

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

**VERİ MADENCİLİĞİ TEKNİKLERİ KULLANILARAK
İNTERNETTEN ALIŞVERİŞ YAPAN
TÜKETİCİLERİN ANALİZİ**

YÜKSEK LİSANS TEZİ

İrem DELİİSMAİL

Enstitü Anabilim Dalı : ENDÜSTRİ MÜHENDİSLİĞİ

Tez Danışmanı : Dr. Öğr. Üyesi Alper KİRAZ

Haziran 2019

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**VERİ MADENCİLİĞİ TEKNİKLERİ KULLANILARAK
İNTERNETTEN ALIŞVERİŞ YAPAN
TÜKETİCİLERİN ANALİZİ**

YÜKSEK LİSANS TEZİ
İrem DELİİSMAIL

Enstitü Anabilim Dalı : ENDÜSTRİ MÜHENDİSLİĞİ

Bu tez 10.06.2019 tarihinde aşağıdaki jüri tarafından oybirliği / oyçokluğu ile kabul edilmiştir.

Dr. Öğr. Üyesi
Alper KIRAZ
Jüri Başkanı

Dr. Öğr. Üyesi
Çağatay TEKE
Üye

Dr. Öğr. Üyesi
M. Rıza ADALI
Üye

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

**VERİ MADENCİLİĞİ TEKNİKLERİ KULLANILARAK
İNTERNETTEN ALIŞVERİŞ YAPAN
TÜKETİCİLERİN ANALİZİ**

YÜKSEK LİSANS TEZİ

İrem DELİİSMAİL

Enstitü Anabilim Dalı : ENDÜSTRİ MÜHENDİSLİĞİ

Bu tez 10.06.2019 tarihinde aşağıdaki jüri tarafından oybirliği / oyçokluğu ile kabul edilmiştir.

**Dr. Öğr. Üyesi
Alper KIRAZ
Jüri Başkanı**

**Dr. Öğr. Üyesi
Çağatay TEKE
Üye**

**Dr. Öğr. Üyesi
M. Rıza ADALI
Üye**

BEYAN

Tez içindeki tüm verilerin akademik kurallar çerçevesinde tarafımdan elde edildiğini, görsel ve yazılı tüm bilgi ve sonuçların akademik ve etik kurallara uygun şekilde sunulduğunu, kullanılan verilerde herhangi bir tahrifat yapılmadığını, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezde yer alan verilerin bu üniversite veya başka bir üniversitede herhangi bir tez çalışmasında kullanılmadığını beyan ederim.

İrem DELİİSMAİL

TEŞEKKÜR

Çalışmamın her aşamasında bana yön veren ve her türlü yardımı esirgemeyen danışmanım Dr. Öğr. Üyesi Alper KİRAZ'a, maddi, manevi desteklerini esirgemeyen aileme ve arkadaşlarıma teşekkür ederim.



İÇİNDEKİLER

TEŞEKKÜR.....	i
İÇİNDEKİLER	ii
SİMGELER VE KISALTMALAR LİSTESİ	iv
ŞEKİLLER LİSTESİ	v
TABLolar LİSTESİ.....	vii
ÖZET.....	ix
SUMMARY	x
BÖLÜM 1.	
GİRİŞ	1
1.1. Çalışmanın Kapsamı.....	4
1.2. Çalışmanın Amacı	5
1.3. Çalışmanın Önemi	5
1.4. Çalışmanın Kısıtları.....	6
BÖLÜM 2.	
LİTERATÜR ARAŞTIRMASI	7
2.1. Veri Madenciliği Tanımı	7
2.2. Veri Madenciliğinin Kullanıldığı Alanlar	9
2.3. Veri Madenciliği Teknikleri	9
2.3.1. Sınıflama ve regresyon teknikleri.....	10
2.3.2. Kümeleme teknikleri	12
2.3.3. Birliktelik kuralları	13
2.4. Literatür Taraması	13

BÖLÜM 3.

VERİLERİN ELDE EDİLMESİ VE KULLANILAN YÖNTEMLER.....	19
3.1. Apriori Algoritması	19
3.2. Carma Algoritması	21
3.3. Frequent Pattern Growth (FP-Growth) Algoritması.....	22
3.4. Yapay Sinir Ağları.....	26

BÖLÜM 4.

BULGULAR VE TARTIŞMA	30
4.1. Apriori Algoritması Uygulaması	31
4.2. Carma Algoritması Uygulaması	38
4.3. FP-Growth Algoritması Uygulaması.....	41
4.4. Algoritmaların Karşılaştırılması.....	43
4.5. Zaman Etüdü ve Maliyet Analizi.....	46
4.6. Yapay Sinir Ağları ile Satış Tahmini	55

BÖLÜM 5.

SONUÇLAR	66
KAYNAKLAR	68
EKLER.....	72
ÖZGEÇMİŞ	86

SİMGELER VE KISALTMALAR LİSTESİ

Carma	: Continuous Association Rule Mining Algorithm
FP-Growth	: Frequent Pattern Growth
FP-Tree	: Frequent Pattern Tree
MAPE	: Mean absolute percent error
MSE	: Mean squared error
RMSE	: Root mean squared error
SPSS	: Statistical Package for the Social Science
YSA	: Yapay sinir ağıları

ŞEKİLLER LİSTESİ

Şekil 1.1. Veri Madenciliği İle İlgili Çalışmaların Trendi (Scopus Veri Tabanı)...	2
Şekil 1.2. Apriori Algoritması İle İlgili Çalışmaların Trendi (Scopus Veri Tabanı).....	3
Şekil 1.3. Fp-Growth Algoritması İle İlgili Çalışmaların Trendi (Scopus Veri Tabanı).....	3
Şekil 2.1.Crisp-Dm Süreçleri	8
Şekil 2.2. Tezin Akış Süreci.....	18
Şekil 3.1. Fp-Tree 1.Dalı.....	25
Şekil 3.2. Fp-Tree 2.Dalı.....	25
Şekil 3.3. İlk 3 Sipariş İçin Fp-Tree	26
Şekil 3.5.Yapay Sinir Ağlarının Genel Akışı.....	27
Şekil 3.6. İleri Beslemeli Yapay Sinir Ağları Yapısı	28
Şekil 3.7. Geri Beslemeli Yapay Sinir Ağları Yapısı.....	28
Şekil 4.1. Lojistik Firmasında Mevcut Operasyonel Süreç.....	30
Şekil 4.2. Apriori Algoritmasının Spss Modeler Programı Kurulumu	32
Şekil 4.3. Apriori Algoritmasının Spss Modeler Programı Kurulum Kuralları.....	32
Şekil 4.4. Apriori Algoritması Ürünlerin Beraber Satış Yüzdesi.....	34
Şekil 4.5 Apriori Algoritmasının Spss Modeler Programında Ki Örnek Sonuçları	34
Şekil 4.6. Apriori Algoritması Güven Değerleri	36
Şekil 4.7 Apriori Algoritması Ürün Gruplarının İlgi Değerleri	38
Şekil 4.8. Carma Algoritmasının Spss Modeler Programı Kurulumu	38
Şekil 4.9. Carma Algoritması Spss Modeler Programı Model Özellikleri	39
Şekil 4.10. Carma Algoritması Sonuçları	39
Şekil 4.11. Carma Algoritması Ürün Gruplarının Güven Değerleri	41
Şekil 4.12 Rapidminer Programı Fp-Growth Algoritması Kurulumu	42
Şekil 4.13. Fp-Tree.....	43

Şekil 4.14. Son Satış Verisi Ürünlerin Tekli Satış Miktarları.....	44
Şekil 4.15.Son Satış Verisi Ürünlerin Çiftli Satış Miktarları.....	45
Şekil 4.16. Lojistik Firmasında Yeni Operasyonel Süreç	47
Şekil 4.17. Ürün Başına Mevcut Maliyet Grafiği	54
Şekil 4.18. Ürünlerin Beraber Raflanması Durumunda Ürün Başına Maliyet	55
Şekil 4.19. Rapidminer’da Kurulan Yapay Sinir Ağları Algoritması.....	57
Şekil 4.20. Yapay Sinir Ağları Gizli Katmana Göre Performans Sonuçları.....	58
Şekil 4.21. Yapay Sinir Ağları İterasyon Sayısına Göre Performans Sonuçları.....	60



TABLolar LİSTESİ

Tablo 2.1. Literatür Taraması.....	17
Tablo 3.1 Örnek Market Sipariş Listesi	23
Tablo 3.2. Ürünlerin Geçme Sayısı.....	24
Tablo 3.3. Önem Derecesine Göre Sıralama.....	24
Tablo 3.4. Sipariş-Ürün Önem Derecesi	24
Tablo 4.1. Apriori Algoritması İçin Örnek Veri	31
Tablo 4.2. Apriori İlk 8 Ürün Grupları	33
Tablo 4.3. Apriori Algoritması Sonuçları	35
Tablo 4.4. Apriori Algoritmasının İlk 8 Ürün Grubu İçin Sonuçlar	36
Tablo 4.5. Ürün Grupların İlgili Değerleri	37
Tablo 4.6. Carma Algoritması Sonuçları	40
Tablo 4.7. Carma Algoritması İçin Örnek Hesaplama.....	40
Tablo 4.8. X40 Ürünü İle X39 Alınması	41
Tablo 4.9. Fp-Growth Sonuçları	42
Tablo 4.10. Fp-Growth Ürün Grupları.....	43
Tablo 4.11. En Çok Satılan İkili Ürün Grupları Ve Satış Miktarları	44
Tablo 4.12. Son Satış Verisi-Apriori-Fp-Growth Algoritmaları Tekli Ürün Karşılaştırması.....	45
Tablo 4.13. Son Satış Verisi-Apriori-Fp-Growth Algoritmaları Çiftli Ürün Karşılaştırması.....	46
Tablo 4.14. Firmanın Süreç Zaman Etütleri.....	48
Tablo 4.15. Zaman Etütlerinde Gözlem Sayısının Yeterlilik Kontrolü	49
Tablo 4.16. Firmanın Süreç Yeni Zaman Etütleri-23 Gözlem.....	51
Tablo 4.17. Zaman Etütünde Gözlem Sayısının Yeterlilik Kontrolü.....	52
Tablo 4.18. Maliyet Analizi	53
Tablo 4.19. Operasyonel Süreçlerin Maliyeti (Tl)	54

Tablo 4.20. Yapay Sinir Ağları Parametreleri	56
Tablo 4.21. Gizli Katman Sayısı 10 Ve 30 Olduğunda Ürün Gruplarının Hata Oranları.....	57
Tablo 4.22. Yapay Sinir Ağları Yeni Parametreler.....	59
Tablo 4.23. İterasyon Sayısı 100 Ve 300 Olduğunda Ürün Gruplarının Hata Oranları	59
Tablo 4.24. Yapay Sinir Ağları Parametreleri	61
Tablo 4.25. Ürün Gruplarının İstatistik Hata Oranları.....	61
Tablo 4.26. X40-X39 Ürünlerinin Aylık Sipariş Miktarları	62
Tablo 4.27. X40-X39 Ürünlerinin Normalize Değerleri.....	62
Tablo 4.28. X40-X39 Ürünleri İçin Aylık Tahmin Sipariş Sayısı	63
Tablo 4.29. Belirlenen Ürün Gruplarının Aylık Tahmini Sipariş Miktarları.....	63
Tablo 4.30. Belirlenen Ürün Gruplarının Kök Ortalama Kare Hata Oranları	64

ÖZET

Anahtar kelimeler: E-ticaret, birliktelik kuralları, Apriori, Carma, Frequent Pattern Growth

Bilişim teknolojilerinin gelişmesiyle verilerin toplandığı kaynaklar çeşitlilik kazanmış ve elde edilen verilerin çokluğu nedeniyle anlamlandırılması önem kazanmıştır. Bu çalışmada e-ticaret sektöründe faaliyet gösteren bir firmada en çok satılan ürünlerin analizinin yapılması, beraber satılan ürünlerin tespit edilerek depo içi operasyonel iyileştirilmesi, maliyetlerin azaltılması, çıkış süreçlerinin hızlandırılması amaçlanmıştır. Apriori algoritması birliktelik kurallarından en yaygın olanı olduğu, Frequent Pattern Growth algoritması yüksek performans gösterdiği ve Carma algoritması da daha fazla iyileştirme olanağı sunduğu için tercih edilmiştir. Söz konusu algoritmalar ile firmanın 6 aylık verileri kullanılarak, 10000 adet sipariş içindeki en çok satılan ürünler tespit edilmiştir. Analiz sonuçları 9.ayın 1200 siparişinin satış verileri ile karşılaştırılmış. En iyi sonucu veren Apriori algoritmasına göre belirlenen ilk ürün grubu olan X40-X39 kodlu ürünler tüm siparişlerin %5'ini kapsamaktadır. Siparişlerin %5 ile %1 aralığını kapsayan ilk 7 ürün grubu için, birlikte depo raflarına yerleşmesinin maliyete etkisi zaman etüdü yapılarak analiz edilmiştir. Analiz sonuçları, önerilen sistemin süreç iyileştirmeye olumlu etkisini doğrulamaktadır. Bulunan ürün gruplarının gelecekteki siparişlerde yer alıp almaması durumu yapay sinir ağları ile analiz edilmiştir. 9. ayı takiben 6 aylık süreç boyunca ürün grupların siparişlerde bulunacağı kanıtlanmıştır.

ONLINE SHOPPING CONSUMERS' ANALYSIS WITH DATA MINING TECHNIQUES

SUMMARY

Keywords: E-commerce, Association rules, Apriori , Carma, Frequent Pattern Growth

With the development of information technologies, the sources where data collected have diversified and it has gained importance because of the multiplicity of data obtained. This study aims to analyze the top-selling products in a company operating in e-commerce sector, besides identifying the products sold together, improving operational performance in the warehouse, reducing the costs and expediting the release processes. The reasons of preferring algorithms used in the study were; Apriori algorithm was the most common of the association rules, the Frequent Pattern Growth algorithm showed high performance and the Carma algorithm provided further improvement. These algorithms were used to identify the best-selling products in 10000 orders of using the company's 6-month data. The results of the analysis were compared with the sales data of the 9th month, consisting of 1200 order. The X40-X39 coded products, which are the first product group determined according to the Apriori algorithm which gives the best result, cover 5% of all orders. For the first 7 product groups covering 5% to 1% of the orders, the cost effect in bundle of products was analyzed by time study. The analysis results confirm the positive effect of the proposed system on process improvement. The determined product groups included in future orders was analyzed by artificial neural networks. During 6 month from 9. months, it has been proved that the product groups would be included in the order.

BÖLÜM 1. GİRİŞ

Günümüzde internet kullanımı yaygınlaşmaktadır. İnternetin yaygınlaşması firmalar için bir fırsat oluşturmıştır. Birçok firma e-ticaret üzerinden kazanç sağlamaya başlamıştır. Bilgisayar ve internetin kullanımının artmasıyla firmalar satış verilerini, müşteri bilgilerini elektronik ortamlarda depolamaya başlamıştır. Bu elektronik verilerin doğru analiz edilmesi firmalara hem kar sağlamaktadır hem de kalite, hızlı bir hizmet vermelerini sağlamaktadır. Elektronik verileri kullanan firmaların rekabet ortamında üstünlük sağladığı gözlemlenmiştir. Rekabet ortamında üstünlük sağlamak isteyen firmaların elektronik verileri analiz etmesi önem kazanmıştır.


1990'dan itibaren ülkemizde de birçok gazete internet ortamında yayınlanmaya başlamıştır, bankalar hizmetlerini internet üzerinden sunmaktadır. Market alışverişleri, ev eşyaları artık sanal ortamlardan satın alınmaktadır. İnternet böylece günlük hayatımızın vazgeçilmezi haline gelmiştir.

Teknolojinin ilerlemesi ve internetin bu kadar önem kazandığı bu günlerde sanal ortamlar her gün artmaktadır ve rekabet ortamı oluşturmaktadır. Yeni bir alışveriş ortamı olan internet son kullanıcıya çeşitli alternatifler sunmaktadır. Geleneksel alışveriş ortamlarından farklı bir hizmet vermektedir. Son kullanıcıya sunulan alternatifler arttıkça rekabet artmaktadır. Bu durumda hizmet veren firmalar, ellerinde bulunan bu elektronik verileri doğru yorumlama yöntemleri aramaktadır.


Teknolojinin hızla değişmesi ve pazardaki rekabet ortamı firmaların süreçlerini değiştirmesine sebep olmaktadır. Firmalar hem maliyetlerini azaltmaya hem de daha kaliteli hizmet vermek için çalışmalar yapmaktadır. Gelecek günler için firmalar operasyon süreçlerini doğru planlamak için farklı yollara başvurmaktadır. Bunlardan biri de veri madenciliği yöntemleridir. Perakende ve e-ticaret hizmeti veren firmalar

veri madenciliği yöntemlerini kullanarak satış tahminlemesi yapmaktadır. Yapılan bu tahminler maliyet çalışmalarında kullanılmaktadır. Verimli bir sonuç çıkması sonucunda operasyonel iyileşmeler yapılmaktadır.


Veri madenciliğinin kullanımı yıllara göre artış göstermektedir. Bununla beraber veri madenciliğinin birliktelik kuralları algoritmaları olan Apriori ve FP-Growth algoritmalarının kullanıldığı çalışmaların sayısı da artmaktadır [1]. Scopus veri tabanından alınan verilere göre veri madenciliği ile ilgili 2000’li yılların başında yaklaşık 1500 çalışma bulunmakta iken günümüzde yaklaşık 15 bine yakın çalışmada bu yaklaşım ve metotlarından bahsedilmektedir. Şekil 1.1.’de veri madenciliği, Şekil 1.2.’de Apriori algoritması, Şekil 1.3.’te ise FP-Growth algoritması ile ilgili yapılan çalışmaların trendini göstermektedir.



Şekil 1.1. Veri madenciliği ile ilgili çalışmaların trendi (Scopus veri tabanı) [1].



Şekil 1.2. Apriori algoritması ile ilgili çalışmaların trendi (Scopus veri tabanı) [1].



Şekil 1.3. FP-Growth algoritması ile ilgili çalışmaların trendi (Scopus veri tabanı) [1].

Lojistikte termin ve işin başlangıç tarihleri önemli kavramlardır. Müşterinin teslim almak istediği tarih termin tarihidir, termin tarihine göre de işin başlangıç tarihi hesaplanır. Veri madenciliği yöntemleri ile müşterilerin siparişleri incelenerek iki tarih arasındaki ilişki incelenebilir, daha hızlı ve kaliteli hizmet verebilmek için operasyonel süreçlerde iyileştirme yapılabilir. Satış verileri incelenerek ileriye dönük planlamalar yapılabilir. Operasyonel süreçler dışında en çok satılan ürünler veri madenciliği yöntemleri ile tespit edilerek tesis yerleştirme için de çalışmalar yürütülebilir.

Günümüzdeki firmalar rekabet ortamında farkındalık yaratmaya çalışmaktadır. Bu farkındalıklarla birlikte kendi süreçlerini iyileştirmek ve fazla maliyetten de kurtulmak istenmektedir. Özellikle de sanal alışveriş yapılan firmalar geleneksellikten uzaklaşmalıdır.

Bu çalışma beş bölümden oluşmaktadır. İlk bölümde çalışmanın konusu, amacı, öneminden bahsedilmektedir. İkinci bölümde veri madenciliğinin tanımı, teknikleri, literatürde konuyla ilgili çalışma örneklerini içermektedir. Üçüncü bölümde ise çalışmada kullanılan veri madenciliği teknikleri ve kullanılan materyaller üzerinde durulmuştur. Dördüncü bölümde ise çalışmanın analiz uygulaması olan veri madenciliği yöntemlerini kullanarak geçmiş satış siparişlerinde ki beraber en çok satılan ürünler bulunmuştur. Bulunan ürün grupları son satış verileri ile karşılaştırılarak doğru olma durumları karşılaştırılmıştır. Son olarak da zaman etüdü yöntemi kullanılarak maliyet tahminlemesi yapılmıştır. Çalışmada SPSS Modeller, RapidMiner programları kullanılmıştır. Beşinci ve son bölümde çalışmanın sonuçları yer almıştır.

1.1. Çalışmanın Kapsamı

Bu çalışmada, piyasanın önde gelen markalarının internet siparişlerini son kullanıcıya ulaştırmak amacıyla ilgili markaların ürünlerini depolayan bir lojistik firmasının depo süreçlerinin iyileştirilmesi için, küçük parçalar olarak nitelendirilen askılık, mum, bebek eşyalarını kapsayan ev eşyalarının veri analizi yapılmıştır. Analiz edilen veriler 2017 yılının ilk 6 aylık periyodunun 10000 tane siparişini kapsamaktadır. Veriler internet siparişlerinden toplanılmıştır. 10000 sipariş için yapılan analizin sonuçları 9.ayın satış verileri ile karşılaştırılarak en iyi sonucu veren algoritma Apriori algoritması olmuştur. Apriori algoritmasının sonucuna göre belirlenen ilk ürün grubu siparişlerin %5'ini kapsamaktadır. Siparişlerin %1 ile %5 aralığını kapsayan ilk 7 ürün grupları bir arada depo raflarına yerleştirildiğinde süre ve maliyete etkisi için zaman etüdü yöntemi kullanılmıştır. Belirlenen ürün gruplarının satış tahminlerinin yapılması için de yapay sinir ağlarına başvurulmuştur.

1.2. Çalışmanın Amacı

Bu çalışmada, piyasanın önde gelen markalarının internet siparişlerini son kullanıcıya ulaştırmak için ilgili markaların ürünlerini depolayan bir lojistik firmasının depo süreçlerinin iyileştirmesi amaçlanmıştır. Ürünlerin stok yerlerinde bulunamaması, siparişlerin zamanında ulaştırılamaması problemine sebep olmaktadır. Bunun için ürünlerin birlikte paketlenerek raflarda tutulmasının, bu problemin çözümündeki etkisi araştırılmaktadır. Çalışmada en çok satılan ürünlerin analizinin yapılarak, beraber satılan ürünleri tespit etmek, depo içi operasyonel iyileştirme yapmak, maliyet azaltmak ve çıkış süreçlerini hızlandırmak amaçlanmıştır. Firmanın 6 aylık verileri kullanılarak, 10000 adet sipariş içindeki en çok satılan ikili ürünler tespit edilmiştir. Analiz sonuçları 9.ayın 1200 siparişinin satış verileri ile karşılaştırılmış ve en iyi sonucu Apriori algoritmasının hesapladığı tespit edilmiştir. Aynı yıla ait 9. ay siparişleri ile hangi algoritma sonucunun daha gerçeği yansıttığını görmek için karşılaştırılmıştır. Belirlenen ürün gruplarının satış tahmini için yapay sinir ağlarına başvurulmuştur. Yılın ikinci yarısında pilot çalışma sonlanmalıdır ve sonuca göre gelecek yıl için standart operasyon süreçleri yenilenecektir.

1.3. Çalışmanın Önemi

E-ticaret firmalarının günlük olarak siparişlerinin depodan çıkması beklenen bir hedeftir. Fakat beklenen hedefin tutturulamaması sebeplerinin başında stokların kaybolması ve sipariş hacminin yüksek olması gelebilir. Firmalar verimliliklerini, karlılıklarını arttırabilmesi için veri madenciliği yöntemlerine başvurulabilir. Veri madenciliği mevcut durumun analizi ya da gelecek tahmini yapılması için kullanılabilir. Literatürdeki çalışmalar genellikle hizmet sektöründe ya da teorik olarak yapılan çalışmalar olup bu çalışma gerçek bir proje olarak bir firmanın operasyonel iyileştirme için birliktelik kurallarının kullanılabileceği gösterilmiş ve maliyet/zaman hesaplamaları ile kanıtlanmıştır. Literatürdeki diğer çalışmalar ile ortak olarak müşterilerin satın aldığı ürünlerin baz alınarak sorunların çözülmesidir. Örneğin market analizinde beraber satılan ürünlerin aynı raflara ya da yakın lokasyonlara konulması müşterilerin faydasına olabilecek iken bu çalışmada son kullanıcıyı

etkileyen faktör konusunda kesinlik bulunmamaktadır. Sipariş toplama ve paketleme aşamalarında zamanda ve maliyette kazançlar sağlanması hedeflenmektedir.

1.4. Çalışmanın Kısıtları

Çalışmada beraber satılan ürünlerin en az 100 siparişte satılması kuralı firmada uzman kişileri tarafından belirlenmiştir. Ayrıca ergonomik sorunların oluşmaması ve raflarda sorun yaşanmaması için ürün grupları ikili olarak belirlenmiştir. 2017 yılının ilk 6 ayının sipariş bilgisine göre belirlenen ürün grupları ile 9. ayın siparişine göre en çok beraber satılan ürün grupları, hangi algoritma sonucunun daha gerçeği yansıttığını görmek için karşılaştırılmıştır. 7.ve 8. aylar yıllık izin, resmi tatiller sebebi ile karşılaştırma yapmak için verilerin kullanılması firma yöneticileri tarafından uygun görülmemiştir.

BÖLÜM 2. LİTERATÜR ARAŞTIRMASI

2.1. Veri Madenciliği Tanımı

Büyük verilerden tahmin yapılmasını sağlayan istatistiğin teknolojiyle birleşmesi ile oluşan araca veri madenciliği denir. Veri madenciliğinin amacı, verilerin birbirleri ile olan ilişkilerini ortaya çıkarmaktır [2,3].

Veri madenciliği verilerdeki unsurların arasındaki ilişkiyi incelemeye yarayan bir analiz tekniğidir [4].


Veri madenciliği, eldeki verilerden üstü kapalı, çok net olmayan, önceden bilinmeyen ancak potansiyel olarak kullanışlı bilginin çıkarılmasıdır [5].

Veri madenciliği 3 adımdan oluşmaktadır;

1. Uygun veri madenciliği metodunu seçmek: Bu adımda, kullanılacak veri madenciliği yöntemi seçilir. Birliktelik, kümeleme ve sınıflandırma yöntemlerinden biri seçilebilir. Yöntemin seçilmesi veri analizinin sebebine bağlıdır. Tahminleme ve tanımlama olmak üzere 2 tane amacı bulunmaktadır. Tahminleme denetimli veri madenciliği, tanımlama ise denetimsiz veri madenciliği ve mevcut veriyi anlama olarak tanımlanmaktadır.
2. Veri madenciliğinde algoritma türünü seçmek: Veri madenciliğinin amacına uygun olan metod seçildikten sonra bu yöntemde yer alan algoritmalarından biri ya da birkaçı seçilmektedir.
3. Seçilen veri madenciliği algoritmasını uygulamak: Algoritma türü seçildikten sonra, kararlaştırılmış değerlere ulaşana kadar değişkenler üzerinde algoritma uygulanmalıdır. Veri madenciliği algoritmalarına K-Mean, Apriori

algoritmaları örnek verilebilir. Algoritma uygulaması sonunda çıkan sonuçlar yorumlanır. Elde edilen modelin anlaşılabilirliği ve kullanılabilirliği araştırılır [4].

SPSS, Daimler Chrysler ve NCR. CRISP şirketleri tarafından 1996 yılında standart süreç olarak CRISP-DM geliştirilmiştir. CRISP-DM altı adımdan oluşmaktadır [6].



Şekil 2.1.CRISP-DM Süreçleri[6]

Veri madenciliği çalışmalarında ilk adım projeyi anlamaktır. Projenin amacı belirlenmelidir ve amacına yönelik veri madenciliği yöntemlerinden uygun olanı seçilmelidir. Projede kullanılacak olan veriler toplanır ve veri anlaşılmaya çalışılır. Uygun veri madenciliği seçilmeden önce eldeki verilerden örneklem veri hazırlanır. Belirlenen veri madenciliği tekniği örneklem veride uygulanır. Uygulama sonunda anlamlı sonuçlara ulaşılamazsa uygulanan veri madenciliği tekniği değiştirilebilir ve projenin amacı tekrar gözden geçirilebilir [7]. Ortaya çıkan sonuçlar, problemin veya uzman kişilerin bakış açılarından incelenir ve uygun olup olmadığı analiz edilir. Model uygun ise bir sonraki adıma geçilir. Sonuçlar yeterli değil ise çalışma durdurulabilir ve ya analizde kullanılan veri dizisi tekrardan kontrol edilebilir. Anlamlı sonuçlar elde edilirse çalışma sonucu raporlanır [8].

Veri madenciliğinin geleneksel analiz için kullanılan yöntemlere göre yeni olan özellikleri [9];

- Çok fazla veri otomatik olarak biriktirilmekte ve bu verilerden kullanılabilir bilgi elde edilmektedir.
- Bilgisayar bilimlerinden gelen sinir ağları, karar ağaçları, mantık kuralları gibi çok çeşitli ve yeni yöntemler kullanılmaktadır.
- Hedef müşteri seçilerek ticari kazanç artırılmaktadır. Profillere göre iyileştirme yapılarak maliyeti azaltmaktır.
- Kullanıcı dostu, profesyonel çözümleyiciler gibi karar verici olan, pahalı olmayan yeni yazılımlar mevcuttur.

2.2. Veri Madenciliğinin Kullanıldığı Alanlar

Günümüzde hizmet ve sanayi sektörlerinde veri madenciliğinin kullanımı önem kazanmaktadır. Verilerin analizi için birçok alanda veri madenciliği kullanılmaktadır. Firmalar doğru bilgiye ulaşmak adına çeşitli veri madenciliği uygulamaları yapmaktadır. Örneğin; hizmet sektöründe müşterilerin davranışlarının analizi için veri madenciliği kullanılabilir. Pazar sepeti analizi sonuçlarına göre satış stratejisi belirlenebilir [10]. Sanayi sektöründe kalite kontrol çalışmaları, lojistik ve üretim süreçleri optimizasyonu için veri madenciliği yöntemleri kullanılabilir. Sanayi ve hizmet sektörlerinde ileriye yönelik planlama yapılabilmesi için de veri madenciliği yöntemleri kullanılabilir. İleriye dönük tahminlemenin yapılması firmaların rekabet ortamında üstünlük sağlamasında yardımcı olabilir.

2.3. Veri Madenciliği Teknikleri

Veri madenciliğinde çalışmanın amacına uygun olarak tahminleyici ve tanımlayıcı olmak üzere modeller iki başlığına ayrılmaktadır. Tahminleyici modeller ileriye için tahminler oluşturmayı, tanımlayıcı modeller ise mevcut olan durumu değerlendirmeyi amaçlamaktadır.

Veri madenciliği modelleri çalışmanın amacına göre seçilir. Ana başlık olarak modeller 3'e ayrılmaktadır.

Bunlar;

- 1.Sınıflama ve Regresyon
- 2.Kümeleme
- 3.Birliktelik Kuralları [4].

Sınıflama ve regresyon modelleri tahminleyici yani ileriye dönük tahminleme, kümeleme ve birliktelik kuralları ise mevcut durum analizi için tanımlayıcı modelleme türleridir.

Modelin kuruluş aşaması öğrenimin denetimli ve ya denetimsiz olmasına göre değişmektedir. Var olandan öğrenme olarak da bilinen denetimli öğrenme de, kullanıcının tanımladığı hedef sınıflar önceden belirlenen bir kritere göre bölünerek her sınıf için çeşitli örnekler verilmektedir. Amaç örneklerden yola çıkarak her bir sınıfın özelliklerinin bulunması ve bulunan özelliklerin kural cümleleri ile ifade edilmesidir [4]. Denetimsiz öğrenmede ise tanımlanmış herhangi bir hedef sınıf yoktur [11].

Denetimli öğrenmede verilerin bir bölümü modelin öğrenimi için diğer bir kısmı ise modelin geçerliliğini test etmek için kullanılır. Verinin ayrılması için basit geçerlilik yöntemi kullanılabilir. Verilerin %5 ile %33 arasındaki bir yüzdesi test verisi olarak ayrılmaktadır. Geri kalan kısmı ise öğrenme verilerini oluşturmaktadır. Bir diğer kullanılan yöntem ise çapraz geçerlilik yöntemidir. Veri rastgele iki eşit parçaya bölünür. Modelin tahmini hata oranı elde edilen sonuçların hata oranlarının ortalamasıdır [4].

2.3.1. Sınıflama ve regresyon teknikleri

Sınıflandırma teknikleri veri madenciliğinde en yaygın olan tekniklerden biridir. Mevcut verilerden hareket ederek geleceğin tahmin edilmesinde kullanılmaktadır.

Sınıflama ve regresyon modelleri arasındaki ana fark, tahmin edilen değişkenin süreklilik gösteren bir değer olmasıdır.

Sınıflandırma yöntemi için örnek, eğitim ya da sağlık sektöründen verilebilir. Eğitim alanında yeni gelen öğrencilerin sınıflara yerleştirilmesi ve ya sağlık sektöründen bir kişinin özel bir rahatsızlığının olup olmaması durumu bir sınıflandırma örneğidir [11].

Sınıflandırma teknikleri 5 başlığa ayrılmaktadır.

- Karar ağaçları ile sınıflandırma: Karar ağaçları görselliğe dayandığı için kolay ve anlaşılırdır. Sayısal ve kategorik veriler üzerinde işlem yapılabilir. Az sayıda işlem yapılarak sınıflandırma yapılabilir.
- Sınıflandırma ve regresyon araçları: Sınıflandırma teknikleri arasında Cart ve Naive-Bayes metotları yaygın olanlardır. Cart algoritmasının önemli özelliklerinden biri regresyon ağacı oluşturmaktır. Regresyon ağacında, ağacın yaprakları bir sınıfı tahminlemez, gerçek sayıları tahminler [6]. Cart algoritmasında bulunan düğümler bütün bölünmeler ile karşılaştırılmaktadır ve homojenliği en yüksek olan özellik seçilmektedir. Naive Bayes hedef değişken ile bağımsız değişken arasındaki ilişkiyi analiz etmeye yarayan tanımlayıcı ve tahminleyici bir sınıflandırma algoritmasıdır [4,12]. Yani bu algoritma hem mevcut durumu incelemekte hem de mevcut durum sonucuna göre gelecek için tahminleme yapabilmektedir. Naive Bayes algoritmasındaki veriler bulanık hale getirilmelidir, net bir değer olmamalıdır.
- Bellek tabanlı sınıflandırma: Bellek tabanlı algoritmalarından en yaygın olanı en yakın komşu algoritmasıdır. Veri setinde birbirine yakın olup aynı tipte olan kayıtlar birbirlerinin komşuları olarak değerlendirilmektedir. Bu algoritmanın mantığı bir verinin durumunu analiz ya da tahmin edilmek istenirse o veriye en yakın olan k verinin durumu incelemektir. K - en yakın komşu algoritmasının ismindeki k harfi de incelenecek olan komşu sayısıdır; 10-en yakın komşu ise 10 komşuya bakılmalıdır [13].
- Yapay sinir ağları: Yapay sinir ağları tahmin, sınıflandırma, veri ilişkilendirme, yorumlama işlemlerinde kullanılmaktadır. Mevcut veriler yorumlanarak gelecek

için planlama yapılabilir. Bir konu hakkında toplanan örneklerden elde edilen ve eğitim sonucu oluşturulan bilgileri kullanarak yeni olayların yorumlanmasını sağlar [11]. Mevcut verilerden hareket ederek çalışmada yapay sinir ağıları kullanılarak satış tahminlemesi yapılmıştır.

2.3.2. Kümeleme teknikleri

Karmaşık yapıdaki ve büyük sorunlu veriler için sorunları alt parçalara ayırmak daha faydalı olmaktadır. Her alt parçanın sorunlarının çözümlerinin birleştirilmesi ile bütünü çözmek gerekmektedir. Bu noktada veri madenciliği yöntemlerinden en faydalı olan kümeleme yöntemleridir. Bazı durumlarda verileri bölmek zor olabilir bu sebeple de otomatik küme bulma yöntemleri geliştirilmiştir.

Sınıflama ve kümelemeyi ayıran özellik, kümelemenin sınıflandırmadaki önceden belirlenen sınıflara bölme yapmamasıdır. Sınıflandırma yöntemlerinde önceden belirlenmiş gruplar eğitilmektedir ve eğitim sonucunda oluşan modele belirlenmiş bir gruba atılmaktadır.

Kümelemede ise örnek gruplar bulunmamaktadır. Bu yöntemde verilerin birbirleri ile olan benzerliklerine göre gruplar oluşmaktadır. Oluşan grupların yorumlamasını kullanıcı yapmaktadır. Veri setindeki kayıtların özellikleri birbirlerinden çok farklı ise kümeleme yöntemi kullanılabilir.

Yapılacak olan çalışmanın amacına, veri setine göre kümeleme algoritması seçilmelidir. Başlıca kümeleme algoritmaları aşağıdaki gibidir [14];

- Yoğunluk Tabanlı Yöntemler
- Model Tabanlı Yöntemler
- Bölme Yöntemleri
- Izgara Tabanlı Yöntemler
- Hiyerarşik Yöntemler

2.3.3. Birliktelik kuralları

Birliktelik kurallarında önemli olan nokta belirli bir zamanda veriler arasındaki birlikteliklerin incelenmesidir [15].

Birliktelik kurallarında veri grupları çok olacağı için ve anlamlı yorumlamalar yapılabilmesi için bir eşik değeri bulunmalıdır. Birliktelik kuralları sonuçlarından hangisinin daha önemli olduğunu bulmak için güven ve destek değerleri bulunmaktadır [16].

Birliktelik kurallarının amaçlarından biri de kullanıcı tarafından belirlenen minimum destek ve güven değerleri doğrultusunda kuralların bulunmasıdır. Çalışma amacına göre bu değerler değişebilmektedir.

Destek ve güven değerleri, X ürününü alan bir kişinin Y ürününü de alması durumlarını analiz edilmesidir [16].

Birliktelik kuralları analizinde kullanılması için çeşitli algoritmalar geliştirilmiştir. 1993'te AIS algoritması [17], sonra SETM algoritması [18], ve 1994'de ortaya çıkan Apriori ve AprioriTid [19], algoritmaları geliştirilmiştir. Bu algoritmaların arasında kullanılan en yaygın algoritma Apriori algoritmasıdır. Çalışmada da mevcut durum analizi yapılacağı için birliktelik kurallarının Apriori, Carma ve FP-Growth algoritmaları kullanılmıştır.

2.4. Literatür Taraması

Lojistik sektörünün temel hedefi müşteri hizmetlerinde kalitenin sağlanması ve kaynakları en iyi kullanılması ile rekabet avantajının yaratılmasıdır. Doğru ürünün, doğru yerde, tam zamanında, doğru tüketiciye ve kaliteli bir şekilde ulaştırılması hedeflenerek operasyon performansını en iyi yapmak lojistik sektörünün amacıdır. Rekabetin fazla olduğu lojistik sektöründe karar vermede etkili olan veri miktarı da oldukça fazladır. Toplanan bu verilerden anlamlı bilgilerin çıkarılması firmaya

rekabet avantajı sağlayabilmektedir. Operasyon süreçlerinin iyileştirilmesi veya gelecek planlamasının yapılması için veri analizi yapılmalıdır. Bir firmanın günlük hareketlerinin verilerinin analizi için veri madenciliği yöntemleri kullanılabilir [20].

Birliktelik kuralları kapsamında çoğunlukla Apriori algoritmasının kullanıldığı çalışmalar literatürde yer almaktadır. Genel olarak hizmet sektöründe (çoğunlukla pazar analizi) bu algorithmadan yararlanılmıştır. Depo süreci iyileştirme için de birliktelik algoritmalarından faydalanılabileceği bu çalışma ile gösterildi. Aynı zamanda Apriori, FP-Growth ve Carma algoritmalarının karşılaştırması yapıldı. Literatürdeki diğer çalışmalar ile ortak olarak müşterilerin satın aldığı ürünlerin baz alınarak sorunların çözümlenmesidir. Market analizinde beraber satılan ürünlerin aynı raflara ya da yakın lokasyonlara konulması müşterilerin faydasına olabilecek iken bu çalışmada son kullanıcıyı etkileyen faktör konusunda kesinlik bulunmamaktadır, lojistik firmasının kendi süreçlerini iyileştirmek ve maliyetini azaltmak için kullanılmıştır.

2012 yılında Erpolat tarafından Türkiye’de otomotiv sektöründe faaliyet gösteren bir yetkili servisin müşterilerine ait satış verileri veri madenciliği yöntemlerinden birliktelik kuralının Apriori ve FP-Growth Algoritmaları kullanılarak analiz edilmiştir. Müşterilerin hangi ürünleri beraber satın aldığı belirlenmiştir ve karı arttırmak için kampanya ve promosyonlar uygulanmasına ağırlık verilmiştir. Apriori algoritması uygulandığında iki ürün grubu elde edilmiş iken aynı veriler FP-Growth algoritması uygulandığında tek ürün grubu elde edilmiştir. FP-Growth algoritması daha net bir şekilde değerlendirmeyi sağlamıştır [21].

2016 yılında Mehmet Aksaraylı ve Dilara Bayyurt Dokuz Eylül Üniversitesi Ekonometri Bölümü öğrencilerinin seçmeli dersleri seçimlerini birliktelik kurallarından Apriori Algoritması ile araştırmışlardır. Araştırmada gerekli veriler anket ile sağlanmıştır. Araştırmanın sonucunda öğrencilerin ilgi alanlarına göre seçmeli dersleri seçtiğine ulaşılmıştır. Ders yükü fazla olan ve bölümü benimsemeyen öğrenciler için de dersin kolay olması ve geçme oranının yüksek olması önemlidir.

Elde edilen sonuçlar derslerin içeriklerinin hazırlanmasında ve işlenişinde yol gösterici niteliğindedir [22].

2005 yılında Borgelt FP-Growth Algoritması üzerinde çalışma yapmıştır. FP-Growth Algoritmasını Apriori, Eclat ve Relim algoritmalarıyla karşılaştırılmıştır. C programı üzerinde yapılan bu çalışmada FP-Growth algoritmasının diğer algoritmalara göre daha iyi bir performans gösterdiği sonucuna varılmıştır [23].

Doğan ve arkadaşları da 2014 yılında sigorta sektörü için birliktelik kuralları kullanarak çalışma yapmıştır. Müşteri ilişkileri yönetimi için yapılan çalışmada birlikte satın alınan sigorta türleri belirlenmiştir. Sigorta türleri Apriori algoritması ile analiz edilmiştir ve sigorta acentesinin pazarlama faaliyetlerine katkıda bulunacak veriler elde edilmiştir [24].

2015 yılında Doğrul ve arkadaşları trafik kazalarının verilerini analiz etmek için birliktelik kurallarından Apriori Algoritmasından yararlanmıştır. Çalışmada kazaların sık yaşandığı yerleri ve zamanları bulmuştur. Bulduğu sonuçlara göre önlem alınması gereken yerler bulmuştur ve kaza sayılarının azalabileceğini göstermiştir [25].

Gülce 2010 yılında veri madenciliği kavramlarının market sepet analizinde kullanılması konusunda çalışma yapmıştır. Veri madenciliği yöntemlerinden olan birliktelik kurallarının apriori algoritmasını ele almışlardır. Apriori algoritması farklı satış verilerinin üzerinde uygulanmıştır. Örneklem olarak kullanılan anket verilerinden apriori algoritması kullanılarak birliktelik kurallarını bulan bir uygulama yapmışlardır [26].

2009 yılında Huang ve arkadaşları Carma algoritmasının verimliliğini değerlendirmek için çalışma yapmışlardır. Yapılan çalışmada Carma algoritması ile Apriori algoritması karşılaştırılmıştır. Destek eşik değerinin aynı olması durumunda Carma algoritması ile Apriori algoritmasının aynı sonuçları verdiği gözlenmiştir. Carma algoritmasının ürettiği grupların Apriori algoritmasının ürettiği veri gruplarının alt kümesi olduğu sonucuna varılmıştır [27].

2009 yılında Kılınç tarafından yapılan çalışmada birliktelik kurallarından yararlanılmıştır. Bir elektronik firmasında üretim ve mal giriş kalite verilerinin analizi için Apriori Algoritması kullanılmıştır. Ortaya çıkarılan kurallar test verileri ile doğruluğu sağlanmıştır ve sonuçlar analiz edilmiştir [28].

2009 tarihinde Lin “Scm'deki Rekabetçi Tedarikçilerin Belirlenmesi İçin FP-Growth Algoritmasının Potansiyel Kullanımı” adlı çalışmasında tedarik zinciri yönetimindeki tedarikçi seçimi için FP-Growth algoritmasını kullanmıştır. Bu çalışmadaki amaç esas ve yedek tedarikçiler seçimindeki karmaşıklığı veri madenciliği yöntemleri ile indirgemektir. FP-Growth algoritmasının tedarikçi elimine edilmesinde ve karmaşıklığı azaltmasında etkili olduğu belirlenmiştir [29].

2018 yılında Mayilvaganan ve arkadaşları yaptıkları çalışmada Apriori, FP-Growth ve Bulanık FP-Growth algoritmalarını karşılaştırmıştır. Bu araştırmada amaç bir veri tabanının kategorik özniteliklere göre yorumlanmasıdır. Çalışma sonucunda Bulanık FP-Growth algoritmasının zaman açısından Apriori ve FP-Growth algoritmalarından daha verimli olduğu ortaya çıkmıştır [30].

2015 yılında Mostafaei ve arkadaşları “Benzin Rasyonunu Analiz Etmede Yeni Yaklaşımlar” adlı çalışmasında 2005 ile 2011 yılları arasındaki karayolu taşımacılığı sektöründe meydana gelen değişiklikleri araştırmışlardır. Benzin tüketiminin durumu Apriori ve Carma algoritmaları incelenmiştir. Benzin tüketiminin doğalgaz, toplu taşıma ve metro kullanımı ile ilişkili olduğu tanımlanmıştır. Sonuçlara göre ulaşım problemlerinin kısa ya da uzun vadede çözümler oluşturması yorumlanmıştır. Ayrıca Apriori ve Carma algoritmalarından elde edilen sonuçları karşılaştırarak, Carma algoritmasının aynı zamanda Apriori algoritmasından elde edilen sonuçlarının aynı olduğu gözlemlenmiştir [31].

2013 yılında Pinheiro ve arkadaşları karaciğer kanserini erken teşhis etmek amacıyla hastaların verileri analiz edilmiştir. Analizde FP-Growth algoritması uygulanmıştır ve karaciğer kanseri teşhisi konulacak değer kalıpları bulunması amaçlanmıştır [32].

Perakende sektöründe Sağın ve arkadaşları 2018 yılında bir firmanın beş buçuk yıllık verilerini iki veri set halinde kullanarak Apriori ve FP-Growth algoritmalarını karşılaştırılmıştır. Kurallarının belirlenmesi için hem Apriori hem de FP-Growth algoritmaları ayrı ayrı çalıştırılmıştır. İlk veri setinde FP-Growth algoritması güven değerleri çok yüksek olduğu için Apriori algoritması daha doğru sonucu vermiş, ikinci veri setinde ise her iki algoritmada aynı sonucu vermiştir. Mevsimsel satışlar için kullanılması amaçlanmıştır. Birinci veri seti, ikinci veri setinde de aynı sonuçları gösterdiği için gerçeğe daha yakın olduğu sonucuna varılmıştır [33].


Barış Yıldız 2010 yılında yaptığı çalışmada sık kümelerin bulunması için Matrix Apriori algoritması üzerinde değişiklik yapmıştır. Yapılan çalışma sonucunda sık küme gizleme çerçevesi de geliştirmiştir [34].

Tablo 2.1. Literatür taraması

Yazar Adı	Çalışmanın Yapıldığı Sektör	Metot			
		Apriori	FP-Growth	Carma	Diğer
Erpolat [21]	Otomotiv	•	•		
Aksaraylı ve ark.[22]	Eğitim	•			
Borgelt Christian [23]	Hizmet	•	•		• ¹
Doğan ve ark. [24]	Sigorta	•			
Doğrul ve ark. [25]	Hizmet	•			
Gülce [26]	Hizmet	•			
Huang ve ark. [27]	Hizmet	•		•	
Kılınç Yasemin [28]	Sanayi	•			
Lin R. [29]	Sanayi		•		
Mayilvaganan ve ark. [30]	Hizmet	•	•		• ²
Mostafaei ve ark. [31]	Sanayi	•		•	
Pinheiro ve ark. [32]	Hizmet		•		
Sağın ve ark. [33]	Hizmet	•	•		
Yıldız Barış [34]	Hizmet				• ³

• : İlgili çalışmada sütundaki yöntemin kullanıldığını gösterir.

•¹ : Eclat ve Relim •² : Bulanık FP-Growth •³ : Matrix Apriori



Şekil 2.2. Tezin akış süreci

BÖLÜM 3. VERİLERİN ELDE EDİLMESİ VE KULLANILAN YÖNTEMLER

Birlikte satılan ürün gruplarının bulunması için de veri madenciliği yöntemlerinden biri olan birliktelik kurallarından yararlanılmıştır. Birliktelik kural yönteminin seçilmesinin sebebi ise mevcut olan durumun incelenmesidir. Birliktelik kurallarından en yaygın olan Apriori algoritması ve diğer algoritmalara göre yüksek performans gösteren, hızlı çalışan FP-Growth algoritması kullanılmıştır. Carma algoritması ise daha fazla iyileştirme olanağı sunduğu ve en iyi çevrimiçi algoritmalarından biri olduğu için seçilmiştir. Bir lojistik firmasında 6 aylık satış verisinden 10000 sipariş içindeki en çok satılan ürün grupları tespit edilmiştir. 10000 sipariş için yapılan analizin sonuçları 9.ayın satış verileri ile karşılaştırılarak en iyi sonucu veren algoritma Apriori algoritması olmuştur. Apriori algoritmasının sonucuna göre belirlenen ilk ürün grubu siparişlerin %5'ini kapsamaktadır. Siparişlerin %1 ile %5 aralığını kapsayan ilk 7 ürün grupları bir arada depo raflarına yerleştirildiğinde süre ve maliyete etkisi için zaman etüdü yöntemi kullanılmıştır. Belirlenen ürün gruplarının satış tahminlerinin yapılması için de yapay sinir ağlarına başvurulmuştur. Hata oranlarının karşılaştırılması MAPE, MSE, RMSE değerleri bulunmuştur. Apriori ve Carma algoritmaları için SPSS Modeler, FP-Growth algoritması ve yapay sinir ağları için de RapidMiner programı kullanılmıştır.

3.1. Apriori Algoritması

Apriori algoritması öğelerin arasındaki ilişkinin nasıl olduğunu analiz eden bir tekniktir. Tekrarı fazla olan nesnelerin bulunmasında kullanılan en yaygın yöntem Apriori algoritmasıdır. Algoritma en az destek eşik değeri dikkate alınarak gereken ürün küme sayılarını azaltmayı sağlar.

Ürünlerin aralarındaki ilişkinin analizini ölçmek için 3 ana unsur kullanılmıştır. Destek: Öğelerin aynı anda bulunması durumudur. Örneğin; X ve Y ürünleri için $P(X \cap Y)$ olarak düşünülebilir. Veri içindeki X ve Y ürünlerinin bir arada bulunduğu değeri. Bu değer eşik değer olarak kullanılmaktadır.

$$\text{Destek} = P(X \cap Y) \quad (3.1)$$

$$\text{Destek}(X) = |X|/|D| \quad (3.2)$$

$|X| \rightarrow$ Verinin içinde X ürünün bulunma sayısı

$|D| \rightarrow$ Toplam veri sayısı

Güven: $X \Rightarrow Y$ kuralın sol tarafının sağlanması durumunda sağ tarafının da sağlanması olasılığıdır. Yani X ürünün alındığında Y ürünün de $(P(Y|X))$ alınma olasılığıdır.

$$\text{Güven}(Y|X) = \text{Destek}(X \cap Y) / \text{Destek}(X) \quad (3.3)$$

Güven ölçüsünün bir dezavantajı, bir birliğin öneminin yanlış yorumlanabilmesidir. Bu konuyu bir örnek ile açıklamak gerekirse X ürünü alındığında Y ürünün de alınma olasılığı yüksek olabilir ama bu durum Y ürünün popüler bir ürün olduğunu göstermemektedir. Bunun içinde ilgi değerine bakılmalıdır.

İlgi: Ürünlerin popülerliğini kontrol etmek için hesaplanan değerdir. X ürünü satın alındığında Y ürünün de alınma olasılığının yüksek olması Y ürünün popüler olduğunu göstermemektedir. Bunun için de iki ürün arasında ilgi değerine ihtiyaç duyulmaktadır.

İlgi değeri=1 $\rightarrow$ X ve Y ürünlerinin arasında bir ilişkinin olmadığını göstermektedir.

İlgi değeri>1 $\rightarrow$ X ürünü alındığında Y ürünün de alınma ihtimalinin yüksek olduğunu göstermektedir.

İlgi değeri $< 1 \rightarrow$ X ürünü alındığında Y ürünün alınma olasılığının düşük olduğunu göstermektedir.

$$\text{İlgi}(Y|X) = \text{Güven}(Y|X) / \text{Destek}(X) \quad (3.4)$$

Apriori algoritmasında birliktelik kuralları belirlenmesi aşağıdaki adımlardan oluşmaktadır [11];

1. Tekrarlanan nesnelerin bulunması: Belirlenen minimum destek seviyesinden daha fazla tekrarlanan nesneler tanımlanır. Minimum destek seviyesi kullanıcı tarafından belirlenmektedir.
2. Tekrar sayısı çok olan nesnelerin birliktelik kurallarını oluşturması: Oluşan kurallar minimum destek ve güven değerini karşılamaktadır.

3.2. Carma Algoritması

Carma algoritması nesne kümelerinin hesaplama işlemini çevrimiçi olarak yapmaktadır. Algoritma çevrimiçi çalıştığı için kullanıcıya mevcut durumdaki birliktelik kurallarını göstermektedir. Bu algoritmanın artı yönlerinden biri de veri tabanının ilk taramasında herhangi bir işlemde kullanıcı minimum destek ve minimum güven değerlerini değiştirmesini sağlamaktadır. Carma algoritması veritabanını ilk tararken nesne kümelerini oluşturmaktadır. İkinci taramada ise minimum destek seviyesini sağlayan nesne kümelerini saymaktadır. Analiz işlemi 2 adımda bitmektedir, veritabanı en fazla 2 kez taranmaktadır. Nesne kümesinin sıklık durumunun kesinleşmesi için nesne kümelerinin üst sınırı hesaplanmaktadır. Hesaplanan değer oluş sayısının tahmini rakamıdır. Oluş sayısı ise nesne kümesi ilk oluşturulurken bulunmaktadır [35,36].

Destek, öncül nesnenin veritabanında geçme sayısının toplam veri sayısına oranıdır. Destek değeri nesne kümesinin öncelik yüzdesidir.

$$\text{Destek} = \text{Öncül Nesnenin Geçme Sayısı} / \text{Toplam Veri Sayısı} \quad (3.5)$$

Kural Desteği ise nesne grupların toplam veride geçme sıklık oranlarıdır.

$$\text{Kural Desteği} = P(X \cap Y) / \text{Toplam Veri Sayısı} \quad (3.6)$$

Güven değeri kural destek değerinin öncül destek değerine oranıdır. Öncül nesne alındığında onu izleyen nesnenin alınma olasılığıdır.

$$\text{Güven} = \text{Kural Desteği} / \text{Destek} \quad (3.7)$$

İlgi değeri ise güven değerinin nesne kümesinde izleyen nesnenin veride bulunma sıklığına oranıdır. İlgi değerinin 1'den fazla olması nesne kümesinin doğruluğunu, nesnelerin arasındaki ilişkinin olduğunu göstermektedir.

$$\text{İlgi} = \text{Güven} / \text{Destek}(X) \quad (3.8)$$

3.3. Frequent Pattern Growth (FP-Growth) Algoritması

Birliktelik kurallarından biri olan FP-Growth (Frequent Pattern Growth) algoritması diğer algoritmalarından yüksek performans göstermektedir. FP-Growth Algoritmasının en büyük avantajı ise büyük veriler için hızlı çalışmasıdır ve sistem kaynaklarının verimli kullanılabilmesidir. Tüm verileri Frequent Pattern Tree (FP-Tree) adında sıkıştırılmış bir ağaç yapısında tutmaktadır. Bu algoritmanın bir özelliği de veri tabanını sadece iki kez taramasıdır. Birinci taramada tüm nesnelerin destek değerlerini bulmaktadır, ikincisinde ise ağaç yapısı oluşturmaktadır. FP-Growth algoritmasında her nesnenin destek değeri bulunur ve kullanıcının vermiş olduğu eşik değerinin altında kalanlar elenmektedir. Elenmeyen değerler büyükten küçüğe sıralanır ve saklanır. Destek değerlerine göre sıralanan nesnelerden destek değeri büyük olanlar köke yakın olanlardır. İşlem kayıtlarında olan bir nesnenin ağacın içinde olup olmadığına bakılır. Ağacın içinde yok ise o nesne için yeni bir düğüm oluşturur ve destek sayısını 1 artırır, varsa da olduğu düğümün destek değerini 1 arttırmaktadır. Ağaç oluştuktan sonra da nesnelerin geçtiği dallar belirlenmektedir. Belirlenen dal tek ise nesnelerin kombinasyonudur. Birden fazla dal var ise destek değeri o daldaki

minimum destek değerine eşitlenir. Bu şekilde FP-Growth Algoritması böl ve yönet kuralını uygulayarak büyük bir nesne kümesini daha küçük nesne kümelerine bölmektedir. Sonuçta oluşan ağaç yapısı (FP-Tree) asıl veri kümesinden büyük olmamaktadır [21].

Örnek olarak; Bir marketin örnek sipariş listesi ve alınan ürünler Tablo 3.1.'de gösterilmektedir.

Tablo 3.1. Örnek market sipariş listesi	
Siparişler	Siparişteki Ürünler
1	E,D,A,B
2	B,D,A,E,C
3	B,A,E,C
4	B,D,A
5	D
6	B,D
7	D,A,E
8	B,C

Minimum destek değeri %30 karşılayan ürünleri ele alalım. FP-Growth algoritmasına göre ağacını oluşturalım. Yapılacak adımlar aşağıdaki gibidir;

1. Minimum destek değeri hesaplanır.
2. Sıklık değerleri bulunur. (Yani toplamda kaç tane satıldıkları bulunur.)
3. Ürünler önem derecelerine göre sıralanır.
4. Siparişin içindeki ürünler önem derecelerine göre sıralanır.
5. FP-Tree çizilir.

1.Adım: Minimum destek değerinin %30 olması bir ürünün toplam veri setinin en az %30'nu içermelidir. Bu durumda $\%30 \cdot 8 = 2,4$ tane minimum ürün sayısı olmalıdır. Yani 8 siparişin içinde minimum 2,4 tane olmalıdır.

2.Adım: Ürünlerin toplam veri setinde geçme sayıları Tablo 3.2.'de verilmektedir;

Tablo 3.2. Ürünlerin geçme sayısı

Ürünler	Geçme Sayısı
A	5
B	6
C	3
D	6
E	4

Veri setindeki tüm ürünlerin geçme sayısı minimum destek sayısı üzerinde olduğu için tüm ürünler için analiz yapılacaktır.

3.Adım: Ürünler önem derecesine göre sıralanır.

Tablo 3.3. Önem derecesine göre sıralama


Ürünler	Geçme Sayısı
B	6
D	6
A	5
E	4
C	3

4.Adım: Siparişin içindeki ürünler önem derecelerine göre sıralanır.

Tablo 3.4. Sipariş-ürün önem derecesi


Siparişler	Siparişteki Ürünler	Ürünler Sıralanması
1	E,D,A,B	B,D,A,E
2	B,D,A,E,C	B,D,A,E,C
3	B,A,E,C	B,A,E,C
4	B,D,A	B,D,A
5	D	D
6	B,D	B,D
7	D,A,E	D,A,E
8	B,C	B,C

5.Adım: FP-Tree çizilir. İlk satır göre ağacın ilk dalı çizilir.




Şekil 3.1. FP-Tree 1.dalı

2.siparişe bakıldığında ağacın yeni durumu aşağıdaki gibi olur. 1.dala ek olarak C ürünü eklenir. Diğer ürünler aynı şekilde bu siparişte de olduğu için sayıları 1 daha artırılır.




Şekil 3.2. FP-Tree 2.dalı

3.siparişe bakıldığında da farklı bir kombinasyon olduğu ve ortak B ürünü olduğu için B ürününden bir dal daha çıkarılır.



Şekil 3.3. İlk 3 sipariş için FP-Tree

Bu şekilde devam edilir. Ağacın son hali aşağıdaki gibidir;




Şekil 3.4. FP-Tree son hali

3.4. Yapay Sinir Ağları


Yapay sinir ağları (YSA) biyolojik sinir sistemlerinin çalışmasına benzer yapıda bir sistemin bilgisayar ortamında oluşturulmasıdır. İnsan beyninin öğrenme işlevinin bilgisayar yoluyla gerçekleştirme olarak da tanımlanabilir [37].

YSA'ya önceden verilen girdi/çıktı değerleri sayesinde öğrenebilir. Bu örnekleri kullanarak genellemeler yapar. Öğrendiği bilgiler ile karşılık gelen çıktıyı üretir. Eksik bilgi ile öğrenme sağlayabilir, tam bilgiyi bulabilir. YSA'lar kendi kendine öğrenme yeteneğine sahiptir ve değişiklik durumunda ortama adapte olabilirler [38].




Şekil 3.5.Yapay sinir ağlarının genel akışı [15].

Yapay sinir ağıları iki mimari yapıdan oluşur. Bu iki mimari yapıdan biri ileri beslemeli çok katmanlı yapay sinir ağılarıdır. İleri beslemeli YSA’larda, hücreler katmanlar şeklindedir ve bir katmandaki hücrelerin çıkışları bir sonraki katmana ağırlıklar üzerinden giriş olarak verilir. Giriş katmanı aldığı bilgileri gizli katmandaki hücrelere iletir. Bu bilgi saklı ve çıkış katmanda işlenerek ağ çıkışını belirler. İleri beslemeli YSA ‘nın eğitiminde geriye yayılım algoritması yaygın olarak kullanılır [39].



Şekil 3.6. İleri beslemeli yapay sinir ağıları yapısı[16].

Bir diğer mimari yapı ise geri beslemeli çok katmanlı YSA’dır. En az bir hücrenin çıkışı kendisine ya da diğer hücrelere giriş olarak verilir. Geriye doğru hesaplamada, ağın ürettiği çıktı değeri, ağın beklenen çıktıları ile kıyaslanır. Bunların arasındaki fark hata olarak kabul edilir. Amaç bu hatanın düşürülmesidir. Toplam hatayı azaltmak için de nöronların ağırlıklarını değiştirilebilir [39].



Şekil 3.7. Geri beslemeli yapay sinir ağıları yapısı

YSA’da gözetimli ve gözetimsiz öğrenme algoritmaları mevcuttur. Gözetimli öğrenmede istenilen ve gerçek çıktı arasındaki hataya göre nöronlar arası bağlantıların ağırlıklarını en uygun çıkış için düzenler. Gözetimsiz öğrenmede ise giriş verilerinden öğrendiklerine göre çıkış bilgisine göre sınıflandırma kurallarını kendisi belirler. Bu tür algoritma da çıkış değerinin bilinmesine gerek yoktur, öğrenme süresince giriş bilgileri iletilir [39].

Yapay sinir ağıları tahmin, sınıflandırma, veri ilişkilendirme, yorumlama işlemlerinde kullanılmaktadır. Mevcut veriler yorumlanarak gelecek için planlama yapılabilir. Bir konu hakkında toplanan örneklerden elde edilen ve eğitim sonucu oluşturulan bilgileri kullanarak yeni olayların yorumlanmasını sağlar [11].

Yapay sinir ağlarının performansının belirlenmesinde birçok istatistik hatalar önemli rol oynar. Yapay sinir ağlarında gizli katman sayısı, iterasyon sayısı, öğrenme katsayısının değişimi hata oranlarının belirlenmesinde rol oynar. Mutlak hata, ortalama mutlak hata (MAE) ve ortalama karesel hatanın (MSE) toplamı tahmin ile gerçek veriler arasındaki farka göre belirlenir. Bu ölçümler kullanım kolaylığı nedeniyle yaygın olarak kullanılır fakat hatanın ciddiyetliğini belirleyemez. Kök ortalama kare hatası (RMSE) ve ortalama mutlak yüzde hatası (MAPE) fonksiyonları bu eksikliğin giderilmesi için kullanılır [40].

MAPE küçük hacimli veriler için kullanılmalıdır [41]. RMSE bir makine öğrenmesi modelin tahmin ettiği değer ile gerçek değer arasındaki uzaklığın bulunmasında kullanılan, hatanın büyüklüğünü ölçen bir metriktir. Bu değerın sifıra yakın olması tahminleyicinin iyi bir performans gösterdiği şeklinde yorumlanır [42].

$$MSE = \frac{1}{n} \sum_{i=1}^n (y' - y)^2 \quad (3.9)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y' - y)^2} \quad (3.10)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n |(y' - y) / y| * 100(\%) \quad (3.11)$$


y' : Tahmini değer

y : Gerçek değer


n : Veri seti küme değeri

BÖLÜM 4. BULGULAR VE TARTIŞMA

Bu çalışmada bir lojistik firmasına internet üzerinden gelen siparişlerin analizi yapılmıştır. Firmanın yöneticileri tarafından ikiden fazla ürünler birleştirilmesi ergonomik olarak doğru bulunmamıştır. Bu yüzden ürün grupları ikili olarak kısıtlanmıştır. Deponun mevcut durumda Şekil 4.1.'de görüldüğü gibi internet üzerinden gelen siparişler ürünlerin raflardan toplanıp paketlenmesi için iş listesine bağlanır ve operatörlere verilir. Ortak bir plastik palete raflardan toplanan ürünler sipariş bazlı ayrılır. Ayrılan siparişler sırasıyla paketlenir ve son müşteriye iletmek üzere kargoya verilir.




Şekil 4.1. Lojistik firmasında mevcut operasyonel süreç



Şekil 4.2. Apriori algoritmasının SPSS Modeler programı kurulumu

Apriori algoritmasında kural olarak minimum kural desteği ve güven değeri %5 belirlenmiştir. İkili nesne gruplarının oluşması için de maksimum kural büyüklüğü 2 olarak belirlenmiştir.



Şekil 4.3. Apriori algoritmasının SPSS Modeler programı kurulum kuralları

İkili ürün grupları oluşturulmuştur. Sipariş listesinde ürünlerin beraber geçme sayısı, bir ürün bulunduğu gruptaki diğer ürünün bulunma olasılığı ve iki ürün arasındaki ilişki için ilgi değerleri bulunmuştur.


Firma için ürün kodları gizli olduğu için ürünler X olarak adlandırılmıştır.

Verilerin %10 nu olan 10000 sipariş incelenmiştir. 10000 tane sipariş içinde minimum destek seviyesi düzeyinde 268 adet ürün grubu bulunmuştur. Tablo 4.2.'de sıralanan ilk sekiz grubu örnek olarak inceleyelim;

Grup Sayısı	Ürün 1	Ürün 2	Geçme Sayısı	1. Ürünün Geçme Sayısı	2. Ürünün Geçme Sayısı
1	X40	X39	521	525	523
2	X40	X8	481	525	500
3	X39	X8	480	523	500
4	X40	X89	257	525	280
5	X39	X89	257	523	280
6	X8	X89	248	500	280
7	X194	X193	126	168	163
8	X116	X119	107	155	141

İlk grup olarak X40 ve X39 ürünleri belirlenmiştir. Bu iki ürünün veritabanında beraber geçme sayısı 521 sipariştir. X40 ürünü 525 tane sipariş içinde satılmıştır aynı şekilde X39 ürünü de 523 sipariş içinde bulunmaktadır.

Firmada uzman kişiler en az 100 siparişte beraber satılan ürün gruplarının dikkate alınması kuralını belirlemişlerdir.



Şekil 4.4. Apriori algoritması ürünlerin beraber satış yüzdesi

Belirlenen kurala göre %21 ile en yüksek ürün grubu X40-X39, %20 ile ikinci grup olarak belirlenen X40 ve X8 ürünleridir (Şekil 4.4.). Bu sonuçlar ile yapılacak bir yorum ise X40 ürünün müşteri portföyünde popüler bir yere sahip olmasıdır.

SPSS Modeler programının örnek sonuçların görüntüsü aşağıdaki gibidir;

Consequent	Antecedent	Instances	Support %	Confidenc...	Rule Supp...	Lift
X40	X39	523	5.23	99.618	5.21	18.975
X39	X40	525	5.25	99.238	5.21	18.975
X40	X8	500	5.0	96.2	4.81	18.324
X39	X8	500	5.0	96.0	4.8	18.356
X8	X39	521	5.21	92.131	4.8	18.426
X8	X40	523	5.23	91.778	4.8	18.356
X8	X39	525	5.25	91.619	4.81	18.324
X89	X8	500	5.0	49.6	2.48	17.714
X89	X39	521	5.21	49.328	2.57	17.617
X89	X40	523	5.23	49.14	2.57	17.55
X89	X39	525	5.25	48.952	2.57	17.483

Şekil 4.5. Apriori algoritmasının SPSS Modeler programında ki örnek sonuçları

Apriori algoritmasının tüm sonuçları Ek A’da bulunmaktadır.

Tablo 4.3. Apriori algoritması sonuçları

Grup Sayısı	Ürün 1	Ürün 2	Geçme Sayısı	1. Ürünün Geçme Sayısı	2. Ürünün Geçme Sayısı
1	X40	X39	521	525	523
2	X40	X8	481	525	500
3	X39	X8	480	523	500
4	X40	X89	257	525	280
5	X39	X89	257	523	280
6	X8	X89	248	500	280
7	X194	X193	126	168	163
8	X116	X119	107	155	141
9	X117	X114	82	200	100
10	X117	X326	79	200	110
				...	
				...	
267	X397	X522	10	55	33
268	X1197	X1198	10	13	12

Bu verilere istinaden tüm ürün grupların güven ve ilgi değerleri bulunmuştur. Her grup için 2 tane güven değeri hesaplanmıştır. Bu güven değerleri X40 ürünün bulunduğu siparişlerde X39 ürünün bulunma olasılığı ve X39 ürünün bulunduğu siparişlerde X40 ürünün bulunma olasılığıdır.

Güven değeri hesaplama denklemi aşağıdaki gibidir;

$$\text{Güven}(Y|X) = \text{Destek}(X \cap Y) / \text{Destek}(X) \quad (4.1)$$

Buna göre X40 ürünün bulunduğu siparişlerde X39 ürünün bulunma olasılığı aşağıdaki gibi hesaplanmıştır;

$$\text{Güven}(X39|X40) = (\text{Beraber geçtikleri sipariş sayısı} / X40 \text{ ürünün bulunduğu sipariş sayısı}) = (521/525) = 0,99.$$

Sonuca göre X40 ürünün bulunduğu siparişlerde X39 ürünün bulunma olasılığı %99’dur.

Aynı şekilde X39 ürünün bulunduğu siparişlerde X40 ürünün satılma olasılığı da bulunur.

Güven (X40|X39)= (Beraber geçtikleri sipariş sayısı/X39 ürünün bulunduğu sipariş sayısı) =(521/523)=0,996.

%99,6 olasılıkla X39 ürünün satıldığı durumlarda X40 ürünü de satılmaktadır.


Bu şekilde tüm ürün grupları hesaplanır, ilk sekiz grup için sonuçlar aşağıdaki gibidir;

Tablo 4.4. Apriori algoritmasının ilk 8 ürün grubu için sonuçlar

Grup Sayısı	Ürün 1	Ürün 2	Geçme Sayısı	1. Ürünün Geçme Sayısı	2. Ürünün Geçme Sayısı	(1 2)	(2 1)
1	X40	X39	521	525	523	1	0,99
2	X40	X8	481	525	500	0,96	0,92
3	X39	X8	480	523	500	0,96	0,92
4	X40	X89	257	525	280	0,92	0,49
5	X39	X89	257	523	280	0,92	0,49
6	X8	X89	248	500	280	0,89	0,5
7	X194	X193	126	168	163	0,77	0,75
8	X116	X119	107	155	141	0,76	0,69

(1|2): 2.ürün alındığında 1.ürünün alınma olasılığı

Belirlenen ürün gruplarının güven değerlerinin grafik sonuçları;



Şekil 4.6. Apriori algoritması güven değerleri

Güven değerlerinde ürünlerin karşılıklı bulunma olasılıkları yaklaşık olarak birbirlerine yakın olunmasına rağmen 3 grupta farklı sonuçlar gözlenmiştir.

X89-X40, X89-X39,X89-X8 ürün gruplarının güven değerleri arasında farklılıklar bulunmaktadır. X40 ürünün bulunduğu siparişlerde X89 ürününde alınma olasılığı

%92 iken X89 ürünün bulunduğu siparişlerde X40 ürünün alınma olasılığı %49'dur. Bunun sebebi X89 ürünün bulunduğu sipariş sayısı fazladır. Hesaplamalara göre tüketiciler X89 ürünü tek başına daha fazla tercih ettiği söylenebilmektedir. X89 ürünü için çıkan bu sonuçlar firmanın uzmanlarının görüşüne göre belirlenmiştir. Beraber geçen sipariş sayısı 100'den fazla olduğu bu ürün grupları da sonuçlar arasında yer almaktadır. X89-X39, X89-X8 ürün grupları içinde aynı durum söz konusudur.

Sipariş sayısı 100 üzerinde olan ürün gruplarının hesaplanan ilgi değerleri tablosu;

Tablo 4.5. Ürün grupların ilgi değerleri


Grup Sayısı	Ürün 1	Ürün 2	Geçme Sayısı	1.Ürünün Geçme Sayısı	2.Ürünün Geçme Sayısı	(2 1)	İlgi Değeri
1	X40	X39	521	525	523	0,99	18,97
2	X40	X8	481	525	500	0,92	18,32
3	X39	X8	480	523	500	0,92	18,36
4	X40	X89	257	525	280	0,49	17,48
5	X39	X89	257	523	280	0,49	17,55
6	X8	X89	248	500	280	0,5	17,71
7	X194	X193	126	168	163	0,75	46,01
8	X116	X119	107	155	141	0,69	48,96

1.ürün grubu olan X40-X39 ürünleri için ilgi değeri:

$$\text{Lift}(X39|X40) = \text{Destek}(X39, X40) / [\text{Destek}(X40) * \text{Destek}(X39)]$$

$$\text{Lift}(X39|X40) = (0,99) / [(525/10000) * (523/10000)] = 18,97$$


İlgi(lift) değerinin 1'den büyük olması iki ürün arasında bir ilişkinin olduğu göstermektedir. Yani X40 ürünü alındığında X39 ürününde alınmasının muhtemel olduğu gözlenmektedir.



Şekil 4.7. Apriori algoritması ürün gruplarının ilgi değerleri


4.2. Carma Algoritması Uygulaması

Çalışmada ikinci olarak Carma algoritması ile analiz edilmiştir. Carma algoritmasının uygulanması için birinci aşamada veri seti makro ile Tablo 4.1.'de ki gibi düzenlenmiştir. Carma algoritması için SPSS Modeler programı kullanılmıştır. Carma algoritmasının sonucuna göre en çok beraber satılan ürünler X39-X40,X8-X40,X8-X39 ürünleridir.



Şekil 4.8. Carma algoritmasının SPSS Modeler programı kurulumu

Carma algoritmasında kural olarak minimum kural desteği ve güven değeri %5 belirlenmiştir. İkili nesne gruplarının oluşması için de maksimum kural büyüklüğü 2 olarak belirlenmiştir. En az 100 tane alınmış ürünler için algoritma çalıştırılmıştır.



Şekil 4.9. Carma algoritması SPSS Modeler programı model özellikleri

Hazırlanan model çalıştırıldığında elde edilen örnek sonuç aşağıdaki gibidir;

Consequent	Antecedent	Instances	Support %	Confidenc...	Rule Supp...	Lift
X40	X39	523	24.834	99.618	24.739	3.996
X39	X40	525	24.929	99.238	24.739	3.996
X40	X8	500	23.742	96.2	22.84	3.859
X39	X8	500	23.742	96.0	22.792	3.866
X40	X89	280	13.295	91.786	12.203	3.682
X39	X89	280	13.295	91.786	12.203	3.696
X8	X39	523	24.834	91.778	22.792	3.866
X8	X40	525	24.929	91.619	22.84	3.859
X8	X89	280	13.295	88.571	11.776	3.731
X194	X193	163	7.74	77.301	5.983	9.69
X116	X119	141	6.695	75.887	5.081	10.311
X193	X194	168	7.977	75.0	5.983	9.69
X119	X116	155	7.36	69.032	5.081	10.311
X89	X8	500	23.742	49.6	11.776	3.731
X89	X39	523	24.834	49.14	12.203	3.696
X89	X40	525	24.929	48.952	12.203	3.682

Şekil 4.10. Carma algoritması sonuçları

Carma algoritmasının sonuçları ve nesne gruplarının listesi;

Tablo 4.6. Carma algoritması sonuçları

İzleyen Nesne	Öncül Nesne	Öncül nesnenin alınma sayısı	Öncül nesnenin destek %	Güven %	İki nesnenin beraber alınma %	İlgi Değeri
X40	X39	523	5,230	99,618	5,210	18,9749
X39	X40	525	5,250	99,238	5,210	18,9748
X40	X8	500	5,000	96,200	4,810	18,3238
X39	X8	500	5,000	96,000	4,800	18,3556
X40	X89	280	2,800	91,786	2,570	17,4830
X39	X89	280	2,800	91,786	2,570	17,5499
X8	X39	523	5,230	91,778	4,800	18,3556
X8	X40	525	5,250	91,619	4,810	18,3238
X8	X89	280	2,800	88,571	2,480	17,7142
X194	X193	163	1,630	77,301	1,260	46,0125
X116	X119	141	1,410	75,887	1,070	48,9594
X193	X194	168	1,680	75,000	1,260	46,0123
X119	X116	155	1,550	69,032	1,070	42,3509
X89	X8	500	5,000	49,600	2,480	17,7143
X89	X39	523	5,230	49,140	2,570	17,5500
X89	X40	525	5,250	48,952	2,570	17,4829

Örnek olarak hesaplanma şekli;

Tablo 4.7. Carma algoritması için örnek hesaplama

İzleyen Nesne	Öncül Nesne	Öncül nesnenin alınma sayısı	Öncül nesnenin destek %	Güven %	İki nesnenin beraber alınma %	İlgi Değeri
X40	X39	523	5,230	99,618	5,210	18,9749


$P(X40|X39) \rightarrow$ X39 ürünü alındığında(öncül nesne) X40 ürünün (izleyen nesne) alınma durumu;

- Öncül nesnenin destek % = (X39 ürünün geçme sıklığı/Toplam işlem sayısı)*100 = (523/10000)*100 = %5,230
- Kural Desteği % = (X39 ve X40 ürünlerinin beraber alındığı işlem sayısı/Toplam işlem sayısı)*100 = (521/10000)*100 = %5,210
- Güven % = (Kural Desteği/Destek) = 5,210/5,230 = 99,168
- İlgi = (Güven/X40 ürünün alımı sıklığı) = 99,618/(525/10000) = 18,975
- Her ürün grubu için 2 tane güven değeri bulunmuştur. Aynı şekilde X40 ürünü alındığı X39 ürünün alınma durumu;

Tablo 4.8. X40 ürünü ile X39 alınması

İzleyen Nesne	Öncül Nesne	Öncül nesnenin alınma sayısı	Öncül nesnenin destek %	Güven %	İki nesnenin beraber alınma %	İlgi Değeri
X39	X40	525	5,250	99,238	5,210	18,9748

Ürün gruplarının güven değerleri Şekil 4.11.'de gösterilmiştir.




Şekil 4.11. Carma algoritması ürün gruplarının güven değerleri

Carma ve Apriori algoritmaları aynı eşik güven değeri için hesaplandığından aynı sonuç çıkmaktadır. Bunun için alternatif olarak FP-Growth algoritması ile çalışma yapılmıştır.

4.3. FP-Growth Algoritması Uygulaması

FP-Growth algoritması için çalışmada Rapidminer programı kullanılmıştır. Hazırlanan MS Excel'de sonuç olarak tanımlanan değerler seçilmiş değer yani "selected attributes" olarak tanımlanmıştır. Veri setimizin sonuç değerleri ürünlerdir. Bu sebeple de ürünler selected attributes olarak tanımlanmıştır. Minimum destek seviyesi de 0,05 olarak tanımlanmıştır.



Şekil 4.12. Rapidminer programı FP-Growth algoritması kurulumu

FP-Growth algoritması ağaç mantığında olduğu için çıkan sonuçlar tekli, ikili, üçlüdür. Apriori algoritmasından farklı sonuçlar elde edilmiştir.

FP-Growth algoritmasının sonuçları detaylı olarak Ek B’de bulunmaktadır.

Tablo 4.9. FP-Growth sonuçları

Grup Sayısı	Ürün Sayısı	Ürün 1	Ürün 2	Ürün 3	Ürün 4	Ürün 5	Destek değeri
1	1	X3					0.987
2	1	X40					0.052
3	1	X39					0.052
4	1	X8					0.050
5	1	X89					0.028
6	1	X117					0.020
7	1	X194					0.017
8	1	X217					0.016
9	1	X193					0.016
10	1	X116					0.015
			...				
			...				
66	4	X40	X39	X8	X89		0.025
67	5	X3	X40	X39	X8	X89	0.025

FP-Growth algoritmasına göre en yüksek alınma durumu X3 ürünüdür. İkili olarak ürünleri grupladığımızda da en yüksek birlikte alınma olasılığı ürünlerin listesi Tablo 4.10.’da bulunmaktadır. X3-X40 ürünleri en çok beraber satılan ürün grubunu oluşturmuştur.

Tablo 4.10. FP-Growth ürün grupları

Ürün Grupları	Ürün 1	Ürün 2
1	X3	X40
2	X3	X39
3	X3	X8
4	X3	X89
5	X40	X39
6	X40	X8
7	X40	X89
8	X39	X8
9	X39	X89
10	X8	X89


Rapidminer programına göre algoritmanın FP-Tree diyagramı Şekil 4.13.'de sunulmuştur.



Şekil 4.13. FP-Tree

4.4. Algoritmaların Karşılaştırılması

Bulunan bu algoritma sonuçlarının karşılaştırılmasının yapılması için yeni bir sipariş verisi üzerinde analiz yapılmıştır. Bu analiz içinde makro kullanılmıştır. Makro ile en çok satılan ürünler ve ikili kombinasyonları üzerinde yorumlama yapılacaktır. Böylece yeni ve gerçek bir veri seti ile hangi algoritmanın sonucuna daha yakın olacağının tespiti yapılacaktır.




Şekil 4.14. Son satış verisi ürünlerin tekli satış miktarları

Ürünlerin tekli satışlarına bakıldığında en çok satılan ürünler X40-X39-X3-X89-X217-X460 ürünleri olmuştur (Şekil 4.14.).

Örneklem olarak satış miktarı 100'den fazla olanlar eklenmiştir. İkili olarak satış yapılan ürünlerin kombinasyonları da Tablo 4.11. ve Şekil 4.15.'de sunulmaktadır. En çok beraber satılan ürünler X40 ve X39 ürünleridir.

Tablo 4.11. En çok satılan ikili ürün grupları ve satış miktarları

1.ürün	2.ürün	Beraber Satış Miktarı
X40	X39	391
X39	X89	208
X40	X89	207
X39	X8	103
X40	X8	99
X217	X460	71
X89	X8	64
X460	X20	59
X194	X193	52
X117	X326	50
X568	X567	46
X3	X50	46
X37	X34	44
X37	X183	42



Şekil 4.15. Son satış verisi ürünlerin çiftli satış miktarları

En çok beraber satılan ürünler X40 ve X39 ürünleridir. Sıralamanın devamı yukarıdaki tablodaki gibidir.

Apriori ve FP-Growth algoritmalarıyla yapılan hesaplamalar ile yeni satış verisine göre en çok satılan tekli ve beraber satılan ilk 10 ürün/ürünler Tablo 4.12. ve Tablo 4.13.'de gösterilmiştir.

Tablo 4.12. Son satış verisi-Apriori-FP-Growth algoritmaları tekli ürün karşılaştırması

	Son Satış Verisi	Apriori Algoritması	FP-Growth Algoritması
1	X40	X40	X3
2	X39	X39	X40
3	X3	X8	X39
4	X89	X89	X8
5	X217	X117	X89
6	X460	X194	X117
7	X37	X193	X194
8	X20	X217	X217
9	X194	X116	X193
10	X8	X20	X116


Tablo 4.13. Son satış verisi-Apriori-FP-Growth algoritmaları çiftli ürün karşılaştırması

	Son Satış Verisi		Apriori Algoritması		FP-Growth Algoritması	
1	X40	X39	X40	X39	X3	X40
2	X39	X89	X40	X8	X3	X39
3	X40	X89	X39	X8	X3	X8
4	X39	X8	X40	X89	X3	X89
5	X40	X8	X39	X89	X40	X39
6	X217	X460	X8	X89	X40	X8
7	X89	X8	X194	X193	X40	X89
8	X460	X20	X116	X119	X39	X8
9	X194	X193	X117	X114	X39	X89
10	X117	X326	X117	X326	X8	X89

İncelenen son satış verileri apriori algoritmasını sonuçlarına daha yakındır. İkili ürün satış durumlarında Apriori ile son satış verileri %70 oranında uymaktadır. FP Growth algoritması ile %50 ile uyumluluk bulunmaktadır. Bunun yanında tekli olarak ürünleri incelediğimizde hem Apriori hem FP-Growth algoritması %70 oranında uymaktadır. Tekli olarak ürünlerin değerlendirilmesi maliyet açısından bir fayda sağlamayacağından ikili satılan ürünleri baz almak maliyet açısından daha faydalı olacaktır.

4.5. Zaman Etüdü ve Maliyet Analizi

Önerilen depo süreci olarak Şekil 4.16.'da gösterildiği gibi beraber en çok satılan ikili ürünler demet halinde paketlenerek raflarda stoklanacaktır. Siparişler geldiğinde toplama, ayrıştırma ve paketleme süreçlerinde geçerek son kullanıcıya ulaştırılacaktır. Pilot çalışma olduğu için ilk etapta raflardan ürünler tekli toplanıp paketlenerek yerleştirilmiştir. Kabul görülmesi durumunda mal kabul esnasında paketlenerek ürünler konulacaktır. Şekil 4.1.'de bahsedilen mevcut sistemden farklı olarak beraber satılan ürünler demet halinde toplanıp paketleneyecektir. Tek tek alındığında toplama ve paketleme sürelerinin daha uzun sürdüğü düşünülmektedir ve bunun doğrulanması için de zaman etüdü yöntemine başvurulmuştur.



Şekil 4.16. Lojistik firmasında yeni operasyonel süreç

Mevcut ve yeni yapılacak olan süreçlerde ayrıştırma süreçleri ortak olduğu için hesaplamalardan muaf tutulmuştur. Bundan bir sonraki yapılacak iyileştirme raflar arasında tekerlekli plastik yerine aynı anda ayrıştırma yapılabilecek bir aracın alınması ve maliyete yansması yapılacaktır.

Beraber satılma olasılıkları yüksek olan ürünler ön paketleme yapılarak raflara konulacaktır. Bu aşamada operasyonel süreçte yeni bir süreç eklenmiş olacaktır. Bu yeni durumun incelenmesi için pilot çalışma yapılmıştır. Aynı siparişler her iki durum için hazırlanmıştır. Bu çalışma için zaman etüdü yöntemi kullanılmıştır. Zaman etüdünde örneklem olarak 10 gözlem yapılmıştır. Süreçlerin standart zamanları bulunmuştur. Bulunan bu standart zamanlar maliyet tahminlenmesinde kullanılmıştır.

Bu yeni durumun incelenmesi için zaman etüdünde örneklem olarak toplamda 2000 ürün içeren siparişler için gözlem yapılmıştır. Günlük ortalama olarak siparişlerde 1500-2500 arasında bu ürünlerden bulunmaktadır. Bu yüzden de 2000 ürün için pilot çalışma yapılmıştır. Örneklem olarak 10 gözlem yapılmıştır ve ilk aşamada bu

gözlemlerin yeterli olup olmaması hesaplanmıştır. Örneklem 10 gözlemin zaman etüdünün sonuç tablosu aşağıdaki gibidir;

Tablo 4.14. Firmanın süreç zaman etütleri

Operasyonel Süreçler	Gözlem No.									
	1	2	3	4	5	6	7	8	9	10
Bundle Ürünlerin Toplama Süreci	18,03	17,04	16,49	20,32	17,11	17,03	17,47	18,14	20,14	21,15
Bundle Ürünlerin Ön Paketleme Süreci	18,46	19,39	13,49	19	19,52	20,24	19,48	20,15	21,33	22,18
Bundle Ürünlerin Paketleme Süreci	15,49	16,31	18,46	18,48	19,14	19,47	18,5	20,02	21,12	20,48
Paketleme Süreci	30,57	28,4	32,13	31,29	22,4	23,53	29,54	36,57	30,16	26,4
Toplama Süreci	32,12	38,33	32,28	30,1	38,15	33,12	22,5	27,02	22,4	32,1

Firmada bilirkişiler tarafından tempo %95, tolerans %7,40 olarak belirlenmiştir. Bu sonucunda her bir operasyon için aynı iş listesi (aynı siparişleri içeren liste) operatörlere verilerek gözlemlenmiştir. Bunun sonucunda standart zamanlar hesaplanmıştır.

İlk olarak her bir süreç için yapılan gözlemlerin yeterli olup olmadığına bakılmıştır. Bunun için de Denklem 4.2'den yararlanılmıştır.

$$N = \frac{40 * \sqrt{n' * \sum_{i=1}^{n'} x_i^2 - (\sum_{i=1}^{n'} x_i)^2}}{\sum_{i=1}^{n'} x_i} \quad (4.2)$$

N: Yeterli gözlem sayısı

n': Örneklem olarak yapılan gözlem sayısı

x_i : Yapılan i. gözlemin süresi

x_i^2 : Yapılan i. gözlemin süresi karesi

Tüm süreçler için $N > n$ ' büyük olduğu için gözlemlere devam edilmelidir.

Operasyonel Süreçler	Gözlem No.										Toplamı	Toplamının Karesi	N
	1	2	3	4	5	6	7	8	9	10			
Bundle Ürünlerin Toplama Süreci	18,03	17,04	16,49	20,32	17,11	17,03	17,47	18,14	20,14	21,15	182,92	3370,24	11,60
Bundle Ürünlerin Ön Paketleme Süreci	18,46	19,39	13,49	19	19,52	20,24	19,48	20,15	21,33	22,18	193,24	3782,83	20,85
Bundle Ürünlerin Paketleme Süreci	15,49	16,31	18,46	18,48	19,14	19,47	18,5	20,02	21,12	20,48	187,47	3542,19	12,61
Paketleme Süreci	30,57	28,4	32,13	31,29	22,4	23,53	29,54	36,57	30,16	26,4	290,99	8624,47	29,66
Toplama Süreci	32,12	38,33	32,28	30,1	38,15	33,12	22,5	27,02	22,4	32,1	308,12	9764,34	46,56
Tüm süreçler için N> n’ büyük olduğu için gözlemlere devam edilmelidir.													

N sayısının hesaplanmasını örnek olarak bundle ürünlerin toplama süreci için hesaplayalım.

1.adım: Yapılan 10 gözlemin süreleri toplanır.

$$18,03 + 17,04 + 16,49 + 20,32 + 17,11 + 17,03 + 17,47 + 18,14 + 20,14 + 21,15 = 182,92$$

2.adım: Her bir gözlem süresinin karesi alınır ve toplanır.

$$18,03^2 + 17,04^2 + 16,49^2 + 20,32^2 + 17,11^2 + 17,03^2 + 17,47^2 + 18,14^2 + 20,14^2 + 21,15^2 = 3370,24$$

3.adım: Denklem 4.3'den yararlanarak hesaplanan değerler yerleştirilerek N değeri bulunur.

$$N = \frac{40 * \sqrt{n' * \sum_{i=1}^{n'} x_i^2 - (\sum_{i=1}^{n'} x_i)^2}}{\sum_{i=1}^{n'} x_i} \quad (4.3)$$

$$N = \frac{40 * \sqrt{10 * 3370,24 - (182,92)^2}}{182,92} = 11,60$$

$N > n'$ yani $11,60 > 10$ olduğu için gözlemlere devam edilir. Tüm süreçlerde bu durum geçerli olduğu için zaman etüdüne devam edilir.

Bu yeni durumun incelenmesi için zaman etüdünde örneklem olarak toplamda 2000 ürün içeren siparişler için 13 tane daha yapılarak toplam 23 gözlem yapılmıştır ve gözlem sayısının yeterli olup olmadığına bakılır.

Tablo 4.16. Firmanın süreç yeni zaman etüdleri-23 gözlem

Operasyonel Süreçler	Gözlem No.																						
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23
	Gözlem Süreleri																						
Bundle Ürünlerin Toplama Süreci	18	17	16,5	20,3	17,1	17	17,5	18,1	20,1	21,2	18,1	17,1	16	17	19	20	21	17,2	18,2	22	19,2	20	22
Bundle Ürünlerin Ön Paketleme Süreci	18,5	19,4	13,5	19	19,5	20,2	19,5	20,2	21,3	22,2	19,1	18,3	20,2	20,3	19,6	20	21	19,4	18,2	20	19,3	20	20
Bundle Ürünlerin Paketleme Süreci	15,5	16,3	18,5	18,5	19,1	19,5	18,5	20	21,1	20,5	18,5	19	21	19,2	20	18	19	20,1	19,1	21	18,4	19,2	20,1
Paketleme Süreci	30,6	28,4	32,1	31,3	22,4	23,5	29,5	36,6	30,2	26,4	30,2	30,1	32,5	32,6	32	34,2	30,3	31,4	30,5	26,3	28,2	30	31
Toplama Süreci	32,1	38,3	32,3	30,1	38,2	33,1	22,5	27	22,4	32,1	32,2	33,1	32,5	32,6	31,4	28,3	28,3	28,3	30,5	30,3	32,2	30,4	29,6

Tablo 4.17. Zaman etüdünde gözlem sayısının yeterlilik kontrolü

Operasyonel Süreçler	Gözlemlerin Toplamı	Gözlemlerin Toplamının Karesi	N
Bundle Ürünlerin Toplama Süreci	429,75	8102,46	14,48
Bundle Ürünlerin Ön Paketleme Süreci	448,43	8799,96	10,42
Bundle Ürünlerin Paketleme Süreci	440,16	8464,61	7,81
Paketleme Süreci	690,13	20928,29	17,04
Toplama Süreci	707,52	22077,29	22,99
Tüm süreçler için $N < n^*$ olduğu için gözlemler yeterlidir. ($n^*=23$)			

Tablo 4.17.'de gösterildiği gibi her bir süreç için yapılan 23 gözlem yeterli olduğu belirlenmiştir. Gözlemlerle ilgili verilerin tamamı Tablo 4.16.'de sunulmaktadır. Gözlem sayısının yeterli olduğunun belirlenmesinden sonra süreçlerin normal ve standart zamanları hesaplanmıştır. Bulunan bu standart zamanlar maliyet tahminlenmesinde kullanılmıştır.

$$\text{Ortalama} = \frac{\sum_{n=1}^N \text{Gözlem (n)}}{N} \quad (4.4)$$

$$\text{Normal Zaman} = \text{Ortalama} * \text{Tempo} \quad (4.5)$$

$$\text{Standart Zaman} = \frac{\text{Normal Zaman}}{1 - \text{Tolerans}} \quad (4.6)$$

Örnek olarak denklem 4.4,4.5 ve 4.6'yı kullanılarak yapılan toplama sürecinin standart zamanının hesaplanması aşağıdaki gibidir;

$$\begin{aligned} \text{Ortalama} = & (32,12 + 38,33 + 32,28 + 30,01 + 38,15 + 33,12 + 22,5 + 27,02 + 22,4 + 32,1 + 32,15 + \\ & 33,05 + 32,53 + 32,59 + 31,42 + 28,28 + 28,3 + 28,26 + 30,52 + 30,25 + 32,23 + 30,35 \\ & + 29,56 / 23) = 30,76 \text{ dk} \end{aligned}$$

$$\text{Normal Zaman} = 30,76 * 0,95 = 29,22 \text{ dk}$$

$$\text{Standart Zaman} = 29,22 / (1 - 0,074) = 31,56 \text{ dk}$$

Bunun sonucunda tahmini maliyet hesaplaması yapılmıştır. Maliyet hesaplamasında kullanılanlar parametreler aşağıdaki gibidir;

- Standart zaman
- Hedef verimlilik(%)
- Her bir operasyonel için maliyet gideri
- Günlük çalışma süresi

Operasyonel maliyet gideri olarak operatörün günlük maliyeti ve taşıma maliyetidir. Taşıma maliyeti de sabit olarak günlük 20 TL’dir. Pilot çalışma olarak yapılan 2000 ürün için $2000 \times 1,41 = 2.820,00$ TL kazanç sağlamaktadır. Maliyetler Denklem 4.7’den yararlanılarak hesaplanmıştır. Detaylı maliyet hesaplaması Tablo 4.18.’de gösterilmiştir.

Tablo 4.18. Maliyet analizi

Maliyet Parametreleri	Toplama Süreci	Paketleme Süreci	Bundle Ürünlerin Toplama Süreci	Bundle Ürünlerin Ön Paketleme Süreci	Bundle Ürünlerin Paketleme Süreci
Standart zaman (dk)	31,56	30,78	19,17	20,00	19,63
Hedef verimlilik(%)	80	80	80	90	90
Her bir operasyonel için maliyet gideri (TL)	60	44,44	60	44,44	44,44
Günlük çalışma süresi (saat)	8	8	8	8	8
Bir ürün için operasyonel maliyeti (TL)	4,93	3,56	3	2,06	2,02
Toplam maliyet (TL)	8,49		7,08		

$$\text{Operasyonel maliyet: } \frac{\text{Standart Zamanı} \times \text{Operasyonel Maliyet Gideri}}{\text{Hedef Verimlilik(\%)} \times \text{Günlük Çalışma Süresi(dk)}} \quad (4.7)$$

Denklem 4.7’de kullanarak toplama süreci için örnek hesaplama yapalım;

- Standart zaman (dk): 31,56
- Hedef verimlilik(%): 80
- Her bir operasyonel için maliyet gideri (TL): Taşıma Maliyeti+ Operatör
Günlük Maliyeti: $20 + (1800/45) = 60$

(Haftalık çalışma süresi 45 saattir, personele verilen maaş 1800 TL’dir.)

- Günlük çalışma süresi (saat): 8
- Bir ürün için operasyonel maliyeti (TL): $(60 \times 31,56) / (0,80 \times 8 \times 60) = 4,93$ TL

Paketleme yapan operatörlerin maaşı farklı olduğu ve taşıma maliyeti olmadığı için örnek olarak paketleme sürecinin maliyet hesaplaması:

- Standart zaman (dk): 30,78
- Hedef verimlilik(%): 80
- Her bir operasyonel için maliyet gideri (TL): Operatör Günlük Maliyeti
(2000/45)=44,44

(Haftalık çalışma süresi 45 saattir, personele verilen maaş 2000 TL’dir.)


- Günlük çalışma süresi (saat):8
- Bir ürün için operasyonel maliyeti (TL): $(44,44 \times 30,78) / (0,80 \times 8 \times 60) = 3,56$ TL

Yeni süreçte paketleme yapan personelin hedef verimliliği %90’a çıkarılmıştır.


Tablo 4.19. Operasyonel süreçlerin maliyeti (TL)

Toplama Süreci	Paketleme Süreci	Bundle Ürünlerin Toplama Süreci	Bundle Ürünlerin Ön Paketleme Süreci	Bundle Ürünlerin Paketleme Süreci
4,93	3,56	3,00	2,06	2,02
	8,49		7,08	

Son durumda operasyonel süreçlerin maliyet durumları aşağıdaki gibidir;



Şekil 4.17. Ürün başına mevcut maliyet grafiği



Şekil 4.18. Ürünlerin beraber raflanması durumunda ürün başına maliyet

Ürün başına maliyet 8,49 TL den 7,08 TL'ye düşmüştür. Bu durum maliyette yaklaşık olarak %16,73'e karşılık gelmektedir. Her bir üründen $8,49 - 7,08 = 1,41$ TL kazanç sağlamaktadır. Pilot çalışma olarak yapılan 2000 ürün için $2000 * 1,41 = 2.820,00$ TL kazanç sağlamaktadır.

Beraber satılan ürünlerin ilk olarak beraber bantlanarak bundle şeklinde raflara yerleştirilmesi toplama sürecini azaltabilir. Toplama yapılırken aynı anda sipariş bazlı ayırma işlemi de yapılabileceği için sipariş ayırma istasyonundaki kaynağa ihtiyaç kalmayacaktır. Paketleme istasyonunda da kaynağın bir siparişe ayıracağı zaman azalabilir ve kaynak başına paketlenen sipariş sayısı artabilir.

4.6. Yapay Sinir Ağları ile Satış Tahmini

Birlikte kuralları ile bulunan beraber satılan ürün gruplarının gelecekteki siparişlerde kaç tane bulunduğunu tahmin etmek için yapay sinir ağlarından yararlanılmıştır. Tahmin yapılmasının sebebi firma içinde operasyon sürecini analiz periyotları arasında sabit tutmak ve operasyon adımlarında iyileştirme yapabilmesinin kararını vermek için sipariş miktarlarını göz önünde bulunduraktır. 9. ayın satış verileri ile karşılaştırılarak karar verilen ürün gruplarının gelecekteki siparişler içinde gelip gelmemesi mevcut operasyonun değişmesi konusunda fikir verecektir.

Geri yayılım algoritması (çok katmanlı algılayıcı) tarafından eğitilmiş ileri beslemeli bir sinir ağı vasıtasıyla gözetimsiz öğrenme metodu ile algoritma kurulmuştur. Çıktı değerinin tahmin edilmesi gerektiği için gözetimsiz öğrenme kapsamındadır. Geçmiş veriler ile sistemin öğrenmesi sağlanmıştır ve gelecekteki girdiler kullanılarak çıktıları tahmin edilmektedir [43].

Yapay sinir ağları için Rapidminer programı kullanılmıştır. RMSE,MAPE ve MSE minimum olacak şekilde öğrenme periyodu ve gizli katman sayısı belirlenmesi hedeflenmiştir.


Yapay sinir ağlarında en uygun parametrelerin bulunması için deneme yanılma işlemine başvurulabilir. Bu parametreler için gizli katman sayısı, iterasyon sayısı, momentum ve öğrenme hızıdır. Bu bağlamda ilk aşama olarak gizli katman sayısı değişiminin sonuçları nasıl etkilediği incelenmiştir. Gizli katman sayısı 2, 3, 5, 10, 20, 30, 50 ve 100 yapılarak hata oranları karşılaştırılmıştır. En iyi hata oranını veren gizli katman sayısı sabit tutularak iterasyon sayısı değişimi incelenmiştir. Gizli katman sayısının değişimi sistemin öğrenmesinde rol oynamaktadır [43].

Tablo 4.20. Yapay sinir ağları parametreleri

Parametreler	Değerler
İterasyon sayısı	30
Öğrenme hızı	0,3
Momentum	0,5

Tablo 4.20.'de gösterilen değerler ile gizli katman sayısı 2, 3, 5, 10, 20, 30, 50 ve 100 olacak şekilde MAPE, MSE, RMSE değerleri bulunmuştur. Ortalama olarak minimum değeri veren gizli katman sayısı belirlenmiştir.

Değerler ilk olarak normalize edilmiştir ve verilerin %85'i de sistemin öğrenmesi , %15'i ise test verisi olarak kullanılmıştır. Kurulan algoritma düzeni Şekil 4.19.'da gösterilmiştir.



Şekil 4.19. Rapidminer’da kurulan yapay sinir ağı algoritması


Her bir ürün grubu için parametreler belirlenerek algoritma düzeni çalıştırılmıştır. Gelecekteki toplam sipariş miktarı firmanın bilirkışileri tarafından verilen değerlerdir.

Örnek olarak ürün gruplarının hata oranlarını gizli katman sayısı 10 ve 30 olduğunda Tablo 4.21.’de inceleyelim. Tablonun detaylı hali Ek D’de listelenmiştir.


Tablo 4.21. Gizli katman sayısı 10 ve 30 olduğunda ürün gruplarının hata oranları

Katman Sayısı	Ürün Grupları	RMSE	MSE	MAPE
10	X40-X39	0,538	0,289	35,337
	X39-X89	0,464	0,215	7,983
	X40-X8	0,241	0,058	4,895
	X39-X8	0,458	0,209	19,449
	X40-X89	0,487	0,237	9,494
	X8-X89	0,131	0,017	7,676
	X194-X193	0,268	0,072	16,723
30	X40-X39	0,533	0,276	47,804
	X39-X89	0,458	0,261	7,197
	X40-X8	0,167	0,248	3,337
	X39-X8	0,559	0,198	26,316
	X40-X89	0,493	0,240	9,838
	X8-X89	0,176	0,059	10,184
	X194-X193	0,264	0,766	17,750


Tüm ürün grupları için sırayla tanımlanan gizli katman sayıları için performans karşılaştırması Şekil 4.20.'de gösterilmiştir.



(a)



(b)



(c)

Şekil 4.20. Yapay sinir ağları gizli katmana göre performans sonuçları

Performans göstergeleri karşılaştırıldığında gizli katman sayısı 10 olduğunda en düşük hata oranlarına ulaşıldığı gözlemlenmiştir. Bu duruma göre yeni sabit tutulacak değerler Tablo 4.22.'de gösterilmiştir.

Tablo 4.22. Yapay sinir ağı yeni parametreler

Parametreler	Değerler
Gizli katman sayısı	10
Öğrenme hızı	0,3
Momentum	0,5


İkinci aşama olarak gizli katman sayısı, öğrenme hızı, momentum değerleri sabit tutularak en düşük hata oranına sağlayacak iterasyon sayısı bulunmuştur. Bunun için de iterasyon sayısı 20, 30, 50, 100, 150, 200,250 ve 300 olacak şekilde denemeler yapılmıştır.

İterasyon sayısı 100 ve 300 olduğunda performans göstergeleri örnek olarak Tablo 4.23.'de listelenmiştir. Tüm performans göstergelerinin detaylı sonuçları Ek E'de bulunmaktadır.


Tablo 4.23. İterasyon sayısı 100 ve 300 olduğunda ürün gruplarının hata oranları

İterasyon Sayısı	Ürün Grupları	RMSE	MSE	MAPE
100	X40-X39	0,549	0,301	26,295
	X39-X89	0,470	0,221	8,809
	X40-X8	0,232	0,054	5,052
	X39-X8	0,459	0,211	19,766
	X40-X89	0,494	0,244	7,083
	X8-X89	0,122	0,015	15,701
	X194-X193	0,255	0,065	13,172
300	X40-X39	0,551	0,304	24,658
	X39-X89	0,471	0,222	8,965
	X40-X8	0,171	0,029	3,256
	X39-X8	0,458	0,210	19,555
	X40-X89	0,503	0,253	9,499
	X8-X89	0,119	0,014	6,835
	X194-X193	0,235	0,055	13,315


İterasyon sayısının etkisini incelemek için Şekil 4.18.'deki algoritma tüm ürün grupları için çalıştırılmış ve Şekil 4.21.'de hata oranları grafikler ile gösterilmiştir.



(a)



(b)



(c)

Şekil 4.21. Yapay sinir ağırları iterasyon sayısına göre performans sonuçları

MSE, MAPE, RMSE performans sonuçlarına bakıldığında en düşük hata oranını gösteren iterasyon sayısı 300 olduğu Şekil 4.21.'de gösterilmiştir. Bu durumda ürün

gruplarının sipariş miktarlarını hesaplamak için kullanılması gereken parametre listesi Tablo 4.24.'de listelenmiştir.

Tablo 4.24. Yapay sinir ağı parametreleri

Parametreler	Değerler
Gizli katman sayısı	10
İterasyon sayısı	300
Öğrenme hızı	0,3
Momentum	0,5

Rapidminer'da çalıştırılan algoritma sonucunda ortaya çıkan performans sonuçları Tablo 4.25.'de gösterilmiştir.

Tablo 4.25. Ürün gruplarının istatistik hata oranları

Ürün Grupları	RMSE	MSE	MAPE
X40-X39	0,551	0,304	24,658
X39-X89	0,471	0,222	8,965
X40-X8	0,171	0,029	3,256
X39-X8	0,458	0,210	19,555
X40-X89	0,503	0,253	9,499
X8-X89	0,119	0,014	6,835
X194-X193	0,235	0,055	13,315

Bu parametrelere göre her ürün grubunun satış tahminlemesinin yapılması için her bir girdi ve çıktı değerleri normalize edilmiştir. Sistem çıktı sonuçlarını normalize bir değer şeklinde verdiği için bu değerleri gerçek rakama dönüştüreceğiz. Bu kapsamda normalize için kullanılan denklem aşağıdaki gibidir;

$$X' = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (4.8)$$

X': Normalize değer

X: Normalize edilecek değer

X_{min}: Veri setindeki en küçük değer

X_{max}: Veri setindeki en büyük değer

Tahminleme için kullanılan örnek veri seti Tablo 4.26.'de listelenmiştir. Detaylı veri seti Ek F'de verilmiştir.

Tablo 4.26. X40-X39 ürünlerinin aylık sipariş miktarları

Ay	Sipariş Sayısı	X40-X39
Ocak 2016	1633	151
Şubat 2016	1528	173
Mart 2016	1021	109
Nisan 2016	1690	73
Mayıs 2016	1923	88
Haziran 2016	1747	104
Temmuz 2016	1747	80
Ağustos 2016	1551	85
Eylül 2016	1616	164
Ekim 2016	1960	192
Kasım 2016	1477	163
Aralık 2016	1531	126
Ocak 2017	1500	88
Şubat 2017	2000	93
Mart 2017	2500	80
Nisan 2017	1500	90
Mayıs 2017	1000	100
Haziran 2017	1500	70
Temmuz 2017	1250	75
Ağustos 2017	1500	83
Eylül 2017	1200	391

Örnek olarak ilk ürün grubu olan X40-X39 ürünleri için sistemi çalıştırıldığında çıkan sonuçlar Tablo 4.27.'de verilmiştir.

Tablo 4.27. X40-X39 ürünlerinin normalize değerleri

Ay	X40-X39_Norm	X40-X39 (Tahmini)	Sipariş Sayısı_Norm
Temmuz 2017	0,016	0,046	0,167
Ağustos 2017	0,040	0,044	0,333
Eylül 2017	1,000	0,046	0,133
Ekim 2017	?	0,046	0,037
Kasım 2017	?	0,042	0,385
Aralık 2017	?	0,046	0,093
Ocak 2018	?	0,040	0,435
Şubat 2018	?	0,038	0,469
Mart 2018	?	0,046	0,065
Nisan 2018	?	0,034	0,518
Mayıs 2018	?	0,042	0,379
Haziran 2018	?	0,043	0,357

X40-X39 tahmini norm değerleri gerçek değerlere dönüştürmek için Denklem 4.8'in tam tersi kullanılmıştır. Yukarıdaki veri setindeki minimum ve maksimum değerler bulunur. Örnek olarak ekim ayının tahmini satış miktarını bulalım.

$$X_{\min}: 70$$

$$X_{\max}: 391$$

$$X = [(X_{\max} - X_{\min}) * X'] + X_{\min} \quad (4.9)$$

X (Ekim ayının değeri) = $[(391 - 70) * 0,046] + 70 = 85$ şeklinde bulunur.

Bu işlem tüm aylar için yapıldığında sipariş sayısı aşağıdaki gibi listelenebilir;

Tablo 4.28. X40-X39 ürünleri için aylık tahmin sipariş sayısı

Ay	X40-X39 (Tahmini)	Sipariş Sayısı_Norm	X40-X39 Tahmini Sipariş Sayısı
Ekim 2017	0,046	0,037	85
Kasım 2017	0,042	0,385	84
Aralık 2017	0,046	0,093	85
Ocak 2018	0,040	0,435	83
Şubat 2018	0,038	0,469	82
Mart 2018	0,046	0,065	85
Nisan 2018	0,034	0,518	81
Mayıs 2018	0,042	0,379	84
Haziran 2018	0,043	0,357	84

Belirlenen 7 ürün grubu için tüm bu işlemler yapıldığında gelecek aylar için tahmini sipariş sayıları Tablo 4.29.'da gösterilmiştir.

Tablo 4.29. Belirlenen ürün gruplarının aylık tahmini sipariş miktarları

Ay	Sipariş Sayısı	X40- X39	X39- X89	X40- X8	X39- X8	X40- X89	X8- X89	X194- X193
Ekim 2017	1055	85	64	86	78	45	67	39
Kasım 2017	1577	84	60	84	79	52	63	53
Aralık 2017	1139	85	63	86	78	46	67	41
Ocak 2018	1652	83	59	84	79	52	62	55
Şubat 2018	1704	82	59	84	79	52	61	57
Mart 2018	1097	85	64	86	78	46	67	40
Nisan 2018	1777	81	58	86	80	51	60	57
Mayıs 2018	1569	84	60	84	79	52	63	52
Haziran 2018	1535	84	60	84	79	51	63	51
Ortalama	1456	83	61	85	79	50	64	50

Ürün gruplarına göre performans sonuçları Tablo 4.30.'da listelenmiştir.

Ürün Grupları	RMSE	MSE	MAPE
X40-X39	0,551	0,304	24,658
X39-X89	0,471	0,222	8,965
X40-X8	0,171	0,029	3,256
X39-X8	0,458	0,210	19,555
X40-X89	0,503	0,253	9,499
X8-X89	0,119	0,014	6,835
X194-X193	0,235	0,055	13,315

Tablo 4.30.'daki istatistiksel hata oranları literatüre göre çok yüksektir. Bu yüzden yapay sinir ağları ile gerçeği temsil ettiği kanıtlanamamıştır. Yeni pilot süreci için belirlenen 7 ürün grubu için gelecek 6 ay içinde satışlarının geleceği öngörülmektedir. 6 ay sonra gerçek veriler ile tekrar analiz yapıldığında yapay sinir ağ algoritmasının doğruluğu da ölçülebilir olacaktır. Görüldüğü gibi internet satışları için sabit bir durumdan bahsetmek doğru olamaz bu bağlamda bu tarz analizlerin belirli periyotlar ile yapılması gerekir.

E-ticaret firmalarının günlük olarak siparişlerinin depodan çıkması beklenen bir hedeftir. Fakat beklenen hedefin tutturulamaması sebeplerinin başında stokların kaybolması ve sipariş hacminin yüksek olması gelebilir. Firmalar verimliliklerini, karlılıklarını arttırabilmesi için veri madenciliği yöntemlerine başvurulabilir. Veri madenciliği mevcut durumun analizi ya da gelecek tahmini yapılması için kullanılabilir. Örnek olarak bir otomotiv sektöründe bir yetkili servisin karını artırması için müşterilerin satış verileri birliktelik kuralları ile incelenerek firmanın promosyonlara yönelmesine yardımcı olmuştur [26]. Bu çalışmada e-ticaret sektöründe satışı fazla olan alçak raf ürünlerinin, ikili gruplar halinde bulunması için, birliktelik kuralları uygulanmış ve belirlenen ürün grupları ön paket sürecinden geçirilerek raflara yerleştirilmiştir. Bu tarz çalışmalarda ürün tipinin doğru seçilmesi gerekir. Örneğin bir temizlik malzemesi ile bir ev eşyası beraber ön paketleme yapılması doğru olmaz. Bu yüzden de çalışmada alçak raf ürünleri olarak tanımlanan küçük ev eşyaları olarak nitelendirilebilecek (mum, askılık, bebek eşyaları vs.) ürünler seçilmiştir. Apriori, FP-Growth ve Carma algoritmaları sonuçlarının birbirlerine karşı

üstünlükleri yerine hangisinin gerçeğe daha yakın sonuçlar verdiği karşılaştırılmıştır. Literatürde genellikle teorik olarak birbirleri ile olan üstünlükleri karşılaştırılmıştır [21,23,27,31,33]. Yapılan çalışmada Apriori ve Carma algoritmaları aynı sonucu vermiştir. Bu çerçevede eşik değerinin etkili olduğu gösterilmiş ve literatürde de 2009 yılında Huang ve arkadaşları tarafından yapılan çalışma ile de kanıtlanmıştır [27]. Literatürdeki çalışmalar genellikle hizmet sektöründe ya da teorik olarak yapılan çalışmalar olup bu çalışma gerçek bir proje olarak bir firmanın operasyonel iyileştirme için birliktelik kurallarının kullanılabileceği gösterilmiş ve maliyet/zaman hesaplamaları ile kanıtlanmıştır. Yapay sinir ağları ile satış tahmini yapılmıştır. İlk olarak iterasyon sayısı, öğrenme katsayısı ve momentum değerleri sabit tutularak gizli katman sayısının sistemi nasıl etkilediği gösterilmiştir. En düşük hata oranı veren (MAPE, MSE ve RMSE) gizli katman sayısı bulunmuştur. İkinci aşama olarak da gizli katman sayısı, öğrenme katsayısı ve momentum sabit tutularak iterasyon sayısının etkisi gösterilmiştir. Ortak küme olarak bulunan iterasyon sayısı, gizli katman sayısı, öğrenme katsayısı ve momentum değerlerine göre ürün gruplarının MSE, MAPE ve RMSE değerleri bulunmuştur. Bu istatistik değerler literatürün yukarısında kaldığı için gerçeği temsil ettiği söylenemez. Literatürdeki çalışmalarda örneğin RMSE değeri en yüksek %2 çıkması gerekirken bu çalışmada ortalama %37 çıkmıştır [40]. Literatürdeki diğer çalışmalar ile ortak olarak müşterilerin satın aldığı ürünlerin baz alınarak sorunların çözümlenmesidir. Örneğin market analizinde beraber satılan ürünlerin aynı raflara ya da yakın lokasyonlara konulması müşterilerin faydasına olabilecek iken bu çalışmada son kullanıcıyı etkileyen faktör konusunda kesinlik bulunmamaktadır.

BÖLÜM 5. SONUÇLAR

Teknolojinin hızla değişmesi ve pazardaki rekabet ortamı firmaların süreçlerini değiştirmesine sebep olmaktadır. Firmalar hem maliyetlerini azaltmaya hem de daha kaliteli hizmet vermek için çalışmalar yapmaktadır. Perakende ve e-ticaret hizmeti veren firmalar veri madenciliği yöntemlerini kullanarak satış tahminlemesi yapmaktadır. Yapılan bu tahminler maliyet çalışmalarında kullanılmaktadır. Verimli bir sonuç çıkması sonucunda operasyonel iyileşmeler yapılmaktadır. Firmaya önerilen sistemle maliyetin ürün başına 1,41 TL düşmesi beklenmektedir. Aynı şekilde operasyonel sürecinde toplamda 3,54 dk. azalma olması beklenmektedir. Ürün grupları bulunurken birliktelik kuralları algoritma sonuçları 9. ay satış verileri ile karşılaştırılmıştır. En iyi sonucu veren Apriori algoritması ile oluşan ürün grupları bir arada demet halinde raflara yerleştirildi. Bu önerilen sistem yeni yıla kadar pilot çalışma olarak düşünülecek ve sonrasında kalıcı bir operasyon olarak hayata geçirilecektir. Kalıcı olarak düşünüldüğü için belirlenen ürün gruplarının gelecek siparişlerde yer alma durumu yapay sinir ağlarının tahmin işlevinden yararlanılarak incelenmiştir. Kurulan algoritma ile ürün gruplarının satış tahmini yapılmaya çalışılmıştır. Literatürdeki çalışmalarda genellikle sentetik veri ile çalışılmış olup, bu çalışmada gerçek proje verileri kullanılarak bir firmanın depo sürecini iyileştirmek için birliktelik kurallarının kullanılabileceğini göstermiştir. En iyi sonucu veren algoritmanın doğruluğu zaman etüdü ve maliyete etkisi ile kanıtlanmıştır. Buna ek belirlenen eşik değerin algoritmalar için önemi gösterilmiştir. Birliktelik kuralları firmanın diğer bölümlerinde uygulanırsa, operasyon süreçlerinde daha iyi bir performans alınabileceği öngörülmektedir. Önerilen sistem ile raflar arasında bölmeli araçlar toplamada kullanılabilir böylelikle belirli siparişler için ayrıştırma süreci ortadan kalkabilir. Bu analiz sonuçlarına göre en çok satılan ürünlerin daha alt katlara ve yakın raflara konulabilir. Personellerin ergonomik sorunlarının azalması için

eriřimi daha kolay olan raflara ürünler koyulabilir. E-ticaret sektörü dinamik olduđu için belirli aralıklarla bu analizin yenilenmesi gerektiđi unutulmamalıdır.



KAYNAKLAR

- [1] <https://www.scopus.com/home.uri> Eriřim Tarihi: 08.05.2018.
- [2] Alpaydın E.,”Zeki Veri Madencilięi: Ham Veriden Altın Bilgiye Ulařma Yöntemleri”, Biliřim 2000 Eęitim Semineri, 1-3,2000.
- [3] Özmen řule,” İř Hayatı Veri Madencilięi İle İstatistik Uygulamalarını Yeniden Keřfediyor”,2002.
- [4] Akpınar Haldun, “Veri Tabanlarında Bilgi Keřfi Ve Veri Madencilięi”, 2000.
- [5] Kalikov A.,”Veri Madencilięi Ve Bir E-Ticaret Uygulaması, Yüksek Lisans Tezi, Gazi Üniversitesi, Fen Bilimleri Enstitüsü,2006.
- [6] Maimon Oded, Rokach Lior,”Data Mining And Knowledge Discovery Handbook”, Springer Usa,2010.
- [7] Berthold Michael R.,Borgelt Christian, Hoppner Frank,Klawonn Frank, “Guide To Intelligent Data Analysis”, Springer-Verlag,London,2010.
- [8] Ağyar Zafer, “Yapay Sinir Ağlarının Kullanım Alanları Ve Bir Uygulama”, Tmmob Makine Mühendisleri Odası Mühendis Ve Makine Dergisi, (Mmo), Cilt 56, Sayı 662, 22-23, 2015.
- [9] Saporta Gilbert, “Data Mining And Official Statistics”, Quinta Conferenza Nazionale Di Statistica, Syf.15-17,Roma,2000.
- [10] Sumathi S.,Sivanandam S.N., “Introduction To Data Mining And Its Applications”,Springer-Verlag Berlin Heidelberg,2006.
- [11] Larose T.Daniel,Larose Chantal D. “Discovering Knowledge İn Data: An Introduction To Data Mining”, John Wiley&Sons, 2005.
- [12] Hudary H.,”Data Mining And Decision Making Support İn The Governmental Sector”, Faculty Of Graduate School Of The University Of Louisville Master Degree Thesis,Kentucky,USA,2004.
- [13] [www. acikerisim.aku.edu.tr](http://www.acikerisim.aku.edu.tr) Eriřim Tarihi:06.11.2017.

- [14] Zantinge Dolf, Adrianns Pieter, “Data Mining”, Addison-Wesley Professional, Usa,1996.
- [15] Goebel Michael, Gruenwald Le, “A Survey Of Data Mining And Knowledge Discovery Software Tools”, Acm Sıgkdd Explorations Newsletter,Syf. 20-33, 1999.
- [16] Brin Sergey, Motwani Rajeev, Silverstein Craig, “Beyond Market Baskets: Generalizing Association Rules”, Acm Sıgmod, 265-276,Usa,1997.
- [17] Agrawal Rakesh, Imelınskı Tomasz, Swamı Arun, “Mining Association Rules Between Sets Of Items In Large Databases”, Proceedings Of The Acm Sıgmod,2017-2016, Usa,1993.
- [18] Houtsma M., Swamı W.,”Set-Oriented Mining For Association Rules In Relational Databases”, 11th International Conference On Data Engineering,Taipei,1995.
- [19] Agrawal Rakesh, Srikant Ramakrishnan,”Fast Algorithms For Mining Association Rules”, Proceedings Of The 20th International Conference Very Large Databases, 478-499,1994.
- [20] Kiremitçi Barış, "Veri Ambarlarında Veri Madenciliği Ve Ulaştırma- Lojistik Sektöründe Bir Uygulama", İstanbul Üniversitesi Sosyal Bilimler Enstitüsü Sayısal Yöntemler Yüksek Lisans Tezi, İstanbul,2005.
- [21] Erpolat Yrd. Doç.Dr Semra, “Otomobil Yetkili Servislerinde Birliktelik Kurallarının Belirlenmesinde Apriori Ve Fp-Growth Algoritmalarının Karşılaştırılması”, Anadolu Üniversitesi Sosyal Bilimler Dergisi, 137,Cilt 12,Sayı1,2012.
- [22] Aksaraylı Mehmet, Bayyurt Dilara, “Veri Madenciliği Teknikleri İle Seçimli Ders Eğilimlerine İlişkin Veri Desenlerin Belirlenmesi”, Research Gate, 260-269,2016.
- [23] Borgelt Christian, “An Implementation Of The Fp-Growth Algorithm”, Proceedings Of The 1st International Workshop On Open Source Data Mining: Frequent Pattern Mining Implementations,1-5,2015.
- [24] Doğan, B., Erol, B., Buldu, A. “Sigortacılık Sektöründe Müşteri İlişkileri Yönetimi İçin Birliktelik Kurallarının Kullanılması”, Marmara Fen Bilimleri Dergisi, 3, 105-114,2014.
- [25] Doğrul, G., Akay, D., Kurt, M., “Trafik Kazalarının Birliktelik Kuralları İle Analizi”, Gazi Mühendislik Bilimleri Dergisi, 1(2),265-284,2015.

- [26] Gülce Ali Cenk, Veri Madenciliğinde Apriori Algoritması Ve Apriori Algoritmasının Farklı Veri Kümelerinde Uygulanması, Trakya Üniversitesi Fen Bilimleri Enstitüsü,2010.
- [27] Huang Yuan, Wang Xing, Shia Ben- Chang,” Efficiency And Consistency Study On Carma”, 2009 Fifth International Joint Conference On Inc, Ims And Idc,2009.
- [28] Kılınç Yasemin., “Mining Association Rules For Quality Related Data In An Electronics Company”, Orta Doğu Teknik Üniversitesi Endüstri Mühendisliği,2009.
- [29] Lin R.H, “Potential Use Of Fp-Growth Algorithm For Identifying Competitive Suppliers In Scm”, Journal Of The Operatioal Research Socienty, Sayfa 1135-1141,2009.
- [30] Mayılvganan Dr.M, Kalpanadevi D. “Comparision Of Aprior, Fp-Growth And Fuzzy Fp-Growth Algorithm For Generating Association Rule Mining Of Cognitive Skill”, International Journal Of Engineering Research And General Science, 2091-2730,2018.
- [31] Mostafaei S., Shakouri H.,Ghodsı R.,”New Approaches To Analyze Gasoline Rationing”, Journal Of Ai And Data Mining,Vol 6,No 1, 177-190, 2017.
- [32] Pınheiro Fabiola, Kuo Mu-Hsing, Thomo Alex, Barnett Jeff, “Extracting Association Rules From Liver Cancer Data Using The Fp-Growth Algorithm”, The Institute Of Electrical And Electronics Engineers,2013.
- [33] Sağın Ayşe Nur, Ayvaz Berk, “Determination of Association Rules with Market Basket Analysis: An Application in the Retail Sector “, Southeast Europe Journal of Soft Computing Vol.7 No.1, p 10-19, 2018.
- [34] Yıldız Barış, “ Impacts Of Frequent Itemset Hiding Algorithms On Privacy Preserving Data Mining”, İzmir İleri Teknoloji Enstitüsü Bilgisayar Mühendisliği, 2010.
- [35] Döşlü Ayhan, “Veri Madenciliğinde Market Sepet Analizi Ve Birliktelik Kurallarının Belirlenmesi”, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Tezi, İstanbul,2008.
- [36] Yıldırım Muhammet, “İldeki Kurumlar Arasında Çalışma Performansının Artırılması Ve Veri Madenciliği Tekniklerinin Kullanılması”, Fırat Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Tezi, Elazığ,2006.
- [37] Çelik Ufuk, AKÇETİN Eyüp, Gök Murat,”Rapidminer ile Uygulamalı Veri Madenciliği”, 1.Baskı, Pusula 20 Teknoloji ve Yayıncılık A.Ş.,İstanbul,130-131,2017.

- [38] Erdem Mehmet Bilgehan, "İnternet Ortamındaki Tüketicilerin Demografik Tabanlı Modellenmesi ve Ürün Profillerinin Oluşturulması", Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği, Yüksek Lisans Tezi, Sakarya,2009.
- [39] Uslu Metin, "Yapay Sinir Ağları ile Sınıflandırma", Hacettepe Üniversitesi, Fen Fakültesi, İstatistik Bölümü, İleri İstatistik Projeleri 1,Ankara,2013.
- [40] Kiraz Alper, Canpolat Onur, Erkan Enes Furkan, Uygun Özer, "Artificial Neural Networks Modeling for The Prediction of Pb(II) Adsorption", Islamic Azad University, International Journal of Environmental Science and Technology,2018.
- [41] <http://yazilimagiris.com/2017/11/hata-oranlari/?print=print> Erişim Tarihi: 20.02.2019.
- [42] <https://veribilimcisi.com/2017/07/14/mse-rmse-mae-mape-metrikleri-nedir/> Erişim Tarihi:02.02.2019.
- [43] Ceylan Gülden, "Yapay Sinir Ağları ile Kısa Dönem Yük Tahmini", İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik Mühendisliği, İstanbul, 2004.

EKLER

EK A: SPSS programı ile bulunan Apriori algoritmasının tüm sonuçları;

Grup Sayısı	Ürün 1	Ürün 2	Geçme Sayısı	1. Ürünün Geçme Sayısı	2. Ürünün Geçme Sayısı
1	X40	X39	521	525	523
2	X40	X8	481	525	500
3	X39	X8	480	523	500
4	X40	X89	257	525	280
5	X39	X89	257	523	280
6	X8	X89	248	500	280
7	X194	X193	126	168	163
8	X116	X119	107	155	141
9	X117	X114	82	200	100
10	X117	X326	79	200	110
11	X217	X460	75	163	147
12	X37	X183	63	150	133
13	X37	X34	62	150	89
14	X117	X171	61	200	117
15	X326	X114	60	110	100
16	X183	X362	58	133	58
17	X20	X460	56	152	147
18	X460	X19	54	147	93
19	X21	X347	50	81	76
20	X20	X80	49	152	114
21	X217	X80	49	163	114
22	X216	X347	49	121	76
23	X255	X256	48	48	48
24	X20	X19	45	152	93
25	X216	X21	44	121	81
26	X37	X626	43	150	43
27	X363	X364	42	43	42
28	X171	X114	40	117	100
29	X171	X326	39	117	110
30	X217	X19	39	163	93
31	X3	X1	38	135	51
32	X125	X527	37	74	47
33	X125	X227	37	74	58
34	X217	X216	37	163	121
35	X217	X21	37	163	81
36	X194	X116	36	168	155
37	X20	X21	33	152	81
38	X365	X363	33	73	43
39	X227	X527	33	58	47

40	X460	X80	33	147	114
41	X567	X568	33	39	33
42	X365	X364	33	73	42
43	X39	X199	32	523	52
44	X40	X199	32	525	52
45	X302	X304	32	67	42
46	X8	X199	32	500	52
47	X217	X347	32	163	76
48	X374	X375	31	87	52
49	X20	X239	31	152	65
50	X216	X80	30	121	114
51	X3	X50	29	135	48
52	X119	X779	28	141	69
53	X125	X300	28	74	47
54	X19	X21	28	93	81
55	X89	X199	28	280	52
56	X255	X1012	27	48	27
57	X256	X1012	27	48	27
58	X529	X530	27	47	29
59	X3	X620	26	135	60
60	X227	X300	26	58	47
61	X217	X239	26	163	65
62	X193	X116	25	163	155
63	X1004	X996	25	39	34
64	X8	X7	24	500	48
65	X20	X347	24	152	76
66	X460	X216	24	147	121
67	X34	X1299	23	89	24
68	X37	X625	23	150	23
69	X39	X7	23	523	48
70	X626	X625	23	43	23
71	X217	X20	23	163	152
72	X40	X7	23	525	48
73	X256	X257	22	48	22
74	X3	X680	22	135	35
75	X149	X154	22	29	23
76	X255	X257	22	48	22
77	X216	X239	22	121	65
78	X473	X1314	22	29	24
79	X193	X779	21	163	69
80	X529	X296	21	47	23
81	X460	X239	21	147	65
82	X447	X30	20	62	36
83	X527	X300	20	47	47
84	X116	X779	20	155	69
85	X34	X625	20	89	23
86	X34	X626	20	89	43
87	X626	X1050	20	43	20
88	X221	X219	20	57	26
89	X37	X1050	20	150	20
90	X529	X1745	20	47	29
91	X149	X316	19	29	22
92	X840	X838	19	29	24
93	X373	X2556	18	38	21
94	X64	X61	18	58	18
95	X120	X727	18	35	27
96	X259	X738	18	31	25
97	X460	X657	18	147	23

98	X347	X239	18	76	65
99	X216	X19	17	121	93
100	X89	X7	17	280	48
101	X315	X316	17	23	22
102	X40	X1112	17	525	25
103	X8	X1112	17	500	25
104	X259	X254	17	31	20
105	X20	X216	17	152	121
106	X80	X21	17	114	81
107	X80	X347	17	114	76
108	X996	X1442	17	34	23
109	X1004	X998	17	39	23
110	X183	X626	17	133	43
111	X39	X1112	17	523	25
112	X183	X1050	17	133	20
113	X154	X152	16	23	16
114	X154	X312	16	23	19
115	X950	X1322	16	38	19
116	X132	X426	16	50	45
117	X116	X200	16	155	39
118	X478	X567	16	70	39
119	X149	X312	16	29	19
120	X194	X119	16	168	141
121	X1004	X729	16	39	20
122	X194	X779	16	168	69
123	X478	X568	16	70	33
124	X460	X474	15	147	25
125	X4	X6	15	15	15
126	X194	X200	15	168	39
127	X460	X21	15	147	81
128	X117	X18	15	200	110
129	X460	X347	15	147	76
130	X5	X6	15	15	15
131	X149	X315	15	29	23
132	X779	X200	15	69	39
133	X117	X1249	15	200	21
134	X149	X152	15	29	16
135	X164	X961	15	62	53
136	X4	X5	15	15	15
137	X253	X258	15	24	21
138	X1004	X1442	15	39	23
139	X531	X528	15	49	30
140	X996	X998	15	34	23
141	X426	X1390	15	45	37
142	X397	X385	15	55	55
143	X315	X314	14	23	15
144	X221	X1100	14	57	15
145	X21	X239	14	81	65
146	X38	X967	14	23	15
147	X316	X319	14	22	15
148	X998	X545	14	23	18
149	X54	X57	14	48	36
150	X154	X316	14	23	22
151	X312	X152	14	19	16
152	X1071	X1072	14	21	17
153	X996	X997	14	34	24
154	X183	X1698	14	133	19
155	X13	X1947	13	32	13

156	X593	X141	13	50	26
157	X132	X1390	13	50	37
158	X997	X998	13	24	23
159	X404	X403	13	24	24
160	X1044	X401	13	30	26
161	X1442	X537	13	23	18
162	X149	X319	13	29	15
163	X64	X1509	13	58	13
164	X1004	X997	13	39	24
165	X401	X403	13	26	24
166	X193	X115	13	163	28
167	X316	X314	13	22	15
168	X316	X312	13	22	19
169	X216	X346	13	121	38
170	X1745	X530	13	29	29
171	X54	X55	13	48	23
172	X120	X1384	12	35	19
173	X529	X696	12	47	13
174	X171	X18	12	117	110
175	X8	X1042	12	500	20
176	X171	X713	12	117	27
177	X315	X319	12	23	15
178	X89	X1112	12	280	25
179	X171	X418	12	117	23
180	X3	X1765	12	135	17
181	X19	X347	12	93	76
182	X373	X1312	12	38	16
183	X319	X314	12	15	15
184	X325	X328	12	35	30
185	X302	X54	12	67	48
186	X154	X315	12	23	23
187	X791	X1819	12	31	15
188	X727	X1384	12	27	19
189	X167	X811	12	29	15
190	X401	X404	12	26	24
191	X149	X314	12	29	15
192	X997	X1001	11	24	11
193	X1004	X545	11	39	18
194	X253	X2717	11	24	12
195	X88	X250	11	39	36
196	X1061	X1309	11	35	26
197	X7	X1112	11	48	25
198	X231	X686	11	37	33
199	X996	X729	11	34	20
200	X996	X545	11	34	18
201	X54	X56	11	48	28
202	X805	X2631	11	34	11
203	X13	X14	11	32	12
204	X256	X589	11	48	11
205	X160	X720	11	32	22
206	X255	X589	11	48	11
207	X40	X1042	11	525	20
208	X194	X115	11	168	28
209	X1069	X1035	11	71	36
210	X1154	X692	11	26	26
211	X362	X361	11	58	14
212	X167	X182	11	29	13
213	X39	X325	11	523	35

214	X39	X1042	11	523	20
215	X347	X346	11	76	38
216	X37	X64	11	150	58
217	X326	X713	11	110	27
218	X8	X325	11	500	35
219	X362	X1698	11	58	19
220	X18	X114	11	110	100
221	X216	X1114	11	121	25
222	X37	X76	11	150	13
223	X57	X56	11	36	28
224	X1745	X296	11	29	23
225	X183	X361	11	133	14
226	X117	X713	11	200	27
227	X468	X464	11	23	17
228	X315	X312	11	23	19
229	X312	X319	11	19	15
230	X545	X542	11	18	15
231	X870	X871	11	13	11
232	X998	X730	11	23	15
233	X729	X730	11	20	15
234	X40	X325	11	525	35
235	X996	X537	10	34	18
236	X782	X1281	10	36	12
237	X782	X894	10	36	13
238	X208	X184	10	36	29
239	X217	X116	10	163	155
240	X250	X251	10	36	23
241	X154	X319	10	23	15
242	X528	X663	10	30	25
243	X1745	X84	10	29	27
244	X29	X452	10	32	15
245	X193	X20	10	163	152
246	X250	X29	10	36	32
247	X1004	X995	10	39	19
248	X34	X33	10	89	10
249	X217	X459	10	163	30
250	X1466	X1712	10	22	10
251	X114	X713	10	100	27
252	X316	X152	10	22	16
253	X326	X1249	10	110	21
254	X37	X942	10	150	10
255	X183	X1849	10	133	18
256	X729	X995	10	20	19
257	X529	X84	10	47	27
258	X37	X33	10	150	10
259	X149	X148	10	29	11
260	X86	X87	10	28	17
261	X117	X119	10	200	141
262	X37	X988	10	150	10
263	X37	X100	10	150	10
264	X460	X346	10	147	38
265	X2673	X2671	10	14	10
266	X570	X1528	10	14	11
267	X397	X522	10	55	33
268	X1197	X1198	10	13	12

EK B: Rapidminer programı ile bulunan FP-Growth algoritması sonuçları;

Grup Sayısı	Ürün Sayısı	Ürün 1	Ürün 2	Ürün 3	Ürün 4	Ürün 5	Destek değeri
1	1	X3					0.987
2	1	X40					0.052
3	1	X39					0.052
4	1	X8					0.050
5	1	X89					0.028
6	1	X117					0.020
7	1	X194					0.017
8	1	X217					0.016
9	1	X193					0.016
10	1	X116					0.015
11	1	X20					0.015
12	1	X37					0.015
13	1	X460					0.015
14	1	X119					0.014
15	1	X183					0.013
16	1	X216					0.012
17	1	X171					0.012
18	1	X80					0.011
19	1	X326					0.011
20	1	X18					0.011
21	1	X114					0.010
22	2	X3	X40				0.052
23	2	X3	X39				0.052
24	2	X3	X8				0.050
25	2	X3	X89				0.028
26	2	X3	X117				0.020
27	2	X3	X194				0.017
28	2	X3	X217				0.016
29	2	X3	X193				0.016
30	2	X3	X116				0.015
31	2	X3	X20				0.015
32	2	X3	X37				0.015
33	2	X3	X460				0.015
34	2	X3	X119				0.014
35	2	X3	X183				0.013
36	2	X3	X216				0.012
37	2	X3	X171				0.012
38	2	X3	X80				0.011
39	2	X3	X326				0.011
40	2	X3	X18				0.011
41	2	X3	X114				0.010
42	2	X40	X39				0.052
43	2	X40	X8				0.048
44	2	X40	X89				0.026
45	2	X39	X8				0.048
46	2	X39	X89				0.026
47	2	X8	X89				0.025
48	2	X194	X193				0.013
49	2	X116	X119				0.011
50	3	X3	X40	X39			0.052
51	3	X3	X40	X8			0.048
52	3	X3	X40	X89			0.026

53	3	X3	X39	X8			0.048
54	3	X3	X39	X89			0.026
55	3	X3	X8	X89			0.025
56	3	X3	X194	X193			0.013
57	3	X3	X116	X119			0.011
58	3	X40	X39	X8			0.048
59	3	X40	X39	X89			0.026
60	3	X40	X8	X89			0.025
61	3	X39	X8	X89			0.025
62	4	X3	X40	X39	X8		0.048
63	4	X3	X40	X39	X89		0.026
64	4	X3	X40	X8	X89		0.025
65	4	X3	X39	X8	X89		0.025
66	4	X40	X39	X8	X89		0.025
67	5	X3	X40	X39	X8	X89	0.025



EK C: Apriori ve Carma algoritmaları excel makro kodlarıdır.

Sub veri()

Dim deger As String

Dim sayac As Integer

For a = 1 To 10000

sayac = 0

Do

sayac = sayac + 1

deger = Sayfa2.Cells(a, sayac)

If deger = "" Then

Exit Do

Else

For b = 1 To 26

If deger = Sayfa1.Cells(1, b) Then

Sayfa1.Cells(a + 1, b) = 1

'exit for

ElseIf Sayfa1.Cells(a + 1, b) <> 1 Then

Sayfa1.Cells(a + 1, b) = 0

End If

Next

End If

Loop

Next

End Sub



EK D: Yapay sinir ağlarında uygun parametrelerin bulunması için dinamik gizli katman sayısına göre analiz sonucunun listesi verilmiştir.

Katman Sayısı	Ürün Grupları	RMSE	MSE	MAPE
2	X40-X39	0,494	0,244	113,855
	X39-X89	0,517	0,267	15,031
	X40-X8	0,34	0,116	9,375
	X39-X8	0,477	0,228	21,268
	X40-X89	0,448	0,201	7,734
	X8-X89	0,123	0,015	6,977
	X194-X193	0,265	0,070	22,185
3	X40-X39	0,512	0,262	75,836
	X39-X89	0,522	0,272	15,450
	X40-X8	0,258	0,067	6,001
	X39-X8	0,461	0,213	19,770
	X40-X89	0,463	0,214	6,715
	X8-X89	0,12	0,014	6,351
	X194-X193	0,374	0,140	32,880
5	X40-X39	0,489	0,239	122,300
	X39-X89	0,523	0,274	15,774
	X40-X8	0,166	0,028	3,680
	X39-X8	0,528	0,279	24,980
	X40-X89	0,445	0,198	7,572
	X8-X89	0,377	0,142	22,914
	X194-X193	0,503	0,253	44,012
10	X40-X39	0,538	0,289444	35,337
	X39-X89	0,464	0,215296	7,983
	X40-X8	0,241	0,058081	4,895
	X39-X8	0,458	0,209764	19,449
	X40-X89	0,48	0,2304	9,494
	X8-X89	0,131	0,017161	7,676
	X194-X193	0,268	0,071824	16,723
20	X40-X39	0,467	0,218	185,544
	X39-X89	0,452	0,204	7,450
	X40-X8	0,437	0,191	12,400
	X39-X8	0,434	0,188	15,746
	X40-X89	0,439	0,193	8,281
	X8-X89	0,392	0,154	23,769
	X194-X193	0,471	0,222	40,794
30	X40-X39	0,533	0,284	47,804
	X39-X89	0,458	0,210	7,197
	X40-X8	0,167	0,028	3,337
	X39-X8	0,559	0,312	26,316
	X40-X89	0,493	0,243	9,838
	X8-X89	0,176	0,031	10,184
	X194-X193	0,264	0,070	17,750
50	X40-X39	0,535	0,286	50,885

	X39-X89	0,49	0,240	11,154
	X40-X8	0,13	0,017	2,499
	X39-X8	0,438	0,192	14,718
	X40-X89	0,473	0,224	7,254
	X8-X89	0,326	0,106	19,695
	X194-X193	0,261	0,068	21,864
100	X40-X39	0,484	0,234	143,514
	X39-X89	0,496	0,246	11,992
	X40-X8	0,53	0,281	15,382
	X39-X8	0,437	0,191	15,990
	X40-X89	0,434	0,188	9,427
	X8-X89	0,099	0,010	5,188
	X194-X193	0,352	0,124	31,064

EK E: Yapay sinir ağlarında uygun parametrelerin bulunması için dinamik iterasyon sayısına göre analiz sonucunun listesi verilmiştir.

İterasyon	Ürün Grupları	RMSE	MSE	MAPE
20	X40-X39	0,533	0,284	40,172
	X39-X89	0,459	0,211	7,381
	X40-X8	0,232	0,054	4,799
	X39-X8	0,458	0,210	19,523
	X40-X89	0,486	0,236	9,455
	X8-X89	0,136	0,018	8,062
	X194-X193	0,269	0,072	16,707
30	X40-X39	0,538	0,289	35,337
	X39-X89	0,464	0,215	7,983
	X40-X8	0,241	0,058	4,895
	X39-X8	0,458	0,210	19,449
	X40-X89	0,487	0,230	9,494
	X8-X89	0,131	0,017	7,676
	X194-X193	0,268	0,072	16,723
50	X40-X39	0,545	0,297	29,500
	X39-X89	0,467	0,218	8,495
	X40-X8	0,234	0,055	4,786
	X39-X8	0,458	0,210	19,557
	X40-X89	0,491	0,241	9,510
	X8-X89	0,126	0,016	7,366
	X194-X193	0,265	0,070	16,466
100	X40-X39	0,549	0,301	26,295
	X39-X89	0,47	0,221	8,809
	X40-X8	0,232	0,054	5,052
	X39-X8	0,459	0,211	19,766
	X40-X89	0,494	0,244	9,498
	X8-X89	0,122	0,015	7,083
	X194-X193	0,255	0,065	15,701
150	X40-X39	0,55	0,303	25,427
	X39-X89	0,47	0,221	8,895
	X40-X8	0,196	0,038	4,115
	X39-X8	0,459	0,211	19,710
	X40-X89	0,495	0,245	9,460
	X8-X89	0,121	0,015	6,963
	X194-X193	0,248	0,062	15,310
200	X40-X39	0,551	0,303	25,028
	X39-X89	0,471	0,221	8,933
	X40-X8	0,182	0,033	3,646
	X39-X8	0,459	0,21	19,643
	X40-X89	0,498	0,248	9,429
	X8-X89	0,12	0,014	6,897
	X194-X193	0,241	0,058	14,890
250	X40-X39	0,551	0,304	24,802

	X39-X89	0,471	0,222	8,953
	X40-X8	0,175	0,031	3,406
	X39-X8	0,458	0,21	19,594
	X40-X89	0,501	0,251	9,452
	X8-X89	0,119	0,014	6,859
	X194-X193	0,234	0,055	13,997
300	X40-X39	0,551	0,304	24,658
	X39-X89	0,471	0,222	8,965
	X40-X8	0,171	0,029	3,256
	X39-X8	0,458	0,21	19,555
	X40-X89	0,503	0,253	9,499
	X8-X89	0,119	0,014	6,835
	X194-X193	0,235	0,055	13,315



EK F: Yapay sinir ağı ile gelecek sipariş miktarları tahmininde kullanılan satış verisinin detaylı listesi aşağıdaki gibidir;

Ay	Sipariş Sayısı	X40-X39	X39-X89	X40-X8	X39-X8	X40-X89	X8-X89	X194-X193
Ocak 2016	1633	151	73	54	62	96	54	88
Şubat 2016	1528	173	34	88	94	81	98	79
Mart 2016	1021	109	74	90	94	55	98	80
Nisan 2016	1690	73	80	85	63	61	61	55
Mayıs 2016	1923	88	33	89	76	71	74	57
Haziran 2016	1747	104	40	90	94	52	63	75
Temmuz 2016	1747	80	60	87	81	55	65	89
Ağustos 2016	1551	85	60	89	59	84	88	62
Eylül 2016	1616	164	53	68	97	89	86	71
Ekim 2016	1960	192	37	87	84	70	74	68
Kasım 2016	1477	163	54	78	68	54	92	63
Aralık 2016	1531	126	55	83	70	87	79	99
Ocak 2017	1500	88	30	82	79	49	45	20
Şubat 2017	2000	93	55	93	83	43	43	15
Mart 2017	2500	80	45	80	80	35	35	23
Nisan 2017	1500	90	37	75	77	37	37	25
Mayıs 2017	1000	100	35	78	78	50	45	26
Haziran 2017	1500	70	55	73	83	43	43	17
Temmuz 2017	1250	75	66	89	50	20	55	30
Ağustos 2017	1500	83	67	85	60	63	70	80
Eylül 2017	1200	391	208	99	103	207	64	52
Ekim 2017	1055	85	64	86	78	45	67	39
Kasım 2017	1577	84	60	84	79	52	63	53
Aralık 2017	1139	85	63	86	78	46	67	41
Ocak 2018	1652	83	59	84	79	52	62	55
Şubat 2018	1704	82	59	84	79	52	61	57
Mart 2018	1097	85	64	86	78	46	67	40
Nisan 2018	1777	81	58	86	80	51	60	57
Mayıs 2018	1569	84	60	84	79	52	63	52
Haziran 2018	1535	84	60	84	79	51	63	51

ÖZGEÇMİŞ

İrem Deliismail, 27.11.1991 yılında İstanbul'da doğdu. Lise eğitimini 2010 yılında Kenan Evren Anadolu Lisesi'nde tamamladı. Sakarya Üniversitesi Endüstri Mühendisliği bölümünden mezun oldu. Atölye stajı olarak Sadıkoğlu Makina Tic. Ltd. Şti şirketinde çalıştı. Üretim stajını Ford Otosan A.Ş' de üretim planlama bölümünde yaptı. Uygulamalı mühendislik deneyimi eğitimi adlı proje bazlı çalışmasını Toyota Otomotiv AŞ'de Operation Management Development bölümünde yaptı. 2015 yılında başladığı yüksek lisans eğitimine Sakarya Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği bölümünde devam etmektedir. Şu anda halen iş analisti olarak çalışmaktadır.