DOKUZ EYLÜL ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

YEMEK SİPARİŞLERİNDE TÜKETİCİ DAVRANIŞININ BİRLİKTELİK KURALLARI İLE İNCELENMESİ

Halil Can KARADAŞ

Eylül, 2025

İZMİR

YEMEK SİPARİŞLERİNDE TÜKETİCİ DAVRANIŞININ BİRLİKTELİK KURALLARI İLE İNCELENMESİ

Dokuz Eylül Üniversitesi Fen Bilimleri Enstitüsü
Yüksek Lisans Tezi
İstatistik Anabilim Dalı, Veri Bilimi Programı

Halil Can KARADAŞ

Eylül, 2025
İZMİR

YÜKSEK LİSANS TEZİ SINAV SONUÇ FORMU

HALİL CAN KARADAŞ tarafından **PROF.DR. NESLİHAN DEMİREL** yönetiminde hazırlanan **"YEMEK SİPARİŞLERİNDE TÜKETİCİ DAVRANIŞININ BİRLİKTELİK KURALLARI İLE İNCELENMESİ"** başlıklı tez tarafımızdan okunmuş, kapsamı ve niteliği açısından bir Yüksek Lisans tezi olarak kabul edilmiştir.

.....

Prof.Dr. Neslihan DEMİREL

Danışman

.....	.....
Prof. Dr. Özlem EGE ORUÇ	Prof. Dr. Sevcan DEMİR ATALAY
Jüri Üyesi	Jüri Üyesi

Prof. Dr. Abdullah SEÇGİN

Müdür

Fen Bilimleri Enstitüsü

TEŞEKKÜR

Bu tez çalışmasının hazırlık sürecinde iletişimini hiçbir zaman koparmayan, bilgi ve tecrübeleriyle bana her an yol gösteren danışman hocam Sayın Prof. Dr. Neslihan Demirel'e ve her zaman yanımda olan aileme çok teşekkür ederim.

Halil Can KARADAŞ

YEMEK SİPARİŞLERİNDE TÜKETİCİ DAVRANIŞININ BİRLİKTELİK KURALLARI İLE İNCELENMESİ

ÖZ

Günümüzde teknolojinin hızla ilerlemesi, işletmelerin müşterilerine ilişkin çok çeşitli veri toplamasını mümkün kılmıştır. Bu verilerin işletmelerin stratejik karar alma süreçlerine katkı sağlaması için anlamlı bilgilere dönüştürülmesi gerekmektedir. Bu noktada veri madenciliği kavramı ön plana çıkmaktadır. Veri madenciliği, büyük ölçekli veri kümeleri içerisinde doğrudan gözlemlenemeyen örüntülerin ve ilişkilerin, ileri düzey matematiksel modeller ve istatistiksel analiz teknikleri aracılığıyla sistematik biçimde ortaya çıkarılmasını sağlayan bir bilgi keşfi sürecidir. Bu çalışmanın amacı, yemek siparişi alan bir işletmenin yoğun rekabet ortamında sürdürülebilirliğini sağlamak amacıyla, müşteri sipariş verilerinin dinamik bir web arayüzü üzerinden birliktelik kuralları ile analiz edilerek, menü önerileri oluşturmak ve geçmiş satış performansını değerlendirebileceği bir karar destek sistemi sunmaktır. Çalışmada, işletmeye ait Nisan 2023 ve Mart 2025 tarihleri arasındaki çevrimiçi sipariş kayıtları kullanılmıştır. R Shiny tabanlı geliştirilen web uygulaması, kullanıcıların verileri sisteme yüklemesine olanak tanıyarak, Apriori algoritması aracılığıyla anlamlı menü önerileri üretmekte ve geçmiş satış performansını istatistiksel yöntemlerle analiz edip ayrıntılı biçimde sunmaktadır. Apriori algoritmasında destek ve güven parametreleri, genetik algoritma kullanılarak dinamik biçimde optimize edilmiştir. Genetik algoritma parametrelerinin belirlenmesinde Çok Nitelikli Fayda Teorisi (MAUT) yöntemi kullanılmıştır. Bu sayede, veri setinde zaman içerisinde ortaya çıkan değişikliklere karşı işletmenin sürekli uzman müdahalesine ihtiyaç duymadan güncel ve anlamlı kural setlerine ulaşabilmesi sağlanmaktadır.

Anahtar kelimeler: Apriori algoritması, birliktelik kuralları, genetik algoritma, veri madenciliği, çok nitelikli fayda teorisi (MAUT), R Shiny web uygulaması

EXAMINING CONSUMER BEHAVIOR IN FOOD ORDERS WITH ASSOCIATION RULES

ABSTRACT

With the rapid advancement of technology, businesses have become able to collect a wide variety of customer-related data. In order for this data to contribute to the strategic decision-making processes of enterprises, it must be transformed into meaningful information. At this point, the concept of data mining comes to the forefront. Data mining is a knowledge discovery process that systematically reveals patterns and relationships that cannot be directly observed within large-scale datasets by means of advanced mathematical models and statistical analysis techniques. The aim of this study is to ensure the sustainability of a food delivery business operating in a highly competitive environment by analyzing customer order data through association rules via a dynamic web interface, thereby generating menu recommendations and providing a decision support system to evaluate past sales performance. The dataset used in this study consists of online order records from April 2023 to March 2025. The web application, developed on R Shiny, enables users to upload their data into the system, generate meaningful menu recommendations through the Apriori algorithm, and analyze past sales performance in detail using statistical methods. In the Apriori algorithm, support and confidence parameters are dynamically optimized by means of a genetic algorithm. The genetic algorithm parameters were determined using the Multi Attribute Utility Theory (MAUT). In this way, the enterprise can obtain up-to-date and meaningful rule sets in response to changes in the dataset over time without the need for continuous expert intervention.

Keywords: Apriori algorithm, association rules, genetic algorithm, data mining, multi attribute theory utility (MAUT), R Shiny web application

İÇİNDEKİLER

Sayfa

YÜKSEK LİSANS TEZİ SINAV SONUÇ FORMU ii
TEŞEKKÜR iii
ÖZ iv
ABSTRACT v
İÇİNDEKİLER vi
ŞEKİLLER LİSTESİ viii

BÖLÜM BİR - GİRİŞ 1

1.1 Literatür Taraması 2
1.2 Motivasyon ve Tezin Bölümleri 5

BÖLÜM İKİ - APRIORI ALGORİTMASI, GENETİK ALGORİTMA, MAUT VE R SHINY 7

2.1 Apriori Algoritması 7
2.1.1 Apriori Algoritması Parametreleri 8
2.1.3 Apriori Algoritmasının İşleyişi 9
2.2 Genetik Algoritma 12
2.2.1 Başlatma 13
2.2.2 Uygunluk Değerlendirmesi 14
2.2.3 Seçilim 14
2.2.4 Çaprazlama 16
2.2.5 Mutasyon 16
2.2.6. Yeni Nesil Oluşturma 17
2.2.7 Sonlandırma 17
2.3 R Shiny 17
2.4 Çok Nitelikli Fayda Teorisi (MAUT) 18

2.4.1 MAUT Metodunun Adımları 18

BÖLÜM ÜÇ - ANALİZ VE UYGULAMA 21

3.1 Veri Setinin İncelenmesi 21
3.2 Veri İşleme 22
3.2.1 Eksik Veri Tamamlama 23
3.2.2 Veri Temizliği ve Standartizasyon 23
3.2.3 Veri Düzenleme 23
3.3 Genetik Algoritma ile Parametre Belirleme 24
3.4 R Shiny Web Uygulaması 30
3.4.1 Veri Yükleme 31
3.4.2 Satış Analizi 31
3.4.3 Optimum Menü Belirleme 34

BÖLÜM DÖRT - DEĞERLENDİRME VE SONUÇ 41

KAYNAKLAR 43

ŞEKİLLER LİSTESİ

Sayfa

Şekil 2.1 Apriori algoritması sözde kodu 10

Şekil 2.2 Apriori algoritması birleştirme sözde kodu 11

Şekil 2.3 Apriori algoritması budama sözde kodu 11

Şekil 2.4 Genetik algoritma genel akış şeması (Turan, 2024) 13

Şekil 2.5 Örnek kromozom yapısı 14

Şekil 2.6 Örnek rulet tekeri yerleşimi 15

Şekil 2.7 Çaprazlama 16

Şekil 2.8 Mutasyon 17

Şekil 3.1 Siparişlerin içerdiği ürün sayıları 22

Şekil 3.2 Ham veri seti 22

Şekil 3.3 Apriori algoritması için düzenlenmiş veri seti 23

Şekil 3.4 Satış analizi için düzenlenmiş veri seti 24

Şekil 3.5 Apriori algoritması için parametre belirleme süreç akışı 25

Şekil 3.6 İki ürünlü menüler için entropi yöntemiyle hesaplanan kriter ağırlıkları ... 28

Şekil 3.7 Üç ürünlü menüler için entropi yöntemiyle hesaplanan kriter ağırlıkları ... 28

Şekil 3.8 Dört ürünlü menüler için entropi yöntemiyle hesaplanan kriter ağırlıkları 28

Şekil 3.9 MAUT analizinde kullanılan kriterlerin ürün sayısına göre dağılımları 29

Şekil 3.10 MAUT analizine göre en yüksek fayda değerine sahip 10 genetik algoritma parametre kombinasyonu 30

Şekil 3.11 R shiny veri yükleme ekranı 31

Şekil 3.12 R shiny çizgi grafiği 32

Şekil 3.13 R shiny sütun grafiği 33

Şekil 3.14 R shiny satış miktarı tablosu 34

Şekil 3.15 Kuralların örnek görseli 35

Şekil 3.16 Kuralların tablo ile örnek gösterimi 35

Şekil 3.17 İki ürünlü menülerin görselleri 36

Şekil 3.18 İki ürünlü menü kural listesi 36

Şekil 3.19 Üç ürünlü menülerin görseli 37

Şekil 3.20 Üç ürünlü menü kural listesi 38

Şekil 3.21 Dört ürünlü menülerin görseli 39

Şekil 3.22 Dört ürünlü menü kural listesi 39

Şekil 3.23 R shiny kural üretilemedi mesajı 40

Şekil 3.24 R shiny çalışıyor bilgi mesajı 40

Şekil 4.1 Uygulama süreç akış şeması 41

TABLOLAR LİSTESİ

Sayfa

Tablo 2.1 Apriori algoritması notasyonları 10

Tablo 3.1 Veri setindeki değişkenlere ait bilgiler 21

Tablo 3.2 MAUT methodu kombinasyonları 27

Tablo 3.3 Genetik algoritma parametreleri 30

BÖLÜM BİR
GİRİŞ

1990'lı yılların başına kadar perakende satış kayıtlarında çoğunlukla yalnızca parasal veriler saklanmakta, ürün ve müşteri düzeyindeki ayrıntılı bilgiler ise nadiren kaydedilmekteydi. Teknolojide yaşanan gelişmeler sayesinde satış noktalarında artık en küçük işletmeler bile verilerini çok kolay bir şekilde toplayıp, depolayabilir hale geldi (Gürgen, 2008). Bu sayede, yoğun rekabet koşulları altında karlılığını artırmak isteyen işletmeler, verilerini yalnızca kayıt tutma amacıyla değil aynı zamanda pazarlama stratejileri geliştirme ve müşteri içgörüsü oluşturma süreçlerinde de etkin biçimde kullanmaya başladılar.

Özellikle hizmet sektöründe faaliyet gösteren işletmelerde, yüksek sayıda farklı müşteri portföyü, manuel takip süreçlerini imkânsız hale getirmiştir. Üye hareketlerini analiz edemeyen işletmeler, geri bildirim mekanizmalarını etkin şekilde kullanamamakta; bu durum müşteri beklentilerinin karşılanamamasına ve mevcut müşteri kitlesinin kısa sürede fark edilmeden kaybedilmesine yol açmaktadır. Bu nedenle, son yıllarda işletmelerin üzerinde önemle durduğu konulardan biri, depolanan verilerin analizi ve bu analizlerden elde edilen bulguların stratejik kararlara dönüştürülmesidir. Analiz edilen veriler hem hizmet hem de üretim sektöründe faaliyet gösteren işletmelerin pek çok alanda performanslarını geliştirmelerine katkı sağlamaktadır. Dolayısıyla, mevcut veri kümelerinin anlamlı bilgilere dönüştürülmesi amacıyla çeşitli yöntem ve teknolojilerden yararlanılmaktadır. Bu noktada, alınacak kararların veriye dayalı olması büyük önem taşımaktadır.

Bununla birlikte, veri hacmindeki artış veri analiz sürecinin karmaşıklık düzeyini de artırmıştır. Bu durum verilerde saklı olan değerli bilgilerin ortaya çıkarılabilmesi için ileri düzey analiz yöntemlerinin etkin kullanımını zorunlu kılmaktadır (Jabarnejad, 2010). Bu bağlamda, artan veri hacminden anlamlı ve değerli bilgilerin sistematik biçimde elde edilebilmesi için geliştirilen yöntemler bütünü olan veri madenciliği ve bilgi keşfi kavramları önem kazanmaktadır.

Veri madenciliği ve bilgi keşfi söz konusu gereksinimleri karşılamak üzere geliştirilen yöntemler bütünüdür ve literatürde genellikle sınıflandırma, regresyon,

kümeleme ve birliktelik kuralı çıkarımı olmak üzere dört ana işlev altında toplanır. Bu yöntemler arasında öne çıkan birliktelik kuralı madenciliği ise veri kümelerinde gözle görülemeyen yakınlık ilişkilerini ortaya koymayı amaçlar (Jabarnejad, 2010).

Bu tez çalışmasının amacı ise geçmişe dönük verilerin analizini gerçekleştiren ve müşteri eğilimlerini belirleyerek menü önerileri sunan web tabanlı bir karar destek sistemi geliştirerek, işletmenin zorlu rekabet koşullarında sürdürülebilirliğini artırmasına katkıda bulunmaktır.

1.1 Literatür Taraması

Agrawal ve Srikant (1994), büyük satış veri tabanlarında öğeler arasındaki birliktelik kurallarını keşfetmeye yönelik olarak Apriori algoritmasını geliştirmiştir. Yazarlar, bilinen algoritmalardan temelde farklı olan iki yeni yaklaşım sunmuş ve bu yöntemlerin özellikle büyük ölçekli problemlerde önceki yöntemlere kıyasla çok daha yüksek verimlilik sağladığını göstermiştir.

Panjaitan vd. (2019), tüketici satın alma örüntülerinin belirlenmesi için Apriori algoritmasını uygulamışlardır. Elde edilen sonuçlar, %15'in üzerinde destek ve %50'nin üzerinde güven değerine sahip ürün kombinasyonlarının satış analizlerinde işletmelere karar desteği sunabileceğini göstermektedir.

Li ve Ni (2012), ağ güvenliği kapsamında saldırıların tespit edilmesine yönelik olarak Apriori algoritmasına dayalı bir yöntem önermiştir. Çalışmada, geleneksel saldırı tespit yöntemlerinin yüksek yanlış alarm oranı ve düşük performans gibi sınırlılıklarını gidermek amacıyla veri madenciliği teknikleri ile birliktelik kuralları kullanılmıştır. Araştırmacılar, Apriori algoritması ile üretilen kural tabanını ağ tabanlı saldırıların tanımlanmasında uygulamış ve algoritmanın iyileştirilmiş bir sürümüyle verilerin yatay formattan dikey formata dönüştürülmesi sayesinde işlem verimliliğini artırmayı hedeflemişlerdir. Elde edilen sonuçlar, geliştirilen yaklaşımın saldırı tespit sistemlerinin genel performansını artırarak ağ güvenliği için daha etkili bir çözüm sunduğunu göstermektedir.

Sağın (2018), perakende sektöründe faaliyet gösteren büyük bir hırdavat şirketinin satış verileri üzerinde market sepet analizini gerçekleştirmiştir. Beş buçuk yıllık satış

verileri kullanılarak birliktelik kuralları hem Apriori hem de FP-Growth algoritmaları ile çıkarılmıştır. Analizler sonucunda FP-Growth algoritmasının işlem süresi açısından çok daha hızlı çalıştığı görülmüş; ancak yüksek güven değerine sahip bazı birliktelik kurallarının yalnızca Apriori algoritması ile tespit edilebildiği rapor edilmiştir. Bu durum, FP-Growth'un hız avantajına karşın nadir fakat güçlü kuralları gözden kaçırabileceğini, Apriori'nin ise daha kapsamlı sonuçlar sağlayabildiğini göstermektedir.

Zhang ve Zhang (2023), kütüphane kullanıcı davranışlarını incelemek amacıyla Apriori algoritmasına dayalı bir yaklaşım geliştirmiştir. Çalışmada, kullanıcıların kitap ödünç alma verilerinden birliktelik kuralları çıkarılarak hangi kitap türlerinin veya kategorilerinin sıklıkla birlikte tercih edildiği analiz edilmiştir. Elde edilen kurallar, yalnızca kullanıcıların okuma alışkanlıklarının anlaşılmasına değil, aynı zamanda kütüphane raflarının ve yerleşim düzeninin daha verimli bir şekilde planlanmasına da katkı sağlamıştır. Böylece Apriori algoritmasının, kütüphane hizmet kalitesini artırmaya yönelik hem davranış analizi hem de fiziksel düzenlemelerde kullanılabilecek etkili bir veri madenciliği yöntemi olduğu ortaya konmuştur.

Hamidi ve Haghi (2024), müşteri davranışlarının dinamik yapısını dikkate alarak zaman serisi tabanlı bir müşteri segmentasyonu modeli geliştirmiştir. Çalışmada, müşteri davranışları satın alma sıklığı, işlem tutarı, kârlılık ve müşteri maliyeti gibi değişkenlerle zaman serisi olarak modellenmiş; bu özelliklerin ağırlıkları genetik algoritma ile optimize edilmiştir. Ardından farklı kümeleme algoritmaları (K-ortalamalar, hiyerarşik, bulanık C-ortalamalar ve spektral kümeleme) kullanılarak müşteri grupları oluşturulmuştur. Analiz sonuçları, genetik algoritma ile optimize edilmiş özellik ağırlıkları sayesinde özellikle spektral kümelemenin en yüksek doğruluğu sağladığını ve statik yöntemlere kıyasla daha etkili segmentasyon sunduğunu ortaya koymuştur.

Qodmanan vd. (2011), birliktelik kuralları madenciliğinde minimum destek ve minimum güven değerlerinin önceden belirlenmesi zorunluluğunu ortadan kaldırmak amacıyla çok amaçlı genetik algoritma tabanlı bir yöntem önermiştir. Çalışmada, FP-ağaç algoritması kullanılarak hesaplama verimliliği artırılmış ve fitness fonksiyonları esnek bir biçimde tanımlanarak destek ve güven arasındaki korelasyonun en yüksek

olduğu kuralların keşfedilmesi hedeflenmiştir. Araştırma sonuçları, önerilen yaklaşımın geleneksel Apriori tabanlı yöntemlere kıyasla daha az kuralla fakat daha yüksek kalite ve anlamlılık düzeyine sahip sonuçlar üretebildiğini ve yerel minimumlara takılma sorununu büyük ölçüde aştığını ortaya koymuştur.

Kaya (2010), tıbbi veri kümeleri üzerinde birliktelik ve sınıflandırma kurallarını keşfetmek amacıyla çok amaçlı genetik algoritma tabanlı bir yöntem geliştirmiştir. Çalışmada özellikle şizofreni hastalarına ait sosyodemografik ve biyokimyasal veriler kullanılarak farklı veri kümeleri arasındaki ilişkiler incelenmiştir. Önerilen yöntem, klasik destek ve güven eşiklerinin belirlenmesindeki zorlukları aşmakta ve genetik algoritmaların çok amaçlı optimizasyon gücünden yararlanarak daha az sayıda fakat daha anlamlı kurallar elde edilmesini sağlamaktadır. Elde edilen kuralların, tıbbi tanı süreçlerinde uzmanlar tarafından doğrulanabilir nitelikte olması, yöntemin karar destek sistemleri için uygulanabilirliğini artırmıştır.

Akpınar (2009), 1.tip karma montaj hattı dengeleme problemi, belirlenen çevrim süresi için en az istasyon sayısını bulmayı amaçlayan ve NP-zor yapısı nedeniyle çözümü güç bir problemdir. Büyük ölçekli problemlerde kesin yöntemler etkisiz kalırken, meta-sezgisel ve melez algoritmalar önemli bir alternatif olarak öne çıkmaktadır. Bu kapsamda genetik algoritmaların farklı sezgisel yöntemlerle birleştirilmesi, paralel istasyon atamaları ve zoning gibi kısıtları da dikkate alarak daha gerçekçi çözümler üretmektedir. Literatürde yapılan çalışmalar, bu tür hibrit yaklaşımların özellikle büyük ölçekli problemlerde daha başarılı sonuçlar verdiğini göstermektedir.

Chadokar vd. (2013), Apriori algoritması ile genetik algoritma tabanlı bir hibrit yöntem önererek ağ trafiği üzerinde birliktelik kurallarının çıkarımını gerçekleştirmiştir. Çalışmada, Apriori algoritması ile elde edilen sık öğe kümeleri daha sonra genetik algoritma ile işlenmiş ve böylece daha az sayıda fakat daha anlamlı kurallar üretilmiştir. Bu yaklaşımın amacı, özellikle ağ trafiğinde spam ya da istenmeyen davranışların tespitini hızlandırmak ve hesaplama maliyetini azaltmaktır. Deneysel sonuçlar, önerilen hibrit yöntemin klasik Apriori'ye göre daha kısa sürelerde kural üretebildiğini, daha az bellek kullandığını ve daha optimize edilmiş kural setleri sağladığını göstermiştir.

Tüm bu araştırmalar, Apriori algoritmasının farklı alanlarda birliktelik kurallarını keşfetmede etkin bir araç olduğunu, genetik algoritmaların ise parametre optimizasyonu ve çözüm kalitesini artırmada önemli katkılar sağladığını göstermektedir. Literatürde tüketici davranışlarından ağ güvenliğine, tıbbi verilerden üretim hatlarının dengelenmesine kadar geniş bir yelpazede bu yöntemlerin başarıyla uygulandığı görülmektedir. Bu kapsamda, birliktelik kurallarının tüketici davranışlarının analizinde kullanılabileceği ve genetik algoritmalarla destek ve güven gibi parametrelerin optimize edilmesinin daha güçlü karar destek mekanizmalarına kapı aralayacağı anlaşılmaktadır.

1.2 Motivasyon ve Tezin Bölümleri

Yemek sektöründe müşteri davranışlarını anlamak ve yönetmek işletmeler için kritik bir gereklilik haline gelmiştir. Yoğun rekabet ortamında işletmelerin yalnızca kaliteli ürün sunmaları yeterli olmamakta; müşteri memnuniyetini artıracak stratejiler geliştirmeleri ve bu memnuniyeti kalıcı hale getirmeleri beklenmektedir. Müşterilerin olumlu deneyimlerini çevrelerine aktarması, yeni müşteri kazanımında önemli bir etken olmaktadır. Ancak müşteri profillerinin çeşitliliği ve taleplerin hızla değişmesi, işletmeler açısından doğru menü planlaması ve etkin pazarlama stratejileri belirlemeyi zorlaştırmaktadır. Özellikle reklam faaliyetlerinin satışlara etkisinin ölçülmesi, hangi ürünlerin birlikte tercih edildiğinin anlaşılması ve bu bilgilerin doğru şekilde yorumlanması, işletmelere rekabet avantajı sağlayabilecek önemli konulardır.

Günümüzde işletmeler çok sayıda satış verisine sahip olmasına rağmen, bu verilerin çoğu anlamlı bilgiye dönüştürülmediği için karar süreçlerinde yeterince kullanılamamakta ve kararlar sezgisel olarak alınmaktadır. Oysa dinamik bir analiz altyapısı ile müşteri tercihlerini sürekli takip edebilen, değişen koşullara hızla uyum sağlayabilen karar destek sistemleri, yemek sektöründe sürdürülebilir başarı için büyük önem taşımaktadır. Bu çalışmada, işletmenin sahip olduğu verilerden yararlanarak müşteri davranışlarını anlamaları, menü planlamalarını daha bilinçli yapmaları ve satış stratejilerini optimize etmeleri hedeflenmektedir. Apriori algoritması ile müşteri tercih örüntülerinin ortaya çıkarılması, Apriori algoritmasının parametrelerinin genetik algoritma ile dinamik biçimde, genetik algoritma parametrelerinin ise Çok Nitelikli Fayda Teorisi (MAUT) yöntemiyle belirlenmesi

sayesinde, işletmenin veriye dayalı ve sürekli kullanılabilir bir karar destek sistemine kavuşmaları amaçlanmaktadır.

Çalışmanın ikinci bölümünde apriori algoritması, genetik algoritma, R Shiny ve MAUT açıklanmıştır. Üçüncü bölümde, çevrimiçi yemek satışı gerçekleştiren firmaya ait veri seti hakkında bilgi verilmiş, Apriori algoritması ile birliktelik kuralları çıkarılmış; Apriori algoritmasının parametreleri genetik algoritma ile, genetik algoritmanın parametreleri ise Çok Nitelikli Fayda Teorisi (MAUT) yaklaşımıyla belirlenmiş ve bu yapının işletme tarafından kullanılması için R Shiny web uygulaması geliştirilmiştir. Çalışmanın dördüncü ve son bölümünde çalışma sonuçları değerlendirilmiştir.

BÖLÜM İKİ
APRIORI ALGORİTMASI, GENETİK ALGORİTMA, MAUT VE R SHINY

Bu bölümde uygulama sırasında kullanılan Apriori algoritması, genetik algoritma, Çok Nitelikli Fayda Teorisi (MAUT) ve R Shiny hakkında genel bilgiler verilmiştir.

2.1 Apriori Algoritması

Birliktelik kuralları analizi, birlikte ortaya çıkan durumları tespit etmeye çalışan bir veri madenciliği yöntemidir. Birliktelik kurallarının çıkarım süreci iki adımdan oluşur. Birinci adım, kullanıcının belirlediği minimum destek eşiğinden düşük olmayan tüm sık öğe kümelerini bulmak, ikinci adım ise bu sık öğe kümelerinden kurallar üretmektir. Bu kuralların hem minimum destek hem de minimum güven koşullarını sağlaması gerekir (Li ve Ni, 2012).

Agrawal ve Srikant (1994), veriler arasındaki birliktelik kurallarını ortaya çıkarmak amacıyla Apriori algoritmasını önermiştir. Apriori algoritması birliktelik kurallarının keşfedilmesi konusunda literatürde en sık kullanılan yöntemdir (Köle, 2023).

Öğeler kümesi $I = \{i_1, i_2, \ldots, i_m\}$ olsun. İşlemler kümesi $\mathcal{D}$, öğe kümelerinden oluşur ve her işlem T, $T \subseteq I$ olacak biçimde tanımlanır. Her işlem, *TID* adı verilen benzersiz bir kimlik ile gösterilir. Eğer $X \subseteq T$ ise I kümesindeki bazı öğelerden oluşan X kümesini, işlem Tiçerir. Bir birliktelik kuralı, $X \Rightarrow Y$ biçiminde ifade edilir; burada $X \subset$ I, $Y \subset$ I, ve $X \cap Y = \emptyset$ koşulları geçerlidir. Kural $X \Rightarrow Y$, işlemler kümesi $\mathcal{D}$'de, X kümesini içeren işlemlerin $\%C$'si aynı zamanda Y kümesini de içeriyorsa, güven değeri C ile tanımlanır. Benzer şekilde, kural $X \Rightarrow Y$, işlemler kümesi $\mathcal{D}$'de $X \cup Y$ kümesini içeren işlemlerin oranı $\%S$ ise, destek değeri S ile ifade edilir (Agrawal ve Srikant, 1994).

Bir birliktelik kuralının anlamlı kabul edilebilmesi için, belirlenen minimum destek ve güven eşiklerinden yüksek olması gerekmektedir. Hem destek hem de güven değerlerinin yüksek olması belirlenen kuralın güçlü bir kural olduğunu ifade eder (Gürgen, 2008). Büyük veri tabanlarında bu güçlü kuralların tespiti, işletmelerin karar alma süreçlerinde yol gösterici bilgiler sağlar.

2.1.1 Apriori Algoritması Parametreleri

2.1.1.1 Destek

Birliktelik kurallarında destek değeri (*S*), kuralda geçen öğe kümesinin tüm veri tabanındaki işlemler içinde ne sıklıkla görüldüğünü gösteren yüzde cinsinden hesaplanan bir orandır. Destek değeri eşitlik 2.1'de gösterildiği gibi hesaplanmaktadır. Burada $n(X \cup Y)$, X ve Y kümesini birlikte içeren işlem sayısını, $n(D)$ ise veri tabanındaki toplam işlem sayısını ifade etmektedir (Panjaitan vd., 2019).

$$S(X,Y) = \frac{n(X \cup Y)}{n(D)} \tag{2.1}$$

Örneğin, destek değeri %15 olan bir kural, veri setindeki tüm işlemlerin %15'inde *X* ve *Y*'nin birlikte yer aldığını ifade eder. Destek değeri, kuralın veri setinde ne kadar yaygın olduğunu ortaya koyar. Destek değeri yüksek olan kurallar güçlü kurallar olarak ifade edilir.

2.1.1.2 Güven

Birliktelik kuralında güven değeri (*C*), bir işlem gerçekleştirğinde diğer işlemin gerçekleşme olasılığını ölçen yüzde cinsinden bir orandır. *X* gerçekleştiğinde *Y*'nin de ortaya çıkma olasılığını ölçer. Güven değeri eşitlik 2.2'de gösterildiği gibi hesaplanmaktadır. Burada $n(X \cup Y)$, X ve Y kümesini birlikte içeren içeren işlem sayısını; $n(X)$ sadece *X* kümesini içeren işlem sayısını ifade etmektedir (Panjaitan vd., 2019).

$$C(X,Y) = \frac{n(X \cup Y)}{n(X)} \tag{2.2}$$

Örneğin, %50 güven değerine sahip bir kural, bir işlem gerçekleştiğinde diğer işlemin %50 olasılıkla gerçekleşeceğini ifade eder. Güven parametresinin yüksek olması kuralın güçlü olduğunu ifade eder.

2.1.1.3 Kaldıraç

Kaldıraç değeri, birliktelik kuralı madenciliğinde bir kuralın sol tarafındaki öğelerin sağ taraf üzerindeki etkisini ölçen bir ilginçlik (interestingness) ölçütüdür. Kaldıraç değeri 1'den büyükse *X* ve *Y* arasında pozitif bir ilişki vardır; 1'den küçükse ilişki negatiftir. Başka bir ifadeyle kaldıraç, *X*'in varlığının *Y*'nin ortaya çıkma olasılığını artırıp artırmadığını gösterir. Eşitlik 2.3'te olduğu gibi hesaplanmaktadır (Hussein, Alashqur & Sowan, 2015).

$$L(X,Y) = \frac{S(X,Y)}{S(X)\,.S(Y)} \tag{2.3}$$

2.1.3 Apriori Algoritmasının İşleyişi

Apriori algoritması, veri tabanı üzerinde birden fazla tarama gerçekleştirmektedir. İlk taramada, öğelerin tekil olarak destek değerleri hesaplanmakta ve minimum destek eşiğini sağlayanlar sık öğeler olarak belirlenmektedir. Sonraki her bir taramada ise, bir önceki adımda elde edilen sık öğe kümeleri başlangıç noktası olarak kullanılmaktadır. Bu başlangıç kümeleri, potansiyel olarak sık olabilecek yeni öğe kümelerinin, yani aday öğe kümelerinin üretilmesi için temel teşkil eder. Aday kümelerin gerçek destek değerleri, veri tabanı üzerinde yapılan tarama sırasında hesaplanır. Tarama sonunda minimum destek koşulunu karşılayan aday kümeler, sık öğe kümeleri olarak kabul edilir ve bir sonraki iterasyon için başlangıç kümesini oluşturur. Bu süreç, yeni sık öğe kümeleri elde edilemeyene kadar yinelenir.

Her bir kayıt, <*TID*, öğe> biçiminde gösterilir ve burada *TID*, ilgili işlemin kimliğini ifade eder. Bir öğe kümesindeki öğe sayısına, o kümenin boyutu denir. Boyutu *k* olan kümeler, *k*-öğeli kümeler olarak adlandırılır.

Algoritmanın ilk aşamasında, tekil olarak tüm öğelerin destek değerleri hesaplanarak 1-öğe kümeleri belirlenir. Daha sonraki bir geçiş, örneğin k. geçiş, iki aşamadan oluşur. İlk aşamada, $(k-1)$. geçişte bulunan büyük öğe kümeleri L_{k-1}, aday kümeler C_k,'yı oluşturmak için kullanılır. İkinci aşamada ise veritabanı taranır ve aday kümelerin destek değerleri hesaplanır. Destek değerleri belirlenen en küçük

destek değerinden küçük olanlar elenir. Apriori algoritması notasyonları tablo 2.1'de sözde kodu ise şekil 2.1'de gösterilmiştir (Agrawal ve Srikant, 1994).

Tablo 2.1 Apriori algoritması notasyonları

Gösterim	Açıklama
L_k	En küçük destek değerini sağlayan k-öğe kümeleri
C_k	Aday k-öğe kümeleri

1) L_1 = {büyük 1-öğe kümeleri}
2) için (k = 2; $L_{k-1} \neq \emptyset$; k++) yap
3) C_k = apriori-gen(L_{k-1}) // Yeni aday kümeler
4) D kümesindeki her işlem t için yap
5) C_t = subset(C_k, t) // t işlemi içinde bulunan aday kümeler
6) C_t kümesindeki her aday küme c için yap
7) c.sayım = c.sayım + 1
8) son
9) $L_k = \{c \in C_k \mid$ c.sayım ≥ minsup$\}$
10) son
11) Çıktı= $\bigcup_k L_k$;

Şekil 2.1 Apriori algoritması sözde kodu

Apriori-gen fonksiyonu, L_{k-1} (tüm sık $k-1$-öğe kümeleri) kümesini girdi olarak alır. Bu fonksiyon, tüm sık k-öğe kümelerinin üst kümesini döndürür. İlk adımda birleştirme (join) yapılır. L_{k-1} kümesi kendi içinde birleştirilerek aday kümeler elde

edilir. Apriori algoritması birleştirme adımı sözde kodu şekil 2.2'de verilmiştir (Agrawal ve Srikant, 1994).

C_k kümesine ekle

seç $(p.\text{öğe}_1, p.\text{öğe}_2, \ldots, p.\text{öğe}_{k-1}, q.\text{öğe}_{k-1})$

L_{k-1} p, L_{k-1} q'dan

koşul: $p.\text{öğe}_1 = q.\text{öğe}_1, \ldots, p.\text{öğe}_{k-2} = q.\text{öğe}_{k-2}$

$p.\text{öğe}_{k-1} < q.\text{öğe}_{k-1}$;

Şekil 2.2 Apriori algoritması birleştirme sözde kodu

Sonraki aşama budama (prune) adımıdır. Bu adımda, C_k kümesindeki her aday küme için kontrol yapılır: Eğer C_k'nin herhangi bir $k-1$-altkümesi L_{k-1} 'de yer almıyorsa, C kümesi C_k'den silinir. Apriori algoritması budama adımı sözde kodu şekil 2.3'te verilmiştir.

tüm öğe kümeleri $c \in c_k$ için yap

c 'nin $(k-1)$-altkümelerinin her biri s için yap

eğer $s \notin L_{k-1}$ ise

c'yi c_k'dan sil;

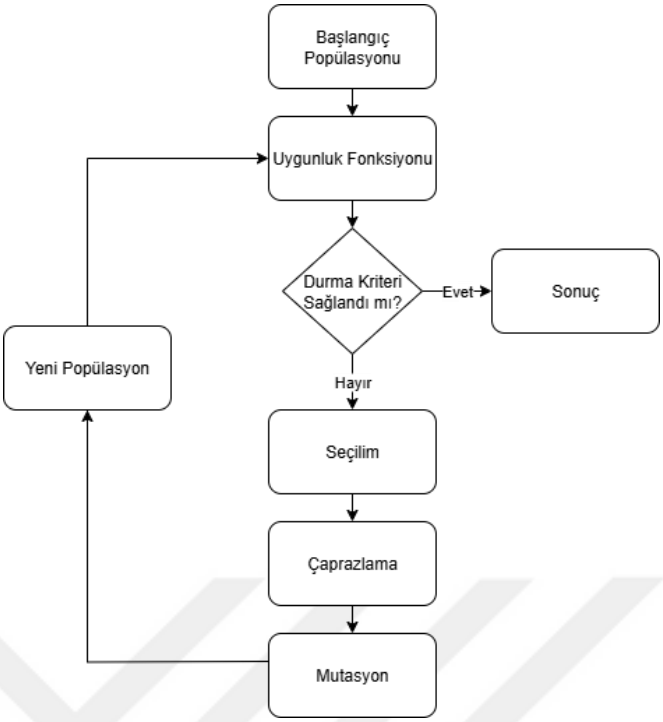
Şekil 2.3 Apriori algoritması budama sözde kodu

Örneğin; L_3 ={{1,2,3},{1,2,4},{1,3,4},{1,3,5},{2,3,4}} olsun. Birleştirme adımından sonra C_4={{1,2,3,4},{1,3,4,5}} olacaktır. Budama adımı, {1,3,4,5} kümesini siler, çünkü {1,4,5} altkümesi L_3 'te yer almamaktadır. Sonuçta yalnızca {1,2,3,4} kalır.

2.2 Genetik Algoritma

Genetik algoritma, Darwin'in evrim teorisinden esinlenerek geliştirilmiş olup en iyinin hayatta kalması ilkesine dayanır. Genetik algoritma, Holland (1975) tarafından ilk kez önerilmiştir. Bu yöntem, genetik süreçlerin bilgisayar ortamında taklit edilmesiyle çözüm uzayında en uygun sonuca ulaşmayı amaçlar. Evrimin temel unsurları olan seçilim, çaprazlama ve mutasyon mekanizmalarını modelleyerek çalışır. Genetik algoritma, farklı problemlere ait olası çözümleri bir popülasyon yapısı içerisinde temsil eder ve bu çözümleri nesiller boyunca iyileştirerek geliştirir. Her bir çözüm, genetik bilgiyi barındıran bir kromozom dizisi biçiminde ifade edilir ve bir bireyi temsil eder. Algoritmanın işleyişinde, mevcut popülasyondaki çözümler uygunluk değerlerine göre değerlendirilir; yüksek uygunluğa sahip bireyler seçilir, bu bireyler arasında çaprazlama işlemleri gerçekleştirilir ve rastgele mutasyonlar ile çeşitlilik sağlanır. Bu evrimsel süreç, belirlenen uygunluk kriterine ulaşılıncaya veya tanımlanan maksimum nesil sayısına erişilinceye kadar tekrarlanır (Turan, 2024).

Genetik algoritmalar, kapsamlı arama uzaylarını sistematik olarak araştırarak optimal veya optimale yakın çözümlere hızlı ve etkin bir biçimde erişebilmektedir. Genetik algoritmanın genel akışı Şekil 2.4'te gösterilmektedir.



Şekil 2.4 Genetik algoritma genel akış şeması (Turan, 2024)

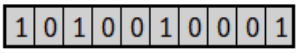
2.2.1 Başlatma

Genetik algoritmalarda sürecin ilk adımı potansiyel çözümlerden oluşan başlangıç popülasyonunun oluşturulmasıdır. Her kromozom, ele alınan problemin olası bir çözümünü temsil eder. Popülasyon büyüklüğü, başlangıç popülasyonunun boyutu, genetik algoritmanın performansını doğrudan etkiler. Daha büyük bir popülasyon, genetik çeşitliliği artırarak çözüm uzayının daha geniş bir bölümünün keşfedilmesine olanak sağlar; ancak, bu durum aynı zamanda her nesilde daha fazla hesaplama yükü anlamına gelir (Turan, 2024).

Genetik algoritmalarda başlangıç popülasyonu iki farklı şekilde oluşturulabilir. Birinci yöntemde, popülasyon tamamen rastgele çözümlerden meydana getirilir. Diğer yöntemde ise popülasyon, problemin yapısına ilişkin bilinen bir sezgisel yaklaşım kullanılarak oluşturulur (Immanuel ve Chakraborty, 2019).

Genetik algoritmanın Holland (1975) tarafından yapılan ilk uygulamasında şekil 2.5'te gösterildiği gibi genler ikili (0–1) biçiminde tanımlanmıştı ancak sonraki

çalışmalarda kromozom yapıları daha çeşitlendirilmiş biçimlerde ele alınmıştır. Her kromozom, çözüm uzayında olası bir çözümü temsil etmektedir. Genetik algoritmalar, kromozom olarak adlandırılan çözüm kümelerinin bir arada bulunduğu bir popülasyon üzerinden çalışmaktadır (Akpınar, 2009).



Şekil 2.5 Örnek kromozom yapısı

2.2.2 Uygunluk Değerlendirmesi

Genetik algoritmalarda uygunluk değeri, bir çözümün yani bir kromozomun problemi ne ölçüde çözdüğünü gösterir. Uygunluk fonksiyonu, her bir çözüm için bir uygunluk değeri hesaplar ve böylece seçilim aşamasında, arama uzayında daha umut vadeden bölgelerine yönelim sağlanır.

Belirli kısıtlar sağlanmak istendiğinde, kısıtları sağlamayan uygunluk fonksiyonlarının değerini azaltmak için ceza terimleri kullanılır. Böylelikle kısıtları sağlamayan bireylerin uygunluk değerleri eklenen ceza terimleriyle azaltılır.

2.2.3 Seçilim

Doğadaki doğal seçilimi taklit ederek, en iyi bireylerin yeni neslin oluşturulmasında kullanılmasını sağlar. Belirlenen uygunluk fonksiyonuna göre en başarılı çözümler bir sonraki aşamaya taşınır. Uygunluk değeri yüksek olan bireylerin üreme için seçilme olasılığı daha fazladır. Rulet tekerleği, turnuva seçimi ve elitizm gibi çeşitli seçilim metotları mevcuttur.

Rulet tekerleği seçiminde popülasyondaki her birey, uygunluk değeri büyüklüğünde bir dilim alır. Uygunluk değeri arttıkça bireyin dilimi büyür ve seçilme ihtimali artar. Tekerlek rastgele döndürülerek hangi dilime denk gelirse, o birey seçilmiş olur. Bu işlem, ihtiyaç duyulan birey sayısına ulaşılana kadar tekrarlanır (Turan, 2024). Eşitlik 2.4'te gösterilen formül ile bireylerin seçilim olasılığı hesaplanır (Kaya, 2010).

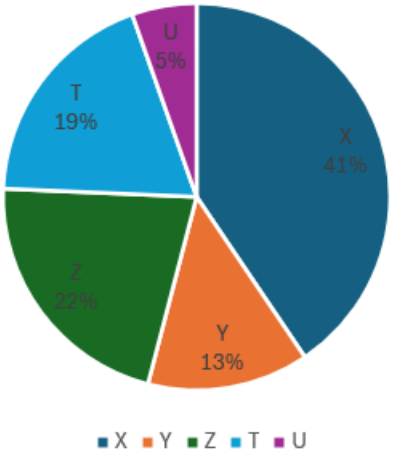
$$P_{seçilen} = f_i \,/\, \sum_{i=1}^{N} f_k \qquad (2.4)$$

Bu formülde;

f_i: Bireyin popülasyondaki uygunluk değeri

f_k: popülasyondaki toplam uygunluk değeridir.

Şekil 2.6'da belirtilen örnek bir rulet tekerleğinde X bireyinin seçilim olasılığı sahip olduğu alanın daha büyük olması sebebiyle diğer bireylerden daha fazladır (Kaya, 2010).



Şekil 2.6 Örnek rulet tekeri yerleşimi

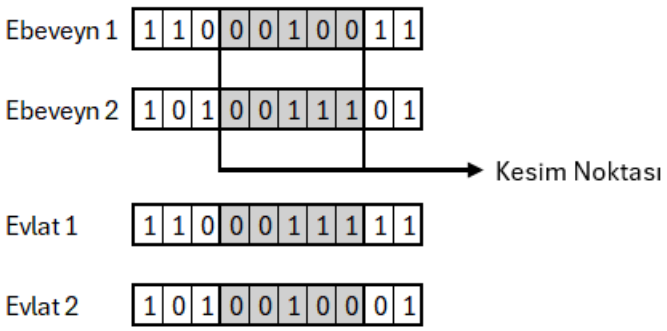
Turnuva seçiminde popülasyondan rastgele seçilen belirli sayıda birey arasında bir 'turnuva' düzenlenir; en yüksek uygunluğa sahip olan seçilir. Bu işlem, ihtiyaç duyulan birey sayısına ulaşana kadar tekrarlanır (Turan, 2024).

Elitizm yönteminde en iyi birkaç birey hiçbir değişikliğe uğramadan doğrudan yeni nesle aktarılır. Bu yöntem, bulunan en iyi çözümlerin kaybolmadan yeni nesillere aktarılmasını sağlar. Ancak aşırı elitizm, çeşitlilik kaybına yol açabilir.

2.2.4 Çaprazlama

Çaprazlama, genetik algoritmanın temel genetik operatörlerinden biridir. Biyolojik üremeyi taklit ederek, iki veya daha fazla ebeveynin genetik bilgisini birleştirerek yeni bireyler yani çözümler üretir. Popülasyonda her birey çaprazlama sürecine dahil olmaz. Belirlenen çaprazlama oranıyla popülasyon içerisinde ne sıklıkla gerçekleştiği belirlenir (Turan, 2024).

İki noktalı çaprazlama işleminde, şekil 2.7'de gösterildiği gibi rastgele belirlenen iki kesim noktası arasındaki tüm genler karşılıklı olarak yer değiştirir. Çaprazlamanın temel amacı, ebeveynlerde bulunan uygun özelliklerin yeni bireylere aktarılmasını sağlamaktır (Akpınar, 2009).

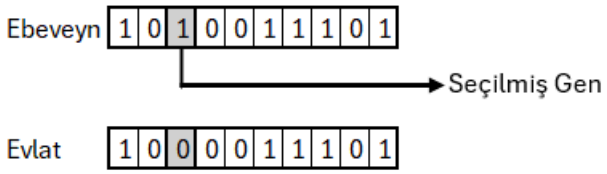


Şekil 2.7 Çaprazlama

2.2.5 Mutasyon

Mutasyon, kromozomdaki bazı genlerin rastgele değiştirilmesidir ve popülasyona çeşitlilik katar. Bu sayede algoritmanın yerel minimumlarda sıkışması engellenir ve yeni çözüm bölgeleri araştırılabilir. Mutasyon oranı genellikle düşük belirlenmelidir, yüksek seçilmesi genetik algoritmayı rasgele aramaya çevirebilir (Meniz, 2024).

Şekil 2.8'de en basit mutasyon türü gösterilmektedir. Bu işlem, ikili bir dizide rastgele seçilen bir genin değerinin 0'dan 1'e ya da 1'den 0'a dönüştürülmesiyle gerçekleştirilir (Akpınar, 2009).



Şekil 2.8 Mutasyon

2.2.6. Yeni Nesil Oluşturma

Yeni popülasyon, ebeveynleri genetik algoritma operatörlerinden oluşan süreçlerden geçirerek farklı özelliklere sahip bireylerin oluşturulmasıdır.

2.2.7 Sonlandırma

Kullanıcı tarafından seçilen en yüksek iterasyon sayısına ulaşılması ya da belirli bir iterasyonda geliştirme sağlanmaması gibi belirlenen koşullara bağlı olarak süreç sonlandırılır.

2.3 R Shiny

R programlama dili, Ross Ihaka ve Robert Gentleman tarafından 1990'lı yılların başında geliştirilmiş olup, istatistiksel hesaplama ve görselleştirme konusunda oldukça güçlü bir araçtır. Ancak, R dilinin web uygulamaları geliştirme amacıyla kullanımı, 2012 yılında RStudio tarafından geliştirilen Shiny paketi ile mümkün hale gelmiştir (Jia vd., 2022).

Shiny, R içerisinde çalışan bir paket olarak, web tabanlı uygulamaların kolayca geliştirilmesine olanak tanır. R Shiny uygulamalarının geliştirilmesi için R ortamının kurulu olması gereklidir. Geliştirme sürecinde zorunlu olmasa da RStudio gibi gelişmiş bir entegre geliştirme ortamı kullanılması önerilmektedir. Ayrıca Shiny paketinin kurulumu da uygulama geliştirme sürecinin temel ön koşullarındandır (Jia vd., 2022).

Tipik bir R Shiny uygulaması, etkileşimli web uygulamalarında olduğu gibi istemci tarafındaki kullanıcı arayüzünün tasarımı ile kullanıcıdan gelen isteklerin sunucu tarafında işlenmesi adımlarını içerir. Bu yapı genellikle iki temel R betiğinden oluşur: ui.R ve server.R. ui.R dosyası, kullanıcı arayüzünü tanımlarken, görünüm, düzen ve kullanılacak bileşenleri (örneğin dosya yükleme, metin giriş alanları veya parametre ayarları) belirler. Kullanıcı girdileri server.R tarafından işlenir ve elde edilen çıktı tablolar, grafikler veya metinler halinde, ui.R içerisinde tanımlanan alanlarda kullanıcıya sunulur. Shiny uygulamaları, paketin runApp() fonksiyonu ile başlatılabilir. Uygulama, RStudio'nun kendi görüntüleyicisinde, yeni bir pencerede ya da sistemin varsayılan tarayıcısında açılabilir (Jia vd., 2022).

2.4 Çok Nitelikli Fayda Teorisi (MAUT)

Çok Nitelikli Fayda Teorisi (MAUT), birden fazla alternatif ve kriterin olduğu karar verme problemlerinde, karar vericinin toplam faydasını en üst düzeye çıkaran alternatifi belirlemeyi amaçlayan bir yaklaşımdır. Yöntem ilk olarak Fishburn (1967) ve Keeney (1974) tarafından uygulanmıştır (Aydın ve Oruç, 2022).

Kriterlerin ağırlıklarını belirlemek amacıyla entropi yaklaşımından yararlanılmaktadır. Entropi, bir sistemin düzensizlik veya rastlantısallık derecesini ölçen bir kavramdır. Bir sistemdeki düzensizlik arttıkça, entropi de artar. Dolayısıyla entropi, zaman içinde sistemin karmaşıklığıyla aynı yönde ilerler. Düzenli bir yapıdan düzensiz bir yapıya geçildiğinde sistemin entropisi artar. Buna paralel olarak, sistem hakkındaki bilgi miktarı da artış gösterir. Bu nedenle, bilgi "negatif entropi" olarak tanımlanmaktadır. Bilgi içeriğe değil, olasılığa bağlıdır. Burada önemli olan olayın kendisi değil, gerçekleşme olasılığıdır. Bu nedenle entropi, herhangi bir varsayım gerektirmediğinden istatistikte parametrik olmayan yöntemler grubunda değerlendirilebilir (Aydın ve Oruç, 2022).

2.4.1 MAUT Metodunun Adımları

MAUT metodunun uygulanma adımları şu şekildedir:

Adım 1: *m* adet alternatif ve *n* adet kriteri içeren karar matrisi oluşturulur.

$$D = \begin{matrix} X_{11} & X_{12} & X_{1n} \\ X_{21} & X_{22} & X_{2n} \\ X_{m1} & X_{m2} & X_{mn} \end{matrix} \quad (2.5)$$

Burada X_{ij}; i. alternatife ait, j. kritere göre elde edilen başarı değerini ifade etmektedir. i=1,2,...,m and j = 1,2,….,n şeklinde tanımlanır.

Adım 2: Normalleştirilmiş karar matrisi eşitlik 2.6'da gösterildiği gibi hesaplanmaktadır.

$$r_{ij} = \frac{X_{ij}}{\sum_{p=1}^{m} X_{pj}} \quad (2.6)$$

Adım 3: Her bir kriterin entropi değeri eşitlik 2.7'de gösterildiği gibi hesaplanmaktadır. Burada e_j, j. kritere ait entropi değerini ifade etmektedir.

$$e_j = \frac{1}{\ln m} \sum_{i=1}^{m} r_{ij} \ln r_{ij} \quad (2.7)$$

Adım 4: Her bir kriterin ağırlık değeri eşitlik 2.8'de gösterildiği gibi hesaplanmaktadır. Eşitlik 2.9'da gösterildiği gibi ağırlıkların toplamı bire eşittir.

$$W_j = \frac{1 - e_j}{\sum_{p=1}^{n} (1 - e_p)} \quad (2.8)$$

$$\sum_{j=1}^{n} W_j = 1 \quad (2.9)$$

Adım 5: Fayda değerleri, fayda kriterlerine göre belirlenir ve normalleştirilmiş değerler eşitlik 2.10'da gösterildiği gibi hesaplanmaktadır.

$$r_{ij} = \frac{x_{ij - I_j^-}}{u_j^+ - I_j^-} \quad (2.10)$$

$$u_j^+ = max_i x_{ij} l_j^- = min_i x_{ij} \quad (2.11)$$

Benzer şekilde, maliyet kriteri dikkate alındığında fayda değeri eşitlik 2.12'de gösterildiği gibi hesaplanır ve normalleştirilmiş değerler elde edilir.

$$r_{ij} = \frac{u_j^+ - x_{ij}}{u_J^+ - I_j^-} \tag{2.12}$$

$$u_j^+ = max_i x_{ij} l_j^- = min_i x_{ij} \tag{2.13}$$

Adım 6: Ağırlıklı r_{ij} değerleri, entropi ağırlıkları (w_j) ile çarpılarak hesaplanır. Bu değerlerin toplamı, toplam fayda değerini verir. Fayda değeri eşitlik 2.14'te gösterildiği gibi hesaplanmaktadır.

$$U_i = \sum_{j=1}^{n} W_j r_{ij} \tag{2.14}$$

Adım 7: Alternatiflerin sıralaması, elde edilen toplam fayda değerlerine göre yapılır. En yüksek toplam fayda değerine sahip alternatif, en uygun (en iyi) seçenek olarak belirlenir.

BÖLÜM ÜÇ
ANALİZ VE UYGULAMA

Tüm kodlama ve modelleme süreçleri, R Studio versiyon 4.2.1 geliştirme ortamında R programlama dili ile gerçekleştirilmiştir.

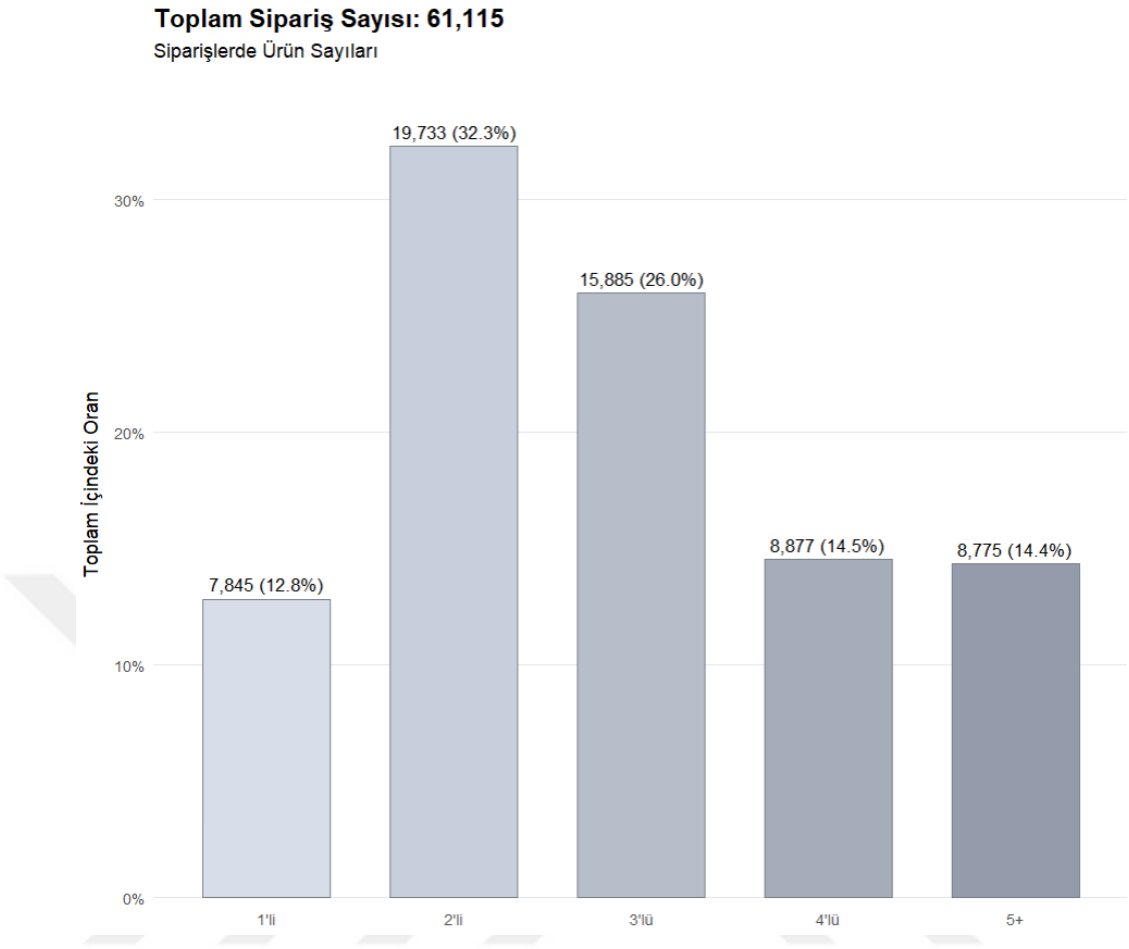
3.1 Veri Setinin İncelenmesi

Veri seti, ev yemeği üretimi ve satışı yapan bir işletmenin çevrimiçi satış kayıtlarını içermekte olup, Nisan 2023 ile Mart 2025 tarihleri arasında gerçekleştirilen 61.115 adet siparişi kapsamaktadır. Ham veri setinde üç adet değişken yer almakta olup, veri tipleri ve açıklamaları tablo 3.1'de sunulmuştur.

Tablo 3.1 Veri setindeki değişkenlere ait bilgiler

Değişken Adı	**Veri Tipi**	**Açıklama**
Siparis_Statusu	nitel	Siparişin teslim edilip edilmediği bilgisi
Siparis_Zamanı	nicel	Siparişin teslim edilme tarihi
Urunler	nitel/nicel	Siparişte yer alan ürün isimleri ve miktar bilgileri

Veri setinde her bir siparişin içerdiği ürün sayısının dağılımı Şekil 3.1'de gösterilmektedir. Siparişlerin %72,8'i iki, üç veya dört üründen oluşmakta, dört adetten fazla ürün içeren siparişlerin oranı ise %14,4'tür. Bu bulgu doğrultusunda, geliştirilen R Shiny web uygulamasında kullanıcıya seçim parametresi olarak 2, 3 ve 4 ürün sayıları sunulmuştur. Apriori algoritması, kullanıcı tarafından seçilen ürün adedine göre dinamik olarak oluşturulan veri alt kümeleri üzerinde çalıştırılmıştır.



Şekil 3.1 Siparişlerin içerdiği ürün sayıları

3.2 Veri İşleme

Veri setinde, ürünlerin birimsel farklılıkları, miktar bilgilerinde eksiklikler, sipariş içerisindeki ürün ve birimlerin tek bir hücrede yer alması gibi nedenlerle verinin düzenlenmesi gerekmektedir. Bu sebeple veri setinde veri ölçeklendirme, eksik veri tamamlanması ve kategorik veri kodlaması işlemleri gerçekleştirilerek, R Shiny web uygulamasında kullanılmak üzere otomatize modeller ve veri işlem hattı (data pipeline) oluşturulmuştur. Şekil 3.2'de ham veri setinin ilk 5 satırı gösterilmektedir.

```
# A tibble: 5 × 3
  Siparis_Statusu Siparis_Zamani   Urunler
  <chr>           <chr>            <chr>
1 Teslim Edildi   2023-08-18 20:32 2 Kabak Mücver (Adet),  1 Tereyağlı Pirinç Pilavı,  1 Şakşuka (200 gr.) [1 Ekmek İstemiyorum]
2 Teslim Edildi   2023-08-04 14:24 1 Kabak Mücver (Adet),  1 Yoğurtlu Kızartma (200 gr.) [1 Ekmek İstemiyorum],  3 Top Köfte (Adet) (Sossuz)
3 Teslim Edildi   2023-08-29 20:01 1 Kısır (200 gr.),  1 Yoğurtlu Semizotu (200 gr.)
4 Teslim Edildi   2023-08-06 15:45 5 Zeytinyağlı Kuru Biber Dolması (Acı) (200 gr.),  3 Kısır (200 gr.),  1 Patatesli Börek (500 gr.)
5 Teslim Edildi   2023-08-07 10:19 2 Aşure (Cam Kavanoz )
```

Şekil 3.2 Ham veri seti

3.2.1 Eksik Veri Tamamlama

Sipariş içerisinde yer alan bazı ürünler için miktar bilgileri eksiktir. Bu sebeple boş veriler ortalama gramaj bilgisiyle doldurulmuştur.

3.2.2 Veri Temizliği ve Standartizasyon

Aynı ürün için siparişler adet veya gram biriminde açılabilmektedir. Hem adet hem gram biriminde siparişi bulunan ürünler için ortalama gramaj bilgisi kullanılarak, ortak bir birime dönüştürülmüştür. Ayrıca, bazı siparişlerin İngilizce, bazılarının ise Türkçe olarak açıldığı görülmüştür. Bu siparişler kodun içerisine gömülen eşleşme tablosu (mapping) tablosu kullanılarak tamamı Türkçe'ye çevrilerek standart bir hale getirilmiştir.

3.2.3 Veri Düzenleme

Bu veri setinde, bir sipariş içerisinde yer alan ürün ve gramaj bilgileri aynı hücrede, virgüller ile ayrılmış biçimde bulunmaktadır. Apriori algoritması ve satış analizi için verilerin düzenleme ihtiyacı bulunmaktadır.

Apriori algoritması, işlemsel (transactional) veri yapısıyla çalıştığından, öncelikle veri setinden gramaj ve ek bilgiler ayıklanmıştır. Ardından, bir siparişte yer alan ürünler farklı sütunlara ayrılmış ve son aşamada işlemsel yapıya dönüştürülerek Apriori algoritması için hazır hale getirilmiştir. Apriori algoritması için hazırlanan verinin son hali şekil 3.3'te olduğu gibidir. Her satır bir sipariş içerisinde yer alan ürünleri içerecek şekilde işlemsel bir yapıdadır.

```
    items
[1] {Kabak Mücver, Şakşuka, Tereyağlı Pirinç Pilavı}
[2] {Kabak Mücver, Top Köfte, Yoğurtlu Kızartma}
[3] {Kısır, Yoğurtlu Semizotu}
[4] {Kısır, Patatesli Börek, Zeytinyağlı Kuru Biber Dolması}
[5] {Aşure}
```

Şekil 3.3 Apriori algoritması için düzenlenmiş veri seti

Satış verilerinin analizi için ise veri seti, "ürün" ve "sipariş tarihi" değişkenlerini içerecek şekilde uzun formata dönüştürülmüş; sonrasında, aynı ürün ve aynı ay için

miktar bilgileri birleştirilerek toplanmış ve grafiklerin oluşturulması için hazır hâle getirilmiştir. Şekil 3.4'te olduğu gibi satış analizi kısmı için veriler hazırlanmıştır. Her bir satır satışı yapılan ürünün ismi, tarihi, birimi ve miktar bilgisini saklamaktadır.

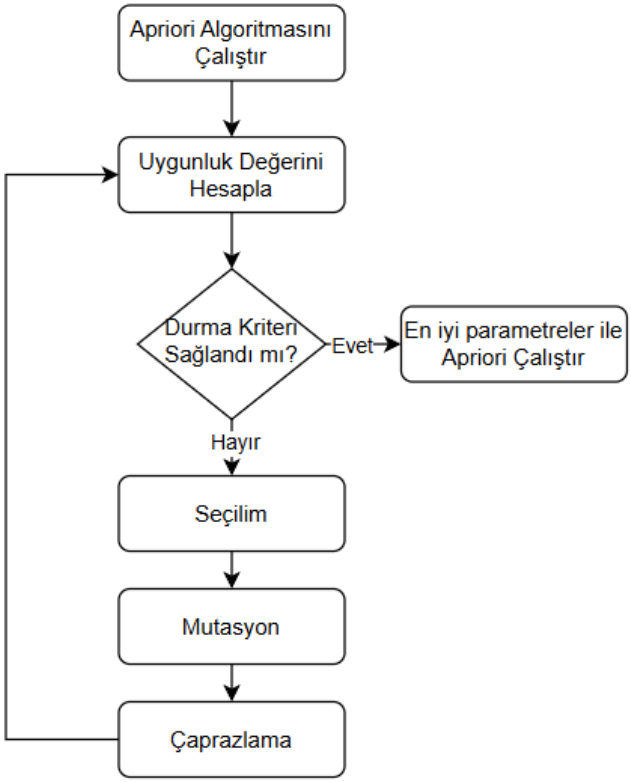
	month	order_date	product_name	weekday_type	year	unit	total_quantity
	<fct>	<date>	<chr>	<chr>	<chr>	<chr>	<dbl>
1	1	2024-01-01	Arnavutciğeri	Haftaiçi	2024	gram	1080
2	1	2024-01-01	Brownie Kurabiye	Haftaiçi	2024	Adet	16
3	1	2024-01-01	Dereotlu Peynirli Poğaça	Haftaiçi	2024	Adet	36
4	1	2024-01-01	Etli Bezelye	Haftaiçi	2024	Adet	2
5	1	2024-01-01	Etli Kuru Fasulye	Haftaiçi	2024	Adet	6

Şekil 3.4 Satış analizi için düzenlenmiş veri seti

3.3 Genetik Algoritma ile Parametre Belirleme

Apriori algoritmasının güven ve destek parametreleri genetik algoritma ile belirlenmiştir. R Shiny web uygulaması ile otomatize çalışacak şekilde model oluşturulmuştur.

Apriori algoritmasının çıktılarının kalitesi büyük ölçüde destek ve güven eşiklerine bağlıdır. Bu iki parametrenin çok küçük seçilmesi durumunda anlamlı olmayan kuralların türetilmesi, çok büyük seçilmesi durumunda ise güçlü kuralların elimine edilmesine yol açmaktadır. Ek olarak, işletmenin ilerleyen zaman içinde ürün çeşidi ya da satış miktarında gerçekleşebilecek değişikliklerde yazılım bilgisine gerek kalmadan, parametrelerin otomasyon ile belirlenmesi amaçlanmıştır. Parametrelerinin belirlenmesinde oluşturulan süreç akışı şekil 3.5'te olduğu gibidir.



Şekil 3.5 Apriori algoritması için parametre belirleme süreç akışı

Her birey yani kromozom, bir destek ve bir güven değeri çiftiyle temsil edilir ve bu çiftle elde edilen birliktelik kuralları üzerinden bir amaç fonksiyonu hesaplanır. Uygulamada kullanılan kromozom yapısı güven ve destek değerlerinden oluşmaktadır.

Bu çalışmada önerilen ağırlıklandırma faktörü (α), az sayıda kural üretildiğinde uygunluk değerinin aşırı yükselmesini engeller. Bu yaklaşım, literatürde yaygın biçimde kullanılan ceza (penalty) fonksiyonu fikrinin bir uyarlamasıdır. Coit vd. (1996), kısıtlı optimizasyon problemlerinde genetik algoritmaların uygun (feasible) çözüm bulmadaki zorluklarını aşmak amacıyla, arama sürecinden elde edilen geri bildirimleri kullanan adaptif bir ceza fonksiyonu yaklaşımı önermiştir. Kazarlis ve Petridis (1998) ise, ceza fonksiyonlarının genetik algoritma performansı üzerindeki etkilerini incelemiş ve üstel ceza fonksiyonlarının uygulanabilirliğini göstermiştir.

Bu bağlamda, çalışmada kullanılan ağırlıklandırma faktörü (α), literatürdeki örnek yaklaşımların prensiplerini izleyerek örneklem büyüklüğüne bağlı dinamik bir ağırlıklandırma mekanizması olarak tasarlanmıştır. Buradaki "20" sabiti, deneysel bir ölçek parametresidir ve bu değer MAUT yöntemiyle belirlenmiştir. Ağırlıklandırma faktörü eşitlik 3.1'de verildiği gibi hesaplanmaktadır. Bu yapı, etkinin başlangıçta yüksek olup süreç ilerledikçe azalması sayesinde dengeleyici bir iyileştirme dinamiği oluşturur.

$$\alpha = 1 - \exp\left(-\frac{N}{20}\right) \tag{3.1}$$

Algoritma akışı şu şekildedir: Önce, belirlenen aralıklardan rastgele değerler seçilerek bir popülasyon oluşturulur. Her birey, Apriori algoritmasının bir parametre kombinasyonunu temsil eder. Bu bireylerle Apriori algoritması çalışır. Elde edilen kuralların sayısı N, bu kuralların ortalama destek değeri (S) ve ortalama güven değeri (C) değerleri hesaplanır. Ardından uygunluk değeri (fitness) değeri eşitlik 3.2'de verildiği şekilde hesaplanmaktadır.

$$Uygunluk\ değeri = \alpha.(S + C) \tag{3.2}$$

Bu çalışmada kullanılan uygunluk fonksiyonu, birliktelik kuralı madenciliğinde kural kalitesini belirleyen iki temel ölçüt olan destek (support) ve güven (confidence) değerlerini birlikte optimize etmek amacıyla tasarlanmıştır. Yüksek güven ve destek değerine sahip kurallara güçlü kurallar adı verilir (Gürgen,2008). Bu nedenle, genetik algoritma tabanlı optimizasyon sürecinde tanımlanan uygunluk fonksiyonu bu iki metriği birlikte maksimize edilmesini amaçlamaktadır. Aynı zamanda üretilen kural sayısına bağlı dinamik bir dengeleme mekanizmasını da içerir.

Bu yaklaşım, hem yüksek destek ve güven değerlerine ulaşmayı hem de kural setinin niceliksel yeterliliğini korumayı hedefleyen çok amaçlı bir optimizasyon stratejisi ortaya koyar. Burada destek (S) ve güven (C) her ikisi de [0,1] aralığında bir olasılık belirtir. Genetik algoritma, bu uygunluk değerini maksimize etmek için destek ve güven uzayında arama yapar. Popülasyon boyutu, çaprazlama, mutasyon ve elitizm gibi evrimsel hiper parametreler belirlendikten sonra, süreç maksimum iterasyon sayısına kadar yinelenir. Her iterasyonda seçilim, çaprazlama ve mutasyon

işlemleriyle yeni popülasyonlar oluşturulur ve sürecin sonunda en yüksek uygunluk değerine sahip bireyin parametre kombinasyonu, Apriori algoritmasının nihai parametre seti olarak belirlenir.

Bu çalışmada, genetik algoritmanın parametreleri MAUT yaklaşımıyla optimize edilmiştir. Bu kapsamda, destek, güven ve algoritmanın çalışma süresi kriterleri dikkate alınarak her bir parametre kombinasyonu için fayda (utility) skorları hesaplanmıştır. Genetik algoritma her çalıştırıldığında popülasyon büyüklüğü, iterasyon sayısı, mutasyon oranı, çaprazlama oranı, elitizm ve ağırlıklandırma faktöründe (α) kullanılan sabit sayı olmak üzere altı farklı parametre, tablo 3.2'de gösterilen tüm kombinasyonlarla değerlendirilmiştir. İki, üç ve dört ürün içeren siparişler için, her biri bağımsız olmak üzere 144 farklı parametre kombinasyonunda genetik algoritma çalıştırılmış ve bu parametrelerle Apriori algoritmasının sonuçları üretilmiştir.

Tablo 3.2 MAUT methodu kombinasyonları

Popülasyon Büyüklüğü	İterasyon Sayısı	Mutasyon Oranı	Çaprazlama Oranı	Elitizm	Ağırlıklandırma Faktörü Sabiti
25	45	0,2	0,7	3	20
30	55	0,4	0,8	5	30
35	65				

Her bir parametre kombinasyonu sonucunda elde edilen ortalama destek, ortalama güven ve çalışma süresi değerleri bir karar matrisinde toplanmış, kriterlerin ağırlıkları ise entropi yöntemi ile belirlenmiştir. Entropi yaklaşımı, kriterlerin bilgi içeriği ve değişkenliğini temel alarak, değişkenliği yüksek olan kriterlere daha yüksek ağırlık atayan veri temelli bir yöntemdir. Böylece karar verme süreci öznel yargılardan

arındırılmış ve nesnel bir şekilde yürütülmüştür. Entropi yönteminin verdiği ağırlıklar şekil 3.6'da iki ürünlü, şekil 3.7'de üç ürünlü, şekil 3.8'de ise dört ürünlü için verilmiştir.

	Kriter	Ağırlık
	<chr>	<dbl>
1	Ortalama_Destek	0.452
2	Ortalama_Güven	0.0763
3	Çalışma_Süresi	0.472

Şekil 3.6 İki ürünlü menüler için entropi yöntemiyle hesaplanan kriter ağırlıkları

	Kriter	Ağırlık
	<chr>	<dbl>
1	Ortalama_Destek	0.446
2	Ortalama_Güven	0.422
3	Çalışma_Süresi	0.132

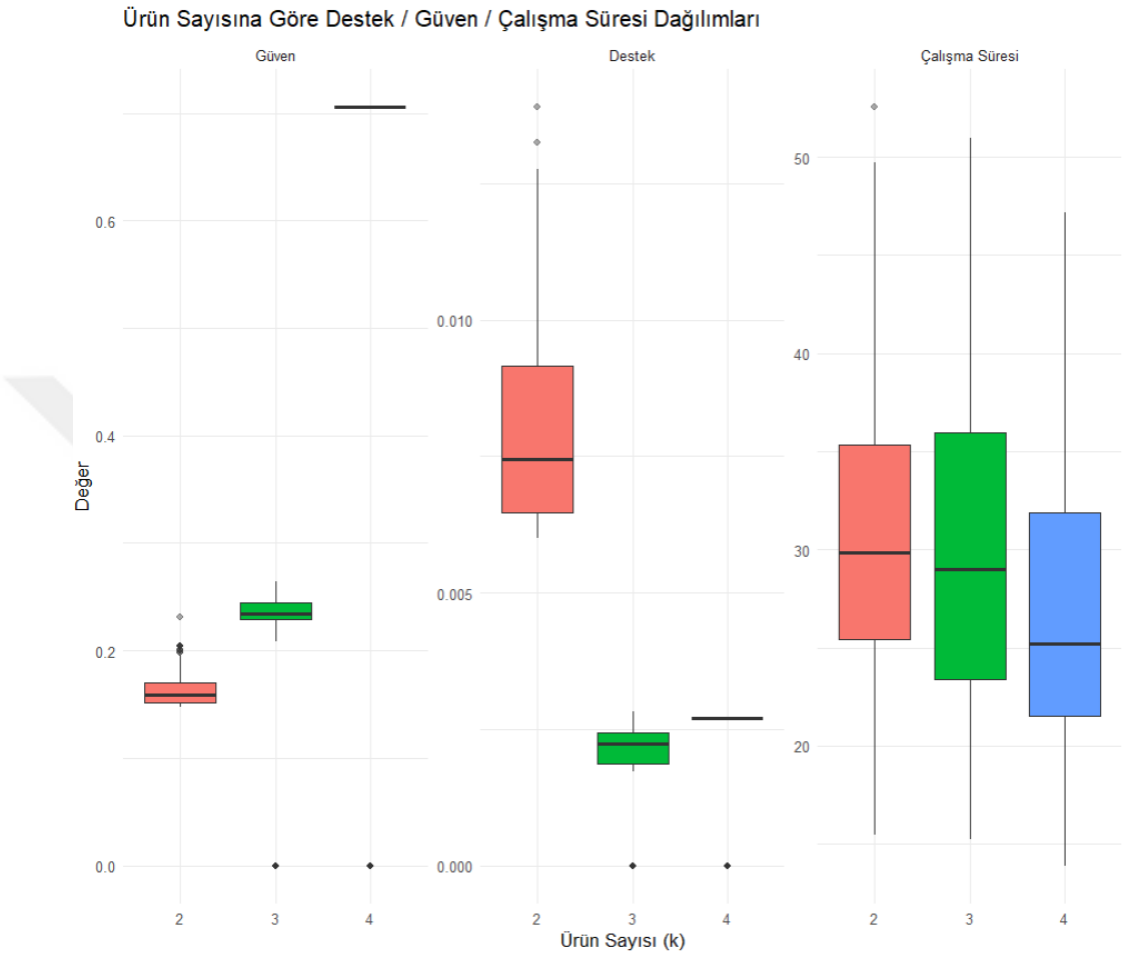
Şekil 3.7 Üç ürünlü menüler için entropi yöntemiyle hesaplanan kriter ağırlıkları

	Kriter	Ağırlık
	<chr>	<dbl>
1	Ortalama_Destek	0.463
2	Ortalama_Güven	0.463
3	Çalışma_Süresi	0.0737

Şekil 3.8 Dört ürünlü menüler için entropi yöntemiyle hesaplanan kriter ağırlıkları

Şekil 3.9'da iki, üç ve dört ürün içeren menüler için destek, güven ve çalışma süresi değerlerinin dağılımları gösterilmektedir. İki ürünlü menülerde güven değerlerinin, destek ve çalışma süresi verilerine göre oldukça dar bir aralıkta yoğunlaştığı görülmektedir; bu durum güven kriterine atanan düşük ağırlığın temel nedenini açıklamaktadır. Destek değerleri açısından bakıldığında, iki ürünlü menülerde ortalama destek düzeyinin diğer kombinasyonlara göre daha yüksek olduğu, ürün sayısı arttıkça bu değerin azaldığı gözlemlenmektedir. Çalışma süreleri ise genel olarak birbirine yakın olmakla birlikte, üç ve dört ürünlü menülerde sürenin hafifçe

kısaldığı görülmektedir. Bu bulgular, ürün sayısı arttıkça kuralların daha özgül hale geldiğini, güven değerlerinin yükselirken destek düzeylerinin doğal olarak azaldığını göstermektedir.



Şekil 3.9 MAUT analizinde kullanılan kriterlerin ürün sayısına göre dağılımları

Elde edilen ağırlıklar ortalama alınarak birleştirilmiş, her parametre kombinasyonu için bütünleşik bir fayda skoru hesaplanmıştır. Fayda skoru yüksek olan kombinasyonlar, destek değeri, güven değeri ve zaman dengesi bakımından en uygun çözüm kümelerini temsil etmektedir. Bu sayede genetik algoritma parametrelerinin, performans ve verimlilik açısından en dengeli yapıların seçilmesini sağlamıştır. En yüksek ortalama fayda değerine sahip ilk on kombinasyon şekil 3.10'da gösterilmiştir.

	Popülasyon_Büyüklüğü	İterasyon	Mutasyon_Oranı	Çaprazlama_Oranı	Elitizm	Ağırlıklandırma_Faktörü_Sabiti	MAUT_Ortalama
	<db1>	<db1>	<db1>	<db1>	<db1>	<db1>	<db1>
1	25	65	0.2	0.8	5	20	0.875
2	30	45	0.2	0.7	3	30	0.874
3	30	45	0.2	0.7	5	20	0.869
4	30	45	0.4	0.7	3	20	0.851
5	35	45	0.2	0.8	5	20	0.837
6	30	45	0.2	0.8	3	20	0.825
7	25	45	0.4	0.7	5	30	0.824
8	25	65	0.2	0.7	5	30	0.817
9	25	55	0.2	0.7	5	20	0.808
10	35	45	0.4	0.8	5	30	0.803

Şekil 3.10 MAUT analizine göre en yüksek fayda değerine sahip 10 genetik algoritma parametre kombinasyonu

Tablo 3.3'te genetik algoritmanın parametreleri verilmiştir.

Tablo 3.3 Genetik algoritma parametreleri

Parametre	**Değer**
Çaprazlama Oranı	0,8
Mutasyon Oranı	0,2
Popülasyon Büyüklüğü	25
Elitizm	5
Maksimum İterasyon	65
Seçilim Yöntemi	**Turnuva Seçimi**

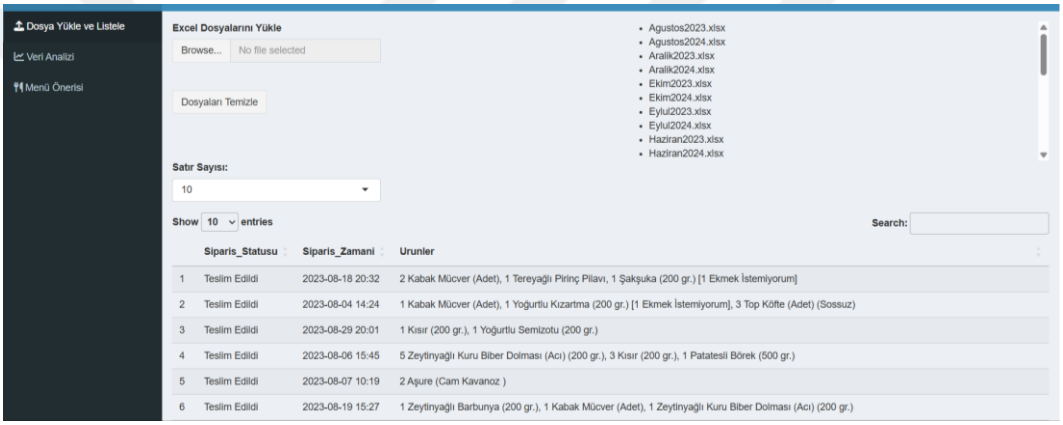
3.4 R Shiny Web Uygulaması

Uygulama, modüler bir yazılım mimarisi temelinde tasarlanmış olup üç ana bileşenden oluşmaktadır. İlk bileşen, kullanıcıların verilerini Excel formatında sisteme aktarabilmesine imkân tanıyarak verileri birleştirmektedir. İkinci bileşen, geçmiş dönemlere ait satış verilerinin sistematik bir biçimde analiz edilmesine olanak sunmakta ve bu sayede eğilimlerin, dönemsel farklılıkların ve performans göstergelerinin ortaya konmasına katkıda bulunmaktadır. Üçüncü bileşen ise, gerçekleştirilen analiz sonuçlarına dayalı olarak karar destek mekanizması işlevi görmekte ve kullanıcılara optimum menü önerileri sunmaktadır. Tüm bileşenler, kullanıcı tarafından belirlenen gün, ay, yıl ve sezon gibi parametrelere duyarlı biçimde

otomatik olarak çalışmakta; böylelikle esnek, dinamik ve kullanıcı odaklı bir etkileşim süreci sağlanmaktadır.

3.4.1 Veri Yükleme

Bu modülde kullanıcı, bir veya birden fazla "*.xlsx"* formatındaki dosyayı sisteme yükleyebilmektedir. Yüklenen dosya isimleri, birleştirilmiş veri seti kullanıcı tarafından incelenebilmektedir. "*Dosyaları Temizle*" butonu ile yüklenen dosyalar temizlenebilmektedir. Bu yapı ile kullanıcı veri yükleme ve yüklediği verilerin kontrolünü esnek ve kontrollü biçimde yönetebilmektedir. Modülün yapısı şekil 3.11'de görüldüğü gibidir.



Şekil 3.11 R shiny veri yükleme ekranı

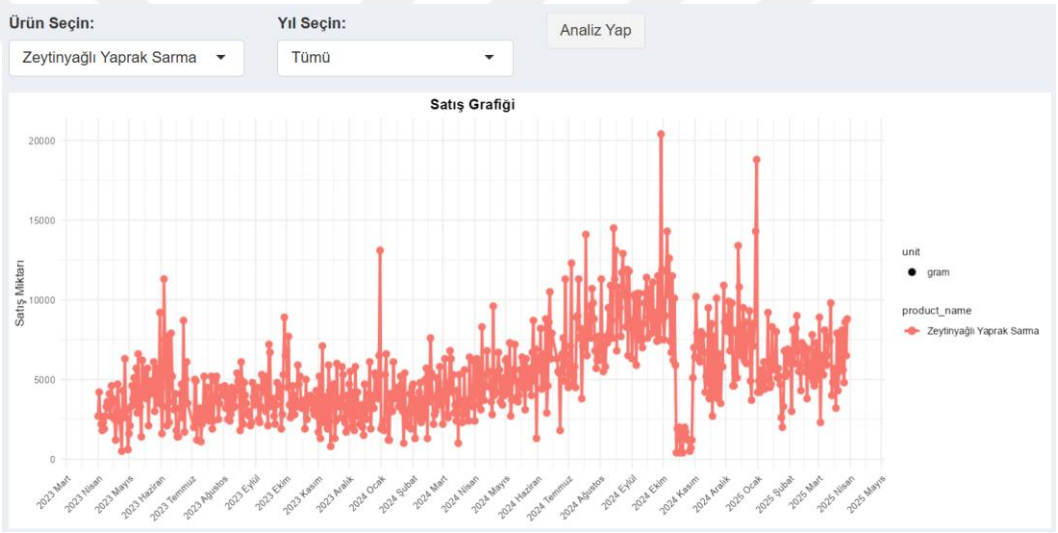
3.4.2 Satış Analizi

Bu modül, kullanıcılara geçmişe dönük satış verilerinin analizini gerçekleştirme olanağı sunmaktadır. *Veri Analizi* sekmesinde iki temel seçim alanı bulunmaktadır: *Ürün* ve *Yıl*. *Ürün* seçeneği aracılığıyla analiz edilmek istenen ürün belirlenirken, *Yıl* seçeneği ile belirli bir yıl ya da alternatif olarak *Tümü* seçeneği tercih edilebilmektedir. Kullanıcı *Analiz Yap* düğmesi aracılığıyla analiz akışını manuel biçimde kontrol edilebilmektedir.

Şekil 3.12'de görülen zaman serisi çizgi grafiği, *Veri Analizi* sekmesinde kullanıcıya sunulmaktadır. Grafik, satış hacmindeki mevsimsellik, ani dalgalanmalar

ve uzun dönemli eğilimlerin bütüncül biçimde değerlendirilebilmesine imkân tanımaktadır. Kullanıcı, seçtiği ürün ve zaman aralığına göre görseli dinamik olarak kontrol edebilmektedir.

Bu örnekte en popüler ürün olan "Zeytinyağlı Yaprak Sarma" seçilmiştir. Grafik incelendiğinde satışların dönemsel dalgalanmalar gösterdiği görülmekte, bu durumun kampanyalar veya özel günlere bağlı sebeplerden kaynaklanabileceği değerlendirilmektedir. Genel eğilim açısından bakıldığında, 2023 yılına kıyasla 2024 yılında satış ortalamasında artış olduğu ve ürün talebinde yükseliş yaşandığı görülmektedir. Ürünün günlük bazda en yüksek satışına 2024 yılının Ekim ayında ulaştığı görülmektedir.

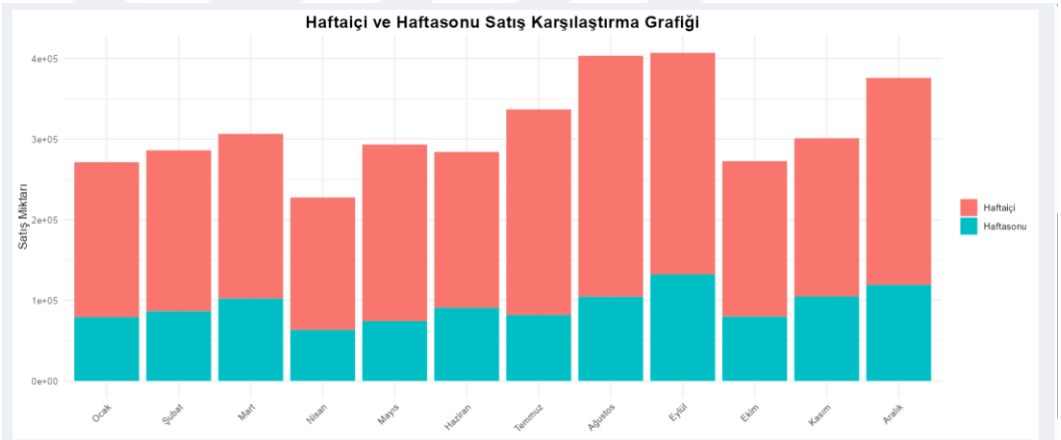


Şekil 3.12 R shiny çizgi grafiği

Şekil 3.13'te, "Zeytinyağlı Yaprak Sarma" ürününe ait haftaiçi ve haftasonu satış miktarlarının ay bazlı karşılaştırmalı sütun grafiği sunulmaktadır. Grafik, ay bazlı haftaiçi ve haftasonu satış hacimlerinin birlikte incelenmesine imkân tanımaktadır. Görsel incelendiğinde, satışların Nisan ayında en yüksek noktaya ulaştığı görülmektedir. Firma ile yapılan değerlendirmeler sonucunda, satış artışının gözlendiği dönemlerde reklam kampanyalarının artırıldığı ve bu kampanyaların satış performansı üzerinde olumlu bir etkisi olduğu belirlenmiştir. Günlük satış bazında değerlendirildiğinde hafta içi günlük ortalama satış miktarı 5.162,57 gram iken, hafta

sonu günlük ortalaması 5.472,06 gramdır. Hafta içi ve hafta sonu satış miktarını karşılaştırmak üzere yapılan Mann Whitney U testine göre bu farkın anlamlı olmadığı tespit edilmiştir (p=0,095). Dolayısıyla, günlük satış miktarı açısından %5 önem düzeyinde hafta içi ve hafta sonu satış miktarları arasında istatistiksel açıdan anlamlı bir farklılık bulunmamaktadır.

Üretim süreci gerekli hammaddeleri temin etmek ve iş gücünü planlamak açısında kritik bir süreçtir. Stok tutmak maliyetleri arttırıcı etki yaratmakta ancak eksik stok ise ürünün gerekli zamanda temin edilmesi önünde engel oluşturmaktadır. Aynı şekilde iş gücü planlamasının eksik yapılması müşteri memnuniyetsizliği ve termin süresinde işlerin tamamlanamaması gibi sonuçlar doğurmakta fazla iş gücü ise firmaya ek bir yük getirmektedir. Bu tür analizler firmanın karlılığını artırmak için destekleyici sonuçlar ortaya koymaktadır.



Ürün	Haftaiçi_Ortalama	Haftasonu_Ortalama	Haftaiçi_Gün_Sayısı	Haftasonu_Gün_Sayısı	p_degeri	anlamli_fark
Zeytinyağlı Yaprak Sarma	5 162.57	5 472.06	513	204	0.095	Hayır

Şekil 3.13 R shiny sütun grafiği

Şekil 3.14'te ürün bazında toplam satış miktarlarını gösteren tablo sunulmaktadır. Tüm ürünlerin satış hacmini karşılaştırmalı olarak değerlendirmeye imkân tanımaktadır. Veriler incelendiğinde, "Zeytinyağlı Yaprak Sarma" ürününün 3.764.700 gram ile açık ara en yüksek satış hacmine sahip olduğu görülmektedir. Bu ürünün ardından "Kısır" (1.856.000 gram) ve "Mercimek Köftesi" (1.854.700 gram)

gelmektedir. İlk üç ürün, toplam satış hacminde baskın bir paya sahip olduğu görülmektedir. Bu tablo, işletme açısından ürün çeşitliliğinin talep dağılımını nasıl etkilediğini göstermektedir.

Ürün Adı	Birim	Toplam Satış Miktarı
Zeytinyağlı Yaprak Sarma	gram	3.764.700
Kısır	gram	1.856.000
Mercimek Köftesi	gram	1.854.700
Zeytinyağlı Biber Dolması	gram	1.174.400
Kıymalı Yaprak Sarma	gram	1.091.900
Patates Salatası	gram	1.012.000
Yoğurtlu Kızartma	gram	951.950
Zeytinyağlı Taze Fasulye	gram	798.600
Kuru Patlıcan Dolması	gram	711.550
Arnavutciğeri	gram	667.160

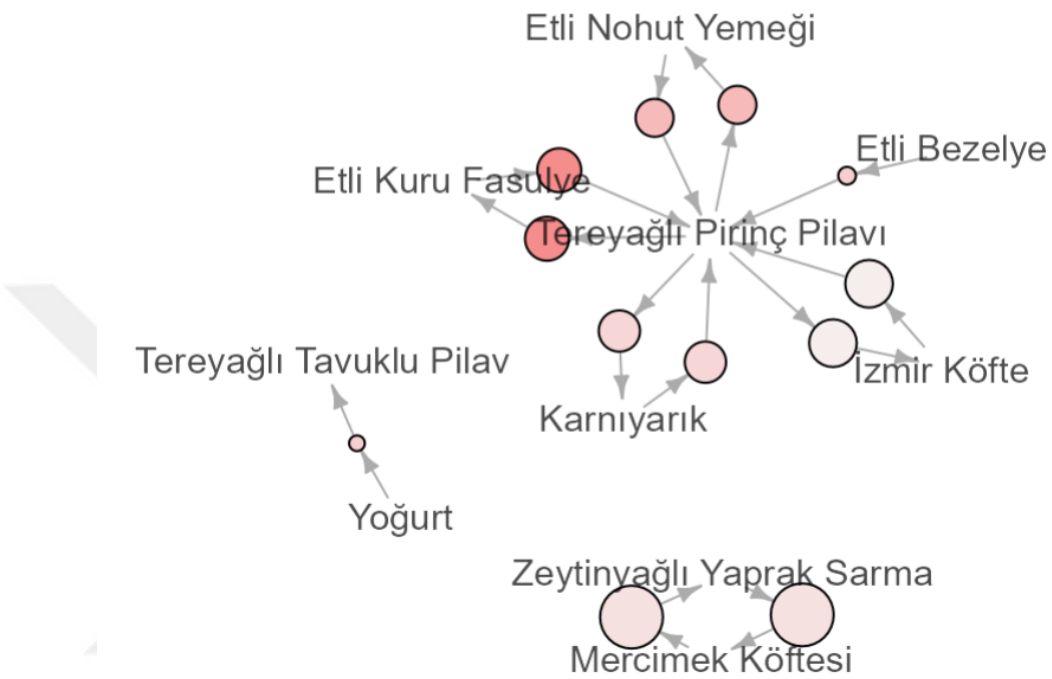
Showing 1 to 10 of 176 entries Previous 1 2 3 4 5 … 18 Next

Şekil 3.14 R shiny satış miktarı tablosu

3.4.3 Optimum Menü Belirleme

Menü Önerisi sekmesi, kullanıcıdan *Hafta Sonu / Hafta İçi / Tümü* seçeneğini, menüde yer alacak ürün sayısını (2 ile 4 arasında) ve sezon bilgilerini girdi olarak alır. Bu bilgiler doğrultusunda sistem, genetik algoritma yardımıyla minimum destek ve minimum güven parametrelerini otomatik olarak belirler ve kullanıcıya uygun menü alternatiflerini üretir. Bu üretilen kurallar arasından en iyi olarak bir kuralı göstermek mümkün değildir. Destek ve güven değeri yüksek olan kurallar anlamlı kurallar olarak etiketlendirilse de kullanıcının tecrübe ve bilgisine göre yorumlanması gerekmektedir. Kuralların görselleştirilmesi sırasında, görsel karmaşıklığını azaltmak amacıyla güven ve destek değerlerinin çarpımıyla elde edilen skorlar kullanılmış ve bu skorlar arasında en yüksek değere sahip 12 kuralın içerdiği ürünler görselleştirilmiştir. Üretilen kural ve görseller şu şekilde değerlendirilmektedir.

Kuralların görselleştirilmesine yönelik oluşturulan örnek bir grafik, şekil 3.15'te gösterilmektedir. Şekildeki düğümlerin (yuvarlakların) büyüklüğü, ürünlerin tüm siparişler içindeki görülme sıklığını yani destek değerini; oklar ise birbirleriyle birliktelik kuralı oluşturan ürünleri temsil etmektedir.



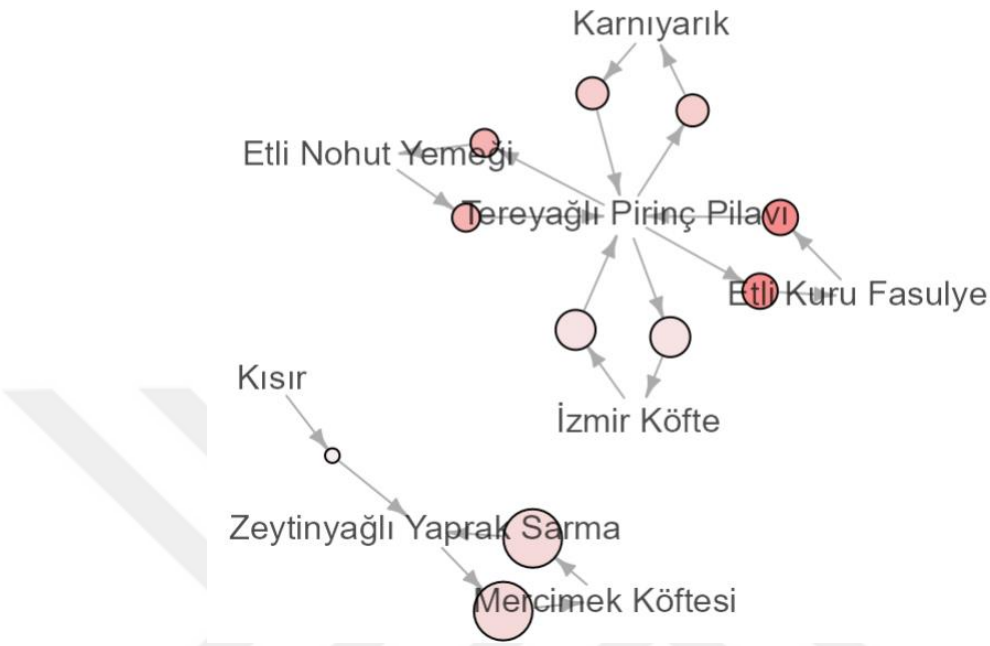
Şekil 3.15 Kuralların örnek görseli

Şekil 3.16'da gösterilen örnek kurallardan ilkini yorumlayacak olursak; "Mercimek Köftesi" ve "Zeytinyağlı Yaprak Sarma" birlikte tüm siparişlerin %1,78'inde yer almaktadır. "Mercimek Köftesi" alanların %26,74'ü "Zeytinyağlı Yaprak Sarma" da almıştır.

rules	Destek	Güven	Kaldıraç
{Mercimek Köftesi} => {Zeytinyağlı Yaprak Sarma}	%1.78	%26.74	2.05
{Zeytinyağlı Yaprak Sarma} => {Mercimek Köftesi}	%1.78	%13.64	2.05
{Tereyağlı Pirinç Pilavı} => {İzmir Köfte}	%1.44	%16.49	1.59
{İzmir Köfte} => {Tereyağlı Pirinç Pilavı}	%1.44	%13.81	1.59
{Etli Kuru Fasulye} => {Tereyağlı Pirinç Pilavı}	%1.35	%37.33	4.29
{Tereyağlı Pirinç Pilavı} => {Etli Kuru Fasulye}	%1.35	%15.51	4.29

Şekil 3.16 Kuralların tablo ile örnek gösterimi

Hafta sonu/Hafta içi ve sezon ayrımı yapmadan iki ürünlü menüler için üretilen sonuç görseli şekil 3.17'de verilmiştir. Üretilen tüm kuralların listesi ise şekil 3.18'de verilmiştir.



Şekil 3.17 İki ürünlü menülerin görselleri

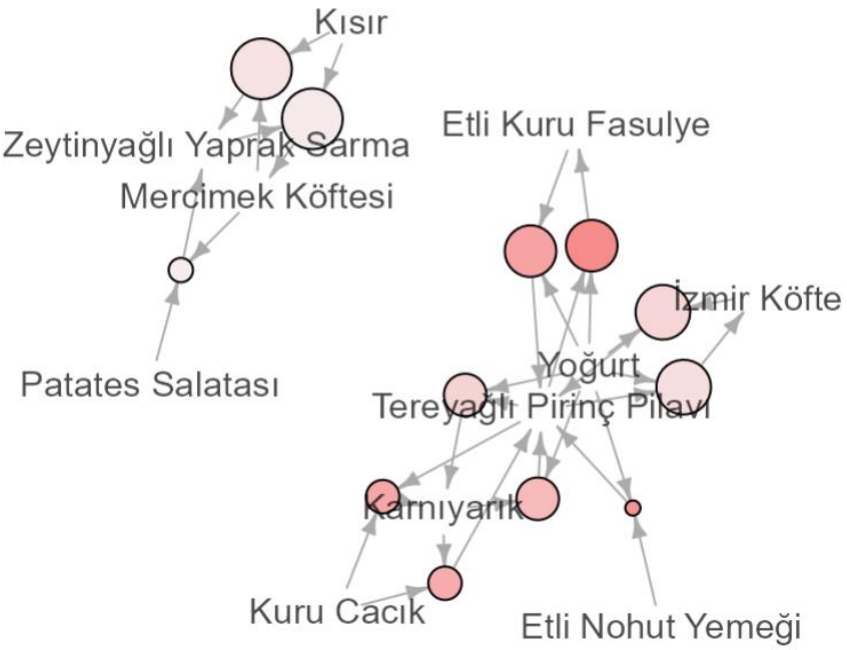
rules	Destek	Güven	Kaldıraç
{Mercimek Köftesi} => {Zeytinyağlı Yaprak Sarma}	%1.78	%26.74	2.05
{Zeytinyağlı Yaprak Sarma} => {Mercimek Köftesi}	%1.78	%13.64	2.05
{Tereyağlı Pirinç Pilavı} => {İzmir Köfte}	%1.44	%16.49	1.59
{İzmir Köfte} => {Tereyağlı Pirinç Pilavı}	%1.44	%13.81	1.59
{Etli Kuru Fasulye} => {Tereyağlı Pirinç Pilavı}	%1.35	%37.33	4.29
{Tereyağlı Pirinç Pilavı} => {Etli Kuru Fasulye}	%1.35	%15.51	4.29
{Karnıyarık} => {Tereyağlı Pirinç Pilavı}	%1.29	%21.68	2.49
{Tereyağlı Pirinç Pilavı} => {Karnıyarık}	%1.29	%14.81	2.49
{Etli Nohut Yemeği} => {Tereyağlı Pirinç Pilavı}	%1.21	%28.83	3.31
{Tereyağlı Pirinç Pilavı} => {Etli Nohut Yemeği}	%1.21	%13.95	3.31
{Kısır} => {Zeytinyağlı Yaprak Sarma}	%0.97	%14.76	1.13
{Etli Bezelye} => {Tereyağlı Pirinç Pilavı}	%0.75	%24.03	2.76
{Yoğurt} => {Tereyağlı Tavuklu Pilav}	%0.7	%23.53	2.78

Showing 1 to 13 of 13 entries Previous 1 Next

Şekil 3.18 İki ürünlü menü kural listesi

Şekil 3.18‘de Apriori algoritması tarafından üretilen 13 kural kullanıcıya sunulmaktadır. Ana yemek olan ürünlerin ve gün menüsü olarak nitelendirilen ürünler olan Mercimek Köftesi, Kısır ve Zeytinyağlı Yaprak Sarma’nın kümelendiği görülmektedir. Tereyağlı Pirinç pilavının ana yemekler için ortak nokta olması menü seçiminde mutlaka dahil edilmesi gerektiğini göstermektedir. Ana yemek menüsü olarak tabir edebileceğimiz “Etli Kuru Fasulye ve Tereyağlı pirinç pilavı” göze çarpmaktadır. İşletmenin gün menüsü olarak adlandırdığı “Mercimek köftesi ve Zeytinyağlı yapmak sarması” üretilen kurallar içerisinde yüksek destek ve güven değerleriyle optimum bir menü olarak etiketlenebilir.

Hafta sonu/Hafta içi ve sezon ayrımı yapmadan üç ürünlü menüler için üretilen sonuç görseli şekil 3.19’da gösterilmektedir. Üretilen kuralların tam listesi ise şekil 3.20’de verilmektedir.



Şekil 3.19 Üç ürünlü menülerin görseli

rules	Destek	Güven	Kaldıraç
{Kısır,Mercimek Köftesi} => {Zeytinyağlı Yaprak Sarma}	%0.28	%29.03	1.69
{Kısır,Zeytinyağlı Yaprak Sarma} => {Mercimek Köftesi}	%0.28	%14.47	1.27
{İzmir Köfte,Yoğurt} => {Tereyağlı Pirinç Pilavı}	%0.27	%27.39	2.35
{Tereyağlı Pirinç Pilavı,Yoğurt} => {İzmir Köfte}	%0.27	%20.09	1.93
{İzmir Köfte,Tereyağlı Pirinç Pilavı} => {Yoğurt}	%0.27	%12.84	1.83
{Etli Kuru Fasulye,Yoğurt} => {Tereyağlı Pirinç Pilavı}	%0.26	%47.73	4.1
{Etli Kuru Fasulye,Tereyağlı Pirinç Pilavı} => {Yoğurt}	%0.26	%14.48	2.07
{Tereyağlı Pirinç Pilavı,Yoğurt} => {Etli Kuru Fasulye}	%0.26	%19.63	4.72
{Karnıyarık,Yoğurt} => {Tereyağlı Pirinç Pilavı}	%0.24	%39.39	3.39
{Tereyağlı Pirinç Pilavı,Yoğurt} => {Karnıyarık}	%0.24	%18.22	2.48
{Karnıyarık,Tereyağlı Pirinç Pilavı} => {Yoğurt}	%0.24	%11.4	1.63
{Karnıyarık,Kuru Cacık} => {Tereyağlı Pirinç Pilavı}	%0.22	%43.9	3.77
{Kuru Cacık,Tereyağlı Pirinç Pilavı} => {Karnıyarık}	%0.22	%29.27	3.99
{Karnıyarık,Tereyağlı Pirinç Pilavı} => {Kuru Cacık}	%0.22	%10.53	2.47
{Mercimek Köftesi,Patates Salatası} => {Zeytinyağlı Yaprak Sarma}	%0.21	%19.88	1.16
{Patates Salatası,Zeytinyağlı Yaprak Sarma} => {Mercimek Köftesi}	%0.21	%18.54	1.63
{Kısır,Patates Salatası} => {Zeytinyağlı Yaprak Sarma}	%0.19	%18.9	1.1
{Patates Salatası,Zeytinyağlı Yaprak Sarma} => {Kısır}	%0.19	%17.42	1.86

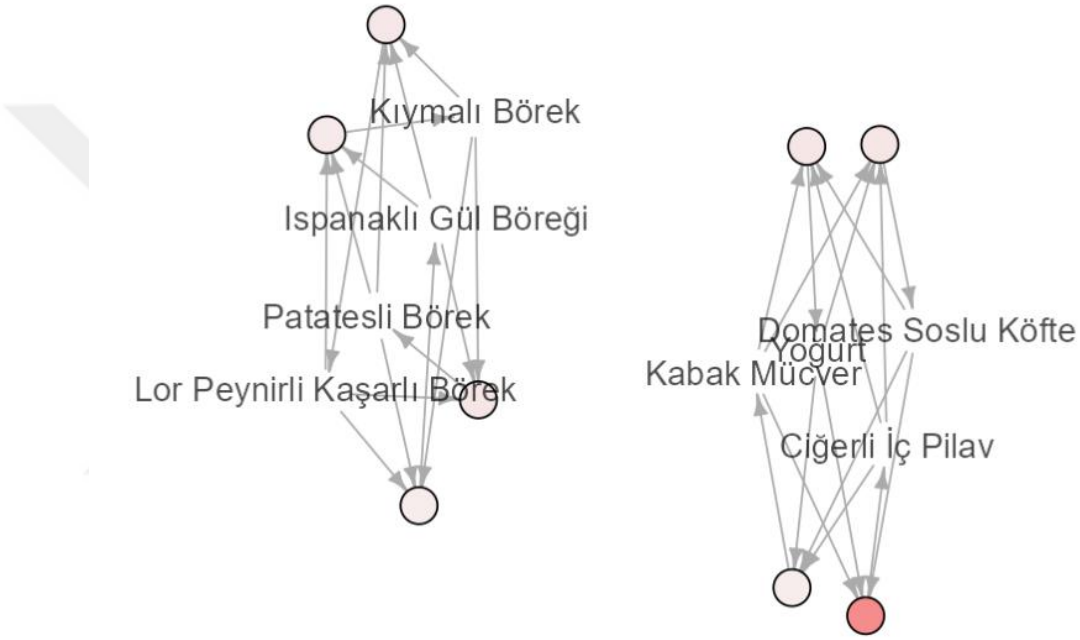
Showing 1 to 18 of 18 entries Previous 1 Next

Şekil 3.20 Üç ürünlü menü kural listesi

Şekil 3.20‘de Apriori algoritması tarafından üretilen üç ürün içeren 18 kural kullanıcıya sunulmaktadır. Destek değerlerinin iki ürünlü menü önerilerine göre düşük olduğu görülmektedir. Kuralların görselleri incelendiğinde “gün menüsü” ürünlerinin ve ana yemeklerin ayrı kümelendiği görülmektedir. “Yoğurt, Etli Kuru Fasulye ve Tereyağlı pirinç Pilavı” optimum ana yemek menüsü, “Zeytinyağlı yaprak sarma, mercimek köftesi ve kısır” optimum gün menüsü olarak değerlendirilebilir.

Hafta sonu/hafta içi ve sezon ayrımı yapılmadan elde edilen dört ürünlü menülere ait sonuç görseli Şekil 3.21’te, kuralların tam listesi ise Şekil 3.22’de sunulmuştur. Destek değerlerinin üç ürünlü menülerle benzer düzeylerde olduğu gözlemlenmiş; buna karşın güven ve kaldıraç değerlerinin iki ve üç ürünlü menülere kıyasla belirgin biçimde daha yüksek çıktığı görülmüştür. Bu durum, dört ürünlü menülerin birlikte sipariş edilme olasılığının tesadüfi olmayan güçlü bir ilişkiyi yansıttığını ve dolayısıyla satış performansı üzerinde pozitif bir etki yaratabileceğini göstermektedir. Özellikle “Kabak Mücver, Yoğurt, Domates Soslu Köfte, Ciğerli İç Pilav” gibi

kombinasyonlar, birbirini tamamlayan ana ve yan yemeklerden oluşmakta ve potansiyel olarak dengeli bir "ev yemeği menüsü" profili sergilemektedir. Benzer biçimde, "Ispanaklı Gül Böreği, Lor Peynirli Kaşarlı Börek, Patatesli Börek, Kıymalı Börek" grubunda ise benzer ürün kategorilerinin birlikte sipariş edildiği görülmektedir. Bu yapı, müşterilerin aynı ürün ailesi içindeki çeşitleri birlikte tercih etme eğiliminde olduklarını göstermekte ve menü öneri sistemlerinde kategorik kümeleme açısından önemli bir içgörü sunmaktadır.



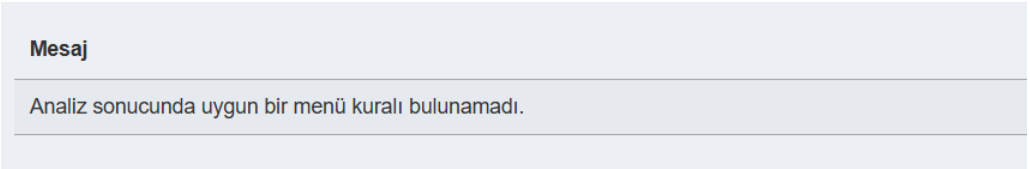
Şekil 3.21 Dört ürünlü menülerin görseli

rules	Destek	Güven	Kaldıraç
{Ciğerli İç Pilav,Domates Soslu Köfte,Yoğurt} => {Kabak Mücver}	%0.27	%88.89	5.29
{Ciğerli İç Pilav,Domates Soslu Köfte,Kabak Mücver} => {Yoğurt}	%0.27	%92.31	12.22
{Ciğerli İç Pilav,Kabak Mücver,Yoğurt} => {Domates Soslu Köfte}	%0.27	%85.71	13.29
{Domates Soslu Köfte,Kabak Mücver,Yoğurt} => {Ciğerli İç Pilav}	%0.27	%85.71	86.03
{Kıymalı Börek,Lor Peynirli Kaşarlı Börek,Patatesli Börek} => {Ispanaklı Gül Böreği}	%0.27	%42.86	5.13
{Ispanaklı Gül Böreği,Lor Peynirli Kaşarlı Börek,Patatesli Börek} => {Kıymalı Börek}	%0.27	%53.33	9.02
{Ispanaklı Gül Böreği,Kıymalı Börek,Lor Peynirli Kaşarlı Börek} => {Patatesli Börek}	%0.27	%66.67	12.15
{Ispanaklı Gül Böreği,Kıymalı Börek,Patatesli Börek} => {Lor Peynirli Kaşarlı Börek}	%0.27	%48.98	10.72

Showing 1 to 8 of 8 entries Previous 1 Next

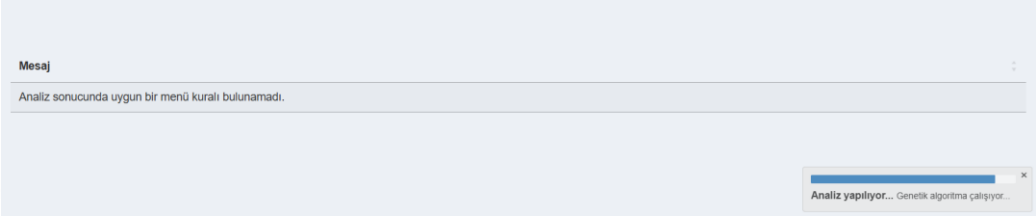
Şekil 3.22 Dört ürünlü menü kural listesi

Farklı çalıştırmalarda genetik algoritmanın çözüm üretemediği durumlarda kullanıcıya şekil 3.23'te görülen "*Analiz sonucunda uygun bir menü kuralı bulunamadı"* mesajı iletilmektedir.



Şekil 3.23 R shiny kural üretilemedi mesajı

Kullanıcı parametrelerde değişiklik yaparak, *Menü Önerisi Yap* tuşuna bastığında sonuçlar üretilene kadar geçen süreçte şekil 3.24'te görülen "*Analiz yapılıyor….Genetik algoritma çalışıyor…"* mesaj yapısı ile bilgilendirilmektedir.

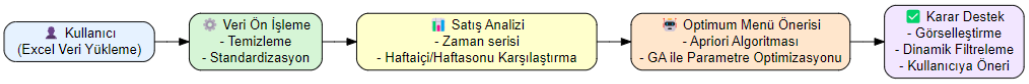


Şekil 3.24 R shiny çalışıyor bilgi mesajı

Kullanıcı, bu seçimlere ek olarak yaz/kış sezonu veya hafta içi/hafta sonu filtrelerini de belirleyebilmektedir. Parametreler değiştirildiğinde, veri seti otomatik olarak güncellenmekte ve analiz süreci tamamen otomatize bir yapı içerisinde yeniden yürütülmektedir.

BÖLÜM DÖRT
DEĞERLENDİRME VE SONUÇ

Günümüzde firmalar, gelişen teknolojiler sayesinde verilerini hızlı ve kolay bir şekilde toplayabilmektedir. Ancak bu verilerin büyük boyutlara ulaşması, anlamlı ve faydalı bilgilerin elde edilebilmesi için ileri düzey istatistiksel yöntemlerin kullanılmasını gerekli kılmaktadır. Bu tez çalışması kapsamında, kullanıcıların geçmişe dönük verilerini görselleştirerek inceleyebileceği, istatistiksel yöntemlerle analizi edebileceği ve optimum menü önerileri ile geleceğe yönelik alacağı kararlara destek sağlayabilecek bir karar destek sistemi oluşturmak amacıyla bir R Shiny web uygulaması geliştirilmiştir. Uygulamanın genel işleyiş akışı Şekil 4.1'de sunulmuştur.



Şekil 4.1 Uygulama süreç akış şeması

Web tabanlı olarak yayınlanan uygulama ile kullanıcıların verilerini yükleyebilmesi, bu verilerin otomatik bir yapı içinde düzenlenmesi ve sonrasında iki farklı modülde analiz edilmesi sağlanmaktadır. İlk modülde kullanıcı geçmiş satışlarını inceleyebilmekte, ikinci modülde ise kendisine optimum menü önerileri sunulmaktadır.

Sonuçlar incelendiğinde; genellikle düşük güven ve destek değerleri gözlenmiştir. Bunun sebebi olarak ürünün gamının (176 çeşit) olması gösterilebilir. Sonuçlar bütüncül bir bakış açısıyla değerlendirildiğinde, menülerin temel olarak 'gün menüsü' ve 'ana yemekler' ekseninde oluşturulmasının optimum bir yaklaşım olduğu görülmektedir. Analiz bulguları, yüksek destek değerleri nedeniyle iki ürünlü menü kombinasyonlarının menü planlamasında mutlaka yer alması gerektiğini ortaya koymaktadır. Üç ürünlü menülerde ise ana yemeğe tamamlayıcı unsur olarak yoğurt veya kuru cacık gibi ürünlerin öne çıkmaktadır. Bununla birlikte, güven değerlerinin yüksekliği, dört ürünlü menülerin de satış performansı ve müşteri memnuniyeti üzerinde olumlu bir etki yaratabileceğini desteklemektedir. Dört ürünlü menü

kombinasyonları incelendiğinde, üçüncü ürün olan yoğurda ek olarak kabak mücverin öne çıktığı ve bu ürünün menüye çeşitlilik kazandırarak pozitif yönde ayrıştığı belirlenmiştir. Bu sonuçlar, menü optimizasyonunda ürün çeşitliliği ile müşteri memnuniyeti arasında işletmeye dinamik bir denge sunması açısından desteklemektedir. Ayrıca hafta sonu/hafta içi ve dönemsel satış grafikleri ile üretim ve stok planlaması karar süreçlerine destek sağlanmıştır.

Sonuç olarak, kullanıcıya dinamik bir şekilde spesifik parametreler seçerek verilerini analiz edebildiği ve değişken koşullarda manuel müdahale gerektirmeden parametrelerin otomatik olarak belirlendiği bir karar destek sistemi sunulmuştur. Bu yapı web tarayıcısı üzerinden yayınlanarak işletmenin erişimine açılmış, böylece zorlu rekabet koşullarında işletmeye profesyonel bir veri analiz kurgusu ile destek sağlanmıştır.

KAYNAKLAR

Agrawal, R., & Srikant, R. (1994). Fast algorithms for mining association rules in large databases. In *Proceedings of the 20th International Conference on Very Large Data Bases (VLDB)* (pp. 487–499). Santiago, Chile.

Akpınar, Ş. (2009). *A hybrid genetic algorithm for mixed-model assembly line balancing problem with parallel workstation assignment* (Yüksek lisans tezi). Dokuz Eylül Üniversitesi, İzmir.

Aydın, B., & Oruç, Ö. E. (2022). Determining the most useful renewable energy alternative for Turkey by combining MAUT and TAOV methods. *International Journal of Energy Studies*, *9*(2), 291-308.

Chadokar, S. K., Singh, D., & Singh, A. (2013). Optimizing network traffic by generating association rules using hybrid apriori-genetic algorithm. *2013 International Conference on Advances in Computing, Communications and Informatics (ICACCI)*, 1–7. IEEE.

Coit, D. W., Smith, A. E., & Tate, D. M. (1996). Adaptive penalty methods for genetic optimization of constrained combinatorial problems. *INFORMS Journal on Computing*, *8*(2), 173-182.

Fishburn, P. C. (1967). Methods of estimating additive utilities. *Management science*, *13*(7), 435-453.

Fishburn, P. C., & Keeney, R. L. (1974). Seven independence concepts and continuous multiattribute utility functions. *Journal of Mathematical Psychology*, *11*(3), 294-327.

Gürgen, G. (2008). *Birliktelik kuralları ile sepet analizi ve uygulaması* (Yüksek lisans tezi). Marmara Üniversitesi, Sosyal Bilimler Enstitüsü, Ekonometri Anabilim Dalı, İstatistik Bilim Dalı, İstanbul.

Hamidi, H., & Haghi, B. (2024). An approach based on data mining and genetic algorithm to optimizing time series clustering for efficient segmentation of customer behavior. *Computers in Human Behavior Reports, 16*, 100520.

Holland, J. (1975). *Adaptation in natural and artificial systems.* Univ. Michigan Ann Arbor, MIT.

Hussein, N., Alashqur, A., & Sowan, B. (2015). Using the interestingness measure *lift* to generate association rules. *Journal of Advanced Computer Science & Technology*, 4(1), 156–162.

Jabarnejad, M. (2010). *An improved organization method for association rules and a basis for comparison of methods* (Yüksek lisans tezi). Orta Doğu Teknik Üniversitesi, Ankara.

Jia, L., Yao, W., Jiang, Y., Li, Y., Wang, Z., Li, H., ... & Zhang, H. (2022). Development of interactive biological web applications with R/Shiny. *Briefings in bioinformatics*, *23*(1), bbab415.

Kaya, B. (2010). *Tıbbi veri kümeleri arasındaki birliktelik kurallarının çok amaçlı genetik algoritma ile çıkarılması* (Yüksek lisans tezi). Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elazığ.

Kazarlis, S., & Petridis, V. (1998, Eylül). Varying fitness functions in genetic algorithms: Studying the rate of increase of the dynamic penalty terms. In *International conference on parallel problem solving from nature* (pp. 211-220). Berlin, Heidelberg: Springer Berlin Heidelberg.

Köle, M. (2023). *Apriori algoritması ile kitap oylamaları analizi* (Yüksek lisans tezi, Manisa Celal Bayar Üniversitesi, Fen Bilimleri Enstitüsü).

Li, H., & Ni, Y. (2012). Intrusion detection technology research based on Apriori algorithm. *Physics Procedia, 24*(Part C), 1615–1620.

Meniz, B. (2024). *Dinamik yapıda yeni bir genetik algoritma önerisi: Seçilim operatörü kararcı genetik algoritma (SOKGA) ve asimetrik kapasiteli araç*

rotalama problemi üzerine bir uygulama (Doktora tezi). Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.

Panjaitan, S., Sulindawaty, Amin, M., Lindawati, S., Watrianthos, R., Sihotang, H. T., & Sinaga, B. (2019, Ağustos). *Implementation of Apriori Algorithm for Analysis of Consumer Purchase Patterns*. *Journal of Physics: Conference Series* (Cilt 1255, Sayı 1, s. 012057). IOP Publishing.

Qodmanan, H. R., Nasiri, M., & Minaei-Bidgoli, B. (2011). Multi objective association rule mining with genetic algorithm without specifying minimum support and minimum confidence. *Expert Systems with Applications, 38*(1), 288–298.

Sağın, A. N. (2018). *Veri madenciliği algoritmaları ile birliktelik kurallarının belirlenmesi: Perakende sektöründe bir uygulama* (Yüksek lisans tezi). İstanbul Ticaret Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.

Immanuel, S. D., & Chakraborty, U. K. (2019). Genetic algorithm: An approach on optimization. In *2019 international conference on communication and electronics systems (ICCES)* (pp. 701-708). IEEE.

Turan, Ö. (2024). *Genetic algorithm and binary masks for co-learning multiple datasets in deep neural networks* (Yüksek lisans tezi). Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, Ankara.

Zhang, X., & Zhang, J. (2023). Analysis and research on library user behavior based on apriori algorithm. *Measurement: Sensors*, *27*, 100802.