ve bunların miktarı, harcanan toplam para ve benzeri ayrıntılarını kaydeder. Bu, genellikle her gün gigabaytlara karşılık gelir. Süpermarket zincirinin istediği, bir ürünün muhtemel müşterilerinin kim olduğunu tahmin edebilmektir. Saklanan veriler, analiz edildiğinde ve örneğin tahminler yapmak için kullanabileceğimiz bilgilere dönüştürüldüğünde faydalı olur. Bir dondurma çeşidini ya da bir yazarın yeni kitabını kimin alacağını ya da yeni çıkan bir filmi kimin izleyeceğini tam olarak bilemiyoruz. Bilseydik, verilerin herhangi bir analizine ihtiyaç duymazdık zaten. Fakat bilemediğimiz için yalnızca veri toplayıp bu sorular verilerle cevap bulmayı umuyoruz. Gözlemlediğimiz verileri açıklayan bir süreç olduğuna inanıyoruz. Verilerin üretilmesini temel alan sürecin ayrıntılarını bilmediğimiz halde, tüketici davranışının da tamamen rasgele olmadığını biliyoruz. İnsanlar süpermarketlere gidip bir şeyler satın alır. Bira alırken cips alırlar, yaz aylarında dondurma, kış aylarında ise yaz aylarına nispeten daha çok baharat alırlar. Verilerde bazı kalıplar vardır. Süreci tamamen tanımlayamayabiliriz, ancak iyi ve kullanışlı bir yaklaşım oluşturulabileceği inancına sahibiz. Bu yaklaşım her şeyi açıklayamayabilir, ancak belirli kalıpları veya düzeni tespit edebilir. Bu tür kalıplar süreci anlamamıza yardımcı olabilir veya tahmin yapmak için bu kalıpları kullanabiliriz. Yakın gelecekte, örnek veriler toplandığında geçmişten çok fazla farklı olmayacağını varsayarsak, gelecekteki tahminlerin de doğru olması beklenebilir (Alpaydın, 2014: 1-2).

Makine öğrenme, bilgisayarların verileri temel alarak öğrenebilme durumunu veya performanslarını geliştirmesini araştırır. Ana araştırma alanı, bilgisayar programlarının karmaşık kalıpları otomatik olarak tanımayı ve verilere dayalı akıllı kararlar vermeyi öğrenmesidir. Örneğin, bir dizi örnekten öğrendikten sonra postadaki

el yazısıyla yazılan posta kodlarını otomatik olarak algılayacak şekilde bir bilgisayarı programlamak tipik bir makine öğrenme problemidir (Han vd., 2011: 24).

Makine öğrenmeyi daha iyi anlayabilmek için öncelikle öğrenmeden bahsetmek gerekirse "öğrenme"nin sözlük anlamları şunlardır:

- Eğitim, tecrübe veya öğretilmek suretiyle bir şeyler hakkında bilgi edinmek.
- Bilgi veya gözlem ile farkında olmak
- Hafızaya almak
- Bilgilendirilmek veya belirlemek
- Talimat almak

Bilgisayarlar hakkında konuşurken bu anlamlar biraz eksik kalır. İlk iki anlam için, öğrenime ulaşılıp ulaşılmadığının sınanması neredeyse imkansızdır. Bir makinenin bir şeyler hakkında bilgi sahibi olup olmadığını anlayamayız. Sadece soru sormak öğrenme yeteneğini değil, sorulara cevap verme becerisini test eder, farkında olup olmadığı anlaşılamaz. Son üç anlamda ise sadece belleğe alma ve talimat almadan bahsederek makine öğrenimi ile kastedilenden çok daha basit bir anlam yüklenmiş olur. Makine öğrenmede yeni durumlardaki performans iyileştirmeleri veya en azından performans potansiyeli ile ilgileniyoruz. Yeni bilgilere yeni koşullar uygulamak zorunda kalmadan, bir şeyleri belleğe kaydedebilir veya öğrenme ile bilgilendirilebiliriz. Birçok şey davranışlarını gelecekte daha iyi performans gösterecek şekilde değiştirir ancak gerçekten öğrendiklerini söylemek doğru olmaz. Buna iyi bir örnek rahat bir terliktir. Ayağın şeklini öğrendiği için terlik rahattır diyemeyiz. Kesinlikle bir terlik olarak daha iyi performans göstermesi için davranışını değiştirmiştir. Yine de, buna tam olarak öğrenme demek yanlış olur. Günlük dilde, zihinsel bir öğrenme türünü belirtmek için genellikle eğitim kelimesini kullanırız. Hayvanları ve hatta bitkileri eğitiriz, ancak herhangi bir anlamda canlı olmayan terlik gibi nesnelerinin eğitiminden bahsettiğimizde sözcüğü biraz esnetiriz. Ancak öğrenme farklıdır. Öğrenme, düşünmeyi ve amacı ifade eder. Öğrenen bir şey bunu kasıtlı yapmak zorundadır. Bu nedenle, bir asmanın üzüm bağında bir kafesin etrafında büyümeyi öğrendiğini söylemeyiz - bunun eğitildiğini söyleyebiliriz. Amaçsız öğrenmek sadece eğitimdir. Veya daha da önemlisi, öğrenmede amaç öğrencinin,

eğitimde ise öğretmenin olmasıdır. Bir şeyin gerçekten öğrenip öğrenmediğine karar vermek için, herhangi bir amacı olup olmadığını görmek gerekir (Witten vd.,2016: 7).

World Wide Web çok büyük ve sürekli büyümeye devam eden bir kaynaktır. Bu devasa ağda ilgili bilgileri aramak manuel olarak yapılamaz. Ancak buradan makine öğreniminin sadece bir veritabanı işlemi olduğu manası çıkarılmamalıdır; makine öğrenme aynı zamanda yapay zekanın bir parçasıdır. Akıllı olmak için, değişen bir ortamda olan bir sistem öğrenme yeteneğine sahip olmalıdır. Sistem, bu tür değişiklikleri öğrenip bunlara adapte olabiliyorsa, sistem tasarımcısının olası tüm durumları öngörmesi ve çözüm sunması gerekmez. Makine öğrenimi ayrıca, görme, konuşma, tanıma ve robotikte karşılaşılan birçok soruna çözüm bulmamıza yardımcı olur. Yüzleri tanıma örneğini ele alalım: Poz, aydınlatma, saç stili vb. farklılıklara rağmen aile üyelerini ve arkadaşlarımızı yüzlerine bakarak veya fotoğraflarından tanıyoruz. Ancak bunu bilinçsizce yapıyoruz ve nasıl yaptığımızı açıklayamıyoruz. Bunu açıklayamadığımız sürece bilgisayar programını da yazamayız. Aynı zamanda, bir yüz imgesinin sadece rastgele bir piksel topluluğu olmadığını biliyoruz, bir yüzün simetrik bir yapısı vardır. Yüzde gözler, burun, ağız belli yerlerde bulunur. Her kişinin yüzü, bunların belirli kombinasyonundan oluşan bir motiftir. Bir öğrenme programı, kişinin örnek yüz görüntülerini analiz ederek o kişiye özgü deseni yakalar ve belirli bir görüntüdeki bu deseni kontrol ederek tanır. Makine öğrenimi, örnek veriler veya geçmiş tecrübeler kullanarak bir performans kriteri optimize etmek üzere bilgisayarları programlamaktır. Bazı parametrelere kadar tanımlanmış bir model var ve bu durumda öğrenme, eğitim verilerini veya geçmiş deneyimleri kullanarak model parametrelerini optimize etmek için bir bilgisayar programının yürütülmesidir. Model, tahminlerde bulunabilir, veriden açıklayıcı bilgi edinebilir veya her ikisini birden yapabilir. Makine öğrenimi, matematik modelleri oluşturmak için istatistik teorisini kullanır; çünkü temel görevi bir örneklemden çıkarsama yapmasıdır. (Alpaydın, 2014: 3).

Makine öğrenimi hem yeni teknikler ve teorik algoritmalar önerisi hem de gerçek yaşam problemlerine uygulanmasında en verimli araştırma alanlarından biridir. Teknolojik açıdan, dünya beklenmedik bir hızda değiştiği için günümüzde nispeten ucuz bir fiyata yüksek kaliteli ve hızlı donanım kullanılabilmektedir. Akıllı bir şekilde

çevreye adapte edilebilen sistemlerin geliştirilmesi büyük bir pratik uygulamaya alanına sahiptir. Genellikle, bu sistemler belirli bir maksimizasyon / minimizasyon kriterine göre belirli bir algoritma performansını optimize ederek, deneysel verileri kullanarak çalışırlar (Olivas vd., 2009: XXVI).

Makine öğrenme, yapay zeka olarak bilinen bilgisayar bilimlerinin alt alanlarından ortaya çıkmıştır. Yapay zekanın odak noktası makineleri zeki yapmaktır. İnsanlar gibi akılcı düşünebilmek ve problemleri çözebilmek için makine öğrenme, bilgisayarların önceki deneyimlerinden "öğrenebilmesi" için bilgisayar sistemleri ve algoritmaları oluşturma ile ilgilidir. Zekâ, öğrenme olanağı olmadan elde edilemediği için, makine öğrenme yapay zekada can alıcı bir rol oynamaktadır. Bir makine, veri, programlar vb. yoluyla birikim yapabildiğinde ne zaman öğreneceğini, belirli görevler üzerindeki performansının zaman içinde geliştiğini ve yeni bilgiler geliştirebildiğini öğrenir. Tecrübelerden öğrenme fikri, makine öğrenmede karşılaşılan çeşitli sorun türlerinin, özellikle sınıflandırma ile ilgili problemlerin (örn., El yazısı rakam tanıma, konuşma tanıma, yüz tanıma, metin sınıflandırma) merkezidir. Bu sorunların her birinin genel amacı, gelecekteki bir örneği (örn. El yazısı örneği, sözlü bir sözcük, yüz imgesi, metin parçası) sınıflandırmanın sistematik bir yolunu bulmaktır. Sınıflandırma, gelecekteki örnek üzerinde benzer örneklerden daha önce öğrenme (ya da eğitim) ile elde edilmiş bilgilere dayanarak yapılır. Büyük ve karmaşık veri setlerini analiz etmek için yeni yöntemler ve terimler yaratma ihtiyacı, istatistik, kalıp tanıma, sinir ağları, sembolik makine öğrenme, hesaplama öğrenme teorisi ve yapay zeka gibi birçok disiplindeki araştırmacıların birlikte çalışmasına yol açmaktadır. Bu ortak çalışma ise makine öğrenmenin gelişimini sağlamaktadır (Izenman, 2008: 9).

Çevremizde davranışlarını gözlemleyebileceğimiz olaylar gerçekleşmektedir. Örneğin, güneş etrafındaki gezegenlerin yörüngelerindeki hareketleri veya gelgitlerin zamanlaması gözlemlenerek öğrenilebilmektedir. Makine öğrenmede bu davranışlara dayalı kalıpları keşfetmek ve tanımlamak için bilgisayarlar kullanılmaktadır. Sınıflamada, bir nesne ya bir nesne sınıfına aittir ya da ait değildir. Bir kedinin memeliler sınıfına ait olduğu kolayca tespit edilebilir veya bir karga görüldüğünde bunun kuşlar sınıfına ait olduğu kabul edilebilir. Soyut konuşma olarak, söz konusu

etiketlerdeki bazı olaylarla bağlantılı olarak bazı işlemlerin, söz konusu sınıfa ait oldukları takdirde doğru oldukları veya sınıfa ait olmadıklarında yanlış oldukları düşünülebilir. Yani, memeli (kedi) = doğru ve memeli (karga) = yanlış ya da kuş (kedi) = yanlış ve kuş (karga) = doğru denilebilir. Burada, memeli ve kuş, sırasıyla, memelilerin sınıfına ve kuş sınıfına göre herhangi bir nesne için etiket sağlayan işlemlerdir. Etiketlerin {doğru, yanlış} isimleri isteğe bağlıdır; doğru ve yanlış yerine D ve Y, 0 ve 1, ya da mavi ve yeşil gibi etiketler de kullanılabilir. Yani bir sınıfa ait olan ve o sınıfa ait olmayan elemanlar için veri seti iki ayrı etiket içermektedir. Sınıflandırma sorunları ikiden fazla olasılıkla da düşünülebilir. Tipik olarak sınıflandırmalar bir hayvanın memeliler veya kuşlar sınıfına etiketlenmesi kadar kolay değildir ve genel olarak nesnelerin etiketleri bizim tarafımızdan yapılan bir şey değil, var olan bir durum veya bir sonuçtur. Bu süreçlerin sonuçları ancak gözlemlenebilir. Makine öğrenmenin amacı daha sonra orijinal işleme mümkün olduğunca yakın olan etiketleme işlemi için uygun bir model ortaya koymaktır (Hamel, 2011: 6).

Makine öğrenme yöntemlerinin büyük veritabanlarına uygulanmasına ise veri madenciliği denir. Veri madenciliği imalat, optimizasyon, kontrol ve sorun giderme vb. için öğrenme modelleri kullanmaktadır. Telekomünikasyonda, şebeke optimizasyonu ve hizmet kalitesini en üst düzeye çıkarmak için arama şablonları analiz edilmektedir. Fizik, astronomi ve biyoloji gibi bilim dallarında çok büyük miktarda veri olduğundan dolayı bu veriler ancak bilgisayarlar tarafından hızlı bir şekilde analiz edilebilmektedir (Alpaydın, 2014: 2-3).

Makine öğrenmenin en cazip özelliklerinden biri, desen tanıma (sinir ağları, destek vektör makineleri, karar ağaçları, takviye öğrenmesi, ...), veri madenciliği (zaman serisi tahmini, modelleme, ...), istatistik (Bayesci yöntemler, Montecarlo yöntemleri, önyükleme, ...) veya sinyal işleme (Markov modelleri).gibi farklı alanlardan gelen bilgileri bir araya getirmesidir. Bu nedenle, Makine öğrenme bu alanların sinerjisinden yararlanmakta ve böylece farklı bilgi alanları kullanan sağlam çözümler sağlamaktadır (Olivas vd.,2009: XXVI).

Makine öğrenme topluluğu, öğrenme problemlerini çeşitli kategorilere bölmektedir:

- Denetimli Öğrenme (Supervised Learning)
- Denetimsiz Öğrenme (Unsupervised Learning)
- Pekiştirerek Öğrenme (Reinforcement Learning)

Denetimli öğrenme temel olarak sınıflandırma ile eşanlamlıdır. Öğrenmedeki denetim, eğitim veri setindeki etiketli örneklerden gelmektedir. Örneğin, posta kodu tanıma probleminde, sınıflandırma modelinin öğrenimini denetleyen eğitim örnekleri olarak bir dizi el yazısı posta kodu görüntüsü ve bunlara karşılık gelen makine tarafından okunabilir çeviriler kullanılmaktadır (Han vd., 2011: 24).

Denetimli öğrenmede öğrenme algoritmasında açık bir "denetimci" tarafından sağlanan sürekli veya kategorik girdi değişkenleri ve denetimci tarafından etiketlenmiş bir çıktı değişkeni vardır. Denetimli öğrenmede, girdi ve çıktı değişkenleri arasındaki ilişkiler incelenmektedir. Sistem, istenen çıktıya yaklaşmak için girdi-çıktı değişkenleri arasında bir ilişki bulmaya çalışmaktadır. Sürekli bir çıktı değişkeni bir regresyon problemi verirken, kategorik bir çıktı değişkeni sınıflandırma problemi doğurmaktadır. Denetimli öğrenmede olası girdi yoğunluğunun tahmin edilmesi, sınıfların araştırılması, yakınlık haritalarının çizilmesi, aykırı değerlerin bulunması veya eksik verilerin atanması gibi belirli girdi değişkenlerinin özellikleri keşfedilmektedir (Izenman, 2008: 10).

Denetimsiz öğrenmede uygun bir çıktı değişkenini tanımlamak için mevcut hiçbir bilgi veya etiket bulunmamaktadır, sadece girdi verileri vardır. Sistem, veriler arasındaki ilişkileri bulmaya ve öğrenmeye çalıştığı için bu yöntem sıklıkla "bilimsel keşif" olarak anılmaktadır (Izenman, 2008: 10).

Denetimsiz öğrenme aslında kümeleme ile eşanlamlıdır. Eğitim verisinde küme etiketi olmadığından, öğrenme süreci denetlenmemekte ve bu yüzden bir denetimci bulunmamaktadır (Han vd., 2011: 25).

Pekiştirerek öğrenmede, sistem doğru davranışın örneklerini görmemektedir. Bunun yerine sadece denediği eylemler için pozitif ve negatif ödüller elde etmektedir. Pekiştirerek öğrenme, verilmiş bir ödülü maksimize etmek için ne yapılacağının öğrenilmesidir. Bu stratejide denetçi her girdi seti için çıktı setini sisteme göstermek

yerine, sistemin girdilere karşılık çıktısını üretmesini beklemekte ve üretilen çıktının doğru veya yanlış olduğunu gösteren bir sinyal üretmektedir. Sistem, denetçiden gelen bu sinyali dikkate alarak öğrenme sürecini devam ettirmektedir (Tolun, 2015: 16).

Veri madenciliği ve makine öğrenme arasında pek çok benzerlik olduğunu görülmektedir. Sınıflama ve kümeleme görevleri için, makine öğrenme araştırması genellikle modelin doğruluğuna odaklanmaktadır. Veri madenciliği araştırması, doğruluğa ek olarak, büyük veri setleri üzerindeki madencilik yöntemlerinin etkinliği ve ölçeklenebilirliğinin yanı sıra karmaşık veri türlerini ele alma ve yeni alternatif yöntemleri keşfetme yolları üzerinde yoğunlaşmaktadır (Han vd., 2011: 26).

3.1.MAKİNE ÖĞRENMENİN TARİHSEL GELİŞİMİ

Hesaplama yaklaşımlarının öğrenmeye olan ilgisi 1950'lerin ortalarında başlamıştır. İlk öğrenme teknikleri, sayısal şifreleme (encoding) ve parametre-ayarlaması (parameter-tuning) tekniklerine odaklanmıştır. 1960'ların ortalarına kadar makine öğrenmedeki ilk araştırmalar yapay zekâdan çok, örüntü tanıma alanında yapılmıştır. İlk öğrenen makine modeli Perceptron, F. Rosenblatt tarafından önerilmiştir. Bu, öğrenme işlemlerinin matematiksel analizinin gerçek anlamda başladığı zamandır. İstatistiksel öğrenme teorisi 1968 yılında geliştirilmiştir. 1986'da öğrenen makinenin genel tipini kurmada bir adım daha atılmıştır. Bu tekniğin adı geri-yayılım (back-propagation)'dır. 1989'da "Ampirik Risk Minimizasyonu" tümevarım prensibi ve "Maksimum Benzerlik" (Maximum Likelihood) yönteminin tutarlılığı için gerek ve yeter şartlar bulunmuştur. 1990'larda genelleme kabiliyetini kontrol eden yeni öğrenen makinelerin sentezi başlamıştır. Bunların arasında en çok göze çarpan "Destek Vektör Makineleri"dir (Tolun, 2015: 5).

3.2.SINIFLANDIRMA

Sınıflandırma kavramı, veriyi sahip olduğu niteliklere göre veri kümesinde bulunan sınıflara dağıtmaktır. Bu sınıfların özellikleri ve sayısı önceden belirlidir. Veri kümesindeki bu sınıfları belirten değerler etiket olarak adlandırılmaktadır. Veri setindeki her örneğin sınıf bilgisi de dahil olmak üzere çeşitli özellikleri mevcuttur. Sınıflandırmada eğiticili bir öğrenme söz konusudur. Eğitim kümesindeki öğelerin sınıfları bellidir ve bu küme bir model oluşturmak için kullanılmaktadır. Sınıflandırma

algoritmaları, verilen eğitim kümesindeki sınıf etiketleri ile diğer özellikler arasındaki ilişkileri analiz edip öğrenme işlemini gerçekleştirmektedir. Kurulan model öğenme kümesinde olmayan öğelerle denenip modelin başarısı ölçülmektedir. Sınıflandırma algoritmalarının çalışması, eğitim verisi ile öğrenme ve öğrenme sonucu test verisinin sınıflandırılması aşamalarından oluşmaktadır. Sonuç olarak yeni gelen öğenin hangi sınıfa ait olduğuna kurulan ve test edilen bu model yardımı ile karar verilmektedir.

Sınıflandırma algoritmaları aşağıda yer alan ana başlıklar altında incelenmektedir:

3.2.1. Bayes Ağları Algoritmaları

Bayes Ağları algoritmaları, Bayes Teoremine göre verinin hangi sınıfa ait olacağının olasılık tahminini yapmaktadır. Teşhis gibi performans görevlerinde kullanışlı oldukları için makine öğreniminde umut verici bir temsil sağlamaktadır. Bu algoritmalar, hem gerçek dünya verisinde iyi çalışır hem de öğrenme yöntemlerini keşfeden makine öğrenmede önemli bir araştırma alanıdır.

Naif Bayes sınıflandırıcısı, olasılık bilgisini temsil etmek, kullanmak ve öğrenmek için net anlamlı basit bir yaklaşım sağlamaktadır. Yöntem, performans hedefinin test örneklerinin sınıfını doğru bir şekilde tahmin etmek ve eğitim örneklerinin sınıf bilgisini içerdiği gözlemlenen tümevarım görevlerinde kullanılmak üzere tasarlanmıştır. Böyle bir sınıflandırıcı, basit iki önemli varsayıma dayandığı için naif olarak adlandırılan Bayes ağının özel bir formu olarak görülmektedir. Özellikle, tahmin özelliklerinin verilen sınıftan bağımsız olduğu göz önüne alınmakta ve tahmin sürecini hiçbir gizli veya ortada olmayan özelliklerin etkilemediği varsayılmaktadır. Bu varsayımlar, sınıflandırma ve öğrenme için çok etkili algoritmaları desteklemektedir. Genel bir varsayım, her sınıfta sayısal özelliklerin değerlerinin normal olarak dağılmasıdır. Her sınıf ve nominal özellik için, sınıf göz önüne alındığında, özelliğin alacağı kendi alanındaki her bir değerin olasılığı tahmin edilmektedir. Her sınıf ve sürekli özellik için, verilen sınıf özelliğinin ortalama ve standart sapmasını tahmin etmektedir. Bu parametrelerin maximum likelihood (maksimum olasılık) tahminleri basittir. Nominal rastgele bir değişkenin belirli bir değer aldığı tahmini olasılık, örneğin frekansına eşittir - bu değerin gözlenme sayısının toplam gözlem sayısına bölünmesiyle elde edilmektedir. Normal dağılıma ait ortalama

ve standart sapmanın maksimum olasılık tahminleri örneklem ortalaması ve örnek standart sapmasıdır. Özetle, Naif Bayes tümevarım problemine basit ve etkili bir yaklaşım sağlamaktadır. Bununla birlikte, genellikle, sayısal özelliklerin bazı alanlar için geçerli olmayabilecek bir Gauss dağılımına uyduğu varsayımına dayanmaktadır. Bu, sürekli dağılımı tahmin etmek için diğer yöntemleri keşfetmesi gerektiğini göstermektedir (John ve Langley, 1995: 339-340).

3.2.2. Tembel (Lazy) Algoritmalar

Tembel (lazy) algoritmaların diğer yöntemlerden en büyük farkı öğrenme kümesini saklamasıdır. Diğer yöntemlerde öğrenme aşamasında yapılan işlemler, bu yöntemde tahminleme aşamasında yapılmaktadır. Sınıflandırılacak yeni bir örnek geldiğinde, en benzer özelliklerin olduğu sınıfa atanmaktadır.

*K * (K Star)*, örnek tabanlı bir sınıflandırıcıdır, başka bir deyişle, bir test örneğinin sınıfı, bazı benzerlik fonksiyonlarıyla belirlendiği şekilde, benzer eğitim örneklerinin sınıfına dayanmaktadır. Entropi tabanlı bir mesafe işlevi kullanması ile diğer örnek tabanlı öğrenicilerden farklıdır. K* kesinlikle mesafe fonksiyonu değildir. Örneğin, K* genel olarak sıfırdan farklıdır ve işlev simetrik değildir. Uzaklık ölçüsü olarak entropiyi kullanmasının birçok yararı vardır. Sembolik nitelikleri, değerli öznitelikleri ve kayıp değerleri tutarlı bir şekilde ele almaktadır (Cleary ve Trigg, 1995: 108-110). Entropi, rastgeleliğin, düzensizliğin ve belirsizliğin ölçüsüdür.

Nesneye dayalı (örnek tabanlı) öğrenme (IBL) algoritmaları, belirli örneklerden türetilmiş bir soyutlama yapmamaktadır. Bu yaklaşım, geniş depolama gereksinimine sahip en yakın komşu algoritmasını genişletmektedir. Örnek tabanlı öğrenme algoritmaları, en yakın komşu model sınıflandırıcısından türetilmektedir. Sınıflandırılmış tahminler oluşturmak için seçilen örnekleri kaydeden ve kullanan düzenlenmiş en yakın komşu algoritmalarına çok benzemektedirler. Örnek tabanlı öğrenme algoritmaları, artımlıdır ve amaçları, daha sonra sunulan örneklerde sınıflandırma doğruluğunun en üst düzeye çıkarılmasıdır. Düzenlenmiş en yakın komşu (ENN) algoritmaları ise artımsızdır ve birincil amacı, ilk eğitim seti ile mükemmel tutarlılığı korumaktır. Verileri özetlemelerine rağmen, yeni örneklerde sınıflandırma doğruluğunu en üst düzeye çıkarmaya çalışmamaktadırlar. Bazı gerçek

dünya problemlerini göz ardı ettiği için düzenlenmiş en yakın komşu algoritmaları kırılgandır (Aha vd., 1991: 38).

K-en yakın komşu (kNN) algoritmaları, bir örneği en benzer örneklerin çoğunluğunun oyuna göre sınıflandırmaktadır. Sınıflandırma kararları almak için k> 1 adet kabul edilebilir örneğe ihtiyaç duyulmaktadır. Kayıt edilen örneklerin azı, erken eğitim aşamaları sırasında kabul edilebilmektedir. Bu nedenle, bazıları sınıflandırılan örnekle göreceli olarak farklıdır (Aha vd., 1991: 60-61). Komşuların uzaklığı Öklid uzaklığı ile ölçülmektedir. Weka'da kNN algoritması IBk algoritması olarak bulunmaktadır.

Makine öğrenme sistemleri tarafından kullanılan sınıflandırma kuralları, iki kritere göre değerlendirilmektedir; bunlar bağımsız bir test kümesindeki sınıflandırmanın doğruluğu ve karmaşıklığıdır. Bu iki kriter arasındaki ilişki makine öğrenme topluluğu için önemli bir alandır (Holte, 1993: 63).

3.2.3. Kural Tabanlı Algoritmalar

Karar tabloları, eğitim setindeki verilerin özellikleri ile oluşturulan ve sınıflandırma yapan bir karar tablosudur. Mümkün olan en basit hipotez alanlarından biridir ve genellikle anlaşılması kolaydır. Deneysel sonuçlar, yalnızca ayrık özellikler içeren suni ve gerçek dünya alanlarında, karar tablolarını kullanan bir algoritma olan IDTM'nin, bazen C4.5 gibi son teknoloji algoritmalardan daha iyi performansa sahip olabildiğini göstermektedir. Şaşırtıcı bir şekilde, sürekli özelliklere sahip bazı veri kümeleri üzerinde performansı oldukça iyidir; bu, makine öğrenmede kullanılan birçok veri kümesinin bu özelliklere gereksinim duymadığını veya bu özelliklerin çok az değer taşıdığını göstermektedir. Artımlı çapraz doğrulamayı kullanarak, belirli bir veri kümesini ve zaman içinde IDTM'yi, örneklerin sayısıyla, özellik sayısıyla ve etiket değerleri sayısıyla doğrusal olarak çapraz doğrulama yapmak mümkündür. Etiketli örneklerin bir veri kümesi göz önüne alındığında, denetlenen makine öğrenme algoritmaları, gelecekte etiketlenmemiş örneklerin sınıfını doğru bir şekilde tahmin edecek bir hipotez aramaktadır (Kohavi, 1995: 174).

0-R (Zero-R), sınıflandırıcı oluşturan ve kullanan için bir sınıflandırma türüdür. Ortalama değeri (sayısal bir sınıf için) veya modu (nominal bir sınıf için) öngörmektedir.

1-R (One-R), adı verilen belirli kurallar, bir nesneyi tek bir nitelik temelinde sınıflandıran kurallardır (diğer bir deyişle, bunlar 1 düzeyli karar ağaçlarıdır). 1-R (1-düzeyli kurallar) sınıflandırıcı oluşturmak ve kullanmak için kullanılan bir sınıflandırma türüdür. Başka bir deyişle, sayısal öznitelikleri ayırma tahmini için minimum hata özniteliğini kullanmaktadır. 1-R her açıdan sıradandır, eğitim setindeki hata oranına göre nitelikleri sıralamaktadır. Sayısal değerli tüm nitelikleri sürekli olarak ele alır ve değer aralığını birkaç ayrık aralıklarla bölmek için basit bir yöntem kullanmaktadır. Sürekli değerli niteliklere sahip veri kümelerinde çok fazla değişkenli veya parametreli modele uyumlu olma riski vardır. Sürekli değer aralıklarının sonlu sayıda aralıklara bölünmesinde, her aralığı aynı sınıftan olan örnekleri içeren "saf" hale getirme eğilimi vardır. Ancak tüm yapraklar saf olana kadar bir karar ağacının derinleşmesiyle çok değişkenli/parametreli modeller meydana gelebilmekte, bu nedenle tüm alt aralıklar saf olana kadar bir aralığın alt bölümlere bölünmesinden oluşabilmektedir. Bunu önlemek için 1-R, tüm aralıkların aynı sınıfta önceden tanımlanmış sayıda örnek içermesini gerektirmektedir. Benzer bir güçlük bazen nominal özelliklerle ortaya çıkmaktadır. Örneğin, bir tıbbi veri kümesindeki bir hastanın adı gibi, her örneği benzersiz şekilde tanımlayan nominal bir nitelik olan bir veri kümesi olsun; bu özniteliği kullanarak, belirli bir eğitim setini %100 doğru bir şekilde sınıflandıran bir 1-R oluşturabilmektedir (Holte, 1993: 63-65).

3.2.4. Karar Ağacı Algoritmaları

Karar ağacı algoritması, tüm veri öğeleri belirli bir sınıfa ait olana kadar derinlik - ilk açgözlü yaklaşımı veya genişlik - ilk yaklaşımı kullanarak bir veri kümesini yinelemeli olarak bölen bir veri madenciliği başlatma tekniğidir. Bir karar ağacı yapısı, kök, iç ve yaprak düğümlerinden oluşmaktadır. Ağaç yapısı, bilinmeyen veri kayıtlarını sınıflandırmada kullanılmaktadır. Ağacın her iç düğümünde, en iyi bölünme kararı, safsızlık ölçümleri kullanılarak yapılmaktadır. Ağaç yaprakları, veri öğelerinin gruplandırıldığı sınıf etiketlerinden oluşmaktadır. Karar ağacı sınıflandırma tekniği iki

aşamada gerçekleştirilmektedir: ağaç büyütme ve ağaç budama. Ağaç büyütme yukarıdan aşağıya doğru yapılmaktadır. Bu aşamada, ağacın tüm veri öğeleri aynı sınıf etiketine gelene kadar tekrar tekrar ayrılmaktadır. Eğitim verisi seti tekrar tekrar geçildiğinden çok görev ve hesaplama yoğunluğu vardır. Ağaç budama aşağıdan yukarıya doğru yapılmaktadır. Aşırı uyum gürültüyü veya eğitim verisinde daha fazla detayı en aza indirgeyerek algoritmanın tahmin ve sınıflandırma doğruluğunu iyileştirmek için kullanılmaktadır. Karar ağacı algoritmasında gereğinden fazla aşırı uyum yanlış sınıflandırma hatasına neden olmaktadır. Ağaç budamada, eğitim veri seti yalnızca bir kez tarandığından, ağaç büyütme evresine kıyasla daha az görev vardır (Anyanwu ve Shiva, 2009: 231).

ID3 (İteratif Dichotomiser 3) karar ağacı algoritması, 1986'da Quinlan Ross tarafından tanıtılmıştır. Hunt'ın algoritmasına dayanmaktadır ve seri olarak uygulanmaktadır. Diğer karar ağacı algoritmalarında olduğu gibi ağaç da iki aşamalı olarak oluşturulmuştur; ağaç büyütme ve ağaç budama. Veriler, ağaç büyütme aşamasında sırayla her düğümde sıralanır ve en iyi bölünen tek nitelik seçilmektedir. ID3, bölme özniteliğini seçerken bilgi kazancı ölçütü kullanılmaktadır. Ağaç modelinin oluşturulmasında yalnızca kategorik nitelikleri kabul etmektedir. Eğitim veri setinde çok fazla gürültü ya da detay varsa, ID3 doğru sonuç vermemekte, dolayısıyla ID3'le karar ağacı modeli oluşturulmadan önce yoğun bir veri ön işlemi uygulanmaktadır (Anyanwu ve Shiva, 2009: 233).

C4.5 algoritması, Quinlan Ross (1993) tarafından geliştirilen bir gelişmiş IDE3 algoritmasıdır. Hunt'ın algoritmasına dayanır ve ayrıca IDE3 gibi seri olarak uygulanmaktadır. Budama C4.5'te iç düğümün bir yaprak düğümüyle değiştirilmesi ve böylece hata oranının düşürülmesi ile gerçekleşmektedir. C4.5, IDE3'ten farklı olarak, karar ağacını oluşturmak için hem sürekli hem de kategorik nitelikleri kabul etmektedir. Ağaç budaması gelişmiş bir yöntemle, gürültüye bağlı yanlış sınıflandırma hatalarını veya eğitim veri setinde çok fazla ayrıntıyı azaltmaktadır. IDE3 gibi, veriler en iyi bölünme niteliğini belirlemek için ağacın her düğümünde sıralanmaktadır (Anyanwu ve Shiva, 2009: 233).

J48 algoritması, kesilmiş veya hazırlanmamış C4.5 karar ağacı oluşturmak için kullanılan, yukarıdan aşağıya doğru bir karar ağacı yapısı oluşturan ve yaprakları sınıf etiketini ifade eden bir sınıflandırma türüdür.

Random Forest (rasgele ormanlar), ağaç tahminleyicilerinin bir kombinasyonu olup, her ağaç, bağımsız olarak örneklenmiş rastgele bir vektörün değerlerine ve ormandaki tüm ağaçlar için aynı dağılıma bağlıdır. Sınıflandırma doğruluğundaki belirgin gelişmeler, bir grup ağaç yetiştirmesinden ve en popüler sınıf için oy kullanmalarından meydana gelmiştir. Bu toplulukları büyütmek için, çoğunlukla topluluktaki her ağacın büyümesini yöneten rastgele vektörler üretilmektedir. Çok sayıda ağaç üretildikten sonra en popüler sınıfa oy verilmektedir. Bu prosedürler "rasgele ormanlar" olarak adlandırılmaktadır. Rastgele orman, {k} bağımsız olarak eşit dağılmış rastgele vektörken ve her ağaç, x girişindeki en popüler sınıf için bir birim oy kullanırken, ağaç yapılı sınıflandırıcılardan {h (x, k), k = 1, ...} oluşan bir koleksiyonu içeren bir sınıflandırıcıdır. Ormanlar için genelleme hatası ormandaki ağaçların sayısı arttıkça bir sınıra yakınsamaktadır. Sınıflandırıcı ağaçlardan oluşan ormanın genelleme hatası, ormandaki bireysel ağaçların mukavemetine ve aralarındaki ilişkiye bağlıdır. İç tahminler hata, güç ve korelasyonu izlemekte ve bunlar bölme işleminde kullanılan özelliklerin sayısının artırılmasına tepki göstermek için kullanılmaktadır. Değişken önemini ölçmek için de iç tahminler kullanılmaktadır. Breiman'in yöntemine göre orijinal eğitim setindeki çıktıları rasgele seçerek yeni eğitim setleri üretilmektedir. Başka bir yaklaşım, eğitim kümesindeki örnekler üzerinde rasgele bir ağırlık kümesinden eğitim kümesini seçmektir. Ho'nun yönteminde ise her ağacı büyütmek için kullanılacak özelliklerin bir alt kümesini rasgele seçen "rasgele altuzay" yöntemi kullanılmaktadır (Breiman, 2001: 5-6).

3.2.5. Sınıflandırmada Kullanılan Fonksiyonlar

Yapay sinir ağları (YSA), insan beyninden esinlenerek geliştirilmiş, biyolojik sinir ağlarını taklit ederek öğrenen, ağırlıklı bağlantılar aracılığıyla birbirine bağlanan ve her biri kendi belleğine sahip işlem elemanlarından oluşan paralel ve dağıtılmış bilgi işleme yapılarında oluşan bilgisayar sistemleridir. Yapay sinir ağları, öğrenme yolu ile

herhangi bir yardım almadan otomatik olarak yeni bilgiler elde edebilme ile geliştirilmiştir (Namlı, 2012: 56).

Destek vektör makineleri (support vector machines), veriyi birbirinden ayırmak için en uygun fonksyonun tahmin edilmesi esasına dayanan, tahmin edilen bu doğrusal veya doğrusal olmayan fonksiyon yardımıyla sınıflandırma ve regresyon problemlerini analiz eden istatistiksel bir yöntemdir (Namlı, 2012: 59).

Destek Vektör Regresyonu (support vector regression), regresyon yapan destek vektör makineleridir. Öğrenme sonucu bir fonksiyonun tahmin edilmesi regresyon problemidir. Destek vektör regresyonlarında regresyon riskini minimize eden bir fonksiyon bulunmaya çalışılmaktadır (Namlı, 2012: 63-64).

Lineer (Doğrusal) Regresyon, bir değişken ve bu değişkeni etkileyen bir veya daha fazla değişken arasındaki ilişkiyi doğrusal bir model ile ifade eden yöntemdir.

3.2.6. Bileşik Makine Algoritmaları

Bagging algoritması, özgün eğitim setlerinin alt kümeleri ile çalışmaktadır. Her bir alt küme, bir eğitim seti olarak kullanılmakta ve bir sınıflandırıcı oluşturmaktadır. Bu sınıflandırıcılar bir birleşik sınıflandırıcı tarafından bileştirildiği için bu algoritmaya Bagging (torbalama) ismi verilmiştir (Özhan, 2014: 1188).

Via Regression algoritması, karar ağaçlarının bir türü olan lineer regresyon fonksiyonları ile karar ağacının yapısını oluşturmaktadır (Özhan, 2014: 1188).

Cost Sensitive Classifier algoritması, temel sınıflandırıcısını maliyete duyarlı hale getiren bir meta sınıflandırıcıdır. Maliyet hassasiyetini ortaya koymak için iki yöntem kullanılmaktadır; her sınıf için belirlenen toplam masrafa göre eğitim örneklerini yeniden ağırlıklandırmak veya minimum beklenen yanlış sınıflandırma maliyetiyle sınıfı tahmin etmektir. Temel sınıflandırıcının olasılık tahminlerini iyileştirmek için genellikle bir Bagging sınıflandırıcı kullanarak performansı iyileştirilebilmektedir (Singh vd., 2013: 24).

Additive Regression algoritması, regresyon tabanlı bir sınıflandırıcının performansını arttıran bir meta sınıflandırıcıdır. Tahmin, her sınıflandırıcının tahminlerini ekleyerek

gerçekleştirilmektedir. Öğrenme oranı parametresinin azaltılması, gereğinden fazla uyumu önlemeye yardımcı olmakta ve yumuşatma etkisi göstermektedir, ancak öğrenme süresini artırmaktadır (Baskin vd.,1999: 26).

Filtered Classifier algoritması, rastgele bir filtreden geçirilen veriler üzerinde rastgele sınıflandırıcı çalıştırmak için kullanılan bir yöntemdir. Sınıflandırıcı gibi, filtrenin yapısı da yalnızca eğitim verilerini temel almakta ve test örnekleri, yapılarını değiştirmeden filtre tarafından işlenmektedir (Erdoğan, 2017: 24).

Boosting algoritması, herhangi bir öğrenme algoritmasının performansını artırmak için genel bir yöntemdir. Teorik olarak, Boosting sürekli rastgele tahminden biraz daha iyi olması gereken sınıflandırıcıları sürekli üreten "zayıf" öğrenme algoritmasının hatasını önemli ölçüde azaltmak için kullanılabilmektedir. Boosting, eğitim verisi üzerindeki çeşitli dağılımlar üzerinde belirli zayıf bir öğrenme algoritmasını tekrar tekrar çalıştırarak ve zayıf öğrencinin ürettiği sınıflayıcıları tek bir bileşik sınıflandırıcıya birleştirerek çalışmaktadır. Teorik sonuçlarla vaat edilen ilerlemenin potansiyel yararlarına rağmen, Boosting'in gerçek pratik değeri ancak "gerçek" öğrenme problemleri üzerindeki metodu test ederek değerlendirilebilmektedir (Freund ve Schapire, 1996: 1). WEKA'da bir Boosting algoritması olan AdaBoostM1 algoritması yer almaktadır.

Random Sub Space algoritması, eğitim verisi üzerinde en yüksek doğruluğu korumakta ve karmaşıklık arttıkça genelleme doğruluğunu geliştiren bir karar ağacı tabanlı sınıflandırıcıyı oluşturmaktadır. Sınıflandırıcı, sistematik olarak, özellik vektörünün bileşenlerinin alt gruplarını rastgele seçerek oluşturulan birden fazla ağaçtan yani, rasgele seçilen altuzaylarda inşa edilmiş ağaçlardan oluşmaktadır (Wei ve Patel, 2012: 8).

İstatistikteki en önemli görevlerden biri, bir tahminleyici veya sınıflandırıcının doğruluğunu değerlendirmektir. Genellikle kullanılan tahminin doğruluk ölçütü, genel olarak "tahmin hatası" olarak tanımlanan hata ölçüsüdür: Bir regresyon probleminde, hata, gerçek çıkış değeri ile buna karşılık gelen tahmini çıktı değeri arasındaki fark olan tahmin hatalarının karesinin ortalamasıdır; yani bir sınıflandırma probleminde,

bir elemanın yanlış sınıflandırma olasılığıdır (Izenman, 2008: 10). Gözlenen değerlerle gerçek değerler arasındaki farkın küçük olması sınıflandırıcın doğru sınıflandırdığını göstermektedir (Özhan, 2014: 1189).

3.3.MAKİNE ÖĞRENME ALGORİTMALARI İLE İLGİLİ LİTERATÜR ÇALIŞMASI

Aha vd. (1991)'nin yaptıkları çalışmada, yalnızca belirli örnekleri kullanarak sınıflandırma tahminleri üreten, örnek tabanlı öğrenme adı verilen bir çerçeve ve metodoloji açıklanmıştır. Bu yaklaşım, geniş depolama gereksinimlerine sahip en yakın komşu algoritmasını genişletilmiş, en yakın komşu model sınıflandırıcısının sağlam uzantıları tanımlanmış, yetenekleri analiz edilmiş ve ampirik davranışları artan, üstün öğrenme uygulamaları içerisinde tanımlanmıştır. Öğrenme hızında ve sınıflandırma doğruluğunda, en azından küçük fedakarlıklar ile depolama gereksinimlerinin nasıl önemli ölçüde azaltılabileceği açıklanmıştır. Depolama azaltıcı algoritmanın, birkaç gerçek dünya veritabanında iyi performans göstermesine rağmen, eğitim örneklerinde performansı düşmüştür. Bu nedenle, gürültülü örnekleri ayırt etmek için bir anlamlılık testi ile model genişletilmiştir.

Wolpert 1992, çalışmasında bir veya daha fazla genellemecinin genelleme hata oranını en aza indirgemeyi amaçlamıştır. Yığılmış genellemeyi tanıtıp; yığınlanmış genellemenin metni fonemlere çeviren NETtalk görevi için ayrı genelleştiriciler kümesinde nasıl geliştiğini gösteren ve yığınlanmış genellemenin tek bir yüzey montajcısının performansını nasıl geliştirdiğini gösteren iki sayısal deney sunmuştur.

Holte (1993), yaptığı çalışmada örnekleri tek bir nitelik temelinde sınıflandıran kuralların doğruluğunu ampirik olarak incelemiştir. Örneklerden öğrenen 1-R ve C4 programları, makine öğrenme araştırmasında yaygın olarak kullanılan on altı veri kümesi ile test etmiş ve sonuçları karşılaştırmıştır. 1-R'nin kuralları, hemen hemen tüm veri kümelerinde C4'ün budama karar ağaçlarına göre biraz daha az doğruluk oranı sağlamıştır.

John ve Langley (1995)'in çalışmalarında, normallik varsayımından vazgeçilip parametrik olmayan yoğunluk tahmini için istatistiksel yöntemler kullanılmıştır. Naif

Bayes sınıflandırıcısı için, normalliği varsayıp her dağılımı tek bir Gauss ile modelleyerek ve parametrik olmayan çekirdek yoğunluk tahmini kullanarak iki yoğunluk kestirim yöntemi karşılaştırılmıştır.

Freund ve Schapire (1996), AdaBoost'un gerçek öğrenme problemlerinde ne kadar iyi performans gösterdiğini değerlendirmek için bazı deneyler yapmıştır. Çeşitli sınıflandırmaları toplamak için Boost algoritmasını Breiman'ın Bagging algoritması yöntemiyle karşılaştırmış, iki yöntemin performansını, makine-öğrenme kriterlerine göre karşılaştırmıştır. Bir diğer deney setinde, en yakın komşu sınıflandırmasını kullanarak performans değerlerini daha ayrıntılı olarak incelemiştir.

Hanley ve Hand (1997)'nin yaptığı çalışmada, kalıp tanımada ve parametrik olmayan istatistiklerde standart bir teknik olan k-en yakın komşu yöntemini kullanan bir kredi puanlama sisteminin yapımını anlatılmıştır. Analizin önemli bir kısmı mesafe metriklerinin seçilmesidir ve Öklid uzaklık metriği tercih edilmiştir. Bu yaklaşım, posta sipariş kredisi için bir uygulama örneğini sınıflandırmak için kullanılmıştır. Karşılaştırma deneylerinin sonuçları, lojistik regresyon ve karar ağaçları gibi bir dizi ayrımcılık tekniği ile değerlendirilmiştir.

Somlertlamvanich vd. (2000), yaptığı çalışma ile C4.5 öğrenme algoritmasını Thai metinlerinden kelime çıkarma amacıyla kullanmıştır. C4.5, sözcük / sözcük dışı anlaşılma için iyi bir karar ağacı oluşturmuştur. Karşılıklı bilgi, entropi, kelime sıklığı, kelime uzunluğu, işlevsel kelimeler, ilk iki ve son iki karakter olan öğrenilen özellikler, kelime çıkarma için faydalı bilgiler olarak kullanılmıştır.

West'in 2000'deki çalışmasında, "beş sinir ağı modelinin" (multilayer perceptron), mixture-of-experts, radial basis function, learning vector quantization ve fuzzy adaptive resonance) kredi puanlamadaki doğruluğu araştırılmıştır. Nöral ağ kredi puanlama modelleri, İki gerçek dünya veri seti üzerinde uygulanmış, sonuçlar doğrusal diskriminant analizi, lojistik regresyon, en yakın komşu, çekirdek yoğunluk tahmini ve karar ağaçları gibi ticari uygulamalar için daha geleneksel yöntemlere kıyasla kıstaslanmıştır.

Breiman 2001'de yaptığı çalışmada rasgele ormanlar için teorik bir arka plan sunup bölünmeyi belirlemek için her bir düğümdeki rastgele seçilmiş özelliklerin kullanıldığı ormanları tanıtmıştır. Kılavuzluk için genelleme hatası, sınıflandırma gücü ve bağımlılığı hakkındaki dahili tahminler hesaplamış, rasgele özelliklerin iki farklı formu için ampirik sonuçlar vermiş, Adaboost'a göre olumlu sonuçlar elde etmiştir. Ayrıca elde ettiği sonuçlar, her bir düğümün bölünmesi için seçilen özelliklerin sayısına duyarlı olduğunu göstermiştir.

Sun'un 2002'de yaptığı bir çalışmada, ton vurgularını tahmin etmek için bileşik makine öğrenimi uygulanmıştır. Temel algoritma olarak CART (sınıflandırma ve regresyon karar ağacı), CART ile birlikte Bagging ve CART ile birlikte Boosting algoritmaları, sadece akustik özellikler kullanılarak, yalnızca metin tabanlı özellikler kullanılarak; hem akustik hem de metin tabanlı özellikleri kullanılarak farklı deney koşullarında değerlendirilmiştir. Yüksek, kademeli yüksek, düşük ve kuvvetsiz olmak üzere dört tane vurgu türü modeli hece seviyesinde oluşturulmuştur. Üç deneyin hepsinde, bileşik makine öğrenme tek başına CART algoritmasından daha olumlu sonuç vermiş, bileşik makine öğrenme ile iyileştirilmiş performansa ulaşıldığı görülmüştür.

Martelli vd. (2003)'nin çalışmasında, alfa membran proteinlerinin yetersizliği nedeniyle, protein topografisi ve topolojisi için öngörülen yöntemlerin eğitim / test setleri, düşük çözünürlüklü olarak bilinen yüz protein ile karıştırılmış, mevcut kestiriciler yakın zamanda kristalleşmiş membran proteinlerini tahmin etmede başarısız olmuşlardır. Tahminleyicileri yalnızca atomik çözünürlük ile bilinen protein setiyle eğitmek / test etmek ve farklı yöntemlerin performansını daha iyi değerlendirmek mümkündür. Basamaklı sinir ağı, iki farklı gizli Markov modeli (ve bunların bileşimi yeni bir yöntem olarak uygulanmıştır. Üç yöntem ile yapılan testler sonucunda bileşik yöntemlerin performansının diğer tahminleyicilerin performansından daha yüksek olduğu ortaya koyulmuştur.

Tan vd. (2003) tarafında yapılan çalışmada, yapısal veri miktarı, protein yapısının elle muayene edilmesi gibi geleneksel yöntemleri imkansız hale getirdiği için diziliş ve yapı arasındaki ilişkileri anlamada önemli bir süreci ve olası fonksiyonel ve evrimsel

ilişkileri temsil eden protein yapısı sınıflaması için makine öğrenme yöntemleri uygulanmış ve başarılı sonuçlar vermiştir. Bu çalışmada, farklı taban sınıflandırıcılarından bilgileri bütünleştirerek çok sınıflı örnek kümeleri altındaki sınıflayıcıların kapsamını geliştiren yeni bir topluluk makine öğrenme yöntemi önerilmiş ve çok sınıflı SCOP protein katlama verilerinin sınıflandırılmasında gösterilmiştir. Yaklaşım PART yöntemi ile karşılaştırılmış ve yöntemin protein katlı sınıflandırmada sınıflandırıcının duyarlılığını geliştirdiği gösterilmiştir.

Tan ve Gilbert 2003'te yaptıkları başka bir çalışmada ise kanser hücrelerini sınıflandırmak için C4.5 karar ağacı, Bagging ile bileşik karar ağacı ve Boosting ile bileşik karar ağacı yöntemlerini kullanmışlardır. Elde edilen sonuçlar göstermiştir ki bileşik karar ağacı yöntemleri tek başına karar ağacı yöntemi olan C4.5'ten daha iyi performans sergilemiştir.

Aydemir ve Sipahioğlu (2004), kağıt sektöründe faaliyet gösteren bir firmanın peçete üretimi yapan iki üretim hattı için geçmiş beş yıla ait makine arıza kayıtlarını inceleyerek makine arızalarına etki edebilecek faktörleri belirlemiş, makine arızaları arasında geçen süreyi tahminlemek için, bir çok katmanlı yapay sinir ağı modeli geliştirmiş, modelde kullanılacak parametre değerlerini ve ağ mimarisini deney tasarımı yöntemiyle belirlemiş ve kullanılan model ile bu makineler için arıza zamanlarının önceden tahminlenmesinde başarı elde etmiştir.

Peng (2005), mikro dizilim verilerinin sınıflandırılmasının geliştirilmesi için yeni bir bileşik makine öğrenme yaklaşımı sunmuştur. Klasik topluluk öğrenme tekniklerinden farklı olarak, bu yaklaşım, gen alt örneklemesine dayalı bir aday taban sınıflandırması havuzu oluşturarak sınıflandırma kümelemesine dayalı sınıflandırma komitesini oluşturmak için uygun taban sınıflandırmalarının bir alt kümesinin seçilmesi ile başlar. Deneysel sonuçlar, sınıflandırmaların sadece klasik makine öğrenme ile üretilen sınıflandırmalarla değil aynı zamanda yaygın olarak kullanılan iki klasik bileşik makine öğrenme yöntemi olan Boosting ve bagging algoritmaları tarafından üretilen sınıflandırmalarla da gerçekleştirildiğini göstermiştir.

Tümörlerin güvenilir ve hassas bir şekilde sınıflandırılması kanseri başarılı bir şekilde tedavi etmek için şarttır. Wang (2006), gen ekspresyonu verileri üzerinde sınıflandırma ve tahmin için yeni bir bileşik makine öğrenme algoritmasının kullanılmasını önermiştir. Algoritmayı test etmiş ve Bagging, Boosting ve Arcing yöntemleri ile karşılaştırmıştır. Sonuçlar, Bootstrapping ve Boosting Skeleton kombinasyonu olan önerilen algoritmanın mevcut metodlardan çok daha iyi performans gösterdiğini ve veri setinde yüksek doğruluk sağladığını göstermiştir.

Simmons vd. (2008)'nin yaptıkları çalışmada, bir grup topluluk tabanlı karar ağacı modellerinin geliştirilmiş, deneyimler model geliştirme sürecindeki çeşitli aşamalarda paylaşılmış ve bu modeller satıcı firmaların tekliflerine uygulandıklarında görülen etki sunulmuştur. Sınıflandırıcıların, tarihsel Yüksek Verimli Tarama sonuçlarına göre eğitilmesi ve sınıfların modellerin nasıl olacağını doğru bir şekilde yansıtan yollarla doğrulanması durumunda geliştirilebileceği görülmüştür. Önemli ölçüde daha düşük hata oranlarına, çoklu kimya tanımlayıcılarından veya kimlik indekslerinden türetilen modellerin bileşimi olan bileşik sınıflandırma yöntemleri ile ulaşılmıştır.

Anyanwu ve Shiva (2009), karar ağacı algoritmalarının seri uygulamalarını gözden geçirip yaygın olarak kullanılan seri karar ağacı algoritmaları belirlemiş, bu algoritmaların performansını değerlendirmek için örnek veri kayıtlarına dayalı deneysel analiz yapmıştır.

Erpolat ve Öz (2010)'da yaptıkları çalışmayla göğüs kanseri verilerinin sınıflandırmasında yapay sinir ağları ve destek vektör makineleri yöntemlerini kullanarak makine öğrenme yöntemlerinin sınıflandırmadaki başarısını test etmiştir.

Deng ve Yeh (2011), bu araştırmada en küçük kareler yöntemini, gövde yapısal projelerinin üretim maliyetini tahmin etme problemini çözen destek vektör makineleri (LS-SVM) yöntemini desteklemek için kullanmıştır. Vaka incelemelerinde, yapım ağırlığını ve üretim karmaşıklığını, üretim emek saatini belirlemedeki ana etken olarak görmüştür. Test sonuçları, LS-SVM modelinin doğru tahmin performansı sağlayabileceğini göstermiş, gövde üretimi endüstrisi için uygun bir çözüm sunmuştur.

Sarıman 2011'de yaptığı çalışmada, bir veritabanından elde ettikleri veri setini alarak k-means ve k-medoids kümeleme algoritmalarıyla ülkelerin özelliklerine göre kümeleme analizi yapmıştır. Uygulamayı geliştirerek internet ortamında kullanıcılara sunmuş, K-Means ve K-Medoids algoritmalarının analizi ile elde edilen sonuçları karşılaştırmıştır.

Farrokhzad vd. (2012) bu çalışmada, yapay sinir ağını kullanarak Tohum ve İdris (1983) yöntemine dayanan Babol kenti için sıvılaştırma mikrobölgeleme haritasını hazırlamayı amaçlamış, alternatif bir genel regresyon sinir ağı modeli önerilmiştir. Bu amaca ulaşmak için, 7 km2'lik bir alanda toplam 30 delikten veri elde edilmiştir.

Hsieh vd. 2012'de yaptıkları çalışma ile meme kanserinin tıbbi tanı verilerini sınıflandırmış, sinir bulanıklığı (Neural Fuzzy), k-en yakın komşu (k Nearest Neighbor), kuadratik sınıflayıcı (Quadratic Classifier) modelleri ile bunlarla ilişkili, bileşik sınıflandırmalar geliştirmiştir. Buna ek olarak, bu üç şemayla kombine bir bileşik model oluşturulmuştur. Deneysel sonuçlar bileşik öğrenmenin bireysel yöntemlerden daha iyi performans gösterdiğini ortaya koymuş, birleşik model tüm modeller arasında meme kanseri sınıflamasının en yüksek doğruluğunu göstermiştir.

Lamrini vd. (2012), yaptıkları çalışmada, yapay sinir ağlarına dayalı yoğurma sürecinin dinamik bir modelini sunmuştur. Bu dinamik nöral model, ekmek hamuru sıcaklığını ve mekanik işi yapmak için gerekli olan gücü tahmin etme amacıyla kurulmuştur. Sürecin dinamiklerini yakalamak için tekrarlayan sinir ağları kullanılmıştır. Sinir ağlarının girdilerinin türü ve sayısı, öğrenme kümesinin doğası, mimari ve parametre öğrenme tekniği incelenmiştir.

Mandal vd. (2012)'nin yaptığı çalışmada, ham petrol ve sıvı yakıt taşıyan boru hattı boyunca oluşabilecek sızıntının tespitinin yanlış belirlenmesi sorununun üstesinden gelmek için kaba küme teorisi ve destek vektör makinesi (SVM) temelli yeni bir sızıntı tespit şeması önerilmiştir. Uygulanan kurallar tarafından saptanamayan vakaları incelemek için SVM sınıflandırıcısı kullanılmış, SVM'nin eğitimi için, arıların zeki besin arama davranışını taklit eden akıllı istihbarat tekniği: yapay arı koloni (ABC) algoritması kullanılmıştır. ABC ile önerilen kaçak saptama şemasının sonuçları,

parçacık sürüsü optimizasyonu (PSO) ve gelişmiş parçacık sürüsü optimizasyonu (EPSO) ile elde edilen sonuçlarla karşılaştırılmıştır.

Marques vd. (2012)'nin bu çalışmada kredi puanı bağlamında her topluluk yaklaşımına uygun sınıflandırıcıları belirlemeti amaçlamıştır. Bunun için C4.5 karar ağacı, çok katmanlı algılayıcı, lojistik regresyon, en yakın komşu ve naif Bayes sınıflandırıcıları beş farklı yöntemin tahmin performansını değerlendirilmiştir.

Marques vd. (2012) yaptıkları bir diğer çalışma ile çeşitlilik indüksiyonu için ortaklaşa farklı stratejiler kullanan kompozit toplulukları sunarak önceki çalışmalarını geliştirmek istemiştir. Buna göre, karma toplulukların inşası için yeniden örnekleme algoritmalarının (bagging ve AdaBoost) ve öznitelik alt küme seçim yöntemlerinin (random subspace ve rotation forest) kombinasyonunu, tahmini performansı arttırmak amacıyla araştırmış, deney sonuçları ve istatistiksel testler ile bu yeni iki seviye sınıflandırıcı topluluğunun kredi puanlama problemleri için uygun bir çözüm oluşturduğunu, geleneksel tekli topluluklardan daha iyi performans gösterdiğini ve bireysel sınıflandırıcılardan çok daha iyi olduğunu ortaya koymuştur.

Savaş vd. (2012) yaptıkları çalışmada veri madenciliğini tanımlamış, önemini vurgulamış ve Türkiye'de yapılmış veri madenciliği çalışmalarına ve gerçekleştirilen uygulamalara yer vermiştir.

Wei ve Patel (2012), çalışmalarında kötü amaçlı yayıncıların, gerçek olmayan reklamlarla elde ettikleri tıklamalar ve bu tıklamalardan elde ettikleri reklam gelirlerinin engellenmesi ve bu hileli yayıncıların tespit edilmesi için Singapur Milli Üniversitesi ekibinin çözümünü açıklamıştır. Bu çözüm yönteminde, karar ağacı modelleri, sinir ağı modelleri gibi çeşitli modellerden yararlanarak farklı öğrenme algoritmalarının bir bileşimi ile algoritmalar kurulmuş, ardışık olarak eğitilmiş ve doğrulama testleri yapılmıştır.

Erdal ve Karakurt (2013), akarsu akış tahmin doğruluğunu ilerletmek için CART topluluklarında iki bileşik öğrenme yönteminin (bagging ve stochastic gradient boosting) potansiyel kullanımını araştırmıştır. Çalışmaya aylık akış tahmini için sınıflandırma ve regresyon ağaçlarının araştırılması ile başlanmış ve referans model

olarak bir destek vektörel regresyon (SVR) modeli seçilmiştir. CART'ın hem eğitim hem de test aşamasında SVR'den daha iyi performans gösterdiğine dair analitik sonuçlar elde edilmiştir. Torbalı regresyon ağaçlarının (BRT) ve stokastik artımlı regresyon ağacı (GBRT) modellerinin sonuçları ile karşılaştırıldığında, genel olarak toplu öğrenme paradigmalarının aylık akış tahmininde CART modellerinin tahmin doğruluğunu önemli ölçüde ilerletebileceği bulunmuştur.

Gabralla vd. (2013), yaptıkları çalışmada, 4 Ocak 1999'dan 10 Ekim 2012'ye kadarki günlük ham petrol fiyatının tahmini performansını test etmek için girdi olarak bir takım etkili özellikleri göz önüne almıştır. Ham petrol fiyatlarının tahmini için çeşitli makine-öğrenme yöntemlerinin performansını araştırmış, özellik (öznitelik) seçimi için üç farklı algoritma kullanmıştır. IBL, KStar ve SMOReg modellerini petrol fiyatı öngörüsü olarak düşündükten sonra bir toplama modeli oluşturmuş, farklı alt grupların eğitim ve test verilerini rastgele dört farklı gruba ayırarak etkisini göstermiştir. Ampirik sonuçlar, gelişmiş bileşik yöntemin SMOReg ve IBL'den bazı niteliklerde daha başarılı olduğunu göstermiştir.

Singh vd. (2013), yaptıkları çalışmada maliyete duyarlı bir öğrenme yaklaşımı sunmuştur. Bu çalışmanın amacı sahteciliğe yönelik saldırının genel maliyetini etkili bir şekilde azaltmaktır. Etkinlik, yanlış sınıflandırma maliyeti ve test maliyeti değerlendirmelerini sunmak için deneyler yapılmış ve elde edilen bulgular AdaCost'a kıyasla sınıflandırmada daha pahalı olan MetaCost öğrenicilerinin en iyi sonucu sağladığını göstermiştir.

Çalış vd. (2014), bilgisayar ve internet güvenliği üzerine bir anket çalışması yapmış, elde edilen veriler, farklı demografik özellikteki kişiler için çıkarım yapılması amacıyla karar ağacı yöntemleri kullanılarak analiz edilmiştir.

Özhan (2014), Dünya genelinde 2013 yılında meydana gelmiş depremlerin özellikleri makine öğrenme yöntemlerinin uygulama programı olan Weka yazılımı ile modellenmiştir. Tüm makine öğrenme algoritmaları ile analiz yapılmış ve en iyi sonuçları elde eden yöntemler ile 2014 yılında gerçekleşen depremler analiz edilmiştir.

Özkan ve Boran (2014), yaptıkları çalışmada şirketlerin ilgili finansal oranlarını hesaplamış, finansal oranlar kullanarak şirketleri gruplandırmış ve bu şirketleri kümeleme sonucunda aynı grupta yer alan diğer şirketler ile karşılaştırmıştır. Veri madenciliği algoritmaları olarak OPTICS, DBSCAN, K-Means ve EM algoritmalarını kullanarak oluşturulan kümelerin doğruluğunu kontrol etmiştir.

Yasa ve Etemad-Shahidi (2014) bu çalışmada boru hattı ile ilgili mühendislik analizinde boru hatları altındaki akım kaynaklı kazma derinliğinin güvenilir bir şekilde tahmin edilmesi için doğru bir formül geliştirmeyi amaçlamıştır. Önceki deneysel veriler toplanmış ve farklı parametrelerin kazma derinliği üzerindeki etkisini incelemek için bir veri tabanı olarak kullanılmıştır.

Karahan (2015), yaptığı çalışmada, başarılı tahminleme yöntemlerinden biri olan yapay sinir ağı modelini kullanılarak, Malatya'da üretilen kuru kayısı ihracat miktarlarını tahminlemiştir. Uygulama sonuçlarına yapılan hata testi, modelin tahminleme doğruluğunun güvenilir ve tutarlı olduğunu göstermiştir.

Özbay (2015), yaptığı çalışmayla veri madenciliğinin tanımını yapmış, veri madenciliği modellerini açıklamış ve eğitimde veri madenciliği uygulamalarına değinmiştir.

Yaday ve Chandel (2015), Batı Himalaya'nın Hindistan'da bulunan bir eyaletinin güneş enerjisi potansiyelini Yapay Sinir Ağı (YSA) modeli ile Küresel Güneş Radyasyonu tahmini modeli oluşturarak değerlendirir. YSA modelinde girdi parametrelerinin seçimi için Waikato Çevresel Bilgi Analizi (WEKA) programında J48 algoritmasını kullanmıştır. En çok ilgili girdi parametrelerinin sıcaklık, yükseklik, güneşli saat süresi, enlem, boylam, netlik indeksi ve yer üstü radyasyonu olduğunu bulmuş, değişken seçiminde J48 algoritmasının kullanışlılığını beş YSA modeli geliştirerek kontrol etmiştir. Geliştirilen YSA modelleri, dünyanın herhangi bir yerindeki güneş potansiyelini değerlendirmek için kullanılabilecek şekilde modellenmiştir.

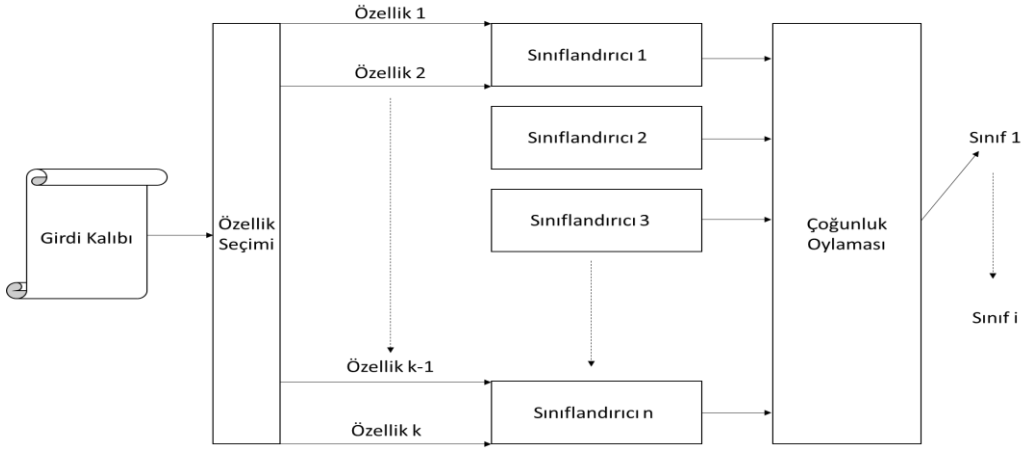
Saatçıoğlu ve Özçakar (2016)'ın yaptığı çalışmada, e-ticaret sektöründe faaliyet gösteren bir işletmenin satış yaptığı bir kategorideki aralıklı talep yapısına sahip

ürünlerinin talep tahminlemesi için Croston yöntemi ve çok katmanlı algılayıcılar kullanılmıştır.

Keleş (2016), veri madenciliği yöntemlerinin inşaat sektöründe uygulanabilirliğini göstermiş, şantiye ve ofislerden gelen bilgilerin sistematiğe bağlanarak elde edilen yararlı bilgilerin iş gücü ve zaman kayıplarını azaltıp ekonomiye katkı sağladığını ortaya koymuştur.

3.4.BİLEŞİK MAKİNE ÖĞRENME

Son birkaç yıldır bileşik modelleme, tahmin modellemesinde önemli bir ilerleme olarak kabul görmüştür ve çok çeşitli makine öğrenme yöntemlerine uygulanmaktadır. Tahmin edici performansındaki önemli iyileştirmeler, birden fazla modelin tek bir sınıflandırıcıya birleştirilmesi durumunda, bireysel modellerin sonuçlarının ortalaması alınarak veya oylama yapılarak gerçekleştirilebilir. Bireysel modellerin tahmin edilecek sınıflara göre tahmin performanslarında çeşitliliği önemlidir, böylece bir modelin zayıflığı başka bir modelin gücüyle telafi edilmektedir. Bir veri kümesinden bir dizi tekrarlayıcı bölümleme sınıflandırıcısı geliştirerek ve her sınıflandırıcıdan gelen tahminlerin ortalamasını alarak son sınıflamayı oluşturmak suretiyle belirgin şekilde daha kuvvetli tahmini modellerin elde edilebileceği yapılan çalışmalarla gösterilmiştir (Simmons vd., 2008: 2196). Bileşik sınıflandırıcıların yapısı Şekil 3.1'de görülmektedir.



Şekil 3.1: Bileşik sınıflandırma makine öğrenme modelinin yapısı (Hsieh, 2012: 2842).

Bileşik öğrenmenin sezgisel kavramı, tek bir yaklaşımın veya sistemin diğerlerinden daha üstün olabileceğini iddia edemeyeceği ve birkaç tek yaklaşımın entegrasyonunun final sınıflandırıcısının performansını artıracağıdır (örn. doğruluk, güvenilirlik, anlaşılabilirlik). Dolayısıyla, bir bileşik sınıflandırıcı, bireysel taban sınıflandırıcılarından genel olarak daha iyi bir performans gösterebilir. Bileşik yöntemlerin etkililiği, temel öğrenen tarafından gerçekleştirilen hatanın bağımsızlığına oldukça bağımlıdır. Bileşik yöntemlerin performansı temel öğrenicilerin doğruluğuna ve çeşitliliğine güçlü bir şekilde bağlıdır (Tan ve Gilbert, 2003: 3). Bileşik öğrenme, çeşitli temel sınıflandırmalar seti üretmek için tek veya çoklu öğrenme algoritmaları kullanmakta ve daha sonra bunları, yeni veri örneklerini sınıflandırmak için daha uygun kararlar vermek üzere birleştirmektedir. Pek çok araştırma, belirsizlikler altında verileri sınıflandırma doğruluğunu iyileştirmek için bileşik öğrenmenin umut verici yönünü göstermiştir. Bir topluluğun bireysel üyelerinden daha iyi performans göstermesi için gerekli ve yeterli şart, temel sınıflandırıcıların doğru ve çeşitli olmasıdır. Doğru sınıflandırıcı, yeni örnekler için sınıfları rastgele tahmin etmekten daha iyi bir hata oranına sahip olan bir sınıftır ve eğer iki sınıflandırıcı, ortak veri örnekleri üzerinde farklı (korelasyonsuz) hatalar yaparsa bunlar birbirinden farklıdır (Peng, 2006: 554-555). Yapılan çalışmalarda çeşitli bileşik teknikler önerilmiştir. Buna ek olarak, bileşik yöntemlerin sınıflandırmaların doğruluğunu önemli ölçüde artırabilecekleri ve daha iyi bir sınıflandırma performansı öngörmeleri konusunda güçlü kanıtlar elde edilmiştir (Hsieh vd., 2012: 2843).

Sınıflandırma problemleri için, bileşik öğrenme algoritmaları sınıflandırıcılar dizisi oluşturur ve daha sonra tahminlerini (ağırlıklı) oy alarak sınıflandırır. Genel olarak, bileşik öğrenme yöntemleri algoritmadan bağımsızdır ve temel öğrenicinin seçimine herhangi bir sınırlama getirmemektedir. Bir sınıflandırıcının tahmin hatasının iki bileşen halinde ayrışabileceği gösterilmiştir: önyargı ve varyans. Bireysel karar ağaçları, genelleme doğruluğu açısından yüksek değişkenlik göstermektedir. Böylece, karar ağacında bileşik öğrenmenin uygulanması varyansı azaltarak performansı artırabilir (Sun, 2002: 1-3). Bileşik öğrenmedeki taban sınıflandırıcıları birçok yolla oluşturulabilir. Örneğin, farklı öğrenme algoritmaları kullanılarak veya orijinal eğitim

veri setinin yeniden örneklenmesinden öğrenme yoluyla oluşturulabilir. Tekrar örnekleme yöntemleri bileşik öğrenmede yaygın olarak kullanılmaktadır. İki temel yeniden örnekleme yöntemi, örneklerin tekrar örneklenmesi ve özelliklerin alt örneklemesidir. Bir takım eğitim setleri, örnek değiştirme ile birlikte orijinal veri kümesinden yeniden örnekleme yoluyla üretilmekte, yani yeniden örneklenmiş veri kümesi, orijinal küme ile aynı sayıda örneğe (bazı örnekler tekrarlanma) sahip olmaktadır. Buna yeniden örnekleme tabanlı bileşik öğrenme denir. Var olan bileşik öğrenme yöntemlerinin çoğu, eğitim örneklerinin yeniden örneklenmesine dayanılarak gerçekleştirilmektedir. Buna, alt örnekleme tabanlı bileşik öğrenme örneği denir (Peng, 2006: 555).

Bileşik öğrenme algoritmalarının tasarımında iki temel yaklaşım vardır: Ilk yaklaşım, her bir hipotezin bağımsız olarak, hipotez setinin sonucunun doğruluğunu ve çeşitliliğini gösterecek şekilde inşa edilmesidir - yani, her bir hipotez, yeni tahminler yapmak için makul düşük hata oranına sahiptir ve hipotezlerin uyumsuzlukları iptal edilmektedir. Bu tür bileşik yöntemler, hem istatistiksel hem de hesaplama problemlerini aşabilir. Hipotezlerin ağırlıklı oyunun verilere iyi uyum sağlaması için bileşik yöntemleri tasarlamaya yönelik ikinci yaklaşım, hipotezleri birbirine bağlı bir şekilde yapılandırmaktadır (Dietterich, 2002: 4).

Bileşik algoritmalar için öğrenme işlemi iki kısma ayrılabilir (Wang, 2006: 3478):

1. Temel sınıflandırıcıları (modelleri) oluşturmak: Bu bölümün temel görevleri şunlardır:
    a. Veri işleme, orijinal eğitim verilerini bozarak sınıflandırıcılar için girdi eğitim verilerini hazırlamak ve
    b. Temel sınıflandırıcı yapıları, temel öğrenci olarak bir öğrenme algoritması ile pertürbasyon verileri üzerine temel sınıflandırıcılar oluşturmaktır.
2. Oylama: Bileşik yöntemlerin ikinci aşaması, önceki aşamada oluşturulan temel modelleri, son bileşik modele birleştirmektir. Çeşitli oylama sistemleri vardır. Ağırlıklı oy kullanma ve ağırlıksız oy kullanma olmak üzere iki ana oylama sistemi genel olarak kullanılmaktadır. Ağırlıklı oylama sisteminde her temel sınıflandırıcı farklı oy verme gücüne sahip olmaktadır. Öte yandan, ağırlıksız

sistemde bireysel taban sınıflandırıcı eşit ağırlığa sahip olmaktadır ve kazanan en çok oy alan gruptur.

Bileşik yöntemler, kararların sistemin performansını iyileştirmek için bir şekilde birleştirildiği makine öğrenme teknikleri seti olarak görülmektedir. Literatürde benzer anlamları ifade eden diğer terminolojiler şunlardır: topluluk öğrenme yöntemleri, çoklu sınıflandırıcılar, çok stratejili öğrenme, kombinasyon, toplama, entegrasyon ve benzeri. Farklı öğrenme algoritmalarını birleştirmenin en basit yolu ağırlıksız oylama veya ağırlıklı oylamadır (Tan ve Gilbert, 2003: 3).

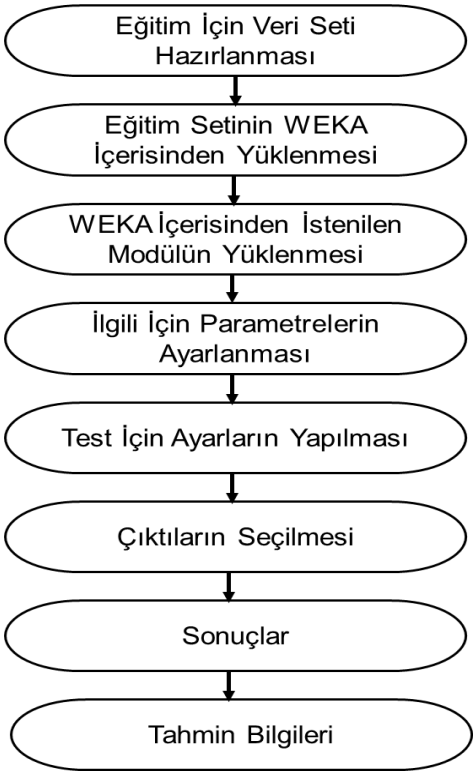
4. MALZEME VE YÖNTEM

4.1.WEKA

WEKA (Bilgi Analizi için Waikato Ortamı), gerçek dünya veri setlerine standart makine öğrenme teknikleri uygulanmasını sağlayan bir programdır. Gerçek dünya veri setleriyle çalışmak için interaktif bir arayüz vasıtasıyla çeşitli makine öğrenme tekniklerine kolay erişim sağlayan bütünleşik bir ortam sağlamak için geliştirilmiştir (Holmes vd., 1994: 1).

WEKA, makine öğrenme algoritmaları ve veri ön işleme araçlarının organize bir koleksiyonudur. Her makine öğrenme algoritması, verilerin kendi formatında bulunmasını gerektirir ve parametrelerin ve çıktıların belirlenmesinde kendine has bir yol vardır. WEKA sistemi, tutarlı bir yöntemle bu verilere kolayca uygulanabilmesi için ortak bir arayüz altında bir dizi makine öğrenme tekniği veya şeması getirmek üzere tasarlanmıştır. Bu arayüz, yeni şemaların eklenmesini teşvik edecek kadar esnektir (Garner, 1995: 57). Bununla birlikte, veri araştırması için, bilgi işlem platformlarında büyük çaplı deneyler yapmak ve akışlı veri işleme konfigürasyonlarını tasarlamak için uygun interaktif grafik kullanıcı arayüzleri sağlanmıştır. WEKA'da makine öğrenme yöntemleri ile tahmin bilgileri elde etme adımları Şekil 4.1'de gösterilmiştir.

Deneyimler, mümkün olan tüm öğrenme problemleri için tek bir makine öğrenme yönteminin uygun olmadığını göstermektedir. Gerçek veri kümeleri değişir ve doğru modeller elde etmek için öğrenme algoritmasının önyargıları alanın yapısıyla eşleşmelidir. Kullanıcılar, yeni veri setleri üzerinde var olan makine öğrenme yöntemlerini hızlı ve kolay şekilde denemek için tasarlanmıştır. Giriş verilerinin hazırlanması, öğrenme planlarının istatistiksel olarak değerlendirilmesi ve hem girdi verilerini hem de öğrenme sonucunun görselleştirilmesini içeren deneysel veri madenciliğinin tüm süreci için kapsamlı bir destek sağlamaktadır.



Şekil 4.1: WEKA'da temel işlem adımları (Evren, Erişim Tarihi: 28.10.2017).

Bu, farklı kavram türlerini öğrenmek için çok çeşitli algoritmalar ve geniş bir ön işleme yöntemleri yelpazesi eklenerek gerçekleştirilmiştir. Bu çeşitlilik ve kapsamlı araç seti, kullanıcıların farklı yöntemleri karşılaştırmalarını ve eldeki soruna en uygun olanları belirlemelerini mümkün kılarak ortak bir arayüz üzerinden çağrılabilir. WEKA, tüm standart veri madenciliği problemleri için regresyon, sınıflandırma, kümeleme, ilişki kuralı incelemesi ve öznitelik seçimi yöntemlerini içermektedir. Tüm algoritmalar ve yöntemler, girdilerini bir dosyadan okunabilen veya bir veritabanı sorgusu tarafından üretilebilen tek bir ilişkisel tablo şeklinde almaktadır. Sistem Java programlama dili ile yazılmıştır (Frank vd., 2009: 1269-1270).

4.2.KULLANILAN ALGORİTMALAR

4.2.1. Destek Vektör Makineleri Algoritması

Namlı (Namlı, 2012: 59-63) çalışmasında Destek Vektör Makineleri (DVM) sürecini şu şekilde tanımlamış, formüllerini açıklamış ve konuyu özetlemiştir:

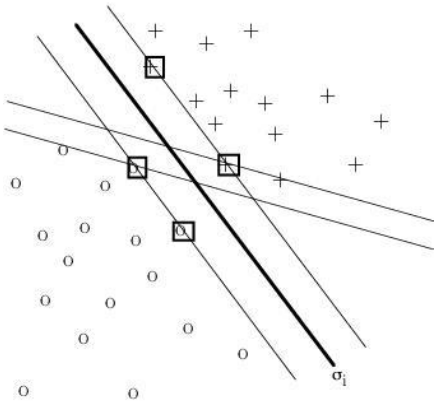
DVM, doğrusal veya doğrusal olmayan bir fonkson yardımıyla sınıflandırma yapmaktadır. DVM, veriyi birbirinden ayıran en uygun fonksyonu tahmin etmektedir.

Bir H_0 hiper düzlemi üzerindeki noktaları bulmak için 4.1'de görülen denklemin, bu hiper düzlemin iki yanındaki düzlemler arasındaki boşluğun $y_i(w^T x_i + b > 1)(i = 1,2, \dots \dots, n)$ kısıtı altında maksimum olması için 4.2'de görülen denklemin çözülmesi gerekmektedir.

$$H_0 = W^T X + b \tag{4.1}$$

$$w^T w/2 \tag{4.2}$$

Şekil 4.2'de görüldüğü gibi iki farklı veri sınıfı birbirlerinden doğrusal olarak ayrılmaktadırlar.



Şekil 4.2: İki farklı veri sınıfının doğrusal olarak ayrılması (Namlı, 2012: 60).

l tane örnekten oluşan bir eğitim kümesi olsun,

$$(x_1, y_1), \dots \dots, (x_n, y_n), \quad x_i \in R^d, \quad y_i \in \{-1, +1\} \tag{4.3}$$

(4.2)'deki eğitim kümesi uygun *w* ağırlık vektörü ve *b* eşik değeri için (4.4)'teki eşitsizlikleri sağlıyorsa o zaman denklem doğrusal olarak ayrılabilmektedir.

$$wx_i + b \geq 1 \qquad y_i = 1$$

$$wx_i + b \leq -1 \qquad y_i = -1 \tag{4.4}$$

Denklem (4.3)'teki eşitsizlik genelleştirilirse:

$$y_i(wx_i + b) \geq 1, \quad i = 1, \dots \dots, l \tag{4.5}$$

Karar sınırı denklemi aşağıda gösterilen en iyi ayırıcı doğrudur:

$$wx_i + b = 0 \tag{4.6}$$

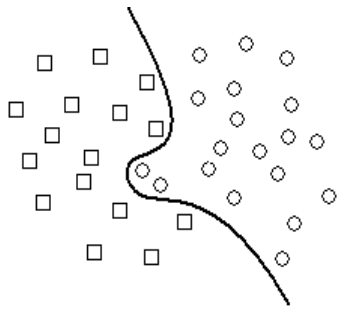
Ayırt edici düzlem üzerindeki iki karar sınırı arasındaki mesafe aşağıdaki gibi yazılabilir.

$$d = \frac{2}{\|w\|} \tag{4.7}$$

w'nin normu $\|w\|$ ile gösterilir. Maksimum d mesafesi, minimum $\|w\|$'ye eşit olduğu için en uygun ayırt edici düzlem denklem (4.3)'teki kısıtları sağlayan ve minimum $\|w\|$ elde eden optimizasyon problemi ile bulunabilir.

Verilerin doğrusal olarak ayrılamadığı durumlarda doğrusal olmayan sınıflandırıcılar kullanılır. Negatif olmayan ve hataları ifade eden ζ gevşek değişkenlerin optimizasyon modeline eklenmesi sağlanarak bu durum çözülmektedir.

Şekil 4.3'te doğrusal olarak ayrılmayan veriler gösterilmiştir.



Şekil 4.3: Doğrusal olarak ayrılamayan verilerin sınıflandırılması (Namlı, 2012: 62).

ξ_i gevşek değişkeni bir uygun sınıfın sınırdan sapma miktarıdır. Bir hatanın oluşması için $\xi_i > 1$ olmalıdır. Ayırt edici düzlem kısıtları olan denklem (4.5)'teki ifadeye ξ_i gevşek değerleri eklenmektedir.

$$y_i(wx_i + b) \geq 1 - \xi_i, \quad i = 1, \dots \dots, l$$
$$\xi_i \geq 0 \quad i = 1, \dots \dots, l \tag{4.8}$$

$\sum_i \xi_i$ eğitim hataları sayısının üst sınırıdır. Buna göre en iyi ayırt edici düzlem,

$$P = \frac{1}{2}\|w\|^2 + C\sum_{i=1}^{l} \xi_i \tag{4.9}$$

Denklem (4.9)'daki parametresi sabit bir düzenleyicidir. Denklem (4.10) ile problem Lagrange çarpanları ile ikili probleme dönüştürülmelidir.

$$L(\alpha) = \sum_{i=1}^{l} \alpha_i - \frac{1}{2}\sum_{i=1}^{l}\sum_{j=1}^{l} \alpha_i \alpha_j y_i y_j \left(x_i x_j\right) \tag{4.10}$$

$$\sum_{i=1}^{l} \alpha_i y_i \quad ve \quad 0 \leq \alpha_i \leq C \quad i = 1, \dots \dots, l \tag{4.11}$$

Sınıflandırma parametrelerini hesaplamak için (4.11) denklemi maksimum yapılmalıdır.

4.2.2. Random Subspace Algoritması

Random Sub Space algoritması Erdoğan (2017)'ın çalışmasında şu şekilde folmülize edilmiştir (Erdoğan, 2017: 68-69):

X, Y : Gözlemlenen veri

B : Alt küme ile çekilen veri sayısı

$|m| < M$: Alt uzayın büyüklüğü

TS_i^* : $\forall i$ için nihai t-tabanlı skor

$C_{i,k}$: Sayaç

- $m^* = \left\{i_1^*, \dots, i_{|m|}^*\right\}$ modeli rassal olarak orijinal özellik alanından alınır.

- $\forall i \in m^*$ için T^2_{i,m^*} hesaplanıp $y \sim x_{m^*}$modeli uyarlanır. $i \notin m^*$ ise $T^2_{i,m^*=0}$ ayarlanır.
- $C_{i,k} = C_{i,k-1} + I\{i \in m^*\}$ olarak güncellenir.

Bu işlemler $k = 1, \dots, B = B_n$ 'e kadar tekrarlanır; $n \to \infty$'a giderken $B_n \to \infty$ gider ve i için C_i, $0 = 0$'dan başlar.

TS_i^* şu şekilde hesaplanmaktadır:

$$TS_i^* = \frac{1}{C_i, B} \sum_{m^*: i \in m^*} \frac{T^2_{i,m^*}}{n - |m|} \tag{4.12}$$

$TS_i^*: TS_{i1}^* \geq TS_{i2}^* \dots \geq TS_{i,M}^*$ skorlarına göre değişken listesi düzenlenir ve $\{i_1, \dots \dots, i_M\}$ şeklinde sıralanır.

4.2.3. Stacking Algoritması

Stacking algoritması, tahmin edicileri birleştirirken birleştirmeyi yapacak bir model eğitme mantığına dayanmaktadır. İlk olarak veriler üzerinde farklı tahmin ediciler tahminler yapar, ana tahminleyici (meta classifier) ise bu elde edilen tahminler ile asıl tahminlemeyi yapmaktadır. Şekil 4.5'te görüldüğü gibi ana tahminleyiciyi eğitmek için eğitim seti iki kümeye ayrılmaktadır. Birinci kümede tahmin ediciler eğitilip daha sonra ikinci kümedeki her bir veri için her bir tahmin edici bir tahmin yapmaktadır. Elde edilen tahminler ve orijinal veriler ile oluşturulan eğitim setinde ana tahminleyici eğitilmektedir. Şekil 4.4'te görüldüğü gibi ana tahminleyici eğitildikten sonra kullanılan sınıflandırma tahminleyicilerinin yaptıkları tahminleri alıp son tahmini yapmaktadır (Koptur, çevrimiçi, 29.10.2017). Stacking süreci aşağıdaki şekilde özetlenmektedir (Erdoğan, 2017: 69-70):

$\mathcal{L} = \{(y_n, x_n), n = 1, \dots, N\}$: veri seti,

y_n: sınıf değeri

x_n: n. örneğe ait öznitelik değerlerini temsil eden, verileri j'ye neredeyse eşit altkümeler $\mathcal{L}_1, \dots, \mathcal{L}_J$ olarak bölmüş bir vektör

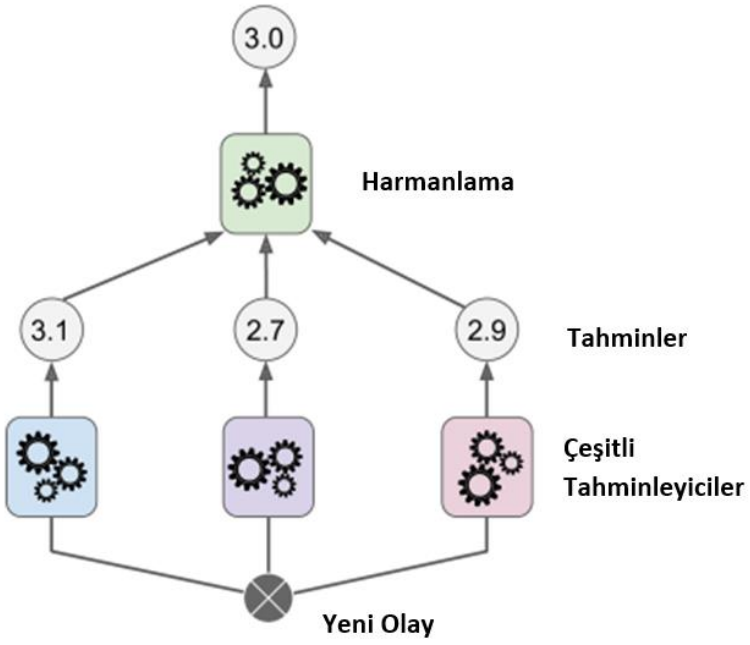
$\mathcal{L}_J$ ve $\mathcal{L}^{(-j)} = \mathcal{L} - \mathcal{L}_j$: *J*-kat çapraz geçerliliğin *j*'inci katına yönelik test ve eğitim setleri

z_{Kn}; $\mathcal{L}_j$'deki her x_n örneği için x_n üzerindeki $M_k^{(-j)}$ modelinin tahmini

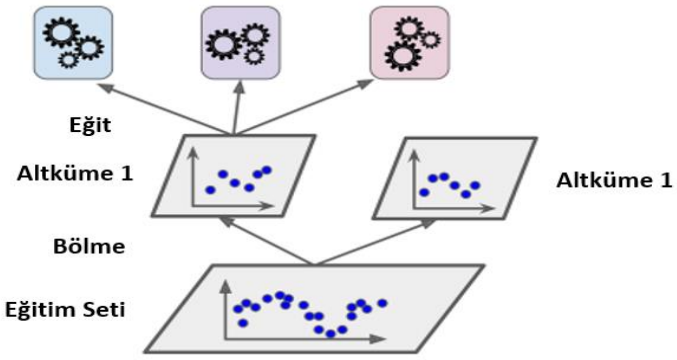
K öğrenme algoritmaları (seviye 0 modelleri), $k = 1, \dots \dots, K$ için bir $M_k^{(-j)}$ modeli oluştururken $\mathcal{L}^{(-j)}$ eğitim kümesindeki veri üzerine k'ıncı algoritmasını çağırmaktadır. Tüm çapraz geçerlilik sürecinin sonunda, *K* modellerinin çıktılarından toplanan seviye1 veri seti şu şekilde hesaplanmaktadır:

$$\mathcal{L}_{CV} = \{(y_n, z_{1n}, \dots, z_{Kn}), n = 1, \dots, N\} \quad (4.13)$$

Bu veri setinden, $(Z_1, \dots \dots, Z_K)$'nın bir fonksiyonu olan $\widetilde{M}$ modeli türetilirken seviye 1 öğrenme algoritmaları kullanılmaktadır. Eğitim sürecini tamamlamak için $\mathcal{L}$'deki tüm veriler kullanılarak Mk modelleri türetilmektedir. Mk modelleri, yeni bir örnek verildiğinde bu örnek için sınıflandırma sonucu olan seviye 1 $\widetilde{M}$ modellerinden olan bir vektör $(Z_1, \dots \dots, Z_K)$ üretmektedir.



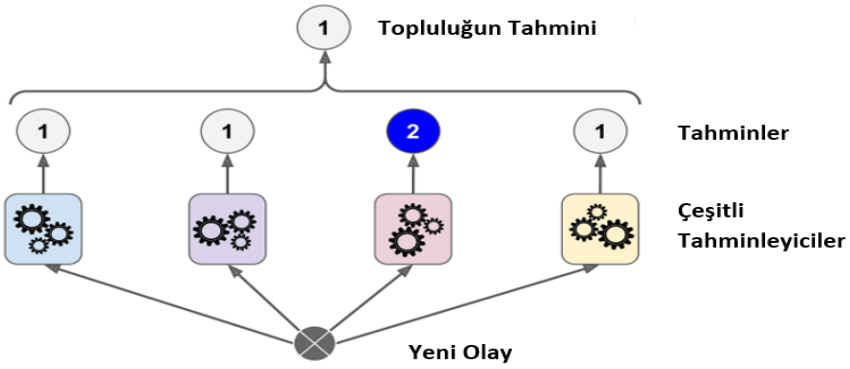
Şekil 4.4: Stacking Yöntemi (Koptur, Erişim Tarihi: 29.10.2017).



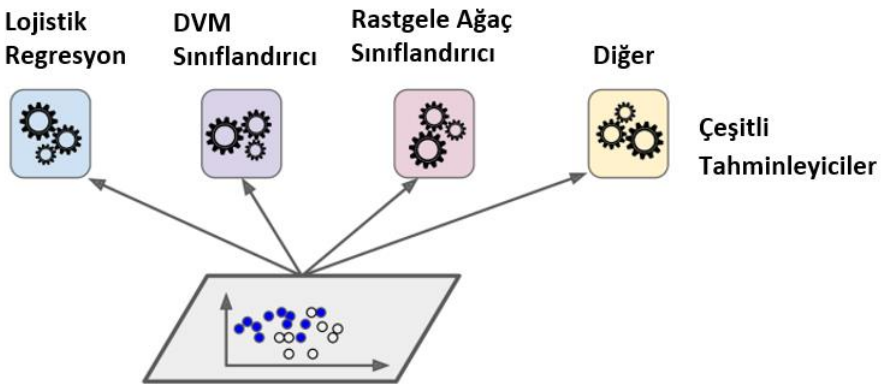
Şekil 4.5: Stacking Yönteminde Tahminleyicilerin Eğitimi (Koptur, Erişim Tarihi: 29.10.2017).

4.2.4. Voting (Oylama) Algoritması

Birden çok sınıflandırıcıyı birleştirerek daha iyi bir sınıflandırıcı elde eden bileşik öğrenme yöntemlerinden en basit ve sık kullanılanlarından biri voting (oylama) yöntemidir. Şekil 4.7'de görüldüğü gibi birden çok (N adet) farklı sınıflandırıcının $C^1 \dots C^N$,aynı veri seti $\mathcal{L}$ üzerinde eğitilerek $(L^1 \dots L^N)$ elde ettikleri sınıflandırma sonuçları değerlendirilmaktadir. En sık tekrarlanan yani en çok oyu alan sınıf tahmin sonucunu oluşturan sınıf olarak seçilmekte veya elde edilen sonuçlar olasılık değerleri şeklindeyse, bu sonuçların ortalaması alınarak tahmin sonucu elde edilmektedir. Sınıflandırıcıların oyları değerlendirilirken her birine eşit ağırlık verilebileceği gibi tüm veri seti kullanılarak eğitim yoluyla elde ettiği doğruluk değerlerine paralel olarak farklı ağırlık değerleri de verilebilmektedir. Voting yöntemi Şekil 4.6'da görülmektedir.



Şekil 4.6: Voting Yöntemi (Koptur, Erişim Tarihi: 29.10.2017).



Şekil 4.7: Voting Yönteminde Tek Bir Eğitim Seti ile farklı sınıflandırma algoritmalarının eğitilmesi (Koptur, Erişim Tarihi: 29.10.2017).

4.2.5. Bagging Algoritması

Breiman'ın Bagging algoritması, karar ağaçlarının birleşmesinin ilk örneklerinden biridir. Bagging ve Boosting gibi topluluk öğrenme algoritmalarının çoğu denetlemeli öğrenme için tasarlanmıştır. Şekil 4.8'de görüldüğü gibi Bagging yöntemi, aynı algoritmayı verinin iadeli örnekleme ile seçilen farklı altkümeleri üzerinde çalıştırmaktadır. Boyutu n olan bir yineleme veri kümesi, n kalıplarının orijinal veri kümesiyle değiştirilerek rastgele çizilmektedir. Bir önyükleme örneği D_1, D içine birden çok kez dahil olabilir, ancak diğerleri dahil edilmez. Önyükleme fikri, gerçek veri kümesi *D*'den örneklemenin bilinmeyen dağılım *P*'den örnekleme için mümkün olan en iyi yaklaşımıdır. Ardından, bu önyükleme veri kümesi kullanılarak bir model oluşturulmaktadır. Bu işlem T kez tekrarlanmakta ve böylece T modelleri elde edilmektedir. Daha sonra T modelleri, regresyon problemleri için ortalama kullanılarak toplanmaktadır. Bagging yöntemi, bir regresyon problemi için şu şekilde çalışmaktadır (Yumurtacı Aydoğmuş vd., 2015: 744-745):

A, $i = 1,2, \dots \dots, n$ olmak üzere (X_i, Y_i) içeren D'nin eğitim setidir. burada X_i çok boyutlu öngörü değişkeninin bir gerçekleştirmesidir ve Y_i gerçek değerli bir değişkenin gerçekleşmesidir. Bir tahminleyici $E(Y|X = x) = f(x)$ şöyle gösterilir;

$$C_n(x) = h_n(D_1, \dots \dots, D_n)(x) \qquad (4.14)$$

Teorik olarak Bagging aşağıdaki gibi tanımlanır: İlk olarak, önyüklemeli bir örnek oluşturulur. $D_i^* = (Y_i^*, X_i^*)$ çiftlerin ampirik dağılımına göre $(i = 1,2, \dots \dots, n)$

olmak üzere $D_i^* = (Y_i^*, X_i^*)$ olur. İkinci olarak, önyüklenmiş öngörme eklenti prensibi ile tahmin edilmektedir,

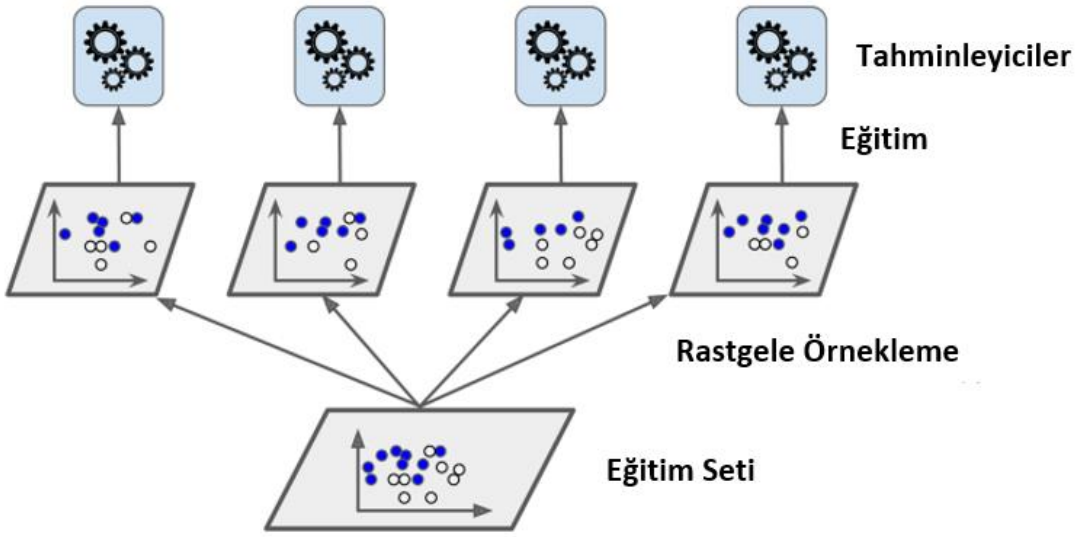
$$C_n^*(x) = h_n(D_1^*, \dots\dots, D_n^*)(x) \quad (4.15)$$

$$C_n(x) = h_n(D_1, \dots\dots, D_n)(x) \quad (4.16)$$

iken sonuç olarak Bagging öngörücü;

$$C_{n;B}(x) = E|D_n^*(x)| \quad (4.17)$$

Özetlemek gerekirse, Bagging, tatmin edici bir performans ile temel öğreniciler ile kombine edildiğinde varyansı azaltabilen en basit uygulamalardan biridir.



Şekil 4.8: Bagging Yöntemi (Koptur, Erişim Tarihi: 29.10.2017).

4.2.6. Doğrusal Regresyon Algoritması

Han ve arkadaşları Doğrusal Regresyon (Linear Regression) algoritmasının 2011'deki çalışmalarında şu şekilde anlatmışlardır (Han, vd., 2011: 355-356): Doğrusal regresyon analizi, bir sonuç değişkeni *y* ve tek bir tahmin değişkeni *x* içermektedir. Regresyonun en basit şeklidir ve *x*'in doğrusal bir fonksiyonu olarak *y*'leri modellemektedir. Yani,

$$y = b + wx \quad (4.18)$$

burada *y*'nin varyansının sabit olduğu, b ve w değerlerinin Y-kesitini ve eğimini belirten regresyon katsayıları olduğu varsayılmaktadır. Regresyon katsayıların *w* ve *b*, aynı zamanda ağırlık olarak düşünülebileceği için eşdeğer olarak yazılabilir,

$$y = w_0 + w_1 x \tag{4.19}$$

Bu katsayılar, gerçek veri ile tahmin doğrusu arasındaki hatayı asgari düzeye indirgeyen doğruyu tahmin eden en küçük kareler yöntemiyle çözülebilir. *D*, tahmin değişkeni *x* ve bununla ilişkili sonuç değişkeni *y*'den oluşan bir eğitim setidir. Eğitim seti $|D|, (x_1, y_1), (x_2, y_2), \dots\dots, (x|D|, y|D|)$ formunun veri noktalarını içermektedir. Regresyon katsayıları aşağıdaki denklemlerle bu yöntemi kullanarak hesaplanabilir:

$$w_1 = \frac{\sum_{i=1}^{|D|}(x_i - \bar{x})\,(y_i - \bar{y})}{\sum_{i=1}^{|D|}(x_i - \bar{x})^2} \tag{4.20}$$

$$w_0 = \bar{y} - w_1 \bar{x} \tag{4.21}$$

Burada x $x_1, x_2, \dots\dots, x|D|$'nin ortalama değeri, *y* ise $y_1, y_2, \dots\dots, y|D|$'nin ortalama değeridir. Katsayılar w_0 ve w_1, genellikle karmaşık regresyon denklemlerine iyi yaklaşımlar sağlamaktadır.

4.2.7. Destek Vektör Regresyonu Algoritması

Destek Vektör Makineleri (Support Vector Machine), denetimli bir öğrenme yöntemi olup sınıflandırma ve regresyon için kullanılmaktadır. Destek vektör makineleri, geleneksel öğrenme yöntemlerine kıyasla doğrusal olmayan problemleri çözmede daha iyi performansa sahiptir. Yaygın olarak sınıflandırma problemleri için kullanılan destek vektör makinelerinin regresyon için uyarlaması Destek Vektör Regresyonu olarak adlandırılmıştır.

4.2.8. Karar Tablosu Algoritması

Etiketli örnekleri içeren bir eğitim örneği verildiğinde, bir tümevarım algoritması bir hipotez oluşturmaktadır. Burada gözlemlediğimiz temsil, çoğunluk sınıfına varsayılan kural eşlemesi olan bir Karar Tablosu (Decision Table)'dur. Bu karar tablosunun iki bileşeni vardır (Ron Kohavi, 1995: 131-132):

1. Bir dizi özellik olan bir şema.
2. Etiketli örneklerin çoklu seti olan bir gövde.

Her örnek, şemadaki her bir özellik için bir değer ve etiket için bir değerden oluşmaktadır. Etiketsiz bir örnek, $\tilde{X}$ verildiğinde, bir karar tablosu sınıflandırıcısı tarafından örneğe atanan etiket aşağıdaki gibi hesaplanmaktadır (Ron Kohavi, 1995: 131-132):

Karar tablosunda, sadece şablondaki özelliklerin eşleştirilmesi ve diğer tüm özelliklerin yoksayılması gereken, verilen örneğe tam olarak uyan etiketli örnekler kümesi olsun, $I = \emptyset$ ise; karar tablosundaki çoğunluk sınıfına geri dön; aksi halde, bağları keyfi olarak kırarak, çoğunluk sınıfını *I*'e geri döndür şeklindedir. Bilinmeyen/eksik değerler, eşleme işleminde farklı değerler olarak değerlendirilmektedir.

Tümevarım algoritmasının amacı, karar tablosu için en uygun özellik alt kümesini bulmaktır. $\tilde{X} = (X_1, \dots \dots, X_n)$ bir dizi özellik ve *D* eğitim seti, özelliklerinin bir alt kümesi olsun. Tümevarım algoritmasının amacı, bir şema seçmektir. $\tilde{X}_{opt}$ şu şekilde formülize edilmektedir:

$$\tilde{X}_{opt} = \arg\max_{\tilde{X}' \subseteq \tilde{X}} acc(DTM(\tilde{X}', D)) \qquad (4.22)$$

Burada acc, karar tablosunun XxY uzayından rasgele seçilen bir örneği doğru olarak sınıflandırma ihtimalini göstermektedir. $\tilde{X}_{opt}$ şeması, eğitim setindeki tüm örneklerin karar tablosunun gövdesinde saklandığı varsayımı altında bir karar tablosu için en uygun özellik alt kümesinden oluşmaktadır.

4.2.9. M5P Algoritması

Bir karar ağacı, her dal düğümünün çeşitli alternatifler arasında bir seçimi temsil ettiği ve her yaprak düğümünün bir sınıflandırma veya kararı temsil ettiği bir ağaçtır (Balouchi, 2015: 56). M5 olarak adlandırılan "model ağacı", öğrenme problemleriyle başa çıkmak için ortaya konulmuştur. Model ağaçları karar ağacı ve doğrusal regresyon fonksiyonlarının bir kombinasyonu olarak tasarlanmıştır. Young ve Witten,

ağaç boyutunu azaltmak için orijinal M5 algoritması üzerinde veri kümesinde daha iyi performans gösteren M5P'yi geliştirmiştir (Ayaz vd., 2015, 236).

M5P modeli, veri madenciliği için karar ağacı ve çoklu doğrusal regresyonu birleştirmektedir. Karar ağacı, gözlemlenen girdileri kategorik veya sayısal veriler için geçerli olan çıkarsama öğrenme ile tahmini çıktılara ilişkilendirmektedir. Karar ağacı girdi ve çıktılar arasındaki mantıksal ve regresyon tipi kuralları çıkarmak için girdi ve çıktı verilerini maksimum (Bayesçi) entropi ile sınıflandırmaktadır (Nikoo vd., 2013, 2777).

M5 ağacını kurmak için öncelikle bir karar ağacı algoritması kullanılmaktadır (Ayaz vd., 2015, 236):

Bir M5 ağacı oluşturmak için bölme ölçütleri tanımlanmalıdır. Dallanma ölçütlerinin bölünmesi, özellik değerlerinin standart sapmasına dayanmaktadır. Beklenen hatayı azaltan öznitelik, ağacın kökü olarak seçilmektedir. Standart sapma azaltma (SDR) formülü aşağıdaki gibi hesaplanmaktadır:

Burada,

T: nitelik değerleri seti

T_i: seçilen özniteliğe göre bölünmüş düğümden alınan öznitelik değeri

$\bar{T}$: T özniteliğinin kümelerinin ortalama değeri

sd(T): T'nin standart sapması

$$SDR = sd(T) - \sum_i \frac{|T_i|}{|T|} \text{x sd}(T_i) \tag{4.23}$$

$$sd(T) = \sqrt{\frac{1}{n-1}\sum_{i=1}^{n}(T_i - \bar{T})^2} \tag{4.24}$$

$$\bar{T} = \frac{1}{n}\sum_{i=1}^{n} T_i \tag{4.25}$$

Ağacı kurduktan sonra, sınıflandırma performansını artırmak için ağaç budama yapılmalıdır. Budama işlemi, öğrenme verilerinde hata oluşturan dalları silmektedir. Ağaç oluşturma işlemi başlar başlamaz, ağaç sürekli bir durma kuralı olmadan bölünerek büyümektedir. Yapı sona erdiğinde budama yapraklardan köke doğru başlamaktadır. Her budama işleminden sonra en başarılı ağaç belirlenmektedir.

M5 algoritmasında, budama işlemi için her şeyden önce, gerçek sınıf değeri ile tahmin edilen değer arasındaki fark, her eğitim örneğinde düğüme ulaşıldığında ortalama alınmaktadır. Bu ortalama değer, bu katsayı ile çarpılmaktadırır.

$$\frac{n+v}{n-v} \tag{4.26}$$

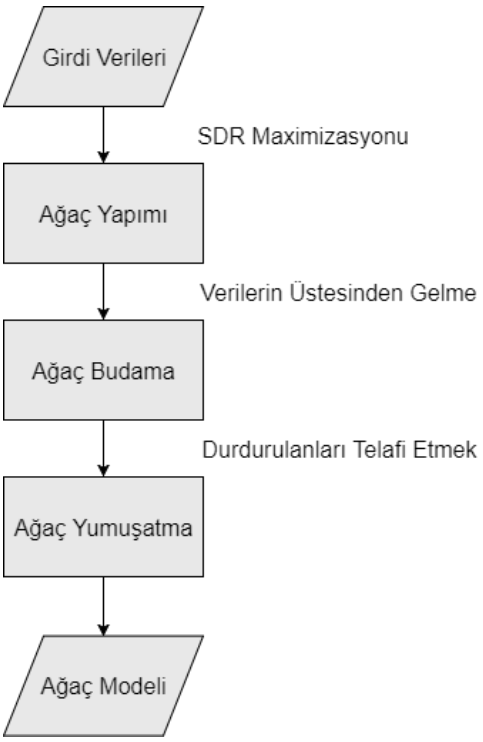
Burada,

n: düğümdeki eğitim örneklerinin sayısı

v: düğümdeki sınıf değerini temsil eden parametre sayısı

Şekil 4.9'da gösterildiği gibi, M5 ağacının geliştirilmesi için üç önemli adım vardır (Zhan, 2011, 1551-1552):

1. ağaç yapımı
2. ağaç budama
3. ağaç yumuşatma



Şekil 4.9: M5P Yöntemi (Zhan, 2011: 1551-1552).

4.2.10. M5Rules Algoritması

M5 kuralı, kural tabanlı bir öğrenme tekniğidir ve nominal ve sayısal değerleri tahmin edebilmektedir. M5 kural setleri model ağaçlarından oluşturulmaktadır. Model ağaçları sayısal ve nominal değerleri tahmin etmek için yeterlidir. Model ağaçları M5 kuralında kullanılmaktadır. Kural algoritması, model ağacı oluşturma işlemini tekrar ederek ve her çevrimde en iyi kuralı seçmeye çalışarak çalışmaktadır. Bir M5 kuralı oluşturmak için aşağıdaki adımlar uygulanmaktadır (Ayaz vd., 2015, 236):

- Tüm eğitim verileri için bir M5 ağacı öğrencisi uygulanır,
- M5P gibi, ağaç budanır,
- En iyi yaprak kural haline getirilir,
- Bütün örnekler kurallara dahil edilinceye kadar devam eder. Bir örnek aynı anda farklı kurallara dahil edilebilir.
- Kategorik tahminde M5 Kuralları kısmen araştırılan ağaçlar yerine tam ağaçlar oluşturur.

4.2.11. Performans Ölçümleri

Tez çalışmasında, önerilen modellerin tahmin doğruluğunu değerlendirmek için performans ölçümleri olarak R, RMSE, MAE ve MAPE kullanılmıştır. Performans ölçüm değerleri aşağıda açıklanmıştır (Chou vd., 2015: 4).

Doğrusal Korelasyon Katsayısı (R): R eğrisinin gerçek verilere ne kadar iyi uyduğunun ortak bir ölçüsüdür. 1 değeri, gerçek değer ile öngörülen değerler arasında mükemmel bir uyuma işaret etmekte, yani değerlerin aynı eğilime sahip olduğu anlamına gelmektedir. Aşağıda R'nin hesaplanması için matematiksel formül verilmiştir:

$$R = \frac{n\sum yy' - (\sum y)(\sum y')}{\sqrt{n(\sum y^2) - (\sum y)^2}\sqrt{n(\sum y'^2) - (\sum y')^2}} \tag{4.32}$$

burada y' tahmin edilen değer; y gerçek değer; ve n veri örneklerinin sayısıdır.

Ortalama Karesel Hatanın Karekökü (RMSE): RMSE, gerçek değerlerle karşılaştırıldığında tahminin karesel hatasını bulmak ve toplam değerin karekökünü bulmak için hesaplanmaktadır. Dolayısıyla bir veri noktasının dikey bir çizgi boyunca ölçülen sabit çizgiden ortalama mesafesi olmaktadır. Bu araç, istenmeyen büyük farklılıkları etkili bir şekilde tanımlamaktadır. RMSE, şu şekilde formüle edilmiştir:

$$RMSE = \sqrt{\frac{\sum_{i=1}^{n}\sum(y' - y)^2}{n}} \tag{4.33}$$

Ortalama Mutlak Hata (MAE): MAE değeri, yakın tahminlerin nihai sonuçlara ne kadar yakın olduğunu ölçmek için kullanılan bir miktardır. Tahmini ve fiili değerler arasındaki hataların ortalama büyüklüğünü, hataların yönünü göz ardı ederek hesaplamaktadır. Aşağıdaki denklem MAE'nin matematiksel formülünü sunmaktadır:

$$MAE = \frac{1}{n}\sum_{i=1}^{n}|y - y'| \tag{4.34}$$

Bağıl Mutlak Hata (RAE): RAE değeri, tahmini ve fiili değerler arasındaki farkın mutlak değerinin gerçek değerlere oranıdır. RAE aşağıdaki gibi formülüze edilmiştir:

$$RAE = \frac{|y'_1 - y_1| + \cdots + |y'_n - y_n|}{|y_1 - \bar{y}| + \cdots + |y_n - \bar{y}|} \tag{4.35}$$

Bağıl Karesel Hatanın Karekökü (RRSE): RRSE değeri, tahmin edilen değer ile gerçek değer arasındaki farkların karelerinin toplamının gerçek değerler ve ortalama değer arasındaki farkların karelerinin toplamına oranının kareköküdür. RRSE aşağıdaki şekilde formülize edilmiştir:

$$RRSE = \sqrt{\frac{(y'_1 - y)^2 + \cdots + (y'_n - y_n)^2}{(y_1 - \bar{y})^2 + \cdots + (y_n - \bar{y})^2}} \tag{4.36}$$

4.3.VERİ ANALİZİ

Bu çalışmada, tersine lojistik süreçleri kapsamında giyim perakendeciliğinde dünya çapında faaliyet gösteren, marka konumlandırması olarak orta sınıf segmente hitap eden ve düşük fiyat politikası izleyen öncü bir firmanın yaz sezonu ürünlerinin sezon dönüşümleri öncesi mağazalarından ana depolarına yapılan ürün iade verileri incelenmiştir.

Verilerin elde edilmesi aşamasında ürün iade tahmin modelinin girdi parametreleri, öncelikle işinde uzman olan iş analistleri ve mağaza çalışanları ile görüşülerek ürün iadesini etkileyen, ürünlere ve mağazalara ait özelliklerin neler olabileceğine ve iade sebeplerinin neler olabileceğine yönelik bilgi toplanarak belirlenmiştir. Belirlenen bu parametreler veri analizi, deneme yanılma yöntemleri, parametre seçim algoritmaları ile de ayrıntılı olarak incelenmiş, böylece detaylı bir çalışma sonucu modelde kullanılacak girdi parametreleri ortaya konmuştur. Bu parametrelere göre sistemden ürün iade verileri çekilmiş, elde edilen verilerde eksik ve aşırı uç veriler düzeltilmiştir. Ürün iadesini etkileyen parametrelerin belirlenmesi amacıyla yapılan bu çalışmayla literatüre katkı sağlanması ve tekstil sektöründe genel olarak kullanılabilecek bir model ortaya konması amaçlanmıştır.

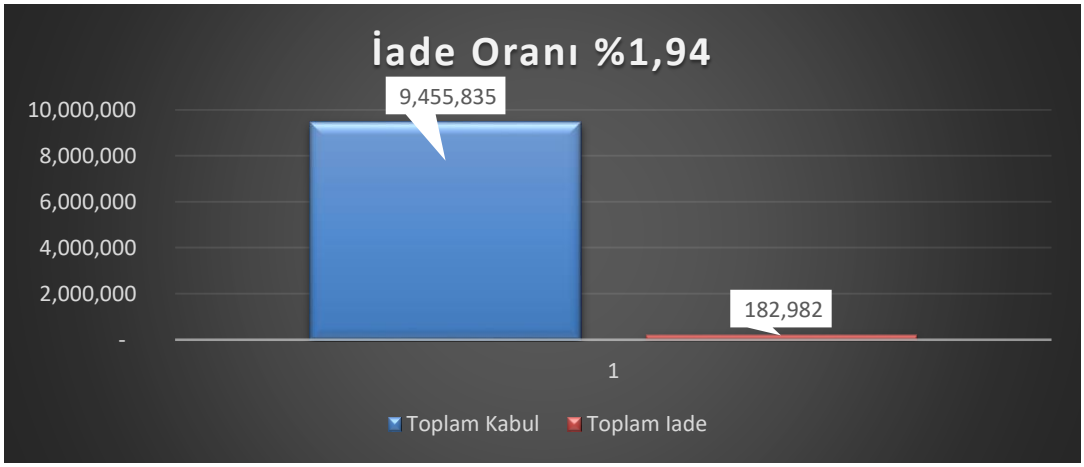
Belirlenen parametrelere göre sistemden çekilmiş, 389.478 farklı üründen oluşan genel veri seti göz önünde bulundurulmuştur. Fakat daha detaylı bir incelemenin mümkün olması için tüm ürün gruplarını kapsayan bu genel veri seti içerisinden iade sebepleri, ürün sayısı, iade oranındaki tutarlılık, eksik ve aşırı uçlu verilerin minimum olması, toplumda aynı kesime hitap ediyor olması sebepleri ile "bayan pantolon" ürün grubu verileri çalışmamızda kullanılmak üzere seçilmiştir. "Bayan pantolon" ürün grubuna ait 52 çeşit ürün özelinde 313 mağazadan merkeze yapılmış 3000 iade faaliyetinden (irsaliye) veri elde edilmiştir. İade ve bunun tersi anlamında tercih nedenlerini yönetebilen bir firma; değişken maliyetlerini, talep tahminlerini, lokasyon ve marka konumlandırmasını, depo ve sevk süreçlerini optimize etmek için elde edilen analiz sonuçlarını iş zekası kapsamında birer çıktı olarak kullanabilecektir.

Tekstil ürünlerinde iade faaliyetine neden olabilecek özellikler ürüne ve mağazaya bağlı özellikler olarak aşağıda görüldüğü iki ana başlık altında gibi toplanmıştır:

- Mağazaya bağlı özellikler
    - Mağaza Adı
    - Lokasyon tipi (AVM, cadde)
    - Kanal (inlet, outlet)
    - Bölge (Çukurova, Trakya, İstanbul Avrupa, …)
    - Şehir (Adana, Adıyaman, Afyon, …)
    - İklim Durumu (Sıcak, soğuk)
    - Mağaza Segmenti (A, A+, B, B+, C, C+)
- Ürüne bağlı Özellikler
    - Ürün grurbu (Kadın –Erkek – Çocuk)
    - Stili (Günlük, genç tarz, …)
    - Renk (Açık mavi, koyu mavi, mat siyah, parlak siyah, kırık beyaz, …)
    - Renk Ailesi (Mavi, siyah, beyaz, …)
    - Renk Tipi (Kot, tek renk, desenli)
    - Beden (S, M, L, …, 27, 28, …, 32, 34, 36, …)
    - Yaş (Bebek, çocuk, genç., yetişkin)
    - Koleksiyon Grup (Keten, kot, …)

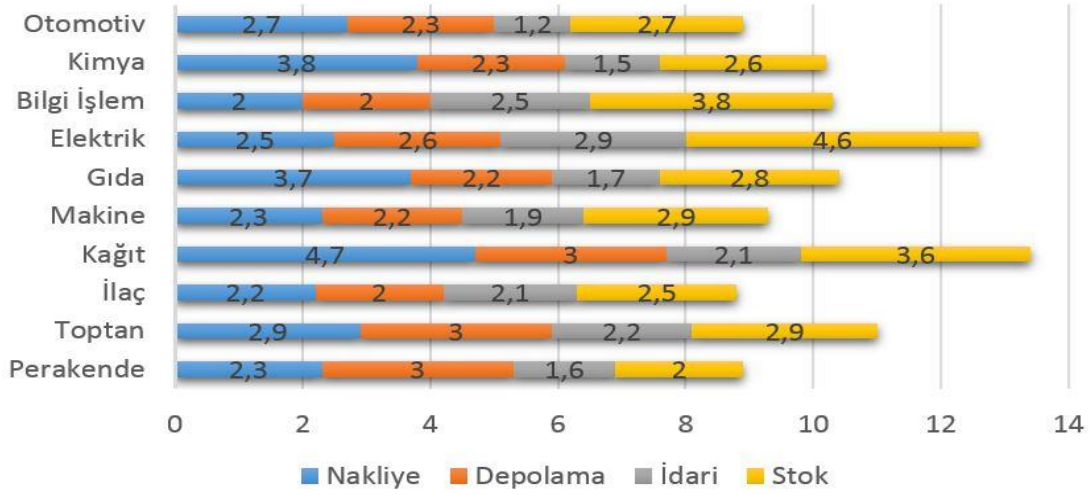
- Sınıf (Pantolon, bluz, ceket, …)
- Bel (Yüksek bel, düşük bel, normal)
- Model (Dar kesim, spor, rahat kesim, …)
- Kalite (1. sınıf, 2. sınıf, 3. sınıf)
- Kabul Edilen Ürün Miktarı
- İade Edilen Ürün Miktarı
- Fiyat (9,99 TL ile 79,99 TL arasında değişen)

Seçilen veriler incelendiğinde mağazaların bayan pantolon sınıfındaki ilgili ürünler için toplamda 9.455.835 adet kabul faaliyeti gerçekleştirdiği, ana depolardan mağazalara belirtilen adet kadar sevk işlemi gerçekleştirildiği, bunun tersine lojistik faaliyeti kapsamında mağazalardan ana depoya 182.982 adet sevk gerçekleştirildiği görülmüştür. Şekil 4.10'da de görüldüğü gibi seçilen verilerin ortalama iade oranı %1.94, seçilen verilerde maksimum iade oranı ise %3'tür.



Şekil 4.10: Toplam iade oranı.

İlgili sektörde satış cirosu üzerinden lojistik faaliyetlere ilişkin maliyetler incelendiğinde Şekil 4.11'deki gibi bir tablo oluşmaktadır:



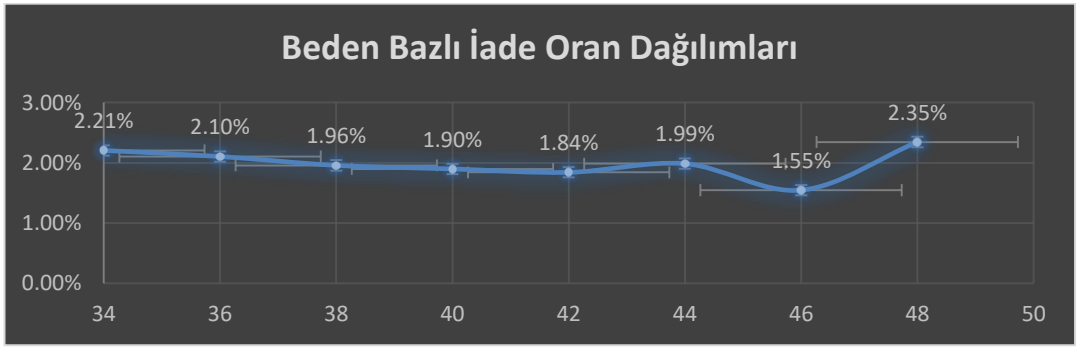
Şekil 4.11: Sektörlere göre lojistik maliyetleri (Uğur, 2007; 82).

İade süreçlerinde yapılacak optimizasyon çalışması ile sadece nakliye, depolama, stok yönetimi değil üretim maliyetleri de azalacaktır. Muadil ürün sevki ve stok dönüşüm oranlarında iyileştirmeler sağlanmış olacak, çapraz satışlara olan çeşitlilik etkisi ve ekonomik sipariş miktarı ve lot optimizasyonlarına konu olabilecek bir çok faaliyet alanında iyileştirme aksiyonları oluşacaktır.

Ürün tercih nedenlerine etki eden en önemli parametrelerden bir tanesi "beden"dir. Firma müşterileri için bir profil bilgisi olarak incelenmektedir. İade oranı yüksek olan bedenlerin lot optimazyonları veya üretim için belirlenen katsayıları azaltılabilir. Firma ilgili klas için 48 ve 34 bedenlerinde yüksek oranda iade almış bulunmaktadır. Bu iade oranlarının üretim katsayıları değiştirilebilir. Burada her şubeye sabit bir lot gönderilmesindense yapılacak lot optimizasyonu çalışması ile lotlar değer segmentleri belirlenmiş mağazalara göre farklı şekillerde oluşturulabilir. Lot sevkiyatlarındaki bu çeşitlilik olumlu anlamda etki yapacağı gibi depo standartlarına olan etkisi depolama faaliyet alanında yapılacak simüle çalışması sonucu belirlenebilir. Tercih nedenlerinin az olmasının sebebi olarak bu ürünleri alan müşteri grubunun farklı olması veya büyük ve küçük bedenlerin şıklık kavramına olumsuz anlamdaki etkileri araştırılıp tasarım anlamında değişiklikler yapılabilir. Beden bazında iade oranları Tablo 4.1'de, iade oranlarının bedenlere göre dağılımı ise Şekil 4.12'de görülmektedir.

Tablo 4.1: Beden bazlı iade oranı.

Beden	Toplam Sevk	İade	Sevk %	İade Oranı
34	161,645	3,566	1.71%	2.21%
36	949,042	19,977	10.04%	2.10%
38	2,248,880	44,038	23.78%	1.96%
40	2,237,390	42,489	23.66%	1.90%
42	2,492,004	45,920	26.35%	1.84%
44	1,306,415	25,949	13.82%	1.99%
46	46,989	727	0.50%	1.55%
48	13,470	316	0.14%	2.35%
Genel Toplam	**9,455,835**	**182,982**	**100.00%**	

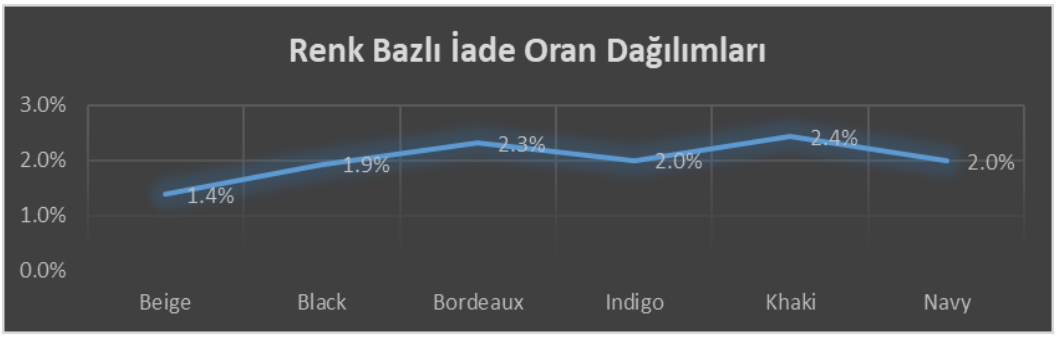


Şekil 4.12: İade oranının beden özelliğine göre dağılımı.

Ürün özelliklerinden renk parametresi incelendiğinde en fazla iade oranının %2,43'le Khaki (haki) renginde olduğu gözlemlenmiştir. Araştırmaya konu olan pantolon sınıfı için müşteri tercihlerinin koyu olan renklerde daha yoğun olduğu tespit edilmiştir. Bu bulgu üzerinden koyu renklerin üretiminin ve sevkiyatının diğer renklere göre daha fazla olacak şekilde planlanmasının uygun olacağı söylenebilir. Tablo 4.2'de renk bazlı iade oranları ve Şekil 4.13'te renklere göre iade oranlarının dağılımı görülmektedir.

Tablo 4.2: Renk bazlı iade oranı.

Renk	Toplam Sevk	İade	Sevk %	İade Oranı
Beige	128,129	1,778	1.36%	1.39%
Black	8,473,854	163,677	89.62%	1.93%
Bordeaux	12,220	282	0.13%	2.31%
Indigo	1,050	21	0.01%	2.00%
Khaki	103,231	2,513	1.09%	2.43%
Navy	737,351	14,711	7.80%	2.00%
Genel Toplam	**9,455,835**	**182,982**	**100.00%**	1.94%

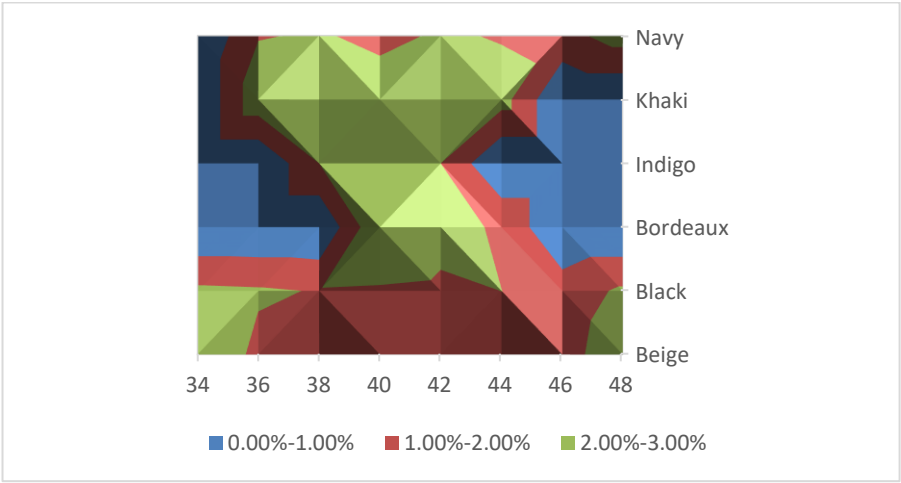


Şekil 4.13: İade oranının renge göre dağılımı.

Renk ve beden bazlı bir değerlendirme yapıldığında ise büyük bedenlerde koyu renk tercih edilme oranının daha fazla olduğu görülmektedir. Beden ve renk bazlı iade oranları Tablo 4.3'te, iade oran dağılımının yoğunluğu ise Şekil 4.14'te görülmektedir. Bu kural çıkarımı doğrultusunda değerlendirildiğinde büyük bedenler için açık renk üretimi yerine koyu renk üretime daha fazla ağırlık verilebilir.

Tablo 4.3: Renk ve bedene göre iade oranları.

Beden / Renk	34	36	38	40	42	44	46	48
Beige	2.94%	1.75%	1.05%	1.43%	1.28%	1.08%	1.67%	2.56%
Black	2.19%	2.12%	1.95%	1.91%	1.81%	2.00%	1.51%	2.15%
Bordeaux	0.00%	0.00%	0.00%	2.94%	2.38%	1.85%	0.00%	0.00%
Indigo	0.00%	0.00%	2.00%	2.00%	2.00%	0.00%	0.00%	0.00%
Khaki	0.00%	2.68%	2.38%	2.55%	2.34%	2.40%	0.00%	0.00%
Navy	0.00%	1.94%	2.09%	1.75%	2.11%	1.93%	1.69%	2.44%

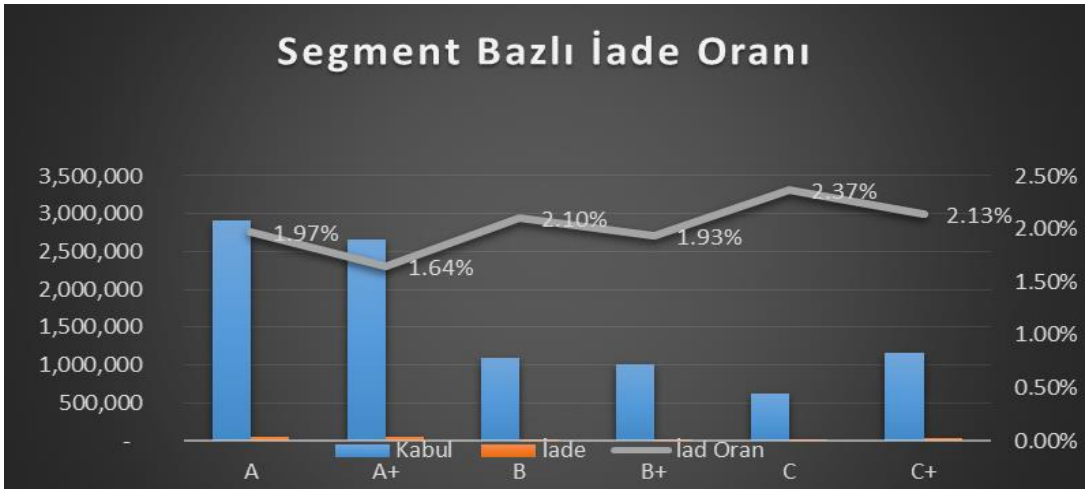


Şekil 4.14: Renk ve bedene göre iade oranı yoğunluğu.

Değer grubuna göre segmente edilmiş mağaza gruplarına göre iade oranları incelendiğinde en fazla iade oranının en düşük değer grubu olan C sınıfındaki mağazalarda olduğu görülmektedir. İade oranlarında görülen bu farklılıklar, ürün sevkiyatlarının kümelenmiş lokasyonlara göre yapılması gerektiğini ortaya koymaktadır. Mağaza segmentlerine göre iade oranları Tablo 4.4'te, İade oranlarının mağaza segmentine göre dağılımı ise Şekil 4.15'te görülmektedir.

Tablo 4.4: Mağaza segmentine göre iade oranı.

Segment	Toplam Sevk	İade	Sevk %	İade Oranı
A	2,913,922	57,302	30.82%	1.97%
A+	2,663,010	43,800	28.16%	1.64%
B	1,085,069	22,813	11.48%	2.10%
B+	1,005,762	19,459	10.64%	1.93%
C	**620,961**	**14,699**	**6.57%**	**2.37%**
C+	1,167,111	24,909	12.34%	2.13%
Genel Toplam	**9,455,835**	**182,982**	**100.00%**	1.94%



Şekil 4.15: İade oranının mağaza segmentine göre dağılımı.

Tablo 4.5'te de görüldüğü gibi cadde mağazalarının iade oranı AVM mağazalarına göre daha yüksektir.

Tablo 4.5: Mağazanın lokasyon tipine göre iade oranı.

Lokasyon Tipi	Toplam Sevk	İade	Sevk %	İade Oranı
AVM	5,643,846	106,188	59.69%	1.88%
Cadde	3,811,989	76,794	40.31%	2.01%
Genel Toplam	**9,455,835**	**182,982**	**100.00%**	1.94%

Araştırmaya konu olan pantolon sınıfında mağazanın lokasyonunun sıcaklık durumuna göre dağılımı Tablo 4.6'da incelendiğinde sıcak iklim gösteren bölgelerde iade oranı %2.10 olarak gözlemlenmiştir.

Tablo 4.6: Mağazanın bulunduğu bölgenin sıcaklığına göre iade oranları.

İklim Durum	Toplam Sevk	İade	Sevk %	İade Oranı
Soğuk	7,039,243	132,177	74.44%	1.88%
Sıcak	2,416,592	50,805	25.56%	2.10%
Genel Toplam	**9,455,835**	**182,982**	**100.00%**	1.94%

Yukarıdaki dağılımlar mağazanın lokasyonlarının belirli özellikleri üzerinden yapılan incelemelerdir. Mağazaların kendisinin de bir parametre olarak değerlendirilmesi gerekir. Mağazalar arasındaki iade farklılıkları aşağıdaki Tablo 4.7'de görülmektedir.

Beden ve şehir bazlı incelemede de bazı şehirler için düşük bedenlerde iade oranı fazla olarak gözlemlenmiştir. Bu da şehirlerin de beden bazlı olarak bir kümeye ayrılıp onun üzerinden sevkiyat planlaması yapılması gerekliliğini ortaya koymaktadır. Örneğin; Anada, Antep, Afyon, Siirt gibi illerde düşük beden iade oranlarının daha yüksek olması nedeni ile bu illere daha az küçük bedenli ürün gönderilmesi gerektiği, daha büyük bedenlerin iade oranı en yüksek olan Bursa, İzmir gibi illere ise daha az büyük beden gönderimi yapılması gerektiği söylenebilir.

Tablo 4.7: Mağaza bazında iade oranları

Mağaza	Toplam Kabul	Toplam Iade	Sıra	Iade Oranı
Mağaza 12	4930	145	1. Sırada	2.94%
Mağaza 44	2652	78	2. Sırada	2.94%
Mağaza 228	4526	124	19. Sırada	2.74%
Mağaza 8	31240	852	20. Sırada	2.73%
Mağaza 270	7280	195	39. Sırada	2.68%
Mağaza 116	11550	308	40. Sırada	2.67%
Mağaza 233	13188	336	59. Sırada	2.55%
Mağaza 87	15222	387	60. Sırada	2.54%
Mağaza 252	6222	153	79. Sırada	2.46%
Mağaza 255	6222	153	80. Sırada	2.46%
Mağaza 259	2352	56	99. Sırada	2.38%
Mağaza 279	2688	64	100. Sırada	2.38%
Mağaza 173	42534	973	119. Sırada	2.29%
Mağaza 72	47600	1088	120. Sırada	2.29%
Mağaza 119	34920	776	139. Sırada	2.22%
Mağaza 198	18000	400	140. Sırada	2.22%
Mağaza 83	10212	222	159. Sırada	2.17%
Mağaza 130	6900	150	160. Sırada	2.17%
Mağaza 269	17936	380	179. Sırada	2.12%
Mağaza 157	15876	336	180. Sırada	2.12%
Mağaza 62	41940	862	199. Sırada	2.06%
Mağaza 214	11680	240	200. Sırada	2.05%
Mağaza 251	43502	862	219. Sırada	1.98%
Mağaza 5	47314	934	220. Sırada	1.97%
Mağaza 170	56808	1080	239. Sırada	1.90%
Mağaza 30	1580	30	240. Sırada	1.90%
Mağaza 58	83154	1488	259. Sırada	1.79%
Mağaza 211	6278	112	260. Sırada	1.78%
Mağaza 35	41661	686	279. Sırada	1.65%
Mağaza 49	73394	1206	280. Sırada	1.64%
Mağaza 185	120020	1381	299. Sırada	1.15%
Mağaza 162	129753	1314	300. Sırada	1.01%
GENEL TOPLAM	9455835	182982		1.94%

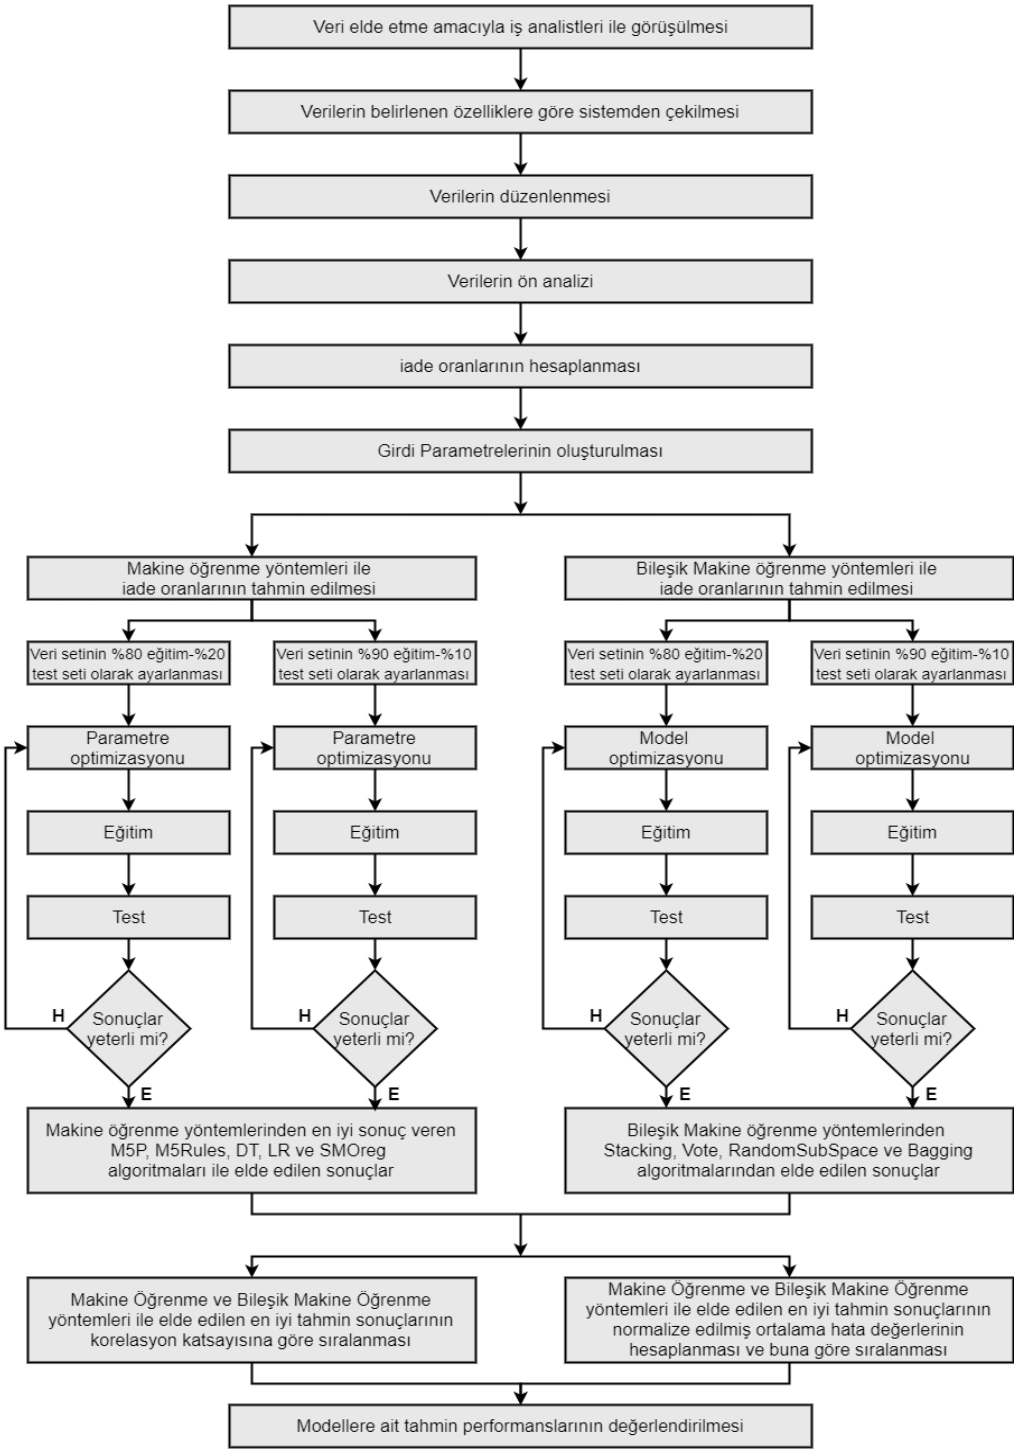
5. BULGULAR

5.1. VAKA ÇALIŞMASI

Çalışmamızın ilk adımında tersine lojistik faaliyetlerinde ürün iadelerinin tahmin edilmesinin önemi üzerine dünya çapında faaliyet gösteren bir tekstil firması iş analistleri ile görüşülmüş, bu iş analistleri ile birlikte firmanın ürün iade verileri incelenmiştir. İade oranlarının daha detaylı olarak incelenebilmesi için çok büyük miktardaki veri havuzundan belirli bir ürün grubu seçilmiştir. İade oranı tahmin edilecek ürün grubu seçilirken ürün yelpazesinin genişliğine, iade oran aralığının tutarlılığına, veri içerisinde eksik veya aşırı uç verilerin mümkün olduğunca az olmasına dikkat edilmiştir. Çalışma için "bayan pantolon" ürün grubu uygun bulunarak bu ürün grubuna ait veriler üzerinde düzenleme ve analiz yapılmıştır. Verilerin düzenlenmesi aşamasında iş analistleri ile görüşülüp ürünlere ve mağazalara ait özellikler belirlenmiş, eksik ve aşırı uç veriler düzeltilmiş ve iade sebepleri hakkında bilgi alınmıştır. Bir ürünün bir mağazadan merkeze geri gönderilen sayısı ile o ürünün o mağazaya gelen sayısı oranlanarak ürün iade oranı hesaplanmıştır.

Düzenlenmiş veri seti WEKA programına girilip verilerin kategorik veya sayısal özellikte olmalarına göre veriler tanımlanmıştır. Tanımlanan veriler üzerinde Makine Öğrenme ve Bileşik Makine Öğrenme teknikleri kullanılarak ürün iade oranları tahmin edilmiş ve bu tahminlere göre tahmin performansları elde edilmiştir. Öncelikle program veri setinin %80'ini öğrenme için kullanıp algoritmaları eğitmek, %20'sini ise iade oranlarını tahmin etmek için kullanacak şekilde ayarlanmıştır. Makine Öğrenme yöntemlerinden kategorik ve sayısal değerlerin ikisini de içeren veri setlerine uygun olan M5P, REPTree, Decision Stump, Random Tree, M5Rules, Decision Table, KStar, IBk, LWL, Linear Regression, SMOreg, Multilayer Perceptron yöntemlerinin iade oranlarını tahmin etme performansları değerlendirilmiştir. Bileşik Makine Öğrenme yöntemleri için sınıflandırıcı olarak Makine Öğrenme yöntemlerinden en iyi performans elde ettiğimiz M5P, M5Rules, Decision Table, Linear Regression ve SMOreg yöntemleri ve bu yöntemlerin çeşitli kombinasyonları kullanılmıştır. Ayrıca program veri setinin %90'ı ile algotitmayı eğitecek ve %10'u ile tahmin yapacak

şekilde ayarlanıp, %80 eğitim-%20 test seti olarak ayarlanarak tahmin yaptırılmış yöntemler ile %90 eğitim-%10 test seti olarak da tahmin yapılmıştır.



Şekil 5.1: Metodoloji

Uygulanan Makine Öğrenme ve Bileşik Makine Öğrenme tekniklerinin veri setinin hem %80 eğitim-%20 test seti hem de %90 eğitim-%10 test seti olarak ayarlanması durumunda elde edilen tahmin performansları tablolar halinde gösterilmiş ve yöntemler birbirleri ile korelasyon katsayısı ve hata değerleri bakımından kıyaslanmıştır. Uygulama metodolojisi Şekil 5.1'de görülmektedir.

5.2. SONUÇLARIN DEĞERLENDİRİLMESİ

İlk olarak Makine Öğrenme tekniklerinin tahmin performansları veri seti %80 eğitim-%20 test seti şeklinde tahmin ve eğitim için ayrılarak ele alınmıştır. Tablo 5.1'de görüldüğü gibi M5Rules algoritması; R, RMSE, MAE, RAE ve RRSE performans değerleri bakımından en iyi sonuçları vermiştir. Bileşik Makine Öğrenme yöntemlerinden Bagging-M5Rules algoritması ise Tablo 5.3'te görüldüğü gibi tüm algoritmaların sonuçları içinde en iyi değerleri elde etmiştir. Tablo 5.5'te görüldüğü gibi Stacking yöntemlerinden Stacking M5P (M5P+M5Rules+DecisionTable+LR+SMOreg) ve Stacking M5Rules (M5P+M5Rules+DecisionTable+LR+SMOreg) algoritmaları; aynı R, RMSE, MAE ve MAPE performans ölçüm değerlerine sahipken, Stacking M5P (M5P+M5Rules+DecisionTable+LR+SMOreg) algoritması 28163,46 saniyelik çalışma süresi ile süre bakımından daha iyi performans göstermiştir. Tablo 5.2'de görülen Random Sub Space bileşik makine yönteminde ise RSS-M5P algoritması en iyi performans değerlerine ve en kısa model kurma süresine sahiptir. Bileşik makine yöntemlerinden Voting yönteminde ise Vote (M5P+M5Rules+Decision Table) algoritması Tablo 5.4'te görüldüğü gibi en iyi R, RMSE, MAE, RAE ve RRSE performans ölçüm değerlerine sahipken süre bakımından en kısa hesaplama süresine sahip değildir.

Tablo 5.1: Basit makine öğrenme algoritmalarından elde edilen sonuçlar (%80 Eğitim-%20 Test Seti)

M5P		**REPTree**	
Correlation coefficient	**0.8018**	Correlation coefficient	0,6953
Mean absolute error	0.0114	Mean absolute error	0,0141
Root mean squared error	0.0151	Root mean squared error	0,0182
Relative absolute error	51.76%	Relative absolute error	64.03%
Root relative squared error	60.10%	Root relative squared error	72.39%
Model Building Duration	276.4	Model Building Duration	1,11
Decision Stump		**Random Tree**	
Correlation coefficient	0,4418	Correlation coefficient	0,6645
Mean absolute error	0,0192	Mean absolute error	0,0142
Root mean squared error	0,0225	Root mean squared error	0,0193
Relative absolute error	87.16%	Relative absolute error	64.52%
Root relative squared error	89.71%	Root relative squared error	77.06%
Model Building Duration	0,02	Model Building Duration	0,2
M5Rules		**Decision Table**	
Correlation coefficient	**0.8098**	Correlation coefficient	0.7412
Mean absolute error	0.0113	Mean absolute error	0.0131
Root mean squared error	0.0148	Root mean squared error	0.0169
Relative absolute error	51.13%	Relative absolute error	59.57%
Root relative squared error	58.82%	Root relative squared error	67.23%
Model Building Duration	408.96	Model Building Duration	1.38
KStar		**IBk**	
Correlation coefficient	0,6732	Correlation coefficient	0,6642
Mean absolute error	0,0141	Mean absolute error	0,0141
Root mean squared error	0,0188	Root mean squared error	0,0192
Relative absolute error	64%	Relative absolute error	64%
Root relative squared error	75%	Root relative squared error	76%
Model Building Duration	0	Model Building Duration	0,01
LWL		**Linear Regression**	
Correlation coefficient	0,5845	Correlation coefficient	0.7478
Mean absolute error	0,0176	Mean absolute error	0.0132
Root mean squared error	0,0206	Root mean squared error	0.0167
Relative absolute error	80%	Relative absolute error	59.73%
Root relative squared error	82%	Root relative squared error	66.44%
Model Building Duration	0,01	Model Building Duration	225.94
SMOreg		**Multilayer Perceptron**	
Correlation coefficient	0.7352	Correlation coefficient	0,4775
Mean absolute error	0.0129	Mean absolute error	0,0314
Root mean squared error	0.0173	Root mean squared error	0,0399
Relative absolute error	58.43%	Relative absolute error	142.41%
Root relative squared error	68.99%	Root relative squared error	159.10%
Model Building Duration	2087.44	Model Building Duration	50871,2

Tablo 5.2: Bileşik makine yöntemi olan random sub-space algoritmalarından elde edilen sonuçlar (%80 Eğitim-%20 Test Seti)

randomsubpace -M5P	
Correlation coefficient	0.7655
Mean absolute error	0.0135
Root mean squared error	0.0165
Relative absolute error	61%
Root relative squared error	66%
Model Building duration	502

randomsubpace -M5RULES	
Correlation coefficient	0.7608
Mean absolute error	0.0136
Root mean squared error	0.0166
Relative absolute error	62%
Root relative squared error	66%
Model Building duration	2096.6

randomsubpace -LR	
Correlation coefficient	0.7478
Mean absolute error	0.0132
Root mean squared error	0.0167
Relative absolute error	60%
Root relative squared error	66%
Model Building duration	229.45

randomsubpace -SMOreg	
Correlation coefficient	0.7352
Mean absolute error	0.0129
Root mean squared error	0.0173
Relative absolute error	58%
Root relative squared error	69%
Model Building duration	2094.09

randomsubpace -DecisionTable	
Correlation coefficient	0.7293
Mean absolute error	0.0141
Root mean squared error	0.0174
Relative absolute error	64%
Root relative squared error	69%
Model Building duration	2.77

Tablo 5.3: Bileşik makine yöntemi olan bagging algoritmalarından elde edilen sonuçlar (%80 Eğitim-%20 Test Seti)

Bagging- M5P		**Bagging- M5Rules**	
Correlation coefficient	**0.8213**	Correlation coefficient	**0.8268**
Mean absolute error	0.0111	Mean absolute error	0.011
Root mean squared error	0.0143	Root mean squared error	0.0141
Relative absolute error	50%	Relative absolute error	50%
Root relative squared error	57%	Root relative squared error	56%
Model Building duration	1568	Model Building duration	8094.67
Bagging- LR		**Bagging- SMOReg**	
Correlation coefficient	0.7478	Correlation coefficient	0.7352
Mean absolute error	0.0132	Mean absolute error	0.0129
Root mean squared error	0.0167	Root mean squared error	0.0173
Relative absolute error	60%	Relative absolute error	58%
Root relative squared error	66%	Root relative squared error	69%
Model Building duration	229.45	Model Building duration	2094.09
Bagging- Decision Table			
Correlation coefficient	0.0097		
Mean absolute error	0.0221		
Root mean squared error	0.0251		
Relative absolute error	100%		
Root relative squared error	100%		
Model Building duration	36.24		

Tablo 5.4: Bileşik makine yöntemi olan voting algoritmalarından elde edilen sonuçlar (%80 Eğitim-%20 Test Seti)

Vote (M5P+M5Rules)		**Vote (M5P+M5Rules+Linear Regression)**	
Correlation coefficient	**0.8207**	Correlation coefficient	**0.8209**
Mean absolute error	0.011	Mean absolute error	0.0111
Root mean squared error	0.0144	Root mean squared error	0.0143
Relative absolute error	49.94%	Relative absolute error	50.45%
Root relative squared error	57.19%	Root relative squared error	57.15%
Model Building Duration	741.8	Model Building Duration	990.71
Vote (M5P+M5Rules+SMOreg)		**Vote (M5P+Decision Table)**	
Correlation coefficient	0.8198	Correlation coefficient	0.8066
Mean absolute error	0.0111	Mean absolute error	0.0115
Root mean squared error	0.0144	Root mean squared error	0.0148
Relative absolute error	50.12%	Relative absolute error	52.26%
Root relative squared error	57.28%	Root relative squared error	59.15%
Model Building Duration	3027.26	Model Building Duration	304.01
Vote (M5P+Decision Table+SMOreg)		**Vote (M5P+Decision Table+Linear Regression)**	
Correlation coefficient	0.8091	Correlation coefficient	0.8116
Mean absolute error	0.0115	Mean absolute error	0.0115
Root mean squared error	0.0148	Root mean squared error	0.0147
Relative absolute error	52.02%	Relative absolute error	52.27%
Root relative squared error	58.86%	Root relative squared error	58.67%
Model Building Duration	2468.25	Model Building Duration	552.19
Vote (M5P+SMOreg)		**Vote (M5Rules+Linear Regression+SMOreg)**	
Correlation coefficient	0.8054	Correlation coefficient	0.7928
Mean absolute error	0.0114	Mean absolute error	0.0119
Root mean squared error	0.0149	Root mean squared error	0.0153
Relative absolute error	51.80%	Relative absolute error	53.80%
Root relative squared error	59.32%	Root relative squared error	60.96%
Model Building Duration	2583.7	Model Building Duration	3128.84
Vote (M5Rules+Linear Regression)		**Vote (M5Rules+Decision Table+SMOreg)**	
Correlation coefficient	0.8074	Correlation coefficient	0.8083
Mean absolute error	0.0116	Mean absolute error	0.0115
Root mean squared error	0.0148	Root mean squared error	0.0148
Relative absolute error	52.52%	Relative absolute error	52.22%
Root relative squared error	59.04%	Root relative squared error	58.97%
Model Building Duration	682.82	Model Building Duration	2740.89
Vote (M5Rules+SMOreg)		**Vote (Decision Table+Linear Regression)**	
Correlation coefficient	0.8035	Correlation coefficient	0.7813
Mean absolute error	0.0115	Mean absolute error	0.0124
Root mean squared error	0.015	Root mean squared error	0.0157
Relative absolute error	52.07%	Relative absolute error	56.26%
Root relative squared error	59.58%	Root relative squared error	62.60%
Model Building Duration	2740.76	Model Building Duration	249.99
Vote (Decision Table+Linear Regression+SMOreg)		**Vote (Linear Regression+SMOreg)**	
Correlation coefficient	0.7755	Correlation coefficient	0.7457
Mean absolute error	0.0124	Mean absolute error	0.013
Root mean squared error	0.0159	Root mean squared error	0.0168
Relative absolute error	56.17%	Relative absolute error	58.90%
Root relative squared error	63.17%	Root relative squared error	66.96%
Model Building Duration	2533.12	Model Building Duration	2519.56
Vote (M5P+Linear Regression+SMOreg)		**Vote (M5P+M5Rules+Decision Table)**	
Correlation coefficient	0.7953	Correlation coefficient	**0.8216**
Mean absolute error	0.0118	Mean absolute error	0.0111
Root mean squared error	0.0152	Root mean squared error	0.0143
Relative absolute error	53.49%	Relative absolute error	50.47%
Root relative squared error	60.63%	Root relative squared error	57.08%
Model Building Duration	2909.4	Model Building Duration	744.14
Vote (M5Rules+Decision Table)		**Vote (M5P+Linear Regression)**	
Correlation coefficient	0.8093	Correlation coefficient	0.8087
Mean absolute error	0.0115	Mean absolute error	0.0115
Root mean squared error	0.0148	Root mean squared error	0.0148
Relative absolute error	52.15%	Relative absolute error	52.08%
Root relative squared error	58.83%	Root relative squared error	58.87%
Model Building Duration	439.35	Model Building Duration	554.56
Vote (Decision Table+SMOreg)		**Vote (M5Rules+Linear Regression+Decision Table)**	
Correlation coefficient	0.7752	Correlation coefficient	0.8111
Mean absolute error	0.0124	Mean absolute error	0.0116
Root mean squared error	0.0159	Root mean squared error	0.0147
Relative absolute error	56.12%	Relative absolute error	52.52%
Root relative squared error	63.24%	Root relative squared error	58.75%
Model Building Duration	2290.94	Model Building Duration	703.51
Vote (M5P+M5Rules+Linear Regression+Decision Table+SMOre		**Vote (M5P+M5Rules+Linear Regression+Decision Table)**	
Correlation coefficient	0,8151	Correlation coefficient	**0,8217**
Mean absolute error	0,0113	Mean absolute error	0,0112
Root mean squared error	0,0146	Root mean squared error	0,0144
Relative absolute error	51.45%	Relative absolute error	50.87%
Root relative squared error	58.07%	Root relative squared error	57.22%
Model Building Duration	4409,37	Model Building Duration	1334,77

Tablo 5.5: Bileşik makine yöntemi olan stacking algoritmalarından elde edilen sonuçlar (%80 Eğitim-%20 Test Seti)

Stacking M5P (M5P+M5Rules)		**Stacking M5P (M5P+M5Rules+Decision Table)**	
Correlation coefficient	**0.8225**	Correlation coefficient	**0.8247**
Mean absolute error	0.0112	Mean absolute error	0.0111
Root mean squared error	0.0143	Root mean squared error	0.0142
Relative absolute error	51%	Relative absolute error	50%
Root relative squared error	57%	Root relative squared error	57%
Model Building duration	7301	Model Building duration	7538.24
Stacking M5P (M5P+M5Rules+SMOreg)		**Stacking M5P (Decision Table+LR+SMOreg)**	
Correlation coefficient	**0.8259**	Correlation coefficient	0.7868
Mean absolute error	0.011	Mean absolute error	0.0121
Root mean squared error	0.0142	Root mean squared error	0.0155
Relative absolute error	50%	Relative absolute error	55%
Root relative squared error	56%	Root relative squared error	62%
Model Building duration	27407.32	Model Building duration	21043.06
Stacking M5P (M5Rules+Decision Table)		**Stacking M5P (M5P+M5Rules+Decision Table+LR+SMOreg)**	
Correlation coefficient	0.8196	Correlation coefficient	**0.8263**
Mean absolute error	0.0113	Mean absolute error	0.011
Root mean squared error	0.0144	Root mean squared error	0.0141
Relative absolute error	51%	Relative absolute error	50%
Root relative squared error	57%	Root relative squared error	56%
Model Building duration	5253.49	Model Building duration	28163.46
Stacking M5Rules (M5P+M5Rules+Decision Table)		**Stacking M5Rules (M5P+M5Rules+SMOreg)**	
Correlation coefficient	**0.8247**	Correlation coefficient	**0.8259**
Mean absolute error	0.0111	Mean absolute error	0.011
Root mean squared error	0.0142	Root mean squared error	0.0142
Relative absolute error	50%	Relative absolute error	50%
Root relative squared error	57%	Root relative squared error	56%
Model Building duration	7319.03	Model Building duration	29306.36
Stacking M5Rules (M5P+M5Rules)		**Stacking M5Rules (M5P+M5Rules+Decision Table+LR+SMOreg)**	
Correlation coefficient	**0.8225**	Correlation coefficient	**0.8263**
Mean absolute error	0.0112	Mean absolute error	0.011
Root mean squared error	0.0143	Root mean squared error	0.0141
Relative absolute error	51%	Relative absolute error	50%
Root relative squared error	57%	Root relative squared error	56%
Model Building duration	8190.01	Model Building duration	29651,49
Stacking LR (M5P+M5Rules+Decision Table+LR+SMOreg)		**Stacking Decision Table (M5P+M5Rules+Decision Table+LR+SMOreg)**	
Correlation coefficient	**0.8264**	Correlation coefficient	0.8111
Mean absolute error	0.0109	Mean absolute error	0.0115
Root mean squared error	0.0141	Root mean squared error	0.0147
Relative absolute error	50%	Relative absolute error	52%
Root relative squared error	56%	Root relative squared error	59%
Model Building duration	39029.64	Model Building duration	29720.71
Stacking SMOreg (M5P+M5Rules)		**Stacking SMOreg (M5P+M5Rules+Decision Table+LR+SMOreg)**	
Correlation coefficient	**0.8223**	Correlation coefficient	**0.8266**
Mean absolute error	0.0109	Mean absolute error	0.0108
Root mean squared error	0.0143	Root mean squared error	0.0142
Relative absolute error	50%	Relative absolute error	490448%
Root relative squared error	57%	Root relative squared error	563906%
Model Building duration	8052.41	Model Building duration	28752.19
Stacking SMOreg (M5P+M5Rules+Decision Table)			
Correlation coefficient	**0.8254**		
Mean absolute error	0.0109		
Root mean squared error	0.0142		
Relative absolute error	49%		
Root relative squared error	57%		
Model Building duration	7339.19		

Makine Öğrenme tekniklerinin tahmin performansları veri seti %90 eğitim-%10 test seti şeklinde tahmin ve eğitim için ayrılarak ele alındığında elde edilen sonuçlar Tablo 5.6'da verilmiştir. Görüldüğü gibi M5P algoritması; R, RMSE, MAE, RAE ve RRSE performans değerleri ve model kurma süresi bakımından en iyi sonuçları vermiştir. Bileşik makine öğrenme yöntemlerinden Bagging-M5Rules algoritması ise Tablo 5.8'de görüldüğü gibi tüm algoritmaların sonuçları içinde model kurma süresi diğer bazı algoritmalardan uzun olsa da en iyi performans değerlerini elde etmiştir. Tablo 5.10'da görüldüğü gibi Stacking yöntemlerinden Stacking-M5P(M5P+M5Rules+SMOreg) 0,8389 değeri ile tüm algoritmalar içinde en iyi R değerine sahiptir. RandomSubSpace bileşik makine yönteminde ise Tablo 5.7'de görüldüğü gibi RSS-M5P algoritması diğer Makine Öğrenme ve Bileşik Makine Öğrenme yöntemlerine kıyasla daha kötü sonuç vermesine rağmen RSS algoritmaları içinde en iyi performans değerlerine sahiptir. Bileşik makine yöntemlerinden voting yönteminde ise Vote(M5P+M5Rules) algoritması en iyi R, RMSE, MAE, RAE ve RRSE performans ölçüm değerlerine sahipken süre bakımından en kısa hesaplama süresine sahip değildir, sonuçlar tablo 5.9'da görülmektedir.

Tablo 5.6: Basit makine öğrenme algoritmalarından elde edilen sonuçlar (%90 Eğitim-%10 Test Seti)

M5P		**REPTree**	
Correlation coefficient	**0.8235**	Correlation coefficient	0.7215
Mean absolute error	0.0106	Mean absolute error	0.0134
Root mean squared error	0.0141	Root mean squared error	0.0173
Relative absolute error	49.14%	Relative absolute error	62.05%
Root relative squared error	56.93%	Root relative squared error	69.53%
Model Building Duration	304.61	Model Building Duration	0.35
Decision Stump		**Random Tree**	
Correlation coefficient	0.4426	Correlation coefficient	0.6782
Mean absolute error	0.019	Mean absolute error	0.0138
Root mean squared error	0.0223	Root mean squared error	0.0187
Relative absolute error	87.87%	Relative absolute error	63.70%
Root relative squared error	89.72%	Root relative squared error	75.33%
Model Building Duration	0.06	Model Building Duration	0.15
M5Rules		**Decision Table**	
Correlation coefficient	**0.8222**	Correlation coefficient	0.7379
Mean absolute error	0.0107	Mean absolute error	0.013
Root mean squared error	0.0142	Root mean squared error	0.0168
Relative absolute error	49.44%	Relative absolute error	60.03%
Root relative squared error	57.24%	Root relative squared error	67.67%
Model Building Duration	450.42	Model Building Duration	1.74
KStar		**IBk**	
Correlation coefficient	0.6819	Correlation coefficient	0.6708
Mean absolute error	0.0137	Mean absolute error	0.0138
Root mean squared error	0.0183	Root mean squared error	0.0187
Relative absolute error	63%	Relative absolute error	64%
Root relative squared error	74%	Root relative squared error	76%
Model Building Duration	0	Model Building Duration	0
LWL		**Linear Regression**	
Correlation coefficient	0.582	Correlation coefficient	0.7423
Mean absolute error	0.0175	Mean absolute error	0.0131
Root mean squared error	0.0204	Root mean squared error	0.0167
Relative absolute error	81%	Relative absolute error	60.40%
Root relative squared error	82%	Root relative squared error	67.18%
Model Building Duration	0	Model Building Duration	253.31
SMOreg		**Multilayer Perceptron**	
Correlation coefficient	0.7252	Correlation coefficient	0.364
Mean absolute error	0.0129	Mean absolute error	0.0254
Root mean squared error	0.0175	Root mean squared error	0.0306
Relative absolute error	59.42%	Relative absolute error	117.24%
Root relative squared error	70.38%	Root relative squared error	123.31%
Model Building Duration	2331.86	Model Building Duration	8805.02

Tablo 5.7: Bileşik makine yöntemi olan random sub-space algoritmalarından elde edilen sonuçlar (%90 Eğitim-%10 Test Seti)

randomsubpace -M5P		**randomsubpace -M5RULES**	
Correlation coefficient	**0.7804**	Correlation coefficient	0.776
Mean absolute error	0.0128	Mean absolute error	0.0129
Root mean squared error	0.0158	Root mean squared error	0.0159
Relative absolute error	59%	Relative absolute error	59%
Root relative squared error	64%	Root relative squared error	64%
Model Building duration	526.62	Model Building duration	2154.91
randomsubpace -LR		**randomsubpace -SMOreg**	
Correlation coefficient	0.7135	Correlation coefficient	0.6994
Mean absolute error	0.014	Mean absolute error	0.0136
Root mean squared error	0.0175	Root mean squared error	0.0178
Relative absolute error	65%	Relative absolute error	63%
Root relative squared error	70%	Root relative squared error	72%
Model Building duration	543.85	Model Building duration	6523.81
randomsubpace -DecisionTable			
Correlation coefficient	0.7496		
Mean absolute error	0.0134		
Root mean squared error	0.0166		
Relative absolute error	62%		
Root relative squared error	67%		
Model Building duration	2.87		

Tablo 5.8: Bileşik makine yöntemi olan bagging algoritmalarından elde edilen sonuçlar (%90 Eğitim-%10 Test Seti)

Bagging- M5P		**Bagging- M5Rules**	
Correlation coefficient	**0.8306**	Correlation coefficient	**0.838**
Mean absolute error	0.0107	Mean absolute error	0.0105
Root mean squared error	0.0138	Root mean squared error	0.0136
Relative absolute error	49%	Relative absolute error	48%
Root relative squared error	56%	Root relative squared error	55%
Model Building duration	1765.33	Model Building duration	8166.09
Bagging- Decision Table		**Bagging- LR**	
Correlation coefficient	0	Correlation coefficient	0.74
Mean absolute error	0.0217	Mean absolute error	0.0131
Root mean squared error	0.0248	Root mean squared error	0.0167
Relative absolute error	100%	Relative absolute error	61%
Root relative squared error	100%	Root relative squared error	67%
Model Building duration	38.82	Model Building duration	3029.73
Bagging- SMOReg			
Correlation coefficient	0.7316		
Mean absolute error	0.013		
Root mean squared error	0.0172		
Relative absolute error	60%		
Root relative squared error	69%		
Model Building duration	22576.23		

Tablo 5.9: Bileşik makine yöntemi olan voting algoritmalarından elde edilen sonuçlar (%90 Eğitim-%10 Test Seti)

Vote (M5P+M5Rules)		**Vote (M5P+M5Rules+Linear Regression)**	
Correlation coefficient	**0.8375**	Correlation coefficient	**0.8354**
Mean absolute error	0.0103	Mean absolute error	0.0105
Root mean squared error	0.0136	Root mean squared error	0.0137
Relative absolute error	47.43%	Relative absolute error	48.63%
Root relative squared error	54.71%	Root relative squared error	55.07%
Model Building Duration	691.3	Model Building Duration	1016.43
Vote (M5P+M5Rules+SMOreg)		**Vote (M5P+Decision Table)**	
Correlation coefficient	**0.8315**	Correlation coefficient	0.8138
Mean absolute error	0.0105	Mean absolute error	0.0111
Root mean squared error	0.0138	Root mean squared error	0.0144
Relative absolute error	48.42%	Relative absolute error	51.27%
Root relative squared error	55.55%	Root relative squared error	58.15%
Model Building Duration	3100.74	Model Building Duration	280.62
Vote (M5P+Decision Table+SMOreg)		**Vote (M5P+Decision Table+Linear Regression)**	
Correlation coefficient	0.8111	Correlation coefficient	0.8158
Mean absolute error	0.0112	Mean absolute error	0.0112
Root mean squared error	0.0145	Root mean squared error	0.0144
Relative absolute error	51.62%	Relative absolute error	51.80%
Root relative squared error	58.52%	Root relative squared error	58.05%
Model Building Duration	2642.52	Model Building Duration	507.86
Vote (M5P+SMOreg)		**Vote (M5Rules+Linear Regression+SMOreg)**	
Correlation coefficient	0.8115	Correlation coefficient	0.7989
Mean absolute error	0.011	Mean absolute error	0.0115
Root mean squared error	0.0145	Root mean squared error	0.0149
Relative absolute error	50.77%	Relative absolute error	53.15%
Root relative squared error	58.46%	Root relative squared error	60.15%
Model Building Duration	2653.37	Model Building Duration	2880.43
Vote (M5Rules+Linear Regression)		**Vote (M5Rules+Decision Table+SMOreg)**	
Correlation coefficient	0.8197	Correlation coefficient	0.8134
Mean absolute error	0.0111	Mean absolute error	0.0112
Root mean squared error	0.0142	Root mean squared error	0.0144
Relative absolute error	51.11%	Relative absolute error	51.54%
Root relative squared error	57.33%	Root relative squared error	58.19%
Model Building Duration	631.15	Model Building Duration	2572.38
Vote (M5Rules+SMOreg)		**Vote (Decision Table+Linear Regression)**	
Correlation coefficient	0.8126	Correlation coefficient	0.7761
Mean absolute error	0.011	Mean absolute error	0.0123
Root mean squared error	0.0145	Root mean squared error	0.0157
Relative absolute error	50.91%	Relative absolute error	56.79%
Root relative squared error	58.32%	Root relative squared error	63.12%
Model Building Duration	2791.86	Model Building Duration	230.91
Vote (Decision Table+Linear Regression+SMOreg)		**Vote (Linear Regression+SMOreg)**	
Correlation coefficient	0,7686	Correlation coefficient	0.7373
Mean absolute error	0,0123	Mean absolute error	0.013
Root mean squared error	0,0159	Root mean squared error	0.0169
Relative absolute error	56.84%	Relative absolute error	59.83
Root relative squared error	63.98%	Root relative squared error	68.11
Model Building Duration	2378,91	Model Building Duration	2586.08
Vote (M5P+Linear Regression+SMOreg)		**Vote (M5P+M5Rules+Decision Table)**	
Correlation coefficient	0.7978	Correlation coefficient	**0.8325**
Mean absolute error	0.0115	Mean absolute error	0.0106
Root mean squared error	0.015	Root mean squared error	0.0138
Relative absolute error	53.04%	Relative absolute error	49.01%
Root relative squared error	60.30%	Root relative squared error	55.47%
Model Building Duration	2744.15	Model Building Duration	753.68
Vote (M5Rules+Decision Table)		**Vote (M5P+Linear Regression)**	
Correlation coefficient	0.8173	Correlation coefficient	0.8193
Mean absolute error	0.0111	Mean absolute error	0.011
Root mean squared error	0.0143	Root mean squared error	0.0143
Relative absolute error	51.14%	Relative absolute error	50.96%
Root relative squared error	57.64%	Root relative squared error	57.46%
Model Building Duration	404.12	Model Building Duration	508.86
Vote (Decision Table+SMOreg)		**Vote (M5Rules+Linear Regression+Decision Table)**	
Correlation coefficient	0.7684	Correlation coefficient	0.8179
Mean absolute error	0.0123	Mean absolute error	0.0112
Root mean squared error	0.0159	Root mean squared error	0.0143
Relative absolute error	56.59%	Relative absolute error	51.73%
Root relative squared error	64.02%	Root relative squared error	57.74%
Model Building Duration	2290.83	Model Building Duration	635.03
Vote (M5P+M5Rules+Linear Regression+Decision Table+SMOr		**Vote (M5P+M5Rules+Linear Regression+Decision Table)**	
Correlation coefficient	0.8214	Correlation coefficient	**0.8312**
Mean absolute error	0.011	Mean absolute error	0.0108
Root mean squared error	0.0142	Root mean squared error	0.0139
Relative absolute error	50.62%	Relative absolute error	49.74%
Root relative squared error	57.13%	Root relative squared error	55.82%
Model Building Duration	3009.87	Model Building Duration	986.48

Tablo 5.10: Bileşik makine yöntemi olan stacking algoritmalarından elde edilen sonuçlar (%90 Eğitim-%10 Test Seti)

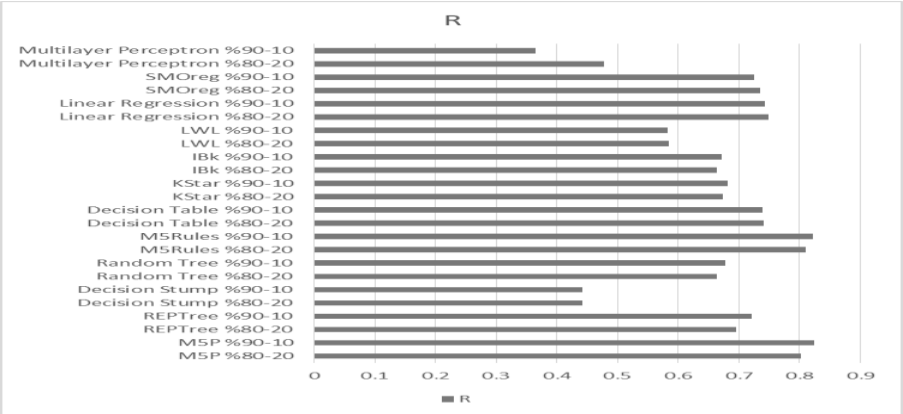
Stacking M5P (M5P+M5Rules)		**Stacking M5P (M5P+M5Rules+Decision Table)**	
Correlation coefficient	**0.8368**	Correlation coefficient	**0.8368**
Mean absolute error	0.0106	Mean absolute error	0.0105
Root mean squared error	0.0136	Root mean squared error	0.0136
Relative absolute error	49%	Relative absolute error	49%
Root relative squared error	55%	Root relative squared error	55%
Model Building duration	7559.15	Model Building duration	7527.49
Stacking M5P (M5P+M5Rules+SMOreg)		**Stacking M5P (Decision Table+LR+SMOreg)**	
Correlation coefficient	**0.8389**	Correlation coefficient	**0.7845**
Mean absolute error	0.0105	Mean absolute error	0.0119
Root mean squared error	0.0135	Root mean squared error	0.0154
Relative absolute error	48%	Relative absolute error	55%
Root relative squared error	55%	Root relative squared error	62%
Model Building duration	30413.19	Model Building duration	24573.54
Stacking M5P (M5Rules+Decision Table)		**Stacking M5P (M5P+M5Rules+Decision Table+LR+SMOreg)**	
Correlation coefficient	0.8283	Correlation coefficient	**0.8375**
Mean absolute error	0.0108	Mean absolute error	0.0105
Root mean squared error	0.0139	Root mean squared error	0.0136
Relative absolute error	50%	Relative absolute error	49%
Root relative squared error	56%	Root relative squared error	55%
Model Building duration	5396.41	Model Building duration	33237.54
Stacking M5Rules (M5P+M5Rules+Decision Table)		**Stacking M5Rules (M5P+M5Rules+SMOreg)**	
Correlation coefficient	**0.8368**	Correlation coefficient	**0.8389**
Mean absolute error	0.0105	Mean absolute error	0.0105
Root mean squared error	0.0136	Root mean squared error	0.0135
Relative absolute error	48.56%	Relative absolute error	48%
Root relative squared error	54.83%	Root relative squared error	55%
Model Building duration	8282.24	Model Building duration	24973.38
Stacking M5Rules (M5P+M5Rules)		**Stacking M5Rules (M5P+M5Rules+Decision Table+LR+SMOreg)**	
Correlation coefficient	**0.8368**	Correlation coefficient	**0.8375**
Mean absolute error	0.0106	Mean absolute error	0.0105
Root mean squared error	0.0136	Root mean squared error	0.0136
Relative absolute error	49%	Relative absolute error	49%
Root relative squared error	55%	Root relative squared error	55%
Model Building duration	7394.72	Model Building duration	30464.71
Stacking LR (M5P+M5Rules+Decision Table+LR+SMOreg)		**Stacking Decision Table (M5P+M5Rules+Decision Table+LR+SMOreg)**	
Correlation coefficient	**0.8375**	Correlation coefficient	0.8189
Mean absolute error	0.0104	Mean absolute error	0.011
Root mean squared error	0.0136	Root mean squared error	0.0142
Relative absolute error	48%	Relative absolute error	51%
Root relative squared error	55%	Root relative squared error	57%
Model Building duration	30760.91	Model Building duration	38361.32
Stacking SMOreg (M5P+M5Rules)		**Stacking SMOreg (M5P+M5Rules+Decision Table+LR+SMOreg)**	
Correlation coefficient	**0.8364**	Correlation coefficient	**0.8378**
Mean absolute error	0.0103	Mean absolute error	0.0103
Root mean squared error	0.0137	Root mean squared error	0.0136
Relative absolute error	47.78%	Relative absolute error	48%
Root relative squared error	55.07%	Root relative squared error	55%
Model Building duration	8220.79	Model Building duration	28657.13
Stacking SMOreg (M5P+M5Rules+Decision Table)			
Correlation coefficient	**0.837**		
Mean absolute error	0.0103		
Root mean squared error	0.0137		
Relative absolute error	47.79%		
Root relative squared error	55.06%		
Model Building duration	8177.58		

Tablo 5.11: Makine Öğrenme yöntemlerinin performans ölçümleri

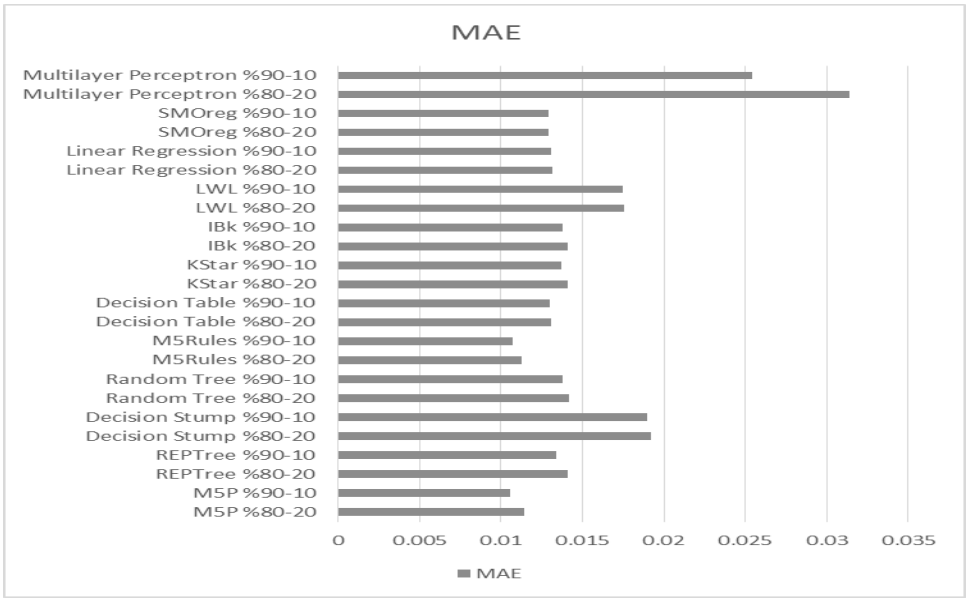
Makine Öğrenme Sınıflandırıcıları	R	MAE	RMSE	RAE	RRSE	MKS
M5P %80-20	0,8018	0,0114	0,0151	51.76%	60.10%	276,4
M5P %90-10	0,8235	0,0106	0,0141	49.14%	56.93%	304,61
REPTree %80-20	0,6953	0,0141	0,0182	64.03%	72.39%	1,11
REPTree %90-10	0,7215	0,0134	0,0173	62.05%	69.53%	0,35
Decision Stump %80-20	0,4418	0,0192	0,0225	87.16%	89.71%	0,02
Decision Stump %90-10	0,4426	0,019	0,0223	87.87%	89.72%	0,06
Random Tree %80-20	0,6645	0,0142	0,0193	64.52%	77.06%	0,2
Random Tree %90-10	0,6782	0,0138	0,0187	63.70%	75.33%	0,15
M5Rules %80-20	0,8098	0,0113	0,0148	51.13%	58.82%	408,96
M5Rules %90-10	0,8222	0,0107	0,0142	49.44%	57.24%	450,42
Decision Table %80-20	0,7412	0,0131	0,0169	59.57%	67.23%	1,38
Decision Table %90-10	0,7379	0,013	0,0168	60.03%	67.67%	1,74
KStar %80-20	0,6732	0,0141	0,0188	63.91%	74.81%	0
KStar %90-10	0,6819	0,0137	0,0183	63.47%	73.83%	0
IBk %80-20	0,6642	0,0141	0,0192	63.80%	76.32%	0,01
IBk %90-10	0,6708	0,0138	0,0187	63.76%	75.55%	0
LWL %80-20	0,5845	0,0176	0,0206	79.77%	82.23%	0,01
LWL %90-10	0,582	0,0175	0,0204	80.92%	82.33%	0
Linear Regression %80-20	0,7478	0,0132	0,0167	59.73%	66.44%	225,94
Linear Regression %90-10	0,7423	0,0131	0,0167	60.40%	67.18%	253,31
SMOreg %80-20	0,7352	0,0129	0,0173	58.43%	68.99%	2087,44
SMOreg %90-10	0,7252	0,0129	0,0175	59.42%	70.38%	2331,86
Multilayer Perceptron %80-20	0,4775	0,0314	0,0399	142.41%	159.10%	50871,2
Multilayer Perceptron %90-10	0.364	0.0254	0.0306	117.24%	123.31%	8805.02

Makine Öğrenme yöntemleri ile hem %80 eğitim -%20 test seti olarak ayarlanmış veri setinden hem de %90 eğitim- %10 test seti olarak ayarlanmış veri setinden elde edilen sonuçlar Tablo 5.11'de verilmiştir.

Korelasyon katsayısına göre Makine Öğrenme algoritmalarının performansı kıyaslandığında en iyi değer M5P %90-10 algoritması ile elde edilmiştir, en kötü sonuç ise Yapay sinir ağları %90-10 algoritması ile elde edilmiştir.

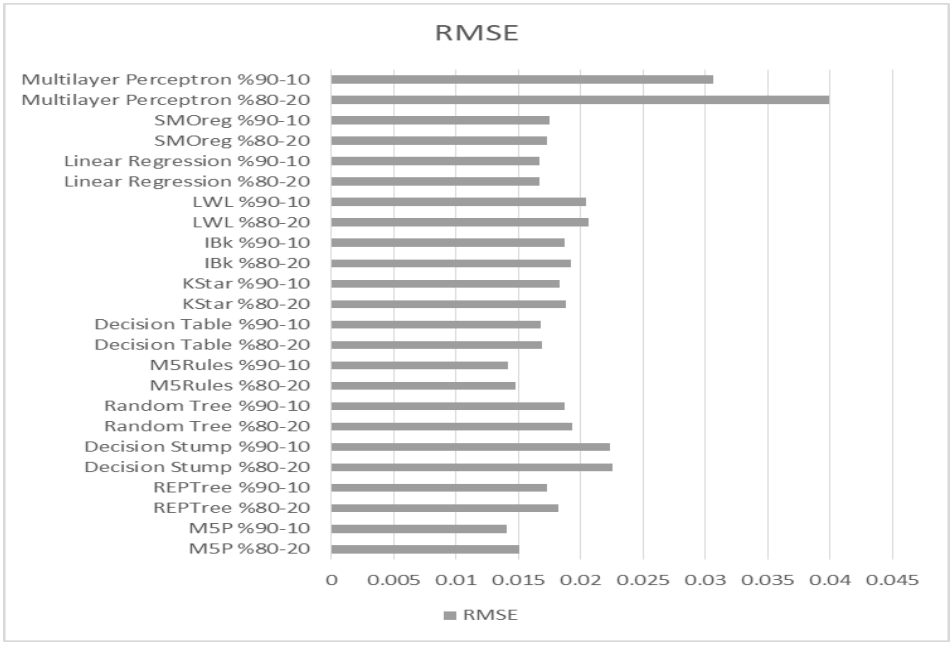


Şekil 5.2: Makine Öğrenme algoritmalarıyla elde edilen sonuçların korelasyon katsayıları

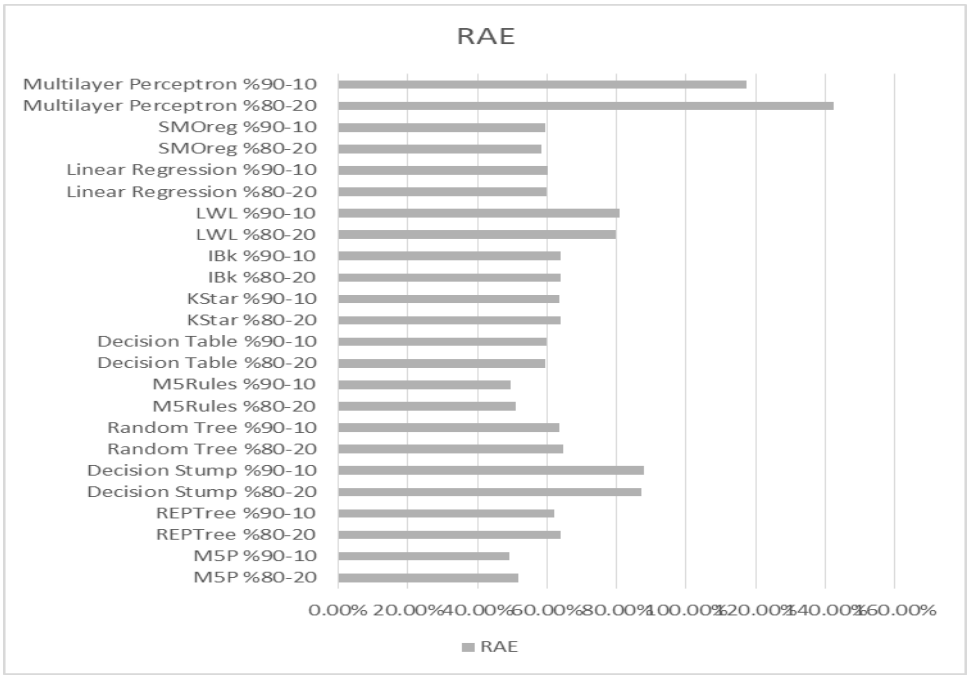


Şekil 5.3: Makine Öğrenme algoritmalarıyla elde edilen sonuçların ortalama mutlak hataları

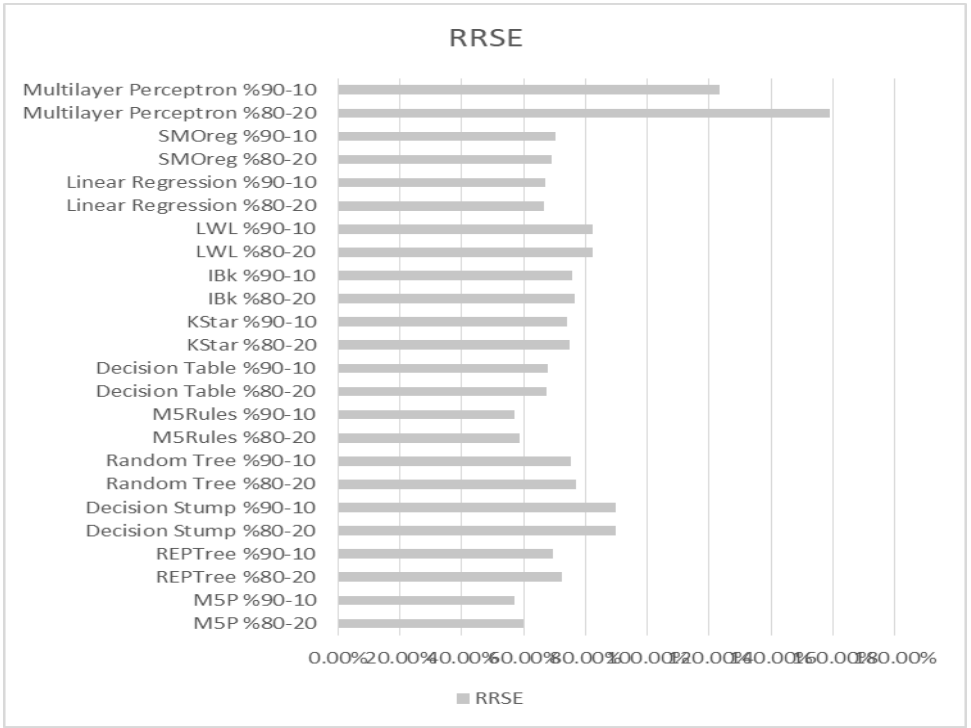
Makine Öğrenme algoritmalarından elde edilen sonuçlar için hata değerlerine bakıldığında tüm hata değerlerinde YSA %80-20 algoritması en çok hata değerine sahipken en az hata değerine M5P %90-10 algoritması sahiptir.



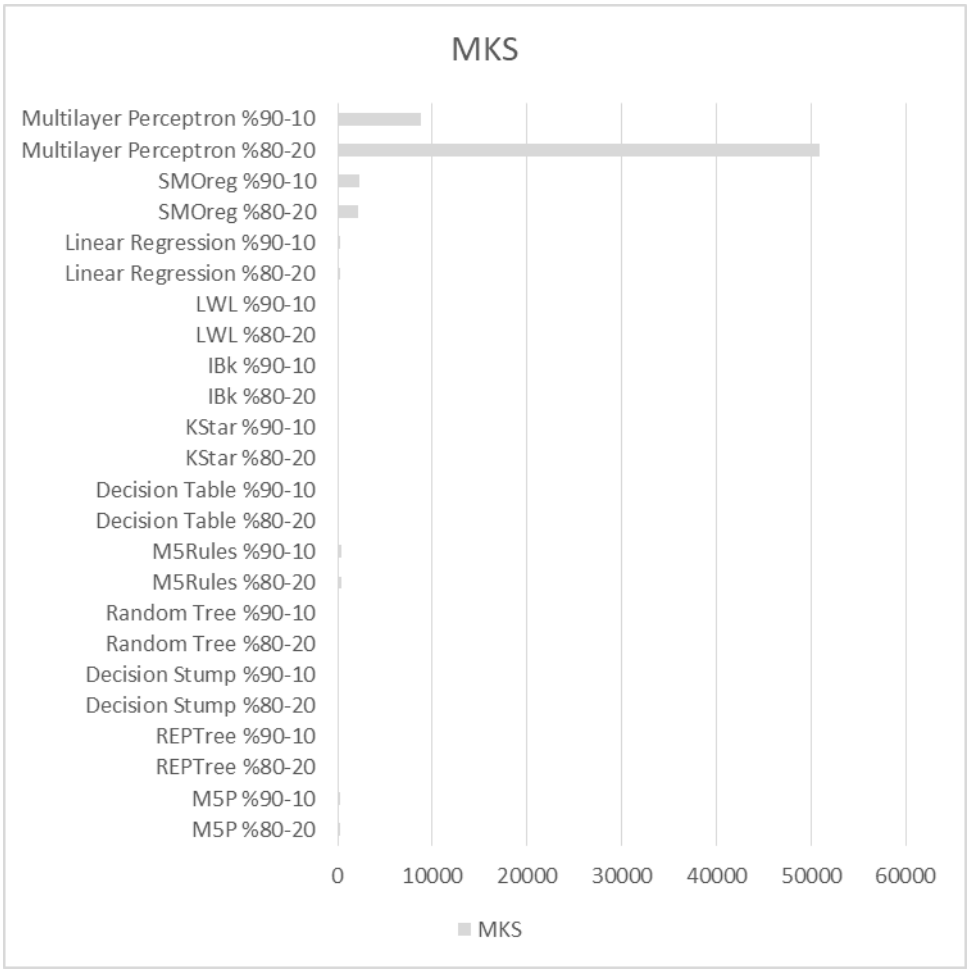
Şekil 5.4: Makine Öğrenme algoritmalarıyla elde edilen sonuçların ortalama karesel hatalarının karekökleri



Şekil 5.5: Makine Öğrenme algoritmalarıyla elde edilen sonuçların bağıl mutlak hataları



Şekil 5.6: Makine Öğrenme algoritmalarıyla elde edilen sonuçların karesel bağıl mutlak hatalarının karekökleri

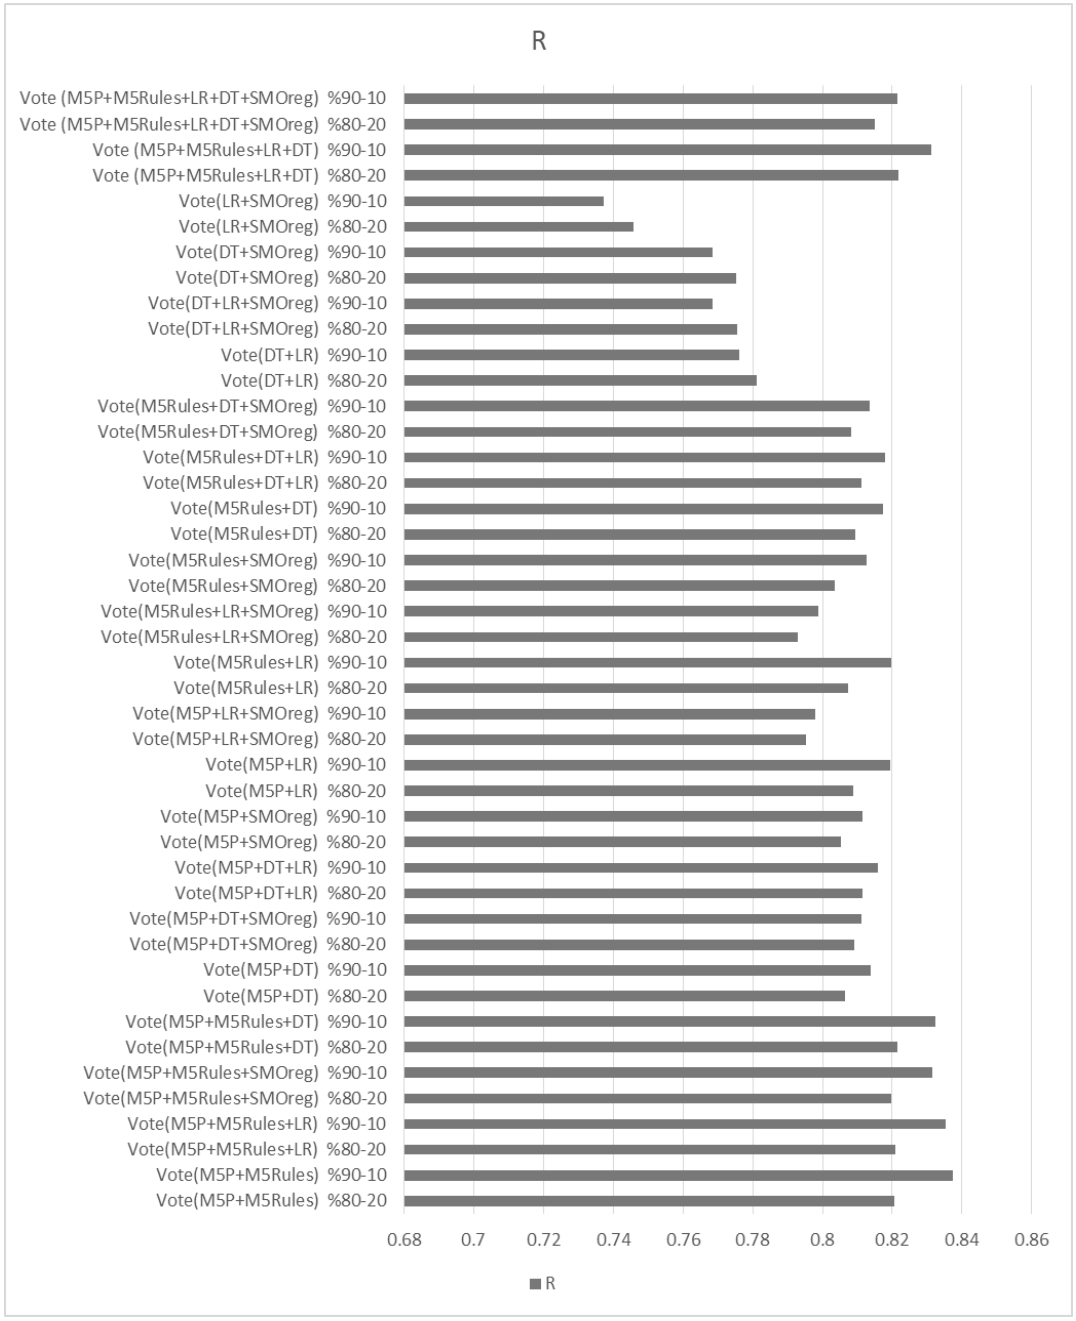


Şekil 5.7: Makine Öğrenme algoritmalarıyla elde edilen sonuçların model kurma süreleri

Tablo 5.12: Bileşik Makine Öğrenme yöntemlerinin performans ölçümleri (Vote)

Bileşik Makine Öğrenme Sınıflandırıcıları	R	MAE	RMSE	RAE	RRSE	MKS
Vote(M5P+M5Rules) %80-20	0,8207	0,011	0,0144	49.94%	57.19%	741,8
Vote(M5P+M5Rules) %90-10	0,8375	0,0103	0,0136	47.43%	54.71%	691,3
Vote(M5P+M5Rules+LR) %80-20	0,8209	0,0111	0,0143	50.45%	57.15%	990,71
Vote(M5P+M5Rules+LR) %90-10	0,8354	0,0105	0,0137	48.63%	55.07%	1016,43
Vote(M5P+M5Rules+SMOreg) %80-20	0,8198	0,0111	0,0144	50.12%	57.28%	3027,26
Vote(M5P+M5Rules+SMOreg) %90-10	0,8315	0,0105	0,0138	48.42%	55.55%	3100,74
Vote(M5P+M5Rules+DT) %80-20	0,8216	0,0111	0,0143	50.47%	57.08%	744,14
Vote(M5P+M5Rules+DT) %90-10	0,8325	0,0106	0,0138	49.01%	55.47%	753,68
Vote(M5P+DT) %80-20	0,8066	0,0115	0,0148	52.26%	59.15%	304,01
Vote(M5P+DT) %90-10	0,8138	0,0111	0,0144	51.27%	58.15%	280,62
Vote(M5P+DT+SMOreg) %80-20	0,8091	0,0115	0,0148	52.02%	58.86%	2468,25
Vote(M5P+DT+SMOreg) %90-10	0,8111	0,0112	0,0145	51.62%	58.52%	2642,52
Vote(M5P+DT+LR) %80-20	0,8116	0,0115	0,0147	52.27%	58.67%	552,19
Vote(M5P+DT+LR) %90-10	0,8158	0,0112	0,0144	51.80%	58.05%	507,86
Vote(M5P+SMOreg) %80-20	0,8054	0,0114	0,0149	51.80%	59.32%	2583,7
Vote(M5P+SMOreg) %90-10	0,8115	0,011	0,0145	50.77%	58.46%	2653,37
Vote(M5P+LR) %80-20	0,8087	0,0115	0,0148	52.08%	58.87%	554,56
Vote(M5P+LR) %90-10	0,8193	0,011	0,0143	50.96%	57.46%	508,86
Vote(M5P+LR+SMOreg) %80-20	0,7953	0,0118	0,0152	53.49%	60.63%	2909,4
Vote(M5P+LR+SMOreg) %90-10	0,7978	0,0115	0,015	53.04%	60.30%	2744,15
Vote(M5Rules+LR) %80-20	0,8074	0,0116	0,0148	52.52%	59.04%	682,82
Vote(M5Rules+LR) %90-10	0,8197	0,0111	0,0142	51.11%	57.33%	631,15
Vote(M5Rules+LR+SMOreg) %80-20	0,7928	0,0119	0,0153	53.80%	60.96%	3128,84
Vote(M5Rules+LR+SMOreg) %90-10	0,7989	0,0115	0,0149	53.15%	60.15%	2880,43
Vote(M5Rules+SMOreg) %80-20	0,8035	0,0115	0,015	52.07%	59.58%	2740,76
Vote(M5Rules+SMOreg) %90-10	0,8126	0,011	0,0145	50.91%	58.32%	2791,86
Vote(M5Rules+DT) %80-20	0,8093	0,0115	0,0148	52.15%	58.83%	439,35
Vote(M5Rules+DT) %90-10	0,8173	0,0111	0,0143	51.14%	57.64%	404,12
Vote(M5Rules+DT+LR) %80-20	0,8111	0,0116	0,0147	52.52%	58.75%	703,51
Vote(M5Rules+DT+LR) %90-10	0,8179	0,0112	0,0143	51.73%	57.74%	635,03
Vote(M5Rules+DT+SMOreg) %80-20	0,8083	0,0115	0,0148	52.22%	58.97%	2740,89
Vote(M5Rules+DT+SMOreg) %90-10	0,8134	0,0112	0,0144	51.54%	58.19%	2572,38
Vote(DT+LR) %80-20	0,7813	0,0124	0,0157	56.26%	62.60%	249,99
Vote(DT+LR) %90-10	0,7761	0,0123	0,0157	56.79%	63.12%	230,91
Vote(DT+LR+SMOreg) %80-20	0,7755	0,0124	0,0159	56.17%	63.17%	2533,12
Vote(DT+LR+SMOreg) %90-10	0,7686	0,0123	0,0159	56.84%	63.98%	2378,91
Vote(DT+SMOreg) %80-20	0,7752	0,0124	0,0159	56.12%	63.24%	2290,94
Vote(DT+SMOreg) %90-10	0,7684	0,0123	0,0159	56.59%	64.02%	2290,83
Vote(LR+SMOreg) %80-20	0,7457	0,013	0,0168	58.90%	66.96%	2519,56
Vote(LR+SMOreg) %90-10	0,7373	0,013	0,0169	59.83%	68.11%	2586,08
Vote (M5P+M5Rules+LR+DT) %80-20	0,8217	0,0112	0,0144	50.87%	57.22%	1334,77
Vote (M5P+M5Rules+LR+DT) %90-10	0.8312	0.0108	0.0139	49.74%	55.82%	986.48
Vote (M5P+M5Rules+LR+DT+SMOreg) %80-20	0,8151	0,0113	0,0146	51.45%	58.07%	4409,37
Vote (M5P+M5Rules+LR+DT+SMOreg) %90-10	0.8214	0.011	0.0142	50.62%	57.13%	3009.87

Bileşik Makine Öğrenme algoritmalarından biri olan Vote algoritması ile elde edilen sonuçlara bakıldığında, Şekil 5.8'de görüldüğü gibi Vote (M5P+M5Rules) %90-10 algoritması en iyi, Vote (LR+SMOreg) %90-10 algoritması en kötü korelasyon katsayısına sahiptir.



Şekil 5.8: Bileşik Makine Öğrenme algoritması Voting ile elde edilen sonuçların korelasyon katsayıları

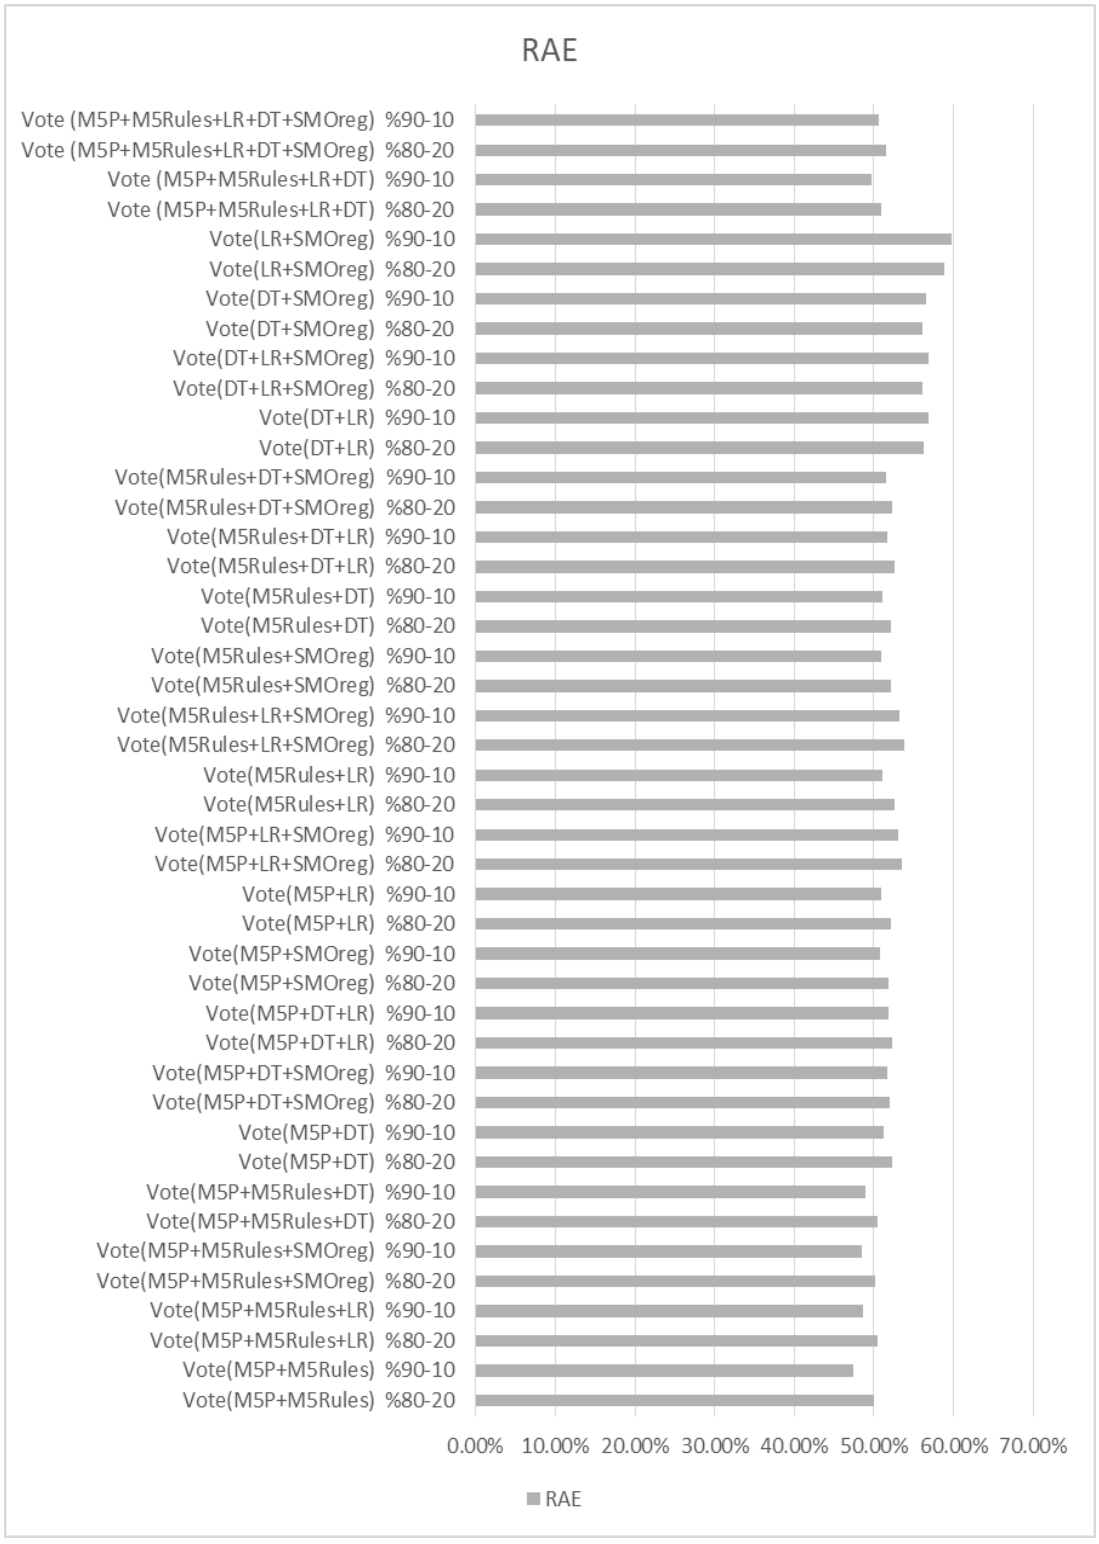
Bileşik Makine Öğrenme algoritmalarından Vote algoritması ile elde edilen sonuçlara göre tüm hata değerlerinde Vote (M5P+M5Rules) %90-10 en düşük hata değerlerine sahipken, Vote (LR+SMOreg) %90-10 en yüksek hata değerlerine sahiptir.



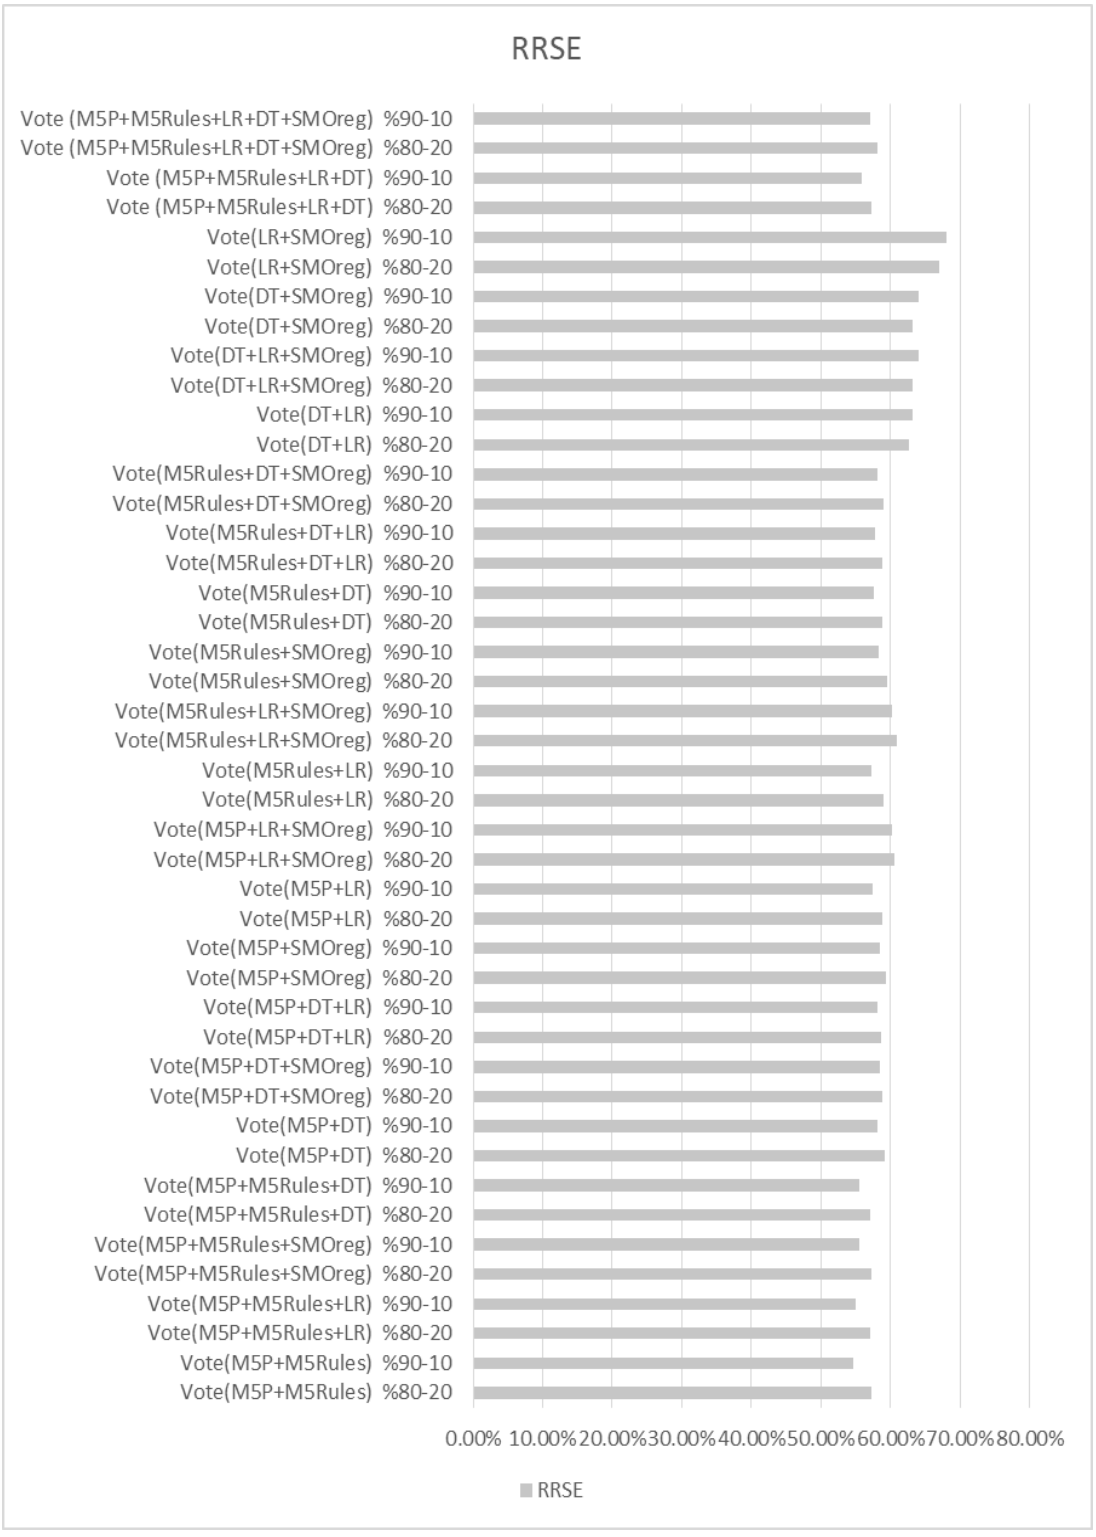
Şekil 5.9: Bileşik Makine Öğrenme algoritması Voting ile elde edilen sonuçların ortalama mutlak hataları



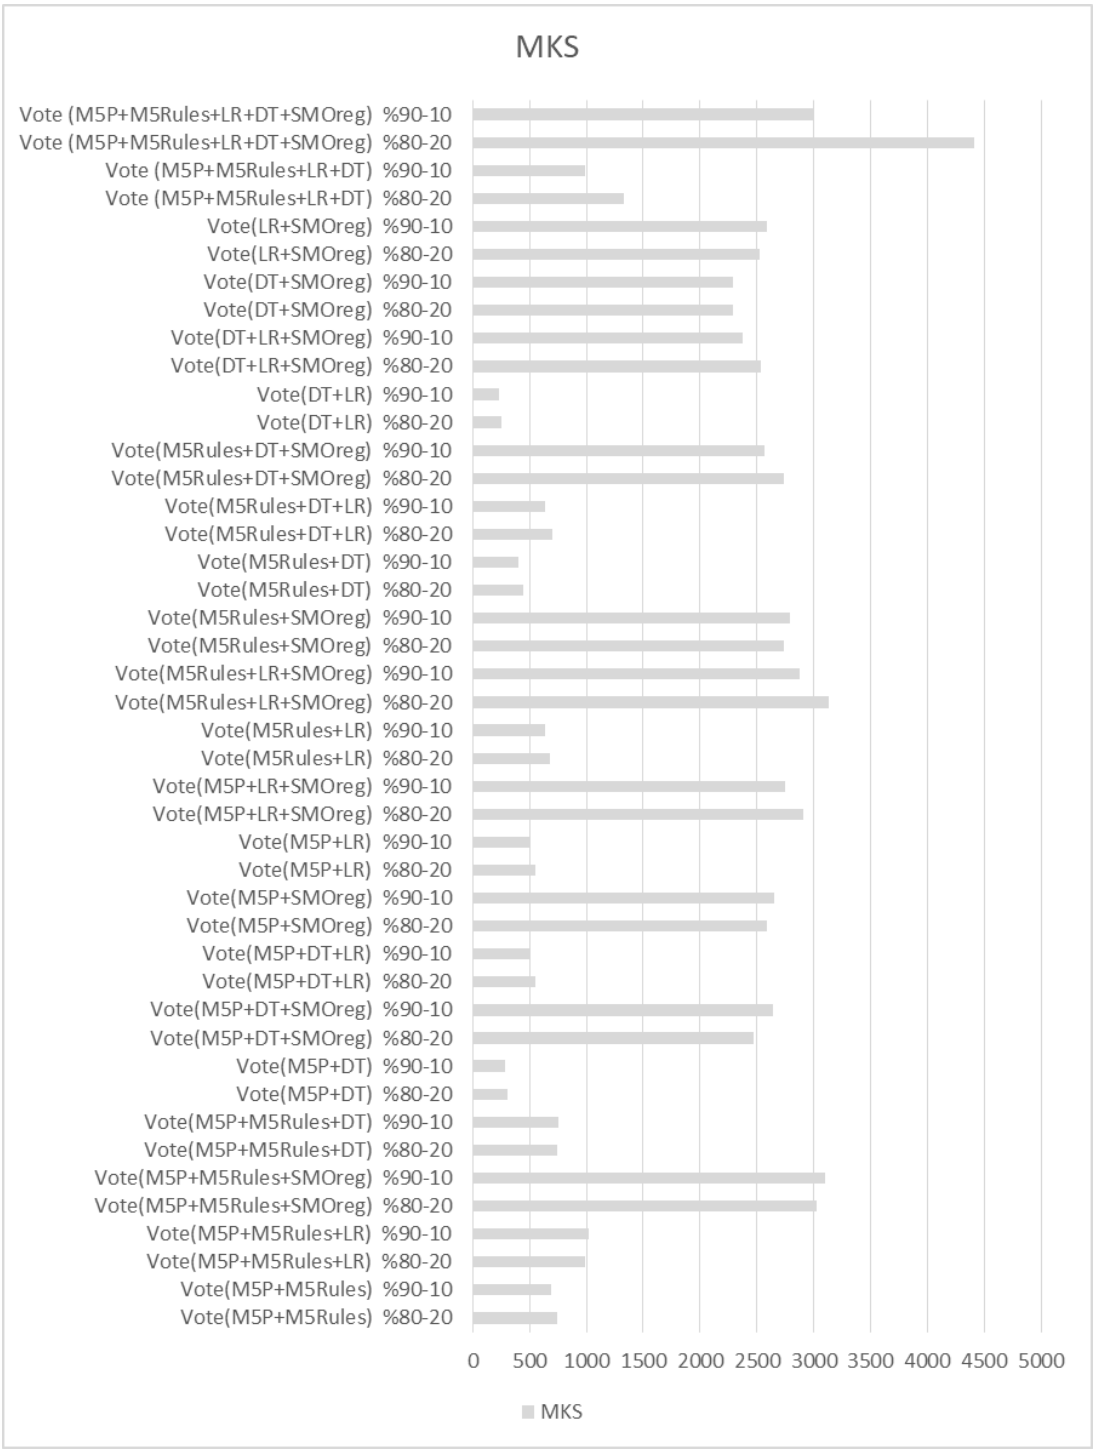
Şekil 5.10: Bileşik Makine Öğrenme algoritması Voting elde edilen sonuçların ortalama karesel hatalarının karekökleri



Şekil 5.11: Bileşik Makine Öğrenme algoritması Voting ile elde edilen sonuçların bağıl mutlak hataları



Şekil 5.12: Bileşik Makine Öğrenme algoritması Voting ile elde edilen sonuçların karesel bağıl mutlak hatalarının karekökleri

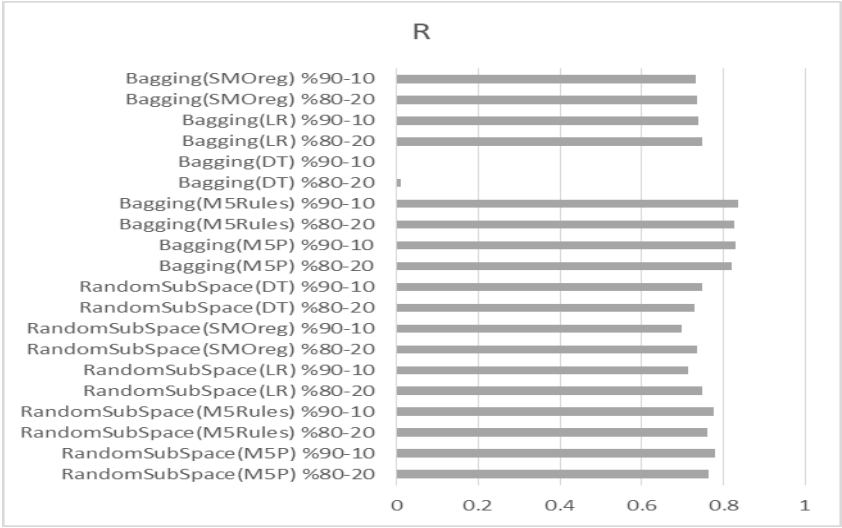


Şekil 5.13: Bileşik Makine Öğrenme algoritması Voting ile elde edilen sonuçların model kurma süreleri

Tablo 5.13: Bileşik Makine Öğrenme yöntemlerinin performans ölçümleri (RSS ve Bagging)

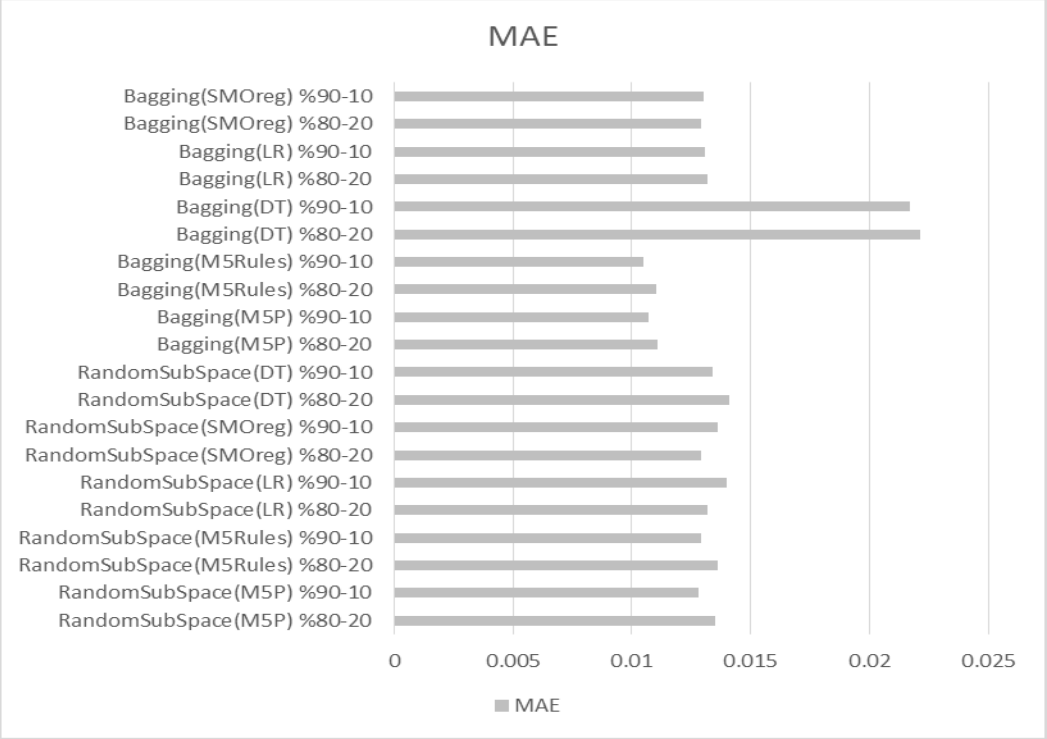
Bileşik Makine Öğrenme Sınıflandırıcıları	R	MAE	RMSE	RAE	RRSE	MKS
RandomSubSpace(M5P) %80-20	0.7655	0.0135	0.0165	61.02%	65.87%	502
RandomSubSpace(M5P) %90-10	0.7804	0.0128	0.0158	0.591278	0.637411	526.62
RandomSubSpace(M5Rules) %80-20	0.7608	0.0136	0.0166	0.615068	0.66325	2096.6
RandomSubSpace(M5Rules) %90-10	0.776	0.0129	0.0159	0.594356	0.641836	2154.91
RandomSubSpace(LR) %80-20	0.7478	0.0132	0.0167	0.597279	0.664366	229.45
RandomSubSpace(LR) %90-10	0.7135	0.014	0.0175	0.646578	0.703682	543.85
RandomSubSpace(SMOreg) %80-20	0.7352	0.0129	0.0173	0.58425	0.68986	2094.09
RandomSubSpace(SMOreg) %90-10	0.6994	0.0136	0.0178	0.627518	0.718106	6523.81
RandomSubSpace(DT) %80-20	0.7293	0.0141	0.0174	0.641458	0.693704	2.77
RandomSubSpace(DT) %90-10	0.7496	0.0134	0.0166	0.619994	0.670197	2.87
Bagging(M5P) %80-20	0.8213	0.0111	0.0143	0.50325	0.571013	1568
Bagging(M5P) %90-10	0.8306	0.0107	0.0138	0.494458	0.557492	1765.33
Bagging(M5Rules) %80-20	0.8268	0.011	0.0141	0.497486	0.562951	8094.67
Bagging(M5Rules) %90-10	0.838	0.0105	0.0136	0.484687	0.546369	8166.09
Bagging(DT) %80-20	0.0097	0.0221	0.0251	1.000333	1.000047	36.24
Bagging(DT) %90-10	0	0.0217	0.0248	1.00022	0.999955	38.82
Bagging(LR) %80-20	0.7478	0.0132	0.0167	0.597279	0.664366	229.45
Bagging(LR) %90-10	0.74	0.0131	0.0167	0.605612	0.674157	3029.73
Bagging(SMOreg) %80-20	0.7352	0.0129	0.0173	0.58425	0.68986	2094.09
Bagging(SMOreg) %90-10	0.7316	0.013	0.0172	0.602422	0.693056	22576.23

Bagging ve Random Subspace Bileşik Makine yöntemlerinden elde edilen sonuçlara baktığımızda en iyi korelasyon sayısı Bagging (M5Rules) %90-10 algoritması ile elde edilirken, en kötü korelasyon katsayısına Bagging (DT) %90-10 algoritması sahiptir.

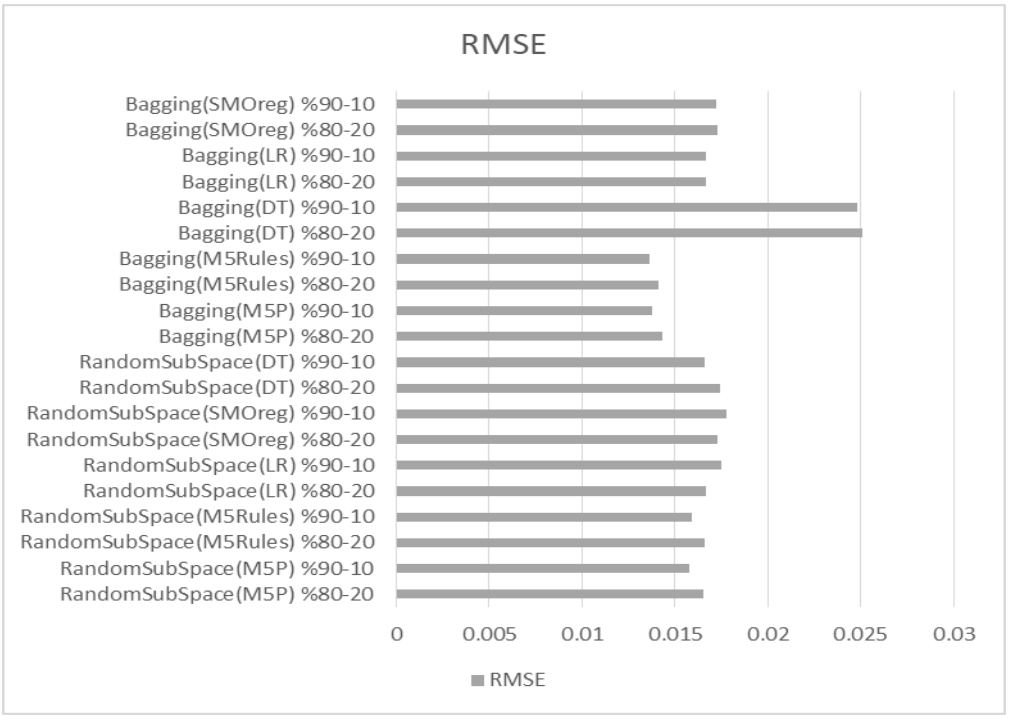


Şekil 5.14: Bileşik Makine Öğrenme algoritmaları RandomSubSpace ve Bagging ile elde edilen sonuçların korelasyon katsayıları

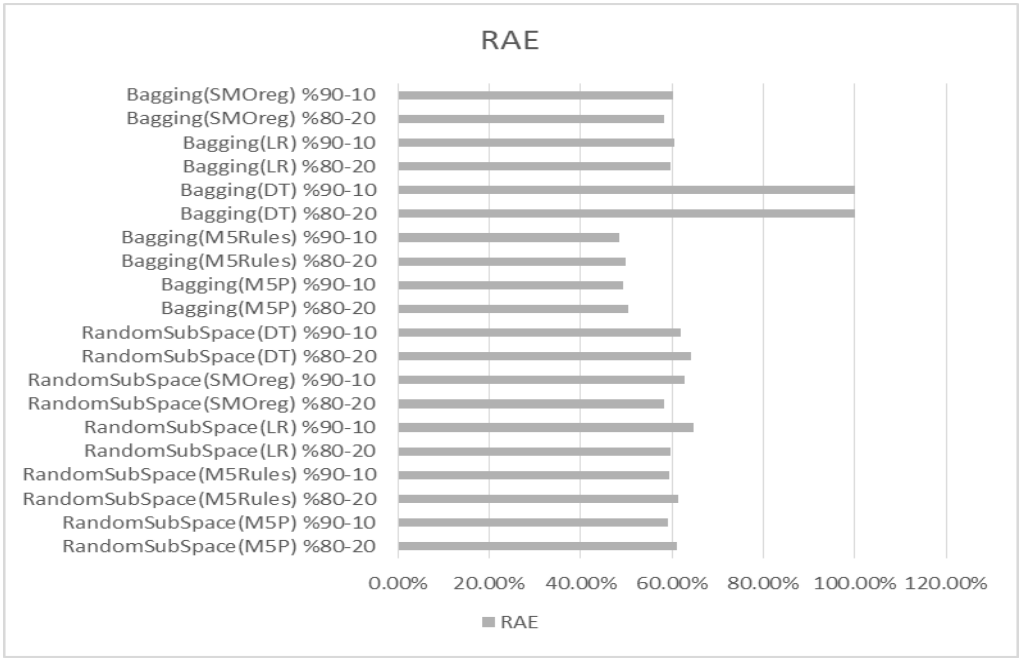
Bagging ve Ransom SubSpace Bileşik Makine Öğrenme algoritmaları ile elde edilen sonuçların hata değerlerine baktığımızda tüm hata değerlerinde Bagging(DT) %80-20 algoritması en yüksek hata değerlerine sahipken, Bagging (M5Rules) %90-10 algoritması en küçük hata değerlerine sahiptir.



Şekil 5.15: Bileşik Makine Öğrenme algoritmaları RandomSubSpace ve Bagging ile elde edilen sonuçların ortalama mutlak hataları



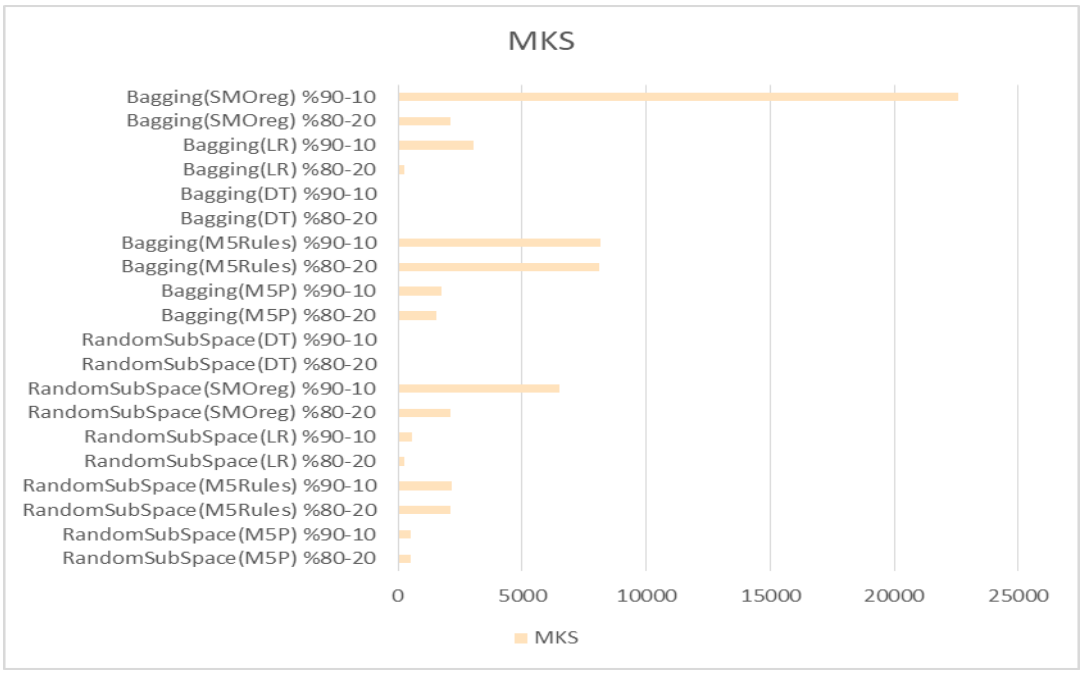
Şekil 5.16: Bileşik Makine Öğrenme algoritmaları RandomSubSpace ve Bagging ile elde edilen sonuçların ortalama karesel hatalarının karekökleri



Şekil 5.17: Bileşik Makine Öğrenme algoritmaları RandonSubSpace ve Bagging ile elde edilen sonuçların bağıl mutlak hataları



Şekil 5.18: Bileşik Makine Öğrenme algoritmaları RandomSubSpace ve Bagging ile elde edilen sonuçların karesel bağıl mutlak hatalarının karekökleri

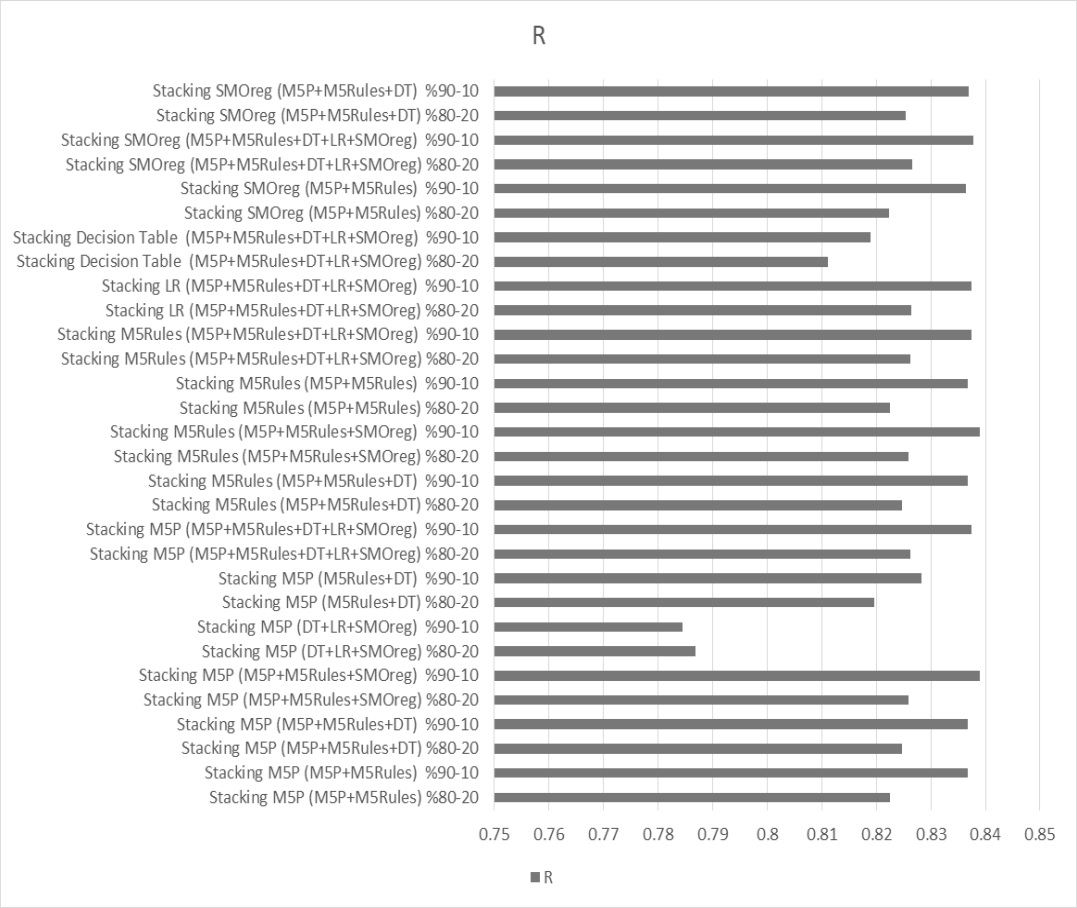


Şekil 5.19: Bileşik Makine Öğrenme algoritmaları RandomSubSpace ve Bagging ile elde edilen sonuçların model kurma süreleri

Tablo 5.14: Bileşik Makine Öğrenme yöntemlerinin performans ölçümleri (Stacking)

Bileşik Makine Öğrenme Sınıflandırıcıları	R	MAE	RMSE	RAE	RRSE	MKS
Stacking M5P (M5P+M5Rules) %80-20	0.8225	0.0112	0.0143	50.79%	56.93%	7301
Stacking M5P (M5P+M5Rules) %90-10	0.8368	0.0106	0.0136	48.95%	54.86%	7559.15
Stacking M5P (M5P+M5Rules+DT) %80-20	0.8247	0.0111	0.0142	50.43%	56.59%	7538.24
Stacking M5P (M5P+M5Rules+DT) %90-10	0.8368	0.0105	0.0136	48.56%	54.83%	7527.49
Stacking M5P (M5P+M5Rules+SMOreg) %80-20	0.8259	0.011	0.0142	50.00%	56.41%	27407.32
Stacking M5P (M5P+M5Rules+SMOreg) %90-10	0.8389	0.0105	0.0135	48.49%	54.52%	30413.19
Stacking M5P (DT+LR+SMOreg) %80-20	0.7868	0.0121	0.0155	55.02%	61.72%	21043.06
Stacking M5P (DT+LR+SMOreg) %90-10	0.7845	0.0119	0.0154	55.10%	62.08%	24573.54
Stacking M5P (M5Rules+DT) %80-20	0.8196	0.0113	0.0144	51.24%	57.33%	5253.49
Stacking M5P (M5Rules+DT) %90-10	0.8283	0.0108	0.0139	49.89%	56.09%	5396.41
Stacking M5P (M5P+M5Rules+DT+LR+SMOreg) %80-20	0.8263	0.011	0.0141	50.07%	56.35%	28163.46
Stacking M5P (M5P+M5Rules+DT+LR+SMOreg) %90-10	0.8375	0.0105	0.0136	48.60%	54.72%	33237.54
Stacking M5Rules (M5P+M5Rules+DT) %80-20	0.8247	0.0111	0.0142	50.43%	56.59%	7319.03
Stacking M5Rules (M5P+M5Rules+DT) %90-10	0.8368	0.0105	0.0136	48.56%	54.83%	8282.24
Stacking M5Rules (M5P+M5Rules+SMOreg) %80-20	0.8259	0.011	0.0142	50.00%	56.41%	29306.36
Stacking M5Rules (M5P+M5Rules+SMOreg) %90-10	0.8389	0.0105	0.0135	48%	55%	24973.38
Stacking M5Rules (M5P+M5Rules) %80-20	0.8225	0.0112	0.0143	50.79%	56.93%	8190.01
Stacking M5Rules (M5P+M5Rules) %90-10	0.8368	0.0106	0.0136	48.95%	54.86%	7394.72
Stacking M5Rules (M5P+M5Rules+DT+LR+SMOreg) %80-20	0.8263	0.011	0.0141	50.07%	56.35%	29651.49
Stacking M5Rules (M5P+M5Rules+DT+LR+SMOreg) %90-10	0.8375	0.0105	0.0136	49%	55%	30464.71
Stacking LR (M5P+M5Rules+DT+LR+SMOreg) %80-20	0.8264	0.0109	0.0141	49.52%	56.33%	39029.64
Stacking LR (M5P+M5Rules+DT+LR+SMOreg) %90-10	0.8375	0.0104	0.0136	48%	55%	30760.91
Stacking Decision Table (M5P+M5Rules+DT+LR+SMOreg) %80-20	0.8111	0.0115	0.0147	52.21%	58.50%	29720.71
Stacking Decision Table (M5P+M5Rules+DT+LR+SMOreg) %90-10	0.8189	0.011	0.0142	50.74%	57.42%	38361.32
Stacking SMOreg (M5P+M5Rules) %80-20	0.8223	0.0109	0.0143	49.64%	57.06%	8052.41
Stacking SMOreg (M5P+M5Rules) %90-10	0.8364	0.0103	0.0137	47.78%	55.07%	8220.79
Stacking SMOreg (M5P+M5Rules+DT+LR+SMOreg) %80-20	0.8266	0.0108	0.0142	49.04%	56.39%	28752.19
Stacking SMOreg (M5P+M5Rules+DT+LR+SMOreg) %90-10	0.8378	0.0103	0.0136	47.63%	54.87%	28657.13
Stacking SMOreg (M5P+M5Rules+DT) %80-20	0.8254	0.0109	0.0142	49.34%	56.58%	7339.19
Stacking SMOreg (M5P+M5Rules+DT) %90-10	0.837	0.0103	0.0137	47.79%	55.06%	8177.58

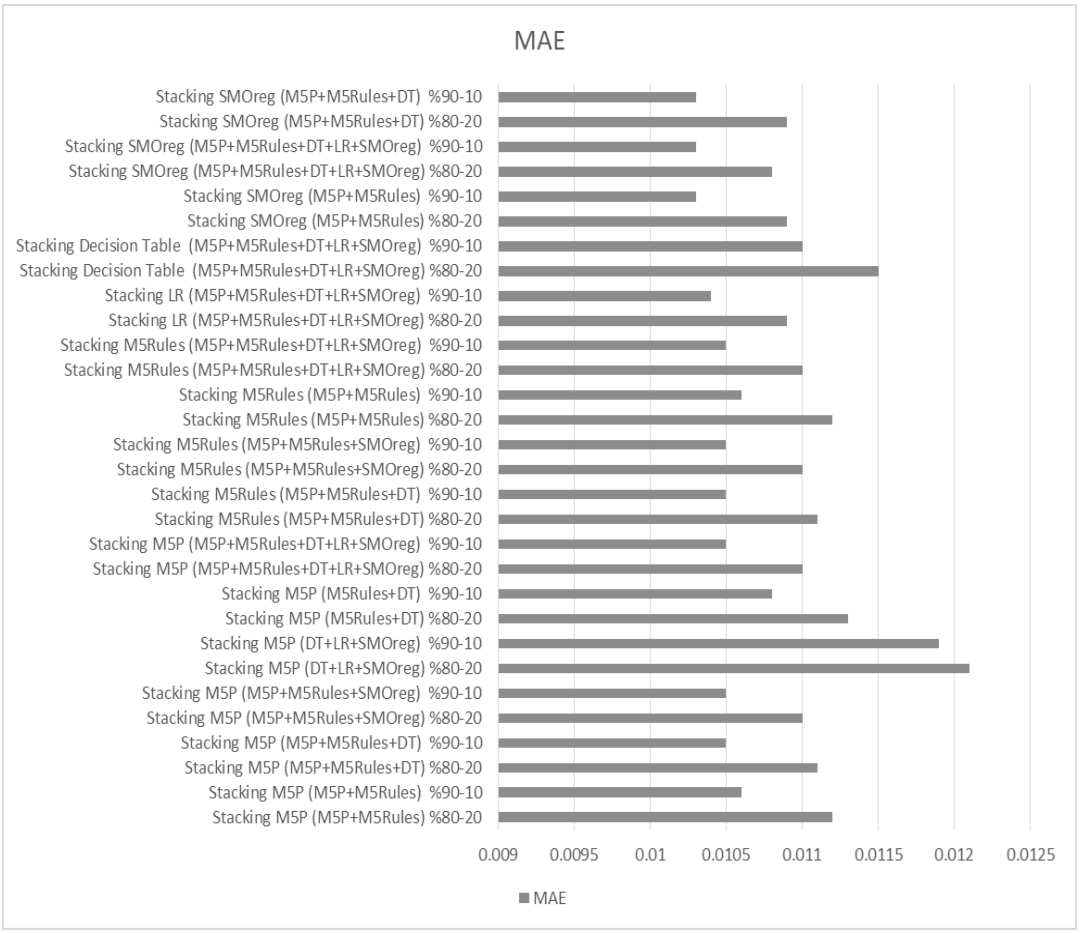
Bileşik Makine Öğrenme algoritmalarından Stacking algoritması ile elde edilen sonuçlara bakıldığında Stacking M5P (M5P+M5Rules+SMOreg) %90-10 algoritması ve Stacking M5Rules (M5P+M5Rules+SMOreg) %90-10 algoritması en iyi korelasyon katsayısına sahiptir, fakat Stacking M5Rules (M5P+M5Rules+SMOreg) %90-10 algoritması algoritmasının model kurma süresi daha düşüktür. Stacking M5P (DT+LR+SMOreg) %90-10 algoritması ise en düşük korelasyon katsayısına sahiptir.



Şekil 5.20: Bileşik Makine Öğrenme algoritması Stacking ile elde edilen sonuçların korelasyon katsayıları

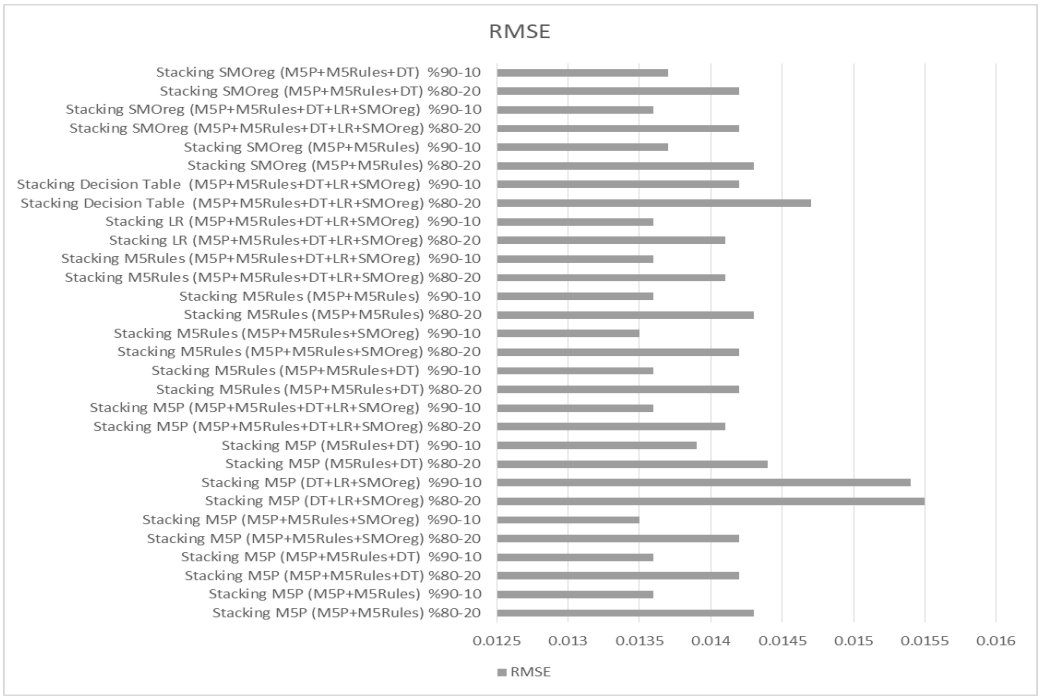
Bileşik Makine Öğrenme algoritmalarından Stacking algoritması ile elde edilen sonuçların hata değerlerine baktığımızda ortalama mutlak hata için Stacking SMOreg (M5P+M5Rules) %90-10 algoritması, Stacking SMOreg (M5P+M5Rules+DT+LR+SMOreg) %90-10 algoritması ve Stacking SMOreg (M5P+M5Rules+DT) %90-10 algoritması en küçük hata değerlerine sahiptir. Stacking M5P (DT+LR+SMOreg) %80-20 algoritması ise en yüksek mutlak hata değerine sahiptir.

Ortalama karesel hataların karekökü değerlerine baktığımızda en küçük hata Stacking M5P (M5P+M5Rules+SMOreg) %90-10 ve Stacking M5Rules (M5P+M5Rules+SMOreg) %90-10 algoritmalarından, en yüksek hata ise Stacking M5P (DT+LR+SMOreg) %80-20 algoritmasından elde edilmiştir.

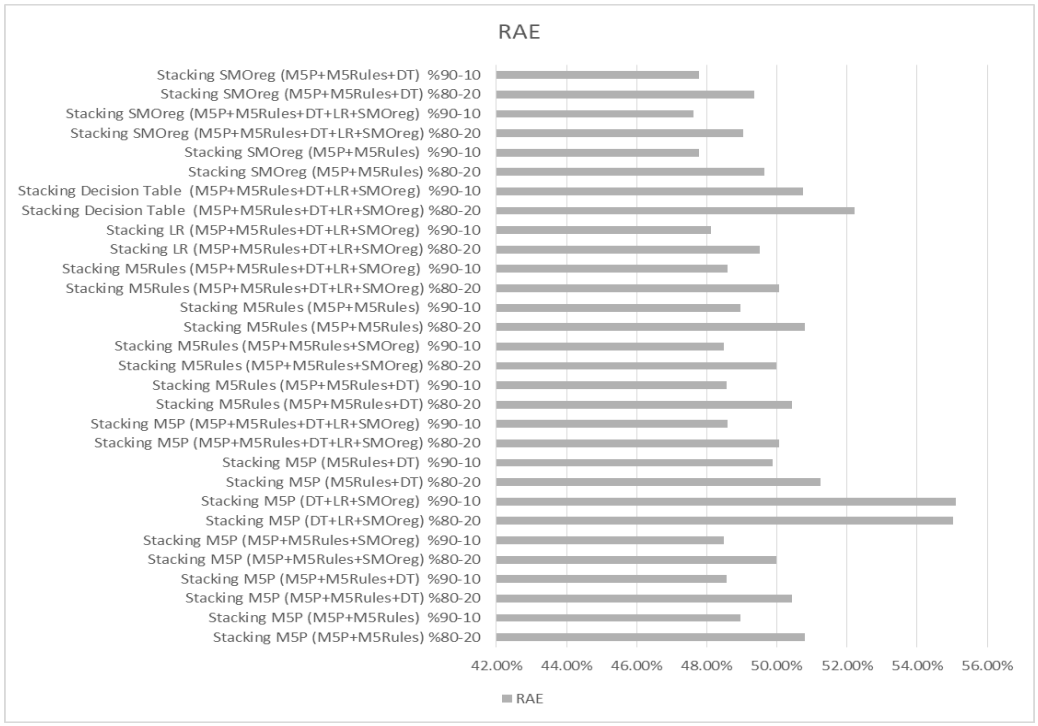


Şekil 5.21: Bileşik Makine Öğrenme algoritması Stacking ile elde edilen sonuçların ortalama mutlak hataları

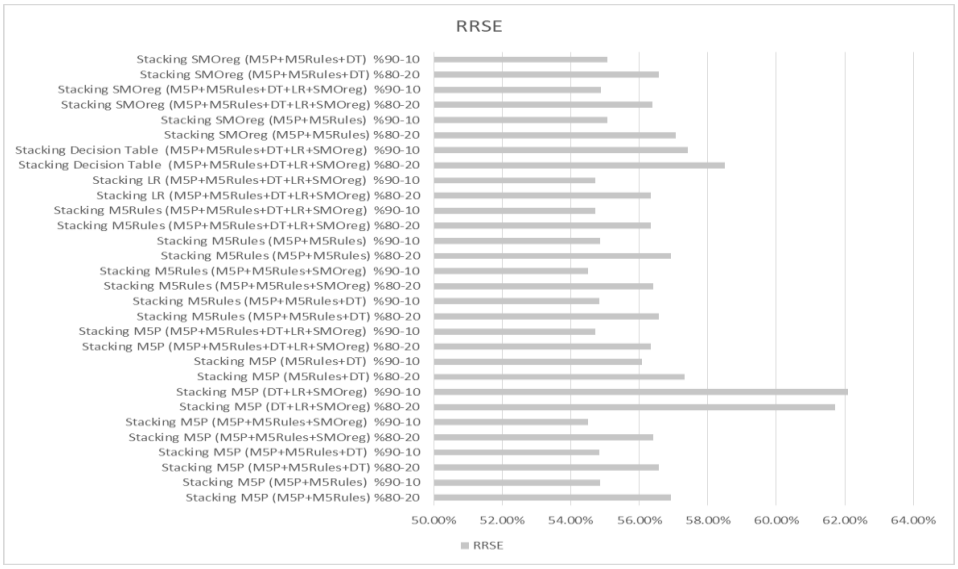
Bağıl mutlak hata değerlerine göre Stacking SMOreg (M5P+M5Rules+DT+LR+SMOreg) %90-10 algoritması en düşük hataya sahipken, Stacking M5P (DT+LR+SMOreg) %90-10 algoritması en yüksek hataya sahiptir.



Şekil 5.22: Bileşik Makine Öğrenme algoritması Stacking elde edilen sonuçların ortalama karesel hatalarının karekökleri

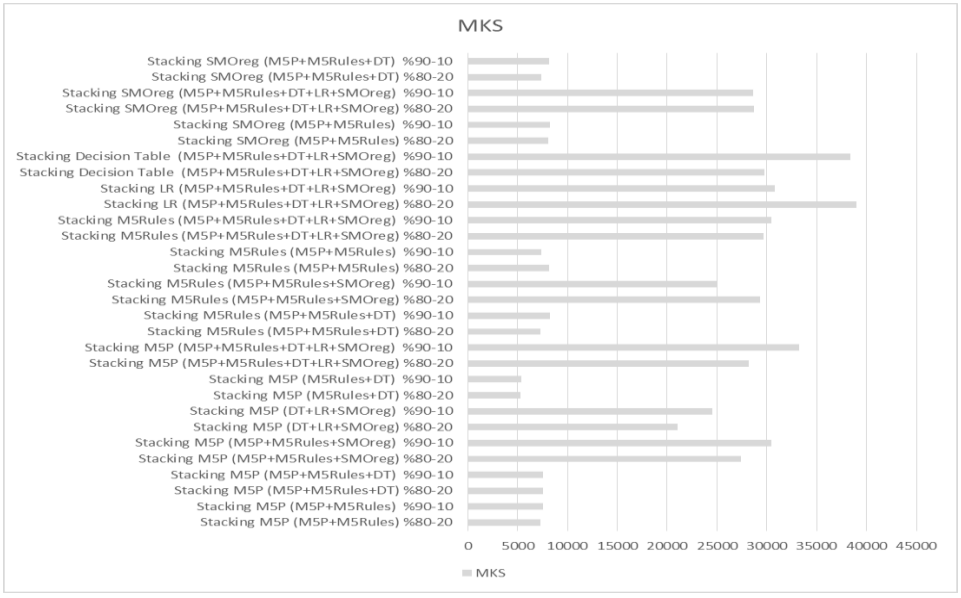


Şekil 5.23: Bileşik Makine Öğrenme algoritması Stacking ile elde edilen sonuçların bağıl mutlak hataları



Şekil 5.24: Bileşik Makine Öğrenme algoritması Stacking ile elde edilen sonuçların karesel bağıl mutlak hatalarının karekökleri

Karesel bağıl mutlak hataların karekökü değerlerine göre Stacking M5P (M5P+M5Rules+SMOreg) %90-10 algoritması en düşük hata değerine sahipken, Stacking M5P (DT+LR+SMOreg) %90-10 algoritması en yüksek hata değerine sahiptir.



Şekil 5.25: Bileşik Makine Öğrenme algoritması Stacking ile elde edilen sonuçların model kurma süreleri

Çalışmadan elde ettiğimiz Makine Öğrenme ve Bileşik Makine Öğrenme algoritmaları sonuçlarından en yüksek korelasyon katsayısına ve en düşük hata değerlerine sahip on beş değerin korelasyon katsayısı bakımından sıralaması Tablo 5.15'te görüldüğü gibidir.

Tablo 5.15: Elde edilen sonuçlardan en iyi 15 değerin korelasyon katsayısı bakımından sıralanması.

ELDE EDİLEN EN İYİ 15 DEĞER (R = 0,85 ÜZERİ SONUÇLAR)	R	MAE	RMSE	RAE	RRSE	MKS	1-R	Sıralama
Stacking M5Rules (M5P+M5Rules+SMOreg) %90-10	0.8389	0.0105	0.014	48%	55%	24973	0.1611	1
Stacking M5P (M5P+M5Rules+SMOreg) %90-10	0.8389	0.0105	0.014	48.49%	54.52%	30413	0.1611	1
Bagging(M5Rules) %90-10	0.838	0.0105	0.014	48.47%	54.64%	8166.1	0.162	2
Stacking SMOreg (M5P+M5Rules+DT+LR+SMOreg) %90-10	0.8378	0.0103	0.014	47.63%	54.87%	28657	0.1622	3
Vote(M5P+M5Rules) %90-10	0.8375	0.0103	0.014	47.43%	54.71%	691.3	0.1625	4
Stacking LR (M5P+M5Rules+DT+LR+SMOreg) %90-10	0.8375	0.0104	0.014	48%	55%	30761	0.1625	4
Stacking M5P (M5P+M5Rules+DT+LR+SMOreg) %90-10	0.8375	0.0105	0.014	48.60%	54.72%	33238	0.1625	4
Stacking M5P (M5P+M5Rules+DT) %90-10	0.8368	0.0105	0.014	48.56%	54.83%	7527.5	0.1632	6
Stacking M5Rules (M5P+M5Rules+DT) %90-10	0.8368	0.0105	0.014	48.56%	54.83%	8282.2	0.1632	6
Stacking M5Rules (M5P+M5Rules+DT+LR+SMOreg) %90-10	0.8375	0.0105	0.014	49%	55%	30465	0.1625	4
Stacking M5Rules (M5P+M5Rules) %90-10	0.8368	0.0106	0.014	48.95%	54.86%	7394.7	0.1632	6
Stacking M5P (M5P+M5Rules) %90-10	0.8368	0.0106	0.014	48.95%	54.86%	7559.2	0.1632	6
Stacking SMOreg (M5P+M5Rules+DT) %90-10	0.837	0.0103	0.014	47.79%	55.06%	8177.6	0.163	5
Stacking SMOreg (M5P+M5Rules) %90-10	0.8364	0.0103	0.014	47.78%	55.07%	8220.8	0.1636	7
Vote(M5P+M5Rules+LR) %90-10	0.8354	0.0105	0.014	48.63%	55.07%	1016.4	0.1646	8
En büyük değer	0.8389	0.0106	0.014	0.4895	0.5507	33238	0.1646	
En küçük değer	0.8354	0.0103	0.014	0.4743	0.5451	691.3	0.1611	

Sadece korelasyon katsayısına değerine bakmak yerine hataları da hesaba katabiliriz. Bunun için öncelikle hataların normalize edilmesi gerekir. Korelasyon katsayısı hatalarla birlikte hesaba katılabilmek için (1-R) şeklinde tahmini değerlerin gerçek değerlerle uyumsuzluğunu ifade eden bir değere dönüştürülerek hata değerlerine eklenir. Hata değerlerinin ortalamasına göre yapılan sıralama Tablo 5.16'da görüldüğü gibi korelasyon katsayısına göre yapılan sıralamadan farklıdır. Burada Vote (M5P+M5Rules) %90-10 algoritması korelasyon katsayısı bakımından en iyi 4. değere sahipken, normalize edilmiş hata değerlerinin ortalamasına bakıldığında ise en düşük ortalama hata değerine sahiptir. Bu sonuçlardan hata değerlerinin de algoritmanın performansına önemli ölçüde etkisi olduğu görülmektedir.

Tablo 5.16: Elde edilen en iyi 15 değerin normalize edilmiş ortalama hata değerlerine göre sıralaması.

NORMALİZE EDİLMİŞ EN İYİ 15 DEĞER (R = 0,85 ÜZERİ SONUÇLAR)	1-R	MAE	RMSE	RAE	RRSE	MKS	Ortalama Hata	Sıralama
Stacking M5Rules (M5P+M5Rules+SMOreg) %90-10	0	0.6667	0	0.6976	0	0.7461	0.4220746	2
Stacking M5P (M5P+M5Rules+SMOreg) %90-10	0	0.6667	0	0.6976	0.0018	0.9132	0.4558617	3
Bagging(M5Rules) %90-10	0.2571	0.6667	0.5	0.6823	0.2204	0.2297	0.5112395	5
Stacking SMOreg (M5P+M5Rules+DT+LR+SMOreg) %90-10	0.3143	0	0.5	0.1299	0.6411	0.8593	0.4888949	4
Vote(M5P+M5Rules) %90-10	0.4	0	0.5	0	0.3435	0	0.2487006	1
Stacking LR (M5P+M5Rules+DT+LR+SMOreg) %90-10	0.4	0.3333	0.5	0.4595	0.3573	0.9239	0.5948171	6
Stacking M5P (M5P+M5Rules+DT+LR+SMOreg) %90-10	0.4	0.6667	0.5	0.7719	0.3697	1	0.7416581	12
Stacking M5P (M5P+M5Rules+DT) %90-10	0.6	0.6667	0.5	0.7428	0.5741	0.21	0.6587361	9
Stacking M5Rules (M5P+M5Rules+DT) %90-10	0.6	0.6667	0.5	0.7426	0.5739	0.2332	0.6632855	10
Stacking M5Rules (M5P+M5Rules+DT+LR+SMOreg) %90-10	0.4	0.6667	0.5	0.7717	0.3697	0.9148	0.7245792	11
Stacking M5Rules (M5P+M5Rules) %90-10	0.6	1	0.5	1	0.6167	0.206	0.7845241	13
Stacking M5P (M5P+M5Rules) %90-10	0.6	1	0.5	0.9993	0.6154	0.211	0.7851383	14
Stacking SMOreg (M5P+M5Rules+DT) %90-10	0.5429	0	1	0.2354	0.9853	0.23	0.5987119	7
Stacking SMOreg (M5P+M5Rules) %90-10	0.7143	0	1	0.2288	1	0.2313	0.634888	8
Vote(M5P+M5Rules+LR) %90-10	1	0.6667	1	0.7893	0.9973	0.01	0.8926439	15

TARTIŞMA VE SONUÇ

Doğal kaynaklarımızı hızla tükettiğimiz bu dönemde bir geleceğimizin olabilmesi için kaynak kullanımı konusunda acilen bilinçlenmemiz gerekmektedir. Her ne kadar Dünyamız doğal kaynak bakımından kendini yenileyebilse de kaynaklarımızı tüketim hızımıza yetişememekte, dolayısı ile kendi kaynağımızı tüketmeyip gelecek nesillerin de kaynaklarını kendini yenileyemeyecek şekilde tüketip tahrip etmekteyiz. Bu durumda, kullanılan ürünleri atık olarak görüp yok etmek yerine bu ürünlerden değer kazanımı ile yeni ürünler veya hammadde elde etmek ya da kaynak kullanımını en başta azaltarak gereksiz üretim ve kaynak israfından kaçınmak hem kendimiz hem de geleceğimiz için atmamız gereken büyük ve önemli bir adımdır. Bu vahim durumun geç de olsa farkına varmaya başlamamız tersine lojistik konusunda bilinçlenmenin yaygınlaşmasını sağlamaktadır.

Kaynakların optimizasyonu ve karar verme, insanlığın tarih boyunca her alanda karşılaştığı en önemli problemlerden biridir. Üretim planlaması, satış tahmini, nakliye, satış politikası, stok planlama, ambalajlama ve dağıtım faaliyetlerinde yapılan hatalar sebebi ile birçok tekstil ürünü dönem sonu satılamayıp tersine lojistik ağına girmektedir. Bu ürünler ileri lojistik aşamasında kaynak, enerji ve sermaye kullanımına neden oldukları gibi satılamayıp tersine lojistik akışına girdiklerinde de taşıma, depolama, değer kazanımı gibi birçok faaliyete neden olacaklarından hem kaynak hem de sermaye tüketimine devam etmektedir. Bu nedenle hem kaynak kullanımı bakımından hem de maliyet açısından kaynak kullanımını en başta azaltmak için doğru sayıda üretim, doğru şubelere doğru sayıda, renkte, bedende ve modelde ürün gönderimi, nakliye ve stok planlamasının doğru bir şekilde yapılması gerekmektedir.

Tekstil ürünlerinde iade oranının tahmini probleminin çok parametreli ve çok değişkenli yapısı nedeni ile matematiksel model kurmak veya moda ve tüketicilerin çok çabuk değişen istekleri nedeni ile genel olarak literatürdeki çalışmalarda görülebileceği gibi zaman serisine dayalı talep tahmini yapmak yerine karmaşık yapılı veri setlerinde daha hızlı ve doğruluğu yüksek sonuçlar vermesi sebebi ile Makine Öğrenme ve Bileşik Makine Öğrenme yöntemleri kullanılmıştır.

Çalışmada müşterilerin tercihleri ile birlikte satışa çıkan ürünlerin iadeleri ve nedenleri üzerinde yoğunlaşılıp iadelerin doğru bir şekilde tahmin edilmesi amacıyla yapılan analizler sonucunda elde edilen tüketici davranışı bilgileri ile mağazalara doğru beden, renk ve modelde ürünlerin gitmesini, gereksiz üretim, nakliye ve depolama faaliyetlerinden kaçınılmasını sağlayacak bilgiler ortaya konulmuştur. Böylece çalışmamız sonucu elde edilen daha doğru bir ürün iade tahmini ile üretim stratejisi belirleme, araç ve depo kapasitesi çalışmaları, araç rotalama, üretim planlama, stok yönetimi, tedarikçi seçimi, sezon sonu ürün stratejileri ve müşteriye doğru bir şekilde hitap etme bakımından firma birçok avantaja sahip olabilecektir.

Makine Öğrenme sınıflandırma tekniklerinden fonksiyonel algoritmalardan Doğrusal Regresyon (LR), Destek Vektör Regresyonu (SVR) ve Yapay Sinir Ağları (ANN), karar ağacı algoritmalarından M5P, REPTree, Random Tree (rasgele ağaç), Decision Stump (Karar Kesme), kural tabanlı algoritmalardan M5Rules ve Decision Table (Karar Tablosu) algoritmaları, tembel algoritmalardan KStar, IBk ve LWL algoritmaları, Bileşik Makine Öğrenme algoritmalarından Stacking, Voting, Bagging ve Random Sub Space algoritmaları ile tahminleme yapılmış, basit makine öğrenme yöntemlerinde M5Rules ve M5P en iyi sonuç verirken, bileşik makine öğrenme yöntemlerinden Bagging, Stacking ve Vote algoritmaları ile en iyi sonuçlar elde edilmiştir. Veri setinin %80 eğitim-%20 test seti ve %90 eğitim-%10 test seti olarak iki ayrı veri seti olarak ayarlanması ile tahminleme için denenmiş algoritmalardan elde edilen sonuçlar karşılaştırmalı olarak verilmiş, Stacking-M5Rules(M5P+M5Rules+SMOreg) %90 eğitim-%10 test seti ve Stacking-M5P(M5P+M5Rules+SMOreg) %90 eğitim- %10 test seti algoritmaları ile %83,89 korelasyon katsayısı değerinde en doğru tahmin oranına ulaşılmıştır. Stacking-M5Rules(M5P+M5Rules+SMOreg) algoritması 24973 saniye model kurma süresi ile daha iyi performans göstermiştir. Çalışma sonuçlarına göre literatürde bu konuda yapılmış son dönem çalışmalarını da destekleyecek şekilde Bileşik Makine Öğrenme yöntemleri ile Makine Öğrenme yöntemlerine göre daha iyi sonuçlar elde edilmiştir.

Normalleştirilmiş hata değerlerinin ortalamaları da hesaba katıldığında en iyi tahmin performansı Vote(M5P+M5Rules) %90 eğitim-%10 test setine sahip algoritma ile elde edilmiştir.

Ürün iade oranlarının tahmin edilmesi konusunda Makine Öğrenme Yöntemleri ve Bileşik Makine Öğrenme Yöntemleri kullanılması bakımından yapılmış ilk çalışmadır.

Ürün iadesi modeline girdi olacak parametrelerin uzman görüşleri, veri analizi, deneme yanılma ve parametre seçim algoritmaları kullanılarak seçilmesi şeklinde yapılan ön çalışma ile de literatüre ve tekstil sektörüne katkı sağlanması beklenmektedir.

Elde edilen sonuçlar, kullanılan Makine Öğrenme ve Bileşik Makine Öğrenme yöntemlerinin tekstil sektöründe ürün iade oranlarını tahmin edebilecek yeteneğe sahip olduğunu göstermektedir.

Ürün iadelerinin daha doğru bir şekilde tahmin edilerek azaltılması ile;

- mağazalarda gereksiz stok oluşumunu,
- stok yetersizliği nedeniyle satışa çıkamayan ürünleri,
- iade edilen ürünlerin merkeze, depoya ya da outlet mağazalara nakliyesini,
- nakliye sürecindeki elleçleme, taşıma, ambalajlama gibi faaliyetler ile yakıt, işçi ve sürücü ücreti gibi taşıma sürecinde oluşan maliyetleri,
- yeni ürünler yerine iade edilen ürünlerin saklanması için depoda yer kaplayacak gereksiz alanları,
- depoda bu işlemler için gerçekleştirilecek faaliyetleri ve bu faaliyetlerin oluşturacağı maliyetleri,
- merkeze dönen ürünlere değer kazandırmak için yapılacak yenileme faaliyetlerini ve bu işlem için gerekli maliyetleri,
- satılamayıp iade edilmiş ürünler için yapılacak stratejileri ve kampanya faaliyetlerini,

yani kısaca tüm tersine lojistik faaliyetlerini oluşmadan en başta azaltarak tüm bu maliyetlerin ve kaynak tüketiminin en aza indirilmesi sağlanmaktadır.

KAYNAKLAR

Agrawal, S., Singh, R.K., Murtaza, Q. "Forecasting product returns for recycling in Indian electronics industry", **J Adv Manag Res.**, C.11, No:1, 2014, 102–14.

Agrawal, S., Singh, R.K., Murtaza, Q. "A literature review and perspectives in reverse logistics", **Resources, Conservation and Recycling**, C.97, 2015, 76–92.

Aha, D. W., Kibler, D., Albert, M. K. "Instance-based learning algorithms", **Machine learning**, C.6, No:1, 1991, 37-66.

Akçalı, E., Çetinkaya, S., Üster, H. "Network design for reverse and closed loop supplychains: an annotated bibliography of models and solution approaches", **Networks**, C.53, No:3, 2009, 231–48.

Akkuş, İ. **Veri Madenciliği Stratejileri,** (Çevrimiçi) https://www.academia.edu/ 9860553/Veri_Madenciliği_Kümeleme_ve_Kümeleme_Yöntemleri, Erişim Tarihi: 28.10.2017.

Akküçük, U. **Veri Madenciliği: Kümeleme ve Sınıflama Algoritmaları**, Yalın Yayıncılık, İstanbul, 2011.

Alpaydın, E. **Introduction to machine learning**, MIT press, 2014.

Anyanwu, M. N., Shiva, S. G. "Comparative analysis of serial decision tree classification algorithms", **International Journal of Computer Science and Security**, C.3, No:3, 2009, 230-240.

Ardıl, E. **Esnek hesaplama yaklaşımı ile yazılım hata kestrimi**, Trakya Üniversitesi Fen Bilimleri Enstitüsü (Yüksek Lisaans Tezi), Edirne, 2009.

Argüden, Y., Erşahin, B. **Veri Madenciliği: Veriden Bilgiye, Masraftan Değere**, ARGE Danışmanlık Yayınları 10, 2008.

Ayaz, Y., Kocamaz, A. F., Karakoç, M. B. "Modeling of compressive strength and UPV of high-volume mineral-admixtured concrete using rule-based M5 rule and tree

model M5P classifiers", **Construction and Building Materials**, C.94, 2015, 235-240.

Aydogmus, H. Y., Erdal, H. İ., Karakurt, O., Namli, E., Turkan, Y. S., Erdal, H. — "A comparative assessment of bagging ensemble models for modeling concrete slump flow", **Computers and Concrete**, C.16, No:5, 2015, 741-757.

Ayvaz, B., Kaçtıoğlu, S., Varol, K. — "Belirsizlikler Altında Tersine Lojistik Ağ Tasarımı Literatür Taraması", **İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi**, C.24, 2013, 1-15.

Balouchi, B., Nikoo, M. R., Adamowski, J. — "Development of expert systems for the prediction of scour depth under live-bed conditions at river confluences: application of different types of ANNs and the M5P model tree", **Applied Soft Computing**, C.34, 2015, 51-59.

Baskin, I., Marcou, G., Varnek, A. — **Tutorial on Ensemble Learning**, Strasbourg, France, 1999.

Bazan, E., Jaber, M.Y., Zanoni, S. — "A review of mathematical inventory models for reverse logistics and the future of its modeling: An environmental perspective", **Applied Mathematical Modelling**, C.40, 2016, 4151–4178.

Benedito, E., Corominas, A. — "Optimal manufacturing policy in a reverse logistic sys-tem with dependent stochastic returns and limited capacities", **Int J Prod Res**, C.51, No:1, 2013, 1–13.

Bernon, M., Cullen, J. — "An integrated approach to managing reverse logistics", **Int J Logist**, C.10, No:1, 2007, 41–56.

Bernon, M., Rossi, S., Cullen, J. — "Retail reverse logistics: a call and grounding frameworkfor research", **Int J Phys Distrib Logist Manag**, C.41, No:5, 2011, 484–510.

Biehl, M., Prater, E., Realff, M.J. — "Assessing performance and uncertainty in developingcarpet reverse logistics systems", **Comput Oper Res**, C.34, 2007, 443–63.

Breiman, L. — "Random forests", **Machine learning**, C.45, No:1, 2001, 5-32.

Bulut, E., Deran, A. "Ters Lojistik ve Şirketlerin Maliyet Yönetimi Üzerine Etkileri", Ekonomik Yaklaşım Dergisi, 2007, 325-344.

Cannella, S., Bruccoleri, M., Framinan, J.M., "Closed-loop supply chains: What reverse logistics factors influence performance?", **Int. J. Production Economics**, C.175, 2016, 35–49.

Carter, C.R., Ellram, L.M. "Reverse logistics: a review of the literature and framework forfuture investigation", **J Bus Logist**, C.19, No:1, 1998, 85–102.

Centobelli, P., Cerchione, R., Esposito, E. "Environmental sustainability in the service industry of transportation and logistics service providers: Systematic literature review and research directions", **Transportation Research Part D**, C.53, 2017, 454–470.

Chen, H., He, H. "Reverse logistics demand forecasting under demand uncertainty", **IntConf Logist Eng Manag ASCE Conf Proc.**, 2010, 1:343.

Chou, J. S., Ngo, N. T., Pham, A. D. "Shear strength prediction in reinforced concrete deep beams using nature-inspired metaheuristic support vector regression", **Journal of Computing in Civil Engineering**, C.30, No:1, 2015, 04015002.

Cleary, J. G., Trigg, L. E. "K*: An instance-based learner using an entropic distance measure", **In Proceedings of the 12th International Conference on Machine learning**, C.5, 1995, 108-114.

Clottey, T., Benton, W.C., Jr, Srivastava, R. "Forecasting product returns for remanufac-turing operations", **Decis Sci**, C.43, No:4, 2012, 589–614.

Çekerol, G. S. **Lojistik yönetimi**, TC Anadolu üniversitesi yayını (2823), Eskişehir, 2013.

De Brito, M.P, Dekker, R. "Reverse logistics: a framework", **Econometric Institute ReportEI**, 2002, 1-19.

Deng, S., Yeh, T. H. "Using least squares support vector machines for the airframe structures manufacturing cost estimation", **International Journal of Production Economics**, C.131, No:2, 2011, 701-708.

Dietterich, T. G. "Ensemble learning", **The handbook of brain theory and neural networks**, C.2, 2002, 110-125.

Dinç, K., Erol, S., Yüceler, Ü. "Tersine Dağıtım Sisteminde Yeni Bir Model", **Mühendislik ve Teknoloji Sempozyumu**, Çankaya Üniversitesi, Ankara, 2008.

Dowlatshahi , S. "A strategic framework for the design and implementation of remanufacturing operations in reverse logistics", **International Journal of Production Research**, C.43 No:16, 2005, 3455-3480.

Dyckhoff, H., Lackes, R., & Reese, J. (Eds.) "Supply chain management and reverse logistics", Springer Science & Business Media, 2013.

Efendigil, T., Onut, S., Kahraman, C. "A decision support system for demand forecastingwith artificial neural networks and neuro-fuzzy models: a comparative analysis", **Expert Syst Appl**, C.36, No:3, 2009, 6697–707.

Erdal, H. I., Karakurt, O. "Advancing monthly streamflow prediction accuracy of CART models using ensemble learning paradigms", **Journal of Hydrology**, C.477, 2013, 119-128.

Erdoğan, Z. **Yaşam Kalitesi Endeksi Tabanlı Bileşik Makine Öğrenme Teknikleriyle Yaşam Alanı Tahmin Modeli**, İstanbul Üniversitesi Fen Bilimleri Enstitüsü (Yüksek Lisans Tezi), İstanbul, Haziran 2017.

Erpolat, S., Öz, E. "Kanser Verilerinin Sınıflandırılmasında Yapay Sinir ağları ile Destek Vektör Makineleri'nin Karşılaştırılması", **İstanbul Aydın Üniversitesi Fen Bilimleri Dergisi**, C.2, No:5, 2010, 71-83.

Esposito, M., Tse, T., Soufani, K. "Reverse Logistics for Postal Services within a Circular Economy", **Thunderbird International Business Review**, C.59, No:2, 2017, DOI: 10.1002/tie, 1-7.

Evren, S. **WEKA'da Temel İşlem Adımları**, (Çevrimiçi) http://bilgisayarkavramlari.sadievrenseker.com/2011/09/19/weka-ile-svm/, Erişim Tarihi: 28.10.2017.

Farrokhzad, F., Choobbasti, A. J., Barari, A. "Liquefaction microzonation of Babol city using artificial neural network", **Journal of King Saud University-Science**, C.24, No:1, 89-100.

Fernandez, G. Statistical data mining using SAS applications, CRC Press, 2010.

Fleischmann, M. "Reverse logistics network structures and design", In: Guide VDRJr, Van Wassenhove LN, editors. **Business aspects of closed-loop**

supply chains.Pittsburgh, PA: Carnegie Bosch Institute, 2001, 117–48.

Fleischmann, M, Van Wassenhove, L.N., Van Nunen, J.A.E.E., van der Laan, E.A., Dekker, R., Bloemhof-Ruwaard, J.M. "Quantitative models for reverse logistics: a review", **European Journal of Operation Research**, C.103, No:1, 1997, 1–17.

Fleischmann, M., Krikke, H.R., Dekker, R., Flapper, S.D.P. "A characterization of logisticsnetworks for product recovery", **Omega**, C.28, No:6, 2000, 653–66.

Frank, E., Hall, M., Holmes, G., Kirkby, R., Pfahringer, B., Witten, I. H., Trigg, L. "Weka-a machine learning workbench for data mining", **In Data mining and knowledge discovery handbook**, Springer, ABD, 2009, 1269-1277.

Freund, Y., Schapire, R. E. "Experiments with a new boosting algorithm", In Icml, C.96, 1996, 148-156.

Garner, S. R. "Weka: The waikato environment for knowledge analysis", In Proceedings of the New Zealand computer science research students conference, Nisan 1995, 57-64.

Gilanlı, E., Altuğ, N., ve Oğuzha, A. "Reverse Logisitcs Activities in Turkey", **Ege Akademik Bakış Dergisi**, C.12, No:3, Temmuz 2012, 391-399.

Gonçalves, M.F., Silva, A.E. "Reverse Logistics: The Portuguese companies' Perspective", **Brazilian Journal of Operations & Production Management**, C.13, 2016, 330-337.

González-Torre, P.L., Adenso-Diaz, B. "Reverse logistics practices in the glass sector inSpain and Belgium", **Int Bus Rev**, C.15, No:5, 2006, 527–46.

González-Torre, P.L., Adenso-Diaz, B., Artiba, H. — "Environmental and reverse logis-tics policies in European bottling and packaging firms", **Int J Prod Econ.**, C.88, No:1, 2004, 95–104.

Govindan, K., Palaniappan, M., Zhu, Q., Kannan, D. — "Analysis of third party reverse logistics provider using interpretive structural modeling", **Int. J. Production Economics**, C.140, 2012, 204–211.

Govindan, K., Soleimani, H., Kannan, D. — "Reverse logistics and closed-loop sup-ply chain: a comprehensive review to explore the future", **Eur J Oper Res.**, C.240, No:3, 2015, 603–26.

Govindan, K., Soleimani, H. — "A review of reverse logistics and closed-loop supply chains: a Journal of Cleaner Production focus", **Journal of Cleaner Production**, C.142, 2017, 371-384.

Greve, C., Davis, J. — **An Executive's Guide to Reverse Logistics: How to Find Hidden Profits by Managing Returns**, editor no identificado, 2012.

Guide, V.D.R., Wassenhove, L.N. — **Full cycle supply chains**, Pittsburgh, PA: Carnegie Mel-lon Press, Guide VDR Jr, 2003.

Gülsün, B., Tuzkaya, G., Bildik, E. — "Reserve Logistics Network Desing: A Simulated Annealing Approach", **Mühendislik ve Fen Bilimleri Dergisi**, 2008.

Gürsoy, U.T.Ş. — **Uygulamalı Veri Madenciliği; Sektörel Analizler**, Pegem Akademi, 2012.

Hamel, L. H. — **Knowledge discovery with support vector machines**, 3. Baskı, John Wiley & Sons, 2011.

Hall, D.J., Huscroft, J.R., Hazen, B.T., Hanna, J.B. — "Reverse logistics goals metrics andchallenges: perspectives from industry", **Int J Phys Distrib Logist Manag**, C.43, No:9, 2013, 768–85.

Han, H., Cueto, E.P. — "Formalization of Reverse Logistics Programs: A Theoretical Framework", **Brazilian Journal of Operations & Production Management**, C.13, 2016, 160-172.

Han, J., Pei, J., Kamber, M. **Data mining: concepts and techniques**, Elsevier, 2011.

Hanafi, J., Kara, S., Kaebernick, H. "Generating fuzzy coloured petri net forecasting modelto predict the return of products", **In: IEEE international symposium on electron-ics and the environment**, 7-10 Mayıs 2007, 245–50.

Henley, W. E., Hand, D. J. "Construction of a k-nearest-neighbour credit-scoring system", **IMA Journal of Management Mathematics**, C.8, No:4, 1997, 305-321.

Holmes, G., Donkin, A., Witten, I. H. "Weka: A machine learning workbench. In Intelligent Information Systems", **Proceedings of the 1994 Second Australian and New Zealand IEEE Conference on**, 1994, 357-361.

Holte, R.C. "Very simple classification rules perform well on most commonly used datasets", **Machine Learning**, C.11, 1993, 63-91.

Hsieh, S. L., Hsieh, S. H., Cheng, P. H., Chen, C. H., Hsu, K. P., Lee, I. S., ... , Lai, F. "Design ensemble machine learning model for breast cancer diagnosis", **Journal of medical systems**, C.36, No:5, 2012, 2841-2847.

Izenman, A. J. **Modern multivariate statistical techniques**, 1. Baskı, Springer, New York, ABD, 2008.

Jalil, E.E.A., Grant, D.B., Nicholson, J.D., Deutz, P. "Reverse logistics in household recycling and waste systems: a symbiosis perspective", **Supply Chain Management: An International Journal**, C.2182, 2016, 245-258.

Jayaraman, V., Luo, Y. "Creating competitive advantages through new value creation:a reverse logistics perspective", **Acad Manag Perspect**, C.21, No:2, 2007, 56–73.

Jayaraman, V., Patterson, R.A., Rolland, E. "The design of reverse distribution networks:models and solution procedures", **Eur J Oper Res**, C.150, No:1, 2003, 128–49.

John, G. H., Langley, P. "Estimating continuous distributions in Bayesian classifiers", **In Proceedings of the Eleventh conference on Uncertainty in artificial intelligence**, Morgan Kaufmann Publishers Inc., Ağustos 1995, 338-345.

Kara, K., Acar, A.Z. Önden, İ. "Tersine lojistik süreçlerinde toplama merkezi yerlerinin matematiksel modelleme ile tespit edilmesi", **12. Ulusal İşletmecilik Kongresi**, 2-4 Mayıs 2013, 911-916.

Karaçay, G. "Tersine Lojistik : Kavram ve İşleyiş", **Çukurova Üniversitesi İ.İ.B.F. Dergisi**, 2012.

Kohavi, R. "The power of decision tables. Machine learning", **ECML-95**, 1995, 174-189.

Kohavi, R. **Wrappers For Performance Enhancement And Oblıvıous Decısıon Graphs**, Carnegie Mellon University, Department of Computer Science, Pittsburgh, Eylül 1995.

Koptur, M. **Stacking Yöntemi**, (Çevrimiçi) https://makineogrenimi.wordpress.com/2017/06/19/modellerin-birlestirilmesi-ensemble-learning-4, Erişim Tarihi:29.10.2017.

Krapp, M., Nebel, J., Sahamie, H. "Forecasting product returns in closed-loop supplychains", **Int J Phys Distrib Logist Manag**, C.43, No:8, 2013, 614–37.

Krapp, M., Nebel, J., Sahamie, H. "Using forecasts and managerial accountinginformation to enhance closed-loop supply chain management", **OR Spectr**, C.35, No:4, 2013, 975–1007.

Kumar, S., Craig, S. "Dell Inc.'s closed loop supply chain for computer assembly plants", **Inf Knowl Syst Manag**, C.6, No:3, 2007, 197–214.

Kumar, D.T., Soleimani, H., Kannan, G. "Forecasting return products in an integratedforward/reverse supply chain utilizing an ANFIS", **Int J Appl Math Comput Sci.**, C.24, No:3, 2014, 669–82.

Kumar, D.T., Palaniappan, M., Kannan, D., Shankar, K.M. "Analyzing the CSR issues behind the supplier selection process using ISM approach", **Resources, Conservation and Recycling**, C.92, 2014, 268–278.

Kumar, S., Gupta, M.K. — "Strategies and Modeling of Reverse Logistics Networks of an Industry in India", **Int. Journal of Engineering Research and Application**, C.6, No:3-4, 2016, 138-143.

Lambert, S., Riopel, D., Abdul-Kader, W. — "A reverse logistics decisions conceptual frame-work", **Comput Ind Eng**, C.61, No:3, 2011, 561–81.

Lamrini, B., Della Valle, G., Trelea, I. C., Perrot, N., & Trystram, G. — "A new method for dynamic modelling of bread dough kneading based on artificial neural network", **Food control**, C.26, No:2, 2016, 512-524.

Lau, K.H., Wang, Y. — "Reverse logistics in the electronic industry of China: a case study", **Supply Chain Manag**, C.14, No:6, 2009, 447–65.

Leskovec, J.,Rajaraman, A.,. Ullman, J. D. — **Mining of Massive Datasets**, Stanford Univ, Copyright 2010, 2011, 2012, 2013,2014.

Linton, J.D., Klassen, R.B., Jayaraman, V. — "Sustainable supply chains: an introduction", **Journal of Oper Manag**, C.25, No:6, 2007, 1075–82.

Liu, W.J., Fang, Z.G. — "A conceptual framework for reverse logistics", **In: Proceedings of 2007 IEEE international conference on grey systems and intelligent services**, 2007, 1180–5.

Mahinderjit-Singh, M., Li, X., Li, Z. — "Counterfeiting Detection in RFID-enabled Supply Chain", **Journal of Advanced Internet of Things**, C.1, 2013, 19-43.

Mandal, S. K., Chan, F. T., Tiwari, M. K. — "Leak detection of pipeline: An integrated approach of rough set theory and artificial bee colony trained SVM", **Expert Systems with Applications**, C.39, No:3, 2012, 3071-3080.

Marqués, A. I., García, V., Sánchez, J. S. — "Exploring the behaviour of base classifiers in credit scoring ensembles", **Expert Systems with Applications**, C.39, No:11, 2012, 10244-10250.

Marqués, A. I., García, V., Sánchez, J. S. — "Two-level classifier ensembles for credit risk assessment", **Expert Systems with Applications**, C.39, No:12, 2012, 10916-10922.

Marx-Gomez, J., Rautenstrauch, C., Nurnberger, A., Kruse, R. "Neuro-fuzzy approach toforecast returns of scrapped products to recycling and remanufacturing", **KnowlBased Syst**, C.15, no:1/2, 2002, 119–28.

Morgan, T.R., Richey Jr, R.G., Autry, C.W. "Developing a reverse logistics competency: The influence of collaboration and information technology", **International Journal of Physical Distribution & Logistics Management**, C.46, No:3, 2016, 293-315.

Nakıboğlu, G. "Tersine Lojistik: Önemi ve Dünyadaki Uygulamaları", **Gazi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi**, , C.9, No:2, 2007, 181 – 196.

Namlı, E. **Proje yönetimi kapsamında risk tabanlı ve yapay zeka destekli bir maliyet tahmin modeli**, İstanbul Üniversitesi Fen Bilimleri Enstitüsü (Doktora Tezi), İstanbul, Nisan 2012.

Narayana, S.A., Elias, A.A., Pati, R.K. "Reverse logistics in the pharmaceuticals industry: asystemic analysis", **Int J Logist Manag**, C.25, No:2, 2014, 379–98.

Nikoo, M. R., Karimi, A., Kerachian, R., Poorsepahy-Samian, H., Daneshmand, F. "Rules for optimal operation of reservoir-river-groundwater systems considering water quality targets: application of M5P model", **Water resources management**, C.27, No:8, 2013, 2771-2784.

Olivas, E. S., Guerrero, J. D. M., Sober, M. M., Benedito, J. R. M., Lopez, A. J. S. **Handbook Of Research On Machine Learning Applications and Trends: Algorithms, Methods and Techniques**, Information Science Reference, New York, ABD, 2009.

Organ, A., Ertuğrul, İ. Ve Fedai Deniş, Ö. "Tersine Lojistik Ağ Modelinin Tamsayılı Programlamayla Tasarımı: Ömrünü Tamamlamış Lastik Geri Kazanım Örneği", **Ç.Ü. İktisadi ve İdari Bilimler Dergisi**, C.14, No:1, 2013.

Özgün Demirel, N., Gökçen, H. "Geri Kazanımlı İmalat Sistemleri İçin Lojistik Ağı Tasarımı: Literatür Araştırması", **Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi**, C.23, No:4, 2008, 903-912.

Özhan, E.	"Yapay Zeka Yöntemleri ile Dünya Depremlerinin Modellenebilirliği", **ISITES2014**, Karabuk/Türkiye, 2014, 1185-1194.
Peng, Y.	"A novel ensemble machine learning for robust microarray data classification", **Computers in Biology and Medicine**, C.36, No:6, 2006, 553-573.
Peralta, G.L., Fontanos, P.M.	"E-waste issues and measures in the Philippines", **J MaterCycles Waste Manag**, C.8, No:1, 2006, 34–9.
Pokharel, S., Mutha, A.	"Perspectives in reverse logistics: a review", **Resour ConservRecycl**, C.53, No:4, 2009, 175–82.
Potdar, A., Rogers, J.	"Reason-code based model to forecast product returns", Foresight, C.14, No:2, 2012, 105–20.
Prahinskia, C., Kocabasoglu, C.	"Empirical research opportunities in reverse supply chains", **Omega the International Journal of Management Science**, C.34, 2006, 519 – 532.
Rathore, P., Kota, S., Chakrabarti, A.	"Sustainability through remanufacturing in India: acase study on mobile handsets", **J Clean Prod**, C.19, No:15, 2011, 1709–22.
Ravi, V., Shankar, R.	"Reverse logistics operations in paper industry: a case study", J AdvManag Res, C.3, No:2, 2006, 88–94.
Richey, G.R., Daugherty, P.J., Genchev, S.E., Autry, C.W.	"Reverse logistics: the impact oftiming and resources", J Bus Logist, C.25, No:2, 2004, 229–50.
Rogers, D.S., Tibben-Lembke, R.S.	"An examination of reverse logistics practices", **J BusLogist**, C.22, No:2, 2001, 129–48.
Rogers, D.S., Melamed, B., Lembke, R.S.	"Modeling and analysis of reverse logistics", **J BusLogist**, C.33, No:2, 2012, 107–17.
Rubio, S., Chamorro, A.	"Miranda, FJ. Characteristics of the research on reverse logistics(1995–2005)", **Int J Prod Res**, C.46, No:4, 2008, 1099–120.

Shih, H.S., Lee, E.S., Chuang, S.H., Chen, CC. "A forecasting decision on the sales volumeof printers in Taiwan: an exploitation of the analytic network process", **ComputMath Appl**, C.64, No: 6, 2012, 1545–56.

Simmons, K., Kinney, J., Owens, A., Kleier, D. A., Bloch, K., Argentar, D., ... , Vaidyanathan, G. "Practical outcomes of applying ensemble machine learning classifiers to High-Throughput Screening (HTS) data analysis and screening", **Journal of chemical information and modeling**, C.48, No:11, 2008, 2196-2206.

Singh, R., Chakraborty, A., Kosambia, M., Shah, P., Karhade, A. "Reverse Logistics Using Genetic Algorithm", **International Journal of Innovative Research & Development**, C.5, No:2, 2016, 323-327.

Sornlertlamvanich, V., Potipiti, T., & Charoenporn, T. "Automatic corpus-based Thai word extraction with the C4. 5 learning algorithm", **Association for Computational Linguistics In Proceedings of the 18th conference on Computational linguistics-Volume 2**, Temmuz 2000, 802-807.

Srivastava, S. "Network design for reverse logistics", **Omega**, C.36, No:4, 2008, 535–48.

Srivastava, S.K., Srivastava, R.K. "Managing product returns for reverse logistics", **Int JPhys Distrib Logist Manag**, C.36, No:7, 2006, 524–46.

Stephens, V.L., White, G.R.T., Mason, J.R.S. "Problematising the concept of 'sustainability' in the supply chain through systematic literature review", **BAM**, Eylül 2016.

Steven, M. "Networks in reverse logistics", **In Supply chain management and reverse logistics**, Springer, Berlin, Almanya, 2004, 163-180.

Stock, J.R. "Development and implementation of reverse logistics program", **Oak Brook,IL: Council of Logistics Management**, 1998.

Stock, J.R, Mulki, J.P. "Product returns processing: an examination of practices of manu-facturers wholesalers/distributors and retailers", **J Bus Logist**, C.30, No:1, 2009, 33–62.

Subramanian, N., Gunasekaran, A., Abdulrahman M., Liu C. "Factors for implementingend-of-life product reverse logistics in the Chinese manufacturing sector", **Int JSustain Dev World Ecol**, C.21, No:3, 2014, 235–45.

Sun, X. "Pitch accent prediction using ensemble machine learning", **In Seventh International Conference on Spoken Language Processing**, 2002.

Şengül, Ü. "Tersine Lojistik Kavramı ve Tersine Lojistik Ağ Tasarımı", **Atatürk Ü. İİBF Dergisi, 10. Ekonometri ve İstatistik Sempozyumu Özel Sayısı**, 2011, 407-429.

Tan, A. C., Gilbert, D. **Ensemble machine learning on gene expression data for cancer classification**, 2003.

Temur, G.T., Balcilar, M., Bolat, B. "A fuzzy expert system design for forecastingreturn quantity in reverse logistics network", **J Enterp Inf Manag**, C.27, No:3, 2014, 316–28.

Tibben-Lembke, R.S. "The Impact of Reverse Logistics on the Total Cost of Ownership", **Journal of Marketing Theory and Practice**, C.6, No:4, 1998, 51-60.

Tibben-Lembke, R.S., Rogers, D.S. "Differences between forward and reverse logistics in a retail environment", **Supply Chain Management: An International Journal**, C.7, No:5, 2002, 271-282.

Toktay, B. "Forecasting Product Returns", **in Business Aspects of Closed-Loop Supply Chains**, Ed: D. Guide, Jr. L.N. Van Wassenhove, Carnegie Bosch Institute, International Management Series: Cilt:2, 2003.

Toktay, B., van der Laan, E.A. de Brito, M.P. "Managing Product Returns: Informational Issues and Forecasting Methods", **in Reverse Logistics: Quantitative Methods for Closed-Loop Supply Chains**, Ed: R. Dekker, Fleischmann, M., K. Inderfurth, L.N. Van Wassenhove, Springer Verlag, 2004.

Tolun, S. **Destek Vektör Makineleri: Banka Başarısızlığının Tahmini Üzerine Bir Uygulama**, İstanbul Üniversitesi Sosyal Bilimler Enstitüsü (Doktora tezi), İstanbul, 2008.

Uğur, N. **Bir Üçüncü Parti Lojistik Şirketinde Kalite Fonksiyonu Yayılımı Uygulaması,** İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü (Yüksek Lisans tezi), İstanbul, Haziran 2007.

Uslu, Ş., Akçadağ, M. "İlaç Sektöründe Tersine Lojistik ve Dağıtımında Bir Uygulama", **Niğde Üniversitesi İİBF Dergisi**, 2012, 149-158.

Vlachos, I. "Conceptual Framework of Reverse Logistics Impact on Firm Performance", **British Academy of Management (BAM) Conference**, 2014.

Wang, C. W. "New ensemble machine learning method for classification and prediction on gene expression data", **In Engineering in Medicine and Biology Society, 2006. EMBS'06, 28th Annual International Conference of the IEEE**, Ağustos 2006, 3478-3481.

Wang, X., Gaustad, G., Babbitt, C. W., Richa, K. "Economies of scale for future lithium-ionbattery recycling infrastructure", **Resour Conserv Recycl**, C.83, 2014, 53–62.

Wei, C., Patel, D. "Hybrid models for click fraud detection in mobile advertising", **Training**, C.3, 2012, 3-173.

West, D. "Neural network credit scoring models", **Computers & Operations Research**, C.27, No:11, 2000, 1131-1152.

Witten, I. H., Frank, E., Hall, M. A., Pal, C. J. **Data Mining: Practical machine learning tools and techniques**, Morgan Kaufmann, 2016.

Wu, C.J., Cheng, W.P. "Reverse logistics in the publishing industry: China, Hong Kongand Taiwan", **Int J Phys Distrib Logist Manag**, C.36, No:7, 2006, 507–23.

Xiaofeng, X., Tijun, F. "Forecast for the amount of returned products based on wavefunction", **Int Conf Inf Manag Innov Manag Ind Eng**, C.2, 2009, 324–7.

Yadav, A. K., Chandel, S. S. "Solar energy potential assessment of western Himalayan Indian state of Himachal Pradesh using J48 algorithm of WEKA in ANN based prediction model", **Renewable Energy**, C.75, 2015, 675-693.

Yasa, R., Etemad-Shahidi, A. "Classification and regression trees approach for predicting current-induced scour depth under pipelines", **Journal of Offshore Mechanics and Arctic Engineering**, C.136, No:1, 2014, 011702.

Yu, J., Williams, E., Ju, M., Yang, Y. "Forecasting global generation of obsolete personalcomputers", **Environ Sci Technol**, C.44, No:9, 2010, 3232–7.

Zhan, C., Gan, A., Hadi, M. "Prediction of lane clearance time of freeway incidents using the M5P tree algorithm", **IEEE Transactions on Intelligent Transportation Systems**, C.12, No:4, 2011, 1549-1557.

Zaïane, O. R. **Principles of knowledge discovery in databases**, Department of Computing Science, University of Alberta, 1999.

Zaki, M. J., Meira Jr, W., Meira, W. **Data mining and analysis: fundamental concepts and algorithms**, Cambridge University Press, 2014.

EKLER

EK-1: Stacking M5Rules (M5P4M5Rules+SMOreg) %90-10 Algoritması ile Yapılan Tahmin sonuçlarının Gerçek Değerlerle Karşılaştırılması			
Örnek	**Gerçek Değer**	**Tahmin Değeri**	**Hata**
1	0,09	0,078	-0,012
2	0,1	0,071	-0,029
3	0,05	0,057	0,007
4	0,04	0,045	0,005
5	0,1	0,074	-0,026
6	0,02	0,031	0,011
7	0,05	0,071	0,021
8	0,04	0,046	0,006
9	0,06	0,05	-0,01
10	0,09	0,075	-0,015
11	0,1	0,094	-0,006
12	0,02	0,026	0,006
13	0,04	0,079	0,039
14	0,06	0,072	0,012
15	0,06	0,062	0,002
16	0,1	0,089	-0,011
17	0,03	0,034	0,004
18	0,06	0,067	0,007
19	0,1	0,09	-0,01
20	0,09	0,087	-0,003

21	0,04	0,045	0,005
22	0,1	0,085	-0,015
23	0,05	0,044	-0,006
24	0,1	0,098	-0,002
25	0,03	0,039	0,009
26	0,09	0,083	-0,007
27	0,01	0,026	0,016
28	0,06	0,079	0,019
29	0,04	0,05	0,01
30	0,03	0,046	0,016
31	0,06	0,071	0,011
32	0,1	0,091	-0,009
33	0,1	0,087	-0,013
34	0,06	0,049	-0,011
35	0,09	0,09	0
36	0,04	0,043	0,003
37	0,09	0,065	-0,025
38	0,04	0,045	0,005
39	0,05	0,092	0,042
40	0,03	0,038	0,008
41	0,09	0,089	-0,001
42	0,1	0,092	-0,008
43	0,05	0,065	0,015
44	0,05	0,05	0

45	0,04	0,059	0,019
46	0,07	0,085	0,015
47	0,1	0,093	-0,007
48	0,05	0,048	-0,002
49	0,07	0,048	-0,022
50	0,03	0,033	0,003
51	0,1	0,09	-0,01
52	0,1	0,089	-0,011
53	0,09	0,087	-0,003
54	0,09	0,091	0,001
55	0,07	0,085	0,015
56	0,02	0,027	0,007
57	0,03	0,036	0,006
58	0,05	0,038	-0,012
59	0,08	0,093	0,013
60	0,1	0,092	-0,008
61	0,1	0,083	-0,017
62	0,02	0,022	0,002
63	0,04	0,039	-0,001
64	0,03	0,035	0,005
65	0,07	0,072	0,002
66	0,1	0,089	-0,011
67	0,08	0,074	-0,006
68	0,08	0,089	0,009

69	0,1	0,09	-0,01
70	0,04	0,04	0
71	0,03	0,035	0,005
72	0,04	0,04	0
73	0,08	0,085	0,005
74	0,04	0,053	0,013
75	0,06	0,083	0,023
76	0,07	0,072	0,002
77	0,1	0,089	-0,011
78	0,08	0,088	0,008
79	0,09	0,084	-0,006
80	0,1	0,095	-0,005
81	0,05	0,071	0,021
82	0,05	0,066	0,016
83	0,04	0,067	0,027
84	0,08	0,083	0,003
85	0,06	0,074	0,014
86	0,1	0,083	-0,017
87	0,09	0,085	-0,005
88	0,08	0,074	-0,006
89	0,03	0,036	0,006
90	0,1	0,09	-0,01
91	0,06	0,047	-0,013
92	0,07	0,081	0,011

93	0,1	0,077	-0,023
94	0,05	0,06	0,01
95	0,1	0,086	-0,014
96	0,08	0,082	0,002
97	0,1	0,085	-0,015
98	0,05	0,087	0,037
99	0,05	0,063	0,013
100	0,05	0,066	0,016
101	0,04	0,057	0,017
102	0,06	0,076	0,016
103	0,08	0,07	-0,01
104	0,1	0,081	-0,019
105	0,03	0,024	-0,006
106	0,1	0,088	-0,012
107	0,09	0,082	-0,008
108	0,04	0,038	-0,002
109	0,08	0,09	0,01
110	0,1	0,07	-0,03
111	0,1	0,092	-0,008
112	0,1	0,09	-0,01
113	0,1	0,049	-0,051
114	0,08	0,089	0,009
115	0,06	0,067	0,007
116	0,02	0,023	0,003

117	0,02	0,013	-0,007
118	0,01	0,005	-0,005
119	0,03	0,046	0,016
120	0,06	0,065	0,005
121	0,04	0,043	0,003
122	0,1	0,07	-0,03
123	0,06	0,07	0,01
124	0,09	0,087	-0,003
125	0,07	0,086	0,016
126	0,03	0,03	0
127	0,09	0,065	-0,025
128	0,05	0,046	-0,004
129	0,1	0,072	-0,028
130	0,1	0,093	-0,007
131	0,09	0,086	-0,004
132	0,1	0,065	-0,035
133	0,1	0,09	-0,01
134	0,04	0,03	-0,01
135	0,05	0,075	0,025
136	0,05	0,05	0
137	0,1	0,07	-0,03
138	0,08	0,089	0,009
139	0,07	0,078	0,008
140	0,08	0,088	0,008

141	0,09	0,089	-0,001
142	0,07	0,07	0
143	0,02	0,044	0,024
144	0,04	0,045	0,005
145	0,08	0,093	0,013
146	0,03	0,05	0,02
147	0,08	0,066	-0,014
148	0,07	0,084	0,014
149	0,04	0,041	0,001
150	0,05	0,036	-0,014
151	0,09	0,089	-0,001
152	0,1	0,096	-0,004
153	0,02	0,02	0
154	0,08	0,082	0,002
155	0,09	0,082	-0,008
156	0,07	0,058	-0,012
157	0,06	0,058	-0,002
158	0,1	0,088	-0,012
159	0,03	0,042	0,012
160	0,04	0,045	0,005
161	0,09	0,086	-0,004
162	0,07	0,069	-0,001
163	0,05	0,038	-0,012
164	0,05	0,066	0,016

165	0,1	0,093	-0,007
166	0,04	0,049	0,009
167	0,05	0,061	0,011
168	0,02	0,03	0,01
169	0,09	0,072	-0,018
170	0,03	0,057	0,027
171	0,07	0,083	0,013
172	0,07	0,068	-0,002
173	0,08	0,076	-0,004
174	0,05	0,065	0,015
175	0,06	0,062	0,002
176	0,06	0,067	0,007
177	0,06	0,075	0,015
178	0,08	0,064	-0,016
179	0,09	0,094	0,004
180	0,1	0,06	-0,04
181	0,05	0,047	-0,003
182	0,08	0,09	0,01
183	0,08	0,071	-0,009
184	0,1	0,089	-0,011
185	0,07	0,067	-0,003
186	0,05	0,054	0,004
187	0,09	0,091	0,001
188	0,04	0,04	0

189	0,04	0,04	0
190	0,1	0,093	-0,007
191	0,1	0,089	-0,011
192	0,04	0,059	0,019
193	0,04	0,067	0,027
194	0,07	0,068	-0,002
195	0,03	0,027	-0,003
196	0,1	0,088	-0,012
197	0,08	0,088	0,008
198	0,09	0,079	-0,011
199	0,04	0,053	0,013
200	0,09	0,085	-0,005
201	0,09	0,088	-0,002
202	0,1	0,088	-0,012
203	0,04	0,039	-0,001
204	0,06	0,059	-0,001
205	0,08	0,076	-0,004
206	0,1	0,095	-0,005
207	0,06	0,07	0,01
208	0,1	0,096	-0,004
209	0,1	0,079	-0,021
210	0,1	0,086	-0,014
211	0,07	0,068	-0,002
212	0,04	0,043	0,003

213	0,09	0,09	0
214	0,09	0,064	-0,026
215	0,09	0,085	-0,005
216	0,09	0,087	-0,003
217	0,09	0,075	-0,015
218	0,09	0,086	-0,004
219	0,06	0,061	0,001
220	0,1	0,084	-0,016
221	0,03	0,056	0,026
222	0,07	0,078	0,008
223	0,1	0,072	-0,028
224	0,09	0,09	0
225	0,1	0,095	-0,005
226	0,08	0,085	0,005
227	0,09	0,084	-0,006
228	0,04	0,04	0
229	0,07	0,086	0,016
230	0,06	0,053	-0,007
231	0,1	0,069	-0,031
232	0,08	0,077	-0,003
233	0,08	0,067	-0,013
234	0,03	0,034	0,004
235	0,07	0,087	0,017
236	0,04	0,061	0,021

237	0,09	0,083	-0,007
238	0,03	0,04	0,01
239	0,09	0,08	-0,01
240	0,07	0,052	-0,018
241	0,06	0,076	0,016
242	0,06	0,068	0,008
243	0,06	0,076	0,016
244	0,06	0,089	0,029
245	0,09	0,075	-0,015
246	0,03	0,028	-0,002
247	0,1	0,08	-0,02
248	0,05	0,057	0,007
249	0,1	0,077	-0,023
250	0,1	0,083	-0,017
251	0,03	0,035	0,005
252	0,06	0,064	0,004
253	0,05	0,044	-0,006
254	0,07	0,067	-0,003
255	0,07	0,08	0,01
256	0,06	0,063	0,003
257	0,07	0,072	0,002
258	0,07	0,077	0,007
259	0,06	0,056	-0,004
260	0,1	0,096	-0,004

261	0,09	0,09	0
262	0,06	0,089	0,029
263	0,1	0,076	-0,024
264	0,07	0,078	0,008
265	0,07	0,075	0,005
266	0,07	0,08	0,01
267	0,04	0,042	0,002
268	0,06	0,076	0,016
269	0,09	0,091	0,001
270	0,07	0,078	0,008
271	0,04	0,04	0
272	0,1	0,091	-0,009
273	0,03	0,029	-0,001
274	0,03	0,034	0,004
275	0,1	0,09	-0,01
276	0,05	0,038	-0,012
277	0,09	0,07	-0,02
278	0,1	0,097	-0,003
279	0,04	0,041	0,001
280	0,04	0,075	0,035
281	0,09	0,084	-0,006
282	0,05	0,05	0
283	0,05	0,08	0,03
284	0,09	0,07	-0,02

285	0,09	0,09	0
286	0,07	0,057	-0,013
287	0,07	0,09	0,02
288	0,02	0,039	0,019
289	0,09	0,088	-0,002
290	0,06	0,091	0,031
291	0,05	0,04	-0,01
292	0,06	0,066	0,006
293	0,03	0,044	0,014
294	0,06	0,076	0,016
295	0,1	0,089	-0,011
296	0,07	0,078	0,008
297	0,06	0,056	-0,004
298	0,1	0,097	-0,003
299	0,06	0,068	0,008
300	0,09	0,092	0,002
301	0,09	0,081	-0,009
302	0,05	0,067	0,017
303	0,06	0,082	0,022
304	0,06	0,061	0,001
305	0,09	0,091	0,001
306	0,08	0,072	-0,008
307	0,03	0,036	0,006
308	0,09	0,093	0,003

309	0,1	0,092	-0,008
310	0,04	0,04	0
311	0,1	0,093	-0,007
312	0,08	0,087	0,007
313	0,07	0,083	0,013
314	0,07	0,098	0,028
315	0,03	0,028	-0,002
316	0,09	0,081	-0,009
317	0,09	0,079	-0,011
318	0,09	0,082	-0,008
319	0,04	0,037	-0,003
320	0,02	0,02	0
321	0,05	0,045	-0,005
322	0,03	0,037	0,007
323	0,02	0,037	0,017
324	0,05	0,053	0,003
325	0,02	0,063	0,043
326	0,08	0,085	0,005
327	0,04	0,042	0,002
328	0,1	0,073	-0,027
329	0,04	0,05	0,01
330	0,09	0,069	-0,021
331	0,08	0,09	0,01
332	0,06	0,066	0,006

333	0,03	0,032	0,002
334	0,1	0,096	-0,004
335	0,06	0,078	0,018
336	0,1	0,087	-0,013
337	0,07	0,065	-0,005
338	0,07	0,085	0,015
339	0,03	0,038	0,008
340	0,03	0,029	-0,001
341	0,03	0,035	0,005
342	0,07	0,091	0,021
343	0,1	0,086	-0,014
344	0,07	0,09	0,02
345	0,07	0,067	-0,003
346	0,1	0,095	-0,005
347	0,05	0,064	0,014
348	0,1	0,083	-0,017
349	0,1	0,08	-0,02
350	0,08	0,093	0,013
351	0,04	0,049	0,009
352	0,1	0,097	-0,003
353	0,09	0,092	0,002
354	0,05	0,048	-0,002
355	0,09	0,088	-0,002
356	0,05	0,07	0,02

357	0,05	0,054	0,004
358	0,07	0,091	0,021
359	0,09	0,083	-0,007
360	0,08	0,072	-0,008
361	0,08	0,083	0,003
362	0,09	0,083	-0,007
363	0,06	0,062	0,002
364	0,09	0,087	-0,003
365	0,05	0,059	0,009
366	0,03	0,028	-0,002
367	0,09	0,089	-0,001
368	0,03	0,036	0,006
369	0,01	0,024	0,014
370	0,06	0,054	-0,006
371	0,06	0,051	-0,009
372	0,09	0,086	-0,004
373	0,07	0,075	0,005
374	0,1	0,09	-0,01
375	0,07	0,083	0,013
376	0,09	0,087	-0,003
377	0,06	0,063	0,003
378	0,04	0,036	-0,004
379	0,09	0,092	0,002
380	0,06	0,059	-0,001

381	0,06	0,07	0,01
382	0,09	0,083	-0,007
383	0,06	0,079	0,019
384	0,07	0,065	-0,005
385	0,07	0,075	0,005
386	0,08	0,076	-0,004
387	0,03	0,03	0
388	0,06	0,052	-0,008
389	0,04	0,051	0,011
390	0,1	0,078	-0,022
391	0,09	0,082	-0,008
392	0,02	0,026	0,006
393	0,04	0,044	0,004
394	0,07	0,059	-0,011
395	0,08	0,082	0,002
396	0,1	0,09	-0,01
397	0,03	0,032	0,002
398	0,07	0,08	0,01
399	0,1	0,062	-0,038
400	0,05	0,04	-0,01
401	0,1	0,088	-0,012
402	0,04	0,053	0,013
403	0,05	0,077	0,027
404	0,1	0,094	-0,006

405	0,04	0,038	-0,002
406	0,02	0,042	0,022
407	0,05	0,044	-0,006
408	0,08	0,092	0,012
409	0,03	0,044	0,014
410	0,09	0,074	-0,016
411	0,09	0,074	-0,016
412	0,09	0,084	-0,006
413	0,07	0,085	0,015
414	0,05	0,047	-0,003
415	0,05	0,067	0,017
416	0,04	0,062	0,022
417	0,1	0,089	-0,011
418	0,09	0,07	-0,02
419	0,03	0,032	0,002
420	0,1	0,081	-0,019
421	0,1	0,082	-0,018
422	0,05	0,057	0,007
423	0,1	0,085	-0,015
424	0,03	0,033	0,003
425	0,1	0,089	-0,011
426	0,06	0,073	0,013
427	0,1	0,089	-0,011
428	0,04	0,05	0,01

429	0,08	0,056	-0,024
430	0,09	0,09	0
431	0,08	0,084	0,004
432	0,06	0,065	0,005
433	0,05	0,065	0,015
434	0,04	0,043	0,003
435	0,02	0,032	0,012
436	0,09	0,089	-0,001
437	0,07	0,099	0,029
438	0,08	0,07	-0,01
439	0,06	0,06	0
440	0,02	0,033	0,013
441	0,09	0,068	-0,022
442	0,05	0,05	0
443	0,09	0,083	-0,007
444	0,09	0,057	-0,033
445	0,09	0,088	-0,002
446	0,09	0,076	-0,014
447	0,09	0,082	-0,008
448	0,06	0,078	0,018
449	0,05	0,047	-0,003
450	0,09	0,081	-0,009
451	0,06	0,073	0,013
452	0,03	0,053	0,023

453	0,09	0,082	-0,008
454	0,07	0,085	0,015
455	0,05	0,073	0,023
456	0,07	0,09	0,02
457	0,05	0,049	-0,001
458	0,05	0,075	0,025
459	0,09	0,088	-0,002
460	0,07	0,075	0,005
461	0,03	0,032	0,002
462	0,04	0,036	-0,004
463	0,08	0,074	-0,006
464	0,07	0,088	0,018
465	0,09	0,095	0,005
466	0,07	0,066	-0,004
467	0,07	0,072	0,002
468	0,09	0,082	-0,008
469	0,06	0,068	0,008
470	0,07	0,055	-0,015
471	0,05	0,048	-0,002
472	0,03	0,059	0,029
473	0,09	0,088	-0,002
474	0,04	0,079	0,039
475	0,1	0,094	-0,006
476	0,06	0,046	-0,014

477	0,06	0,069	0,009
478	0,06	0,073	0,013
479	0,05	0,054	0,004
480	0,03	0,046	0,016
481	0,1	0,081	-0,019
482	0,07	0,071	0,001
483	0,1	0,08	-0,02
484	0,1	0,093	-0,007
485	0,09	0,091	0,001
486	0,09	0,064	-0,026
487	0,1	0,092	-0,008
488	0,09	0,067	-0,023
489	0,05	0,063	0,013
490	0,08	0,064	-0,016
491	0,02	0,034	0,014
492	0,06	0,062	0,002
493	0,02	0,021	0,001
494	0,08	0,069	-0,011
495	0,1	0,093	-0,007
496	0,07	0,076	0,006
497	0,07	0,057	-0,013
498	0,1	0,082	-0,018
499	0,1	0,086	-0,014
500	0,05	0,073	0,023

501	0,1	0,088	-0,012
502	0,1	0,092	-0,008
503	0,09	0,086	-0,004
504	0,1	0,09	-0,01
505	0,03	0,063	0,033
506	0,05	0,059	0,009
507	0,03	0,036	0,006
508	0,09	0,078	-0,012
509	0,07	0,089	0,019
510	0,1	0,081	-0,019
511	0,05	0,046	-0,004
512	0,05	0,064	0,014
513	0,09	0,08	-0,01
514	0,05	0,063	0,013
515	0,09	0,088	-0,002
516	0,06	0,071	0,011
517	0,07	0,07	0
518	0,1	0,093	-0,007
519	0,03	0,033	0,003
520	0,09	0,089	-0,001
521	0,04	0,036	-0,004
522	0,04	0,055	0,015
523	0,09	0,1	0,01
524	0,09	0,088	-0,002

525	0,1	0,098	-0,002
526	0,04	0,033	-0,007
527	0,1	0,093	-0,007
528	0,04	0,045	0,005
529	0,07	0,082	0,012
530	0,07	0,077	0,007
531	0,05	0,059	0,009
532	0,08	0,08	0
533	0,04	0,043	0,003
534	0,05	0,07	0,02
535	0,04	0,027	-0,013
536	0,05	0,07	0,02
537	0,1	0,087	-0,013
538	0,06	0,092	0,032
539	0,1	0,083	-0,017
540	0,02	0,023	0,003
541	0,09	0,059	-0,031
542	0,07	0,077	0,007
543	0,1	0,091	-0,009
544	0,06	0,077	0,017
545	0,09	0,084	-0,006
546	0,1	0,094	-0,006
547	0,06	0,079	0,019
548	0,04	0,035	-0,005

549	0,05	0,053	0,003
550	0,06	0,058	-0,002
551	0,02	0,022	0,002
552	0,02	0,019	-0,001
553	0,05	0,041	-0,009
554	0,03	0,034	0,004
555	0,1	0,084	-0,016
556	0,04	0,034	-0,006
557	0,05	0,065	0,015
558	0,04	0,04	0
559	0,1	0,059	-0,041
560	0,06	0,069	0,009
561	0,06	0,054	-0,006
562	0,1	0,086	-0,014
563	0,08	0,064	-0,016
564	0,03	0,046	0,016
565	0,1	0,091	-0,009
566	0,06	0,069	0,009
567	0,02	0,021	0,001
568	0,05	0,084	0,034
569	0,07	0,088	0,018
570	0,1	0,087	-0,013
571	0,1	0,09	-0,01
572	0,07	0,063	-0,007

573	0,07	0,085	0,015
574	0,09	0,091	0,001
575	0,04	0,046	0,006
576	0,1	0,092	-0,008
577	0,09	0,089	-0,001
578	0,09	0,072	-0,018
579	0,04	0,062	0,022
580	0,1	0,092	-0,008
581	0,05	0,033	-0,017
582	0,07	0,068	-0,002
583	0,06	0,049	-0,011
584	0,05	0,042	-0,008
585	0,1	0,096	-0,004
586	0,1	0,09	-0,01
587	0,05	0,076	0,026
588	0,1	0,068	-0,032
589	0,07	0,076	0,006
590	0,09	0,094	0,004
591	0,1	0,096	-0,004
592	0,07	0,079	0,009
593	0,07	0,072	0,002
594	0,06	0,063	0,003
595	0,03	0,055	0,025
596	0,03	0,044	0,014

597	0,06	0,059	-0,001
598	0,04	0,036	-0,004
599	0,08	0,084	0,004
600	0,07	0,091	0,021
601	0,1	0,088	-0,012
602	0,1	0,084	-0,016
603	0,1	0,089	-0,011
604	0,06	0,073	0,013
605	0,1	0,095	-0,005
606	0,07	0,083	0,013
607	0,1	0,093	-0,007
608	0,08	0,07	-0,01
609	0,05	0,085	0,035
610	0,04	0,041	0,001
611	0,09	0,091	0,001
612	0,03	0,031	0,001
613	0,06	0,07	0,01
614	0,07	0,077	0,007
615	0,05	0,052	0,002
616	0,1	0,095	-0,005
617	0,1	0,085	-0,015
618	0,05	0,058	0,008
619	0,03	0,033	0,003
620	0,1	0,093	-0,007

621	0,1	0,091	-0,009
622	0,06	0,064	0,004
623	0,04	0,058	0,018
624	0,06	0,077	0,017
625	0,08	0,084	0,004
626	0,06	0,071	0,011
627	0,1	0,088	-0,012
628	0,04	0,047	0,007
629	0,05	0,063	0,013
630	0,08	0,073	-0,007
631	0,09	0,067	-0,023
632	0,1	0,091	-0,009
633	0,09	0,077	-0,013
634	0,09	0,088	-0,002
635	0,08	0,094	0,014
636	0,07	0,091	0,021
637	0,09	0,085	-0,005
638	0,04	0,043	0,003
639	0,03	0,036	0,006
640	0,06	0,063	0,003
641	0,08	0,064	-0,016
642	0,05	0,054	0,004
643	0,08	0,092	0,012
644	0,09	0,083	-0,007

645	0,03	0,034	0,004
646	0,08	0,081	0,001
647	0,05	0,076	0,026
648	0,06	0,055	-0,005
649	0,09	0,083	-0,007
650	0,05	0,068	0,018
651	0,09	0,088	-0,002
652	0,07	0,084	0,014
653	0,04	0,035	-0,005
654	0,04	0,043	0,003
655	0,1	0,096	-0,004
656	0,03	0,033	0,003
657	0,1	0,089	-0,011
658	0,03	0,037	0,007
659	0,03	0,031	0,001
660	0,08	0,07	-0,01
661	0,05	0,052	0,002
662	0,09	0,09	0
663	0,05	0,062	0,012
664	0,05	0,075	0,025
665	0,06	0,072	0,012
666	0,04	0,035	-0,005
667	0,1	0,092	-0,008
668	0,05	0,067	0,017

669	0,07	0,072	0,002
670	0,07	0,062	-0,008
671	0,05	0,054	0,004
672	0,1	0,073	-0,027
673	0,02	0,023	0,003
674	0,1	0,09	-0,01
675	0,03	0,031	0,001
676	0,09	0,093	0,003
677	0,06	0,066	0,006
678	0,07	0,058	-0,012
679	0,09	0,094	0,004
680	0,1	0,068	-0,032
681	0,04	0,032	-0,008
682	0,04	0,039	-0,001
683	0,05	0,067	0,017
684	0,04	0,052	0,012
685	0,07	0,07	0
686	0,1	0,094	-0,006
687	0,06	0,072	0,012
688	0,05	0,054	0,004
689	0,06	0,048	-0,012
690	0,1	0,097	-0,003
691	0,05	0,047	-0,003
692	0,04	0,039	-0,001

693	0,09	0,099	0,009
694	0,06	0,08	0,02
695	0,07	0,078	0,008
696	0,09	0,089	-0,001
697	0,03	0,035	0,005
698	0,05	0,072	0,022
699	0,09	0,092	0,002
700	0,05	0,067	0,017
701	0,1	0,091	-0,009
702	0,06	0,071	0,011
703	0,06	0,071	0,011
704	0,06	0,077	0,017
705	0,06	0,05	-0,01
706	0,08	0,048	-0,032
707	0,1	0,089	-0,011
708	0,05	0,043	-0,007
709	0,07	0,07	0
710	0,09	0,09	0
711	0,06	0,073	0,013
712	0,07	0,061	-0,009
713	0,09	0,088	-0,002
714	0,1	0,089	-0,011
715	0,05	0,046	-0,004
716	0,07	0,09	0,02

717	0,09	0,061	-0,029
718	0,04	0,052	0,012
719	0,09	0,083	-0,007
720	0,08	0,057	-0,023
721	0,09	0,083	-0,007
722	0,03	0,037	0,007
723	0,05	0,044	-0,006
724	0,09	0,088	-0,002
725	0,1	0,088	-0,012
726	0,08	0,089	0,009
727	0,04	0,042	0,002
728	0,05	0,066	0,016
729	0,04	0,034	-0,006
730	0,04	0,046	0,006
731	0,1	0,091	-0,009
732	0,05	0,044	-0,006
733	0,1	0,084	-0,016
734	0,05	0,067	0,017
735	0,03	0,036	0,006
736	0,06	0,06	0
737	0,07	0,057	-0,013
738	0,08	0,087	0,007
739	0,07	0,084	0,014
740	0,1	0,09	-0,01

741	0,06	0,057	-0,003
742	0,1	0,078	-0,022
743	0,09	0,064	-0,026
744	0,04	0,033	-0,007
745	0,09	0,067	-0,023
746	0,08	0,059	-0,021
747	0,05	0,076	0,026
748	0,06	0,072	0,012
749	0,1	0,091	-0,009
750	0,06	0,092	0,032
751	0,05	0,051	0,001
752	0,04	0,061	0,021
753	0,1	0,071	-0,029
754	0,06	0,082	0,022
755	0,04	0,041	0,001
756	0,05	0,055	0,005
757	0,08	0,054	-0,026
758	0,07	0,073	0,003
759	0,05	0,059	0,009
760	0,07	0,049	-0,021
761	0,1	0,092	-0,008
762	0,07	0,073	0,003
763	0,06	0,053	-0,007
764	0,03	0,027	-0,003

765	0,07	0,086	0,016
766	0,04	0,047	0,007
767	0,09	0,082	-0,008
768	0,1	0,09	-0,01
769	0,06	0,05	-0,01
770	0,09	0,09	0
771	0,03	0,033	0,003
772	0,1	0,086	-0,014
773	0,1	0,094	-0,006
774	0,1	0,09	-0,01
775	0,06	0,074	0,014
776	0,05	0,069	0,019
777	0,07	0,074	0,004
778	0,1	0,094	-0,006
779	0,07	0,097	0,027
780	0,1	0,084	-0,016
781	0,06	0,071	0,011
782	0,05	0,047	-0,003
783	0,05	0,074	0,024
784	0,07	0,089	0,019
785	0,05	0,048	-0,002
786	0,09	0,093	0,003
787	0,04	0,053	0,013
788	0,04	0,039	-0,001

789	0,1	0,087	-0,013
790	0,08	0,089	0,009
791	0,1	0,092	-0,008
792	0,09	0,09	0
793	0,03	0,036	0,006
794	0,05	0,085	0,035
795	0,03	0,04	0,01
796	0,07	0,074	0,004
797	0,07	0,073	0,003
798	0,09	0,092	0,002
799	0,09	0,092	0,002
800	0,08	0,091	0,011
801	0,1	0,092	-0,008
802	0,1	0,074	-0,026
803	0,04	0,047	0,007
804	0,06	0,056	-0,004
805	0,06	0,071	0,011
806	0,08	0,091	0,011
807	0,06	0,085	0,025
808	0,1	0,075	-0,025
809	0,04	0,033	-0,007
810	0,1	0,063	-0,037
811	0,04	0,036	-0,004
812	0,05	0,048	-0,002

813	0,08	0,078	-0,002
814	0,08	0,089	0,009
815	0,09	0,083	-0,007
816	0,03	0,071	0,041
817	0,05	0,074	0,024
818	0,05	0,095	0,045
819	0,1	0,076	-0,024
820	0,07	0,086	0,016
821	0,08	0,067	-0,013
822	0,05	0,062	0,012
823	0,1	0,077	-0,023
824	0,1	0,09	-0,01
825	0,04	0,041	0,001
826	0,1	0,092	-0,008
827	0,05	0,058	0,008
828	0,09	0,089	-0,001
829	0,03	0,032	0,002
830	0,03	0,061	0,031
831	0,08	0,088	0,008
832	0,06	0,067	0,007
833	0,06	0,068	0,008
834	0,03	0,039	0,009
835	0,09	0,072	-0,018
836	0,09	0,085	-0,005

837	0,1	0,081	-0,019
838	0,1	0,086	-0,014
839	0,06	0,077	0,017
840	0,06	0,051	-0,009
841	0,03	0,033	0,003
842	0,03	0,046	0,016
843	0,1	0,088	-0,012
844	0,06	0,08	0,02
845	0,09	0,088	-0,002
846	0,09	0,092	0,002
847	0,03	0,036	0,006
848	0,07	0,079	0,009
849	0,08	0,088	0,008
850	0,05	0,057	0,007
851	0,09	0,065	-0,025
852	0,09	0,09	0
853	0,06	0,08	0,02
854	0,06	0,072	0,012
855	0,09	0,081	-0,009
856	0,09	0,086	-0,004
857	0,08	0,096	0,016
858	0,06	0,066	0,006
859	0,05	0,058	0,008
860	0,04	0,039	-0,001

861	0,05	0,069	0,019
862	0,06	0,078	0,018
863	0,04	0,056	0,016
864	0,04	0,031	-0,009
865	0,03	0,047	0,017
866	0,1	0,083	-0,017
867	0,02	0,025	0,005
868	0,09	0,083	-0,007
869	0,09	0,09	0
870	0,1	0,077	-0,023
871	0,04	0,055	0,015
872	0,07	0,066	-0,004
873	0,08	0,076	-0,004
874	0,06	0,063	0,003
875	0,09	0,088	-0,002
876	0,05	0,068	0,018
877	0,1	0,092	-0,008
878	0,08	0,058	-0,022
879	0,03	0,033	0,003
880	0,09	0,088	-0,002
881	0,09	0,09	0
882	0,1	0,091	-0,009
883	0,1	0,083	-0,017
884	0,03	0,036	0,006

885	0,07	0,078	0,008
886	0,05	0,047	-0,003
887	0,03	0,038	0,008
888	0,03	0,035	0,005
889	0,06	0,092	0,032
890	0,06	0,066	0,006
891	0,06	0,08	0,02
892	0,09	0,087	-0,003
893	0,1	0,083	-0,017
894	0,1	0,066	-0,034
895	0,05	0,049	-0,001
896	0,04	0,065	0,025
897	0,09	0,066	-0,024
898	0,05	0,052	0,002
899	0,06	0,05	-0,01
900	0,02	0,036	0,016
901	0,1	0,085	-0,015
902	0,02	0,037	0,017
903	0,04	0,066	0,026
904	0,09	0,087	-0,003
905	0,03	0,038	0,008
906	0,08	0,076	-0,004
907	0,04	0,043	0,003
908	0,02	0,034	0,014

909	0,06	0,064	0,004
910	0,03	0,033	0,003
911	0,1	0,092	-0,008

ÖZGEÇMİŞ

Kişisel Bilgiler

Adı Soyadı : Ayşe Nur ADIGÜZEL TÜYLÜ

Doğum tarihi, Yeri : 1985, Adana

E-mail : aysenur.adiguzel@istanbul.edu.tr

Eğitim

Derece	Kurum/Anabilim Dalı/Programı	Yılı
Doktora	İ.Ü. Sosyal Bilimler Enstitüsü / Sayısal Yöntemler	2017
Yüksek Lisans	İ.Ü. Fen Bilimleri Enstitüsü / Endüstri Mühendisliği	2012
Lisans	İ.Ü. / Mühendislik Fakültesi / Endüstri Mühendisliği	2008
Lise	Adana Anadolu Lisesi	2003

Tezleri

Yüksek Lisans, "Tesis Yerleşimi Düzenlenmesi Problemi için Bir Tabu Arama Sezgisel Algoritması", **İstanbul Üniversitesi Endüstri Mühendisliği**, Eylül 2012.

Makaleler

Çelikbilek, Y., **Adigüzel Tüylü, A. N.**, Esnaf, Ş., "Industrial Coffee Machine Selection with the Fuzzy Analytic Hierarchy Process", **International Journal of Management and Applied Science**, C.2, No:2, 2016, 20–23.

Uluslararası Bildiriler

Çelikbilek, Y., **Adıgüzel Tüylü, A. N.**, "Evaluating the Technological Factors of Distance Learning", **The IAFOR International Conference on Education 2016 – Hawaii**, 2016.

Çelikbilek, Y., **Adıgüzel Tüylü, A. N.**, Esnaf, Ş., "Industrial Coffee Machine Selection with the Fuzzy Analytic Hierarchy Process", **2015 The IIER 28th International Conference on Advances in Business Management and Information Technology**, 2015.

Yumurtaci Aydogmus H., Aydogmus U., **Adigüzel Tüylü A.N.**, Karakoc A., "Support Vector Machines Model In Individual Pension Contract Forcasting For Antalya", **1.Uluslararasi Ekonomi Yonetimi Ve Pazar Arastirmalari Kongresi**, Istanbul, Türkiye, 4-5 Aralık 2015, 94-95

Adıgüzel Tüylü, A. N., Çelikbilek, Y., "An Integrated AHP and VIKOR Approach for Excavator Selection in Open Pit Mining", **27. European Conference on Operations Research**, 2015, 12–12.

Çelikbilek, Y., **Adıgüzel Tüylü, A. N.**, "Analysing the Components of E-learning with DEMATEL and ANP", **27. European Conference on Operations Research**, 2015, 79–79.