

T.C
KIRIKKALE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI
YÜKSEK LİSANS TEZİ

ARIZA ÖRÜNTÜLERİNİN BELİRLENMESİNDE SIRALI ÖRÜNTÜ
MADENCİLİĞİ VE OTOBÜS FİLOSUNDA UYGULANMASI

Metin İFRAZ

HAZİRAN 2021

Endüstri Mühendisliği Anabilim Dalında Metin İFRAZ tarafından hazırlanan ARIZA ÖRÜNTÜLERİNİN BELİRLENMESİNDE SIRALI ÖRÜNTÜ MADENCİLİĞİ VE OTOBÜS FİLOSUNDA UYGULANMASI adlı Yüksek Lisans Tezinin Anabilim Dalı standartlarına uygun olduğunu onaylarım.

Prof. Dr. Süleyman ERSÖZ
Anabilim Dalı Başkanı

Bu tezi okuduğumu ve tezin **Yüksek Lisans Tezi** olarak bütün gereklilikleri yerine getirdiğini onaylarım.

Doç. Dr. Tahsin ÇETİNYOKUŞ
Ortak Danışman

Prof. Dr. Süleyman ERSÖZ
Danışman

Jüri Üyeleri

Başkan : Prof. Dr. Serpil EROL _____
Üye (Danışman) : Prof. Dr. Süleyman ERSÖZ _____
Üye : Doç. Dr. Adnan AKTEPE _____

30 / 06 /2021

Bu tez ile Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulu Yüksek Lisans derecesini onaylamıştır.

Prof. Dr. Recep ÇALIN
Fen Bilimleri Enstitüsü Müdürü

ÖZET

ARIZA ÖRÜNTÜLERİNİN BELİRLENMESİNDE SIRALI ÖRÜNTÜ MADENCİLİĞİ VE OTOBÜS FİLOSUNDA UYGULANMASI

İFRAZ, Metin

Kırıkkale Üniversitesi

Fen Bilimleri Enstitüsü

Endüstri Mühendisliği Anabilim Dalı, Yüksek Lisans Tezi

Danışman: Prof. Dr. Süleyman ERSÖZ

Ortak Danışman: Doç. Dr. Tahsin ÇETİNYOKUŞ

Haziran 2021, 62 sayfa

Otobüs filolarında farklı üreticilerden alınan çeşitli model, yakıt vb. özellikli araçlardan dolayı araç çeşitliliği ve sayısı her geçen gün artmaktadır. Bu durum arıza tiplerinin ve sayılarının artmasına ve arızaya bağlı yedek parça çeşitliliğine neden olmaktadır. Bu yüzden bakım onarımın verimli şekilde yapılması güçleşmektedir. Arızaların ve sebep oldukları kaynak kullanımının azaltılması, bir sonraki arızanın tahmin edilebilmesi ve etkin bir yedek parça yönetimi yapılması bakım onarım birimleri için kritik önem teşkil etmektedir. Bu çalışmadaki amaç, arıza örüntülerini bularak her türlü arıza maliyetlerinin azalmasına katkı sağlamak ve bir sonraki arıza ile arızada kullanılacak yedek parça bilgilerini tahmin etmektir. Amaca ulaşabilmek için arıza örüntülerinin belirlenmesinde sıralı örüntü madenciliği yaklaşımı, yedek parçalarının tahmininde ise yaygın öge madenciliği yaklaşımı kullanılmıştır. Uygulamada bir büyükşehir hizmet veren otobüs filosuna ait dört yıllık şanzıman arıza verisi kullanılmıştır. Çalışma sonucunda, seçilen destek ve güven değerlerinde çeşitli arıza örüntüleri ve yedek parça kümeleri bulunmuştur ve öneriler getirilmiştir.

Anahtar Kelimeler: Bakım Yönetimi, Sıralı Örüntü Madenciliği, Yedek parça Yönetimi, Veri madenciliği.

ABSTRACT

SEQUENTIAL PATTERN MINING IN DETERMINING FAULT PATTERNS AND ITS APPLICATION IN BUS FLEET

İFRAZ, Metin

Kırıkkale University

Graduate School of Natural and Applied Sciences

Department of Industrial Engineering Master's Thesis

Supervisor: Prof. Dr. Süleyman ERSÖZ

Co- Supervisor: Assoc. Prof. Dr. Tahsin ÇETİNYOKUŞ

June 2021, 62 pages

In bus fleets, the variety and number of vehicles are increasing day by day due to the different models, fuel, etc. vehicles purchased from different manufacturers. This situation leads to an increase in the types and numbers of faults and a variety of spare parts associated with the fault. Therefore, it becomes difficult to perform maintenance and repair efficiently. Reducing the faults and the resource usage it cause, predicting the next fault and effective spare parts management is critical for maintenance and repair departments. The aim of this study is to contribute to the reduction of all kinds of fault costs by finding fault patterns and to predict the next fault and the spare part information to be used in the next fault. In order to achieve the aim, sequential pattern mining approach was used to determine fault patterns and traditional frequent itemset mining approach was used to predict spare parts. In the application, four years of gearbox fault data of the bus fleet serving a metropolitan city was used. As a result of the study, various fault patterns and spare parts clusters were found in the selected support and confidence values and suggestions were made.

Key words: Maintenance Management, Sequential Pattern Mining, Spare Parts Management, Data Mining

TEŐEKKÜR

Lisans eđitimine bařladıđımdan itibaren desteklerini esirgemedен sürekli yanımda olan danıřman hocam Prof. Dr. Sileyman ERSÖZ 'e; Yüksek Lisans' a bařladıđımdan itibaren sürekli yol göstererek desteklerini esirgemeyen ortak danıřman hocam Doç. Dr. Tahsin ÇETİNYOKUŐ 'a; Tez çalıřmamda ilgili görüő ve önerileriyle katkı sađlayan Prof. Dr. A. Kürőad TÜRKER 'e ve Doç. Dr. Adnan AKTEPE 'ye sonsuz teőekkürlerimi sunarım.

Çalıřmama uygulama yeri sađlayan ve tecrübeleriyle yol gösteren Ankara Büyükşehir Belediyesi EGO Araç Bakım Onarım Daire Bařkanı Sn. İsmail NALBANT 'a; Bölge Atölyeler ve Bakım Planlama Őube Müdürü Sn. Mustafa ŐAHİN 'e ve Merkez Atölye Müdürü Sn. Emin Gökhan İLHAN 'a teőekkürlerimi sunarım.

2210-A Genel Yurt İçi Yüksek Lisans Burs Programı kapsamında yüksek lisans çalıřmama destek sađlayan TÜBİTAK'a teőekkürlerimi sunarım.

Tüm hayatım boyunca hep yanımda olup destek ve dualarını esirgemeyen Canım Annem Sultan İFRAZ 'a, Babam Erol İFRAZ 'a, Ablam Özlem ŐAHİN 'e ve Kardeřim İbrahim İFRAZ 'a sonsuz teőekkür ve saygılarımı sunarım.

Haziran 2021

Metin İFRAZ
(Endüstri Mühendisi)

İÇİNDEKİLER DİZİNİ

	<u>Sayfa</u>
ÖZET	i
ABSTRACT	ii
TEŞEKKÜR	iii
İÇİNDEKİLER DİZİNİ	iv
ÇİZELGELER DİZİNİ	vi
ŞEKİLLER DİZİNİ	vii
KISALTMALAR DİZİNİ	viii
1. GİRİŞ	1
2. BAKIM YÖNETİMİ	6
3. LİTERATÜR TARAMASI	9
4. VERİ MADENCİLİĞİ	15
4.1. Bilgi Keşif Süreci	15
4.2. Veri Madenciliği Yöntemleri	17
4.2.1. Tahmin Edici Yöntemler.....	18
4.2.1.1. Sınıflandırma.....	18
4.2.1.2. Regresyon.....	22
4.2.1.3. Zaman Serileri Analizi	22
4.2.2. Tanımlayıcı Yöntemler	22
4.2.2.1. Birliktelik Kuralları.....	22
4.2.2.1.1. Yaygın Öğe Madenciliği	25
4.2.2.2. Kümeleme	27
4.2.2.3. Sıralı Örüntü Madenciliği	28
5. ÇALIŞMA ALANI	31
5.1. İşletme Hakkında.....	31
5.2. CNG Otobüsler.....	33
5.3. Şanzıman	34

6. MODELİN TASARLANMASI VE UYGULANMASI	35
6.1. Verilerin Seçimi	36
6.2. Verilerin Ön İşlenmesi ve Dönüştürülmesi	37
6.3. Çalışmada Kullanılan Yazılım	40
6.4. Sıralı Örüntülerin ve Kuralların Bulunması	41
6.5. Sık (Bağımlı) Yedek Parça Gruplarının Bulunması	46
6.6. Sıralı Örüntü Kuralları ile Sık (Bağımlı) Yedek parça Gruplarının Entegrasyonu	54
7. SONUÇ VE ÖNERİLER	57
KAYNAKLAR	59

ÇİZELGELER DİZİNİ

Sayfa

Çizelge 4.1. Satın alınan ürün verileri	25
Çizelge 4.2. Tekli kombinasyonların destek değerleri.....	26
Çizelge 4.3. İkili kombinasyonların destek değerleri	26
Çizelge 4.4. Üçlü kombinasyonların destek değerleri	27
Çizelge 4.5. Zaman etiketli dizi veri tabanı	29
Çizelge 4.6. Zaman etiketli örüntüler	30
Çizelge 6.1. Arıza tipleri ve kodları.....	38
Çizelge 6.2. Ön işlemlerden geçirilmiş veri seti örneği.....	38
Çizelge 6.3. Zaman Etiketleri	39
Çizelge 6.4. Tüm örüntüler	42
Çizelge 6.5. En iyi sıralı örüntülerden elde edilen kurallar	45
Çizelge 6.6. Test verisiyle tahmin sonuçları	46
Çizelge 6.7. 31 ve 18 nolu arızaların yedek parçaları ve kodları.....	47
Çizelge 6.8. 31 nolu arıza yedek parça tüketim verileri	47
Çizelge 6.9. 31 nolu arıza sık kullanılan yedek parça kümeleri	48
Çizelge 6.10. 18 nolu arıza yedek parça tüketim verileri	48
Çizelge 6.11. 18 nolu arıza sık kullanılan yedek parça kümeleri	49
Çizelge 6.12. 23,16 ve 4 nolu arızaların yedek parçaları ve kodları.....	50
Çizelge 6.13. 23 nolu arıza yedek parça tüketim verileri	51
Çizelge 6.14. 23 nolu arıza sık kullanılan yedek parça kümeleri	51
Çizelge 6.15. 16 nolu arıza yedek parça tüketim verileri	52
Çizelge 6.16. 16 nolu arıza sık kullanılan yedek parça kümeleri	52
Çizelge 6.17. 4 nolu arıza yedek parça tüketim verileri	53
Çizelge 6.18. 4 nolu arıza sık kullanılan yedek parça kümeleri	53

ŞEKİLLER DİZİNİ

Sayfa

Şekil 2.1. Bakım Stratejileri.....	7
Şekil 2.2. Bakım maliyeti ve bakım sayısı arasındaki ilişki	8
Şekil 4.1. BKS sürecinin adımları (Han vd. 2011)	16
Şekil 4.2. Veri madenciliği yöntemlerinin sınıflandırılması.....	18
Şekil 4.3. Kalp yetmezliği karar ağacı yapısı (Algı, 2020).....	19
Şekil 4.4. YSA mimarisi	20
Şekil 5.1. CNG Otobüs	34
Şekil 5.2. Otobüs Şanzımanı.....	34
Şekil 6.1. Methodoloji	35
Şekil 6.2. Çalışmada kullanılan ham veri örneği	37
Şekil 6.3. (Hirata ve Yamana, 2006)'ın geliştirdiği algoritmanın girdi formatı.....	40
Şekil 6.4. SPMF programı ara yüzü.....	41
Şekil 6.5. Arıza örüntüleri ve Yedek parça grupları (%10-%40)	54
Şekil 6.6. Arıza örüntüleri ve Yedek parça grupları (%10-%30)	55
Şekil 6.7. Arıza örüntüleri ve Yedek parça grupları (%10-%40)	55
Şekil 6.8. Arıza örüntüleri ve Yedek parça grupları (%10-%30)	56

KISALTMALAR DİZİNİ

ABC	Always Better Control
ATM	Automatic Teller Machine
BOYS	Bakım Onarım Yönetim Sistemi
BKS	Bilgi Keşif Süreci
CNG	Compressed Natural Gas
DVM	Destek Vektör Makineleri
DVR	Destek Vektör Regresyonu
EGO	Ankara Elektrik Havagazı ve Otobüs İşletmesi
FSN	Fast-Slow-Non-moving
GSP	Generalized Sequential Pattern
SPMF	Sequential Pattern Mining Framework
VED	Vital-Essential-Desirable
YSA	Yapay Sinir Ağları

1. GİRİŞ

Üretim ve hizmet endüstrilerinde faaliyet gösteren işletmelerin ulusal ve uluslararası pazarda başarılı olabilmesi kendilerini geliştirerek rekabet gücünü arttırmaları ile mümkündür. Bu gelişmenin sürekli olabilmesi için iş süreçlerinde meydana gelen problemler sistematik olarak incelenmelidir. Problemlerin kök nedenleri araştırılmalıdır. Gerekli aksiyonlar alınarak verimlilik artırılmalı ve maliyetler azaltılmalıdır. Ayrıca artan rekabet ortamında işletmeler müşterilerinin beklentilerini dinleyerek iş süreçlerini geliştirmeli ve müşteri memnuniyetini sağlayarak gelirlerini arttırmayı hedeflemelidirler.

İşletmelerin bu hedeflerini gerçekleştirebilmesi için ihtiyaç duydukları makine, araç ve ekipmanların istenilen zamanda hazır ve çalışabilir olması için etkin ve verimli bir bakım organizasyonu gerekmektedir. Küresel rekabet ortamında işletmeler, ayakta kalabilmek için maliyetlerini düşürme baskısı altındadır. Bakım faaliyetlerinin işletme maliyetleri içerisinde önemli bir paya sahip olması da bakım organizasyonunun yönetilmesini daha da önemli hale getirmektedir.

Bakım organizasyonunun etkin ve verimli bir biçimde çalışabilmesi, arızaların azaltılması, planlı bakımların zamanında yapılması, ihtiyaç duyulan yedek parçaların zamanında ve istenilen miktarda olması ile mümkün olabilmektedir. Planlı bakımlar ile arıza frekansları azaltılabilmesine rağmen arızaları tamamen önlemek mümkün değildir. Bu nedenle planlı bakım çalışmalarının yanı sıra arıza örüntülerinin ve kök nedenlerinin bulunarak azaltılması gerekir.

Birçok durumda bir parça veya ekipmanın arızası sistemde farklı arızalara yol açabilmektedir. Bu durum “ **arızalar arasında ardışık ilişki var mıdır?**” sorusunu akla getirmektedir. Literatürde bu ilişkileri araştıran sıralı örüntü madenciliği algoritmaları bulunmaktadır. Böyle bir yaklaşımın arıza bakım alanında uygulanması çeşitli arızalar arasındaki ilişkileri ortaya çıkarabilir ve sebepler araştırılarak arızaların azalmasına katkı sağlanabilir. Ayrıca, arıza örüntü bilgisini geçmiş arıza kayıtlarından edinen bakım yöneticisi, otobüsler arıza vermeden önce gerekli aksiyonları alarak ardışık gelecek arızaları engelleyebilir.

İşletmeler planlı ve arıza bakımlar için yedek parça tutmak zorundadırlar. Yani yedek parça tutulmasının nedeni planlı ve arıza bakımlardır (Bülbül, 2014). Planlı bakımlarda kullanılacak yedek parça türü, miktarı ve ne zaman kullanılacağı belirli olduğundan planlaması kolaydır. Bu noktada planlaması zor olan arıza bakımlardır. Çünkü arızanın ne zaman gerçekleşeceği, hangi tip arıza olacağı ve arızada hangi yedek parçanın kullanılacağı belirsizdir. Bu sebeple arıza bakım ile yedek parça yönetimi birlikte ele alınmalıdır.

Sağlıklı yürüyen bir bakım organizasyonunda yönetilmesi gereken binlerce yedek parça vardır. Planlı ve arıza bakımlarda kullanılacak yedek parçalar ihtiyaç anında istenilen miktar ve zamanda hazır olmalıdır (Erbaş, 2018). Bu yedek parçaların ciddi maliyetlerinden dolayı gereğinden fazla olması istenmez. İhtiyaç duyulan miktardan az olması durumunda ise makine ve araçlar planlanan görevlerini yerine getiremez. Bu durum hem müşteri memnuniyetsizliğine hem de makine veya araçların çalışmamasından dolayı gelir kaybına neden olur. Dolayısıyla hem maliyetleri azaltmak hem de makine veya araçların optimum kullanılabilirliğini sağlamak için arıza ve yedek parça yönetimini birlikte ele alan bir yaklaşım geliştirilmesi gerekir.

Tek tek takip edilemeyecek kadar çok yedek parçalara sahip olan işletmeler bu stokları yönetmek için çeşitli yöntemler ve kriterler kullanarak sınıflandırmaktadırlar. Literatürde stok gruplamak için en çok kullanılan yöntemler ABC (Always Better Control), VED (Vital-Essential-Desirable), XYZ, FSN (Fast-Slow-Non-moving) ve Çok kriterli karar verme (ÇKKV) yaklaşımlarıdır. ABC yöntemi stokların yıllık kullanım miktarı ve birim maliyetlerinden hareketle sınıflandırma yapar. VED yöntemi, stokların önemine göre sınıflama yapar. Bu yöntemde, eğer bir stok kaleminin olmaması bakımda aksamaya neden olacaksa onu hayati önemdeki grup olan V'de sınıflandırır. XYZ yönteminde, stokların tüketimindeki varyasyona göre sınıflandırma yapılır. Örneğin tüketimi çok sapma gösteren bir parça Z grubuna dahil edilir. FSN yönteminde parçaların yıllık tüketim hızları dikkate alınır. Eğer bir stok kalemi yüksek stok devir hızına sahip ise F grubunda yer alır. ÇKKV yönteminde ise literatürde genel olarak maliyet kriterine ek olarak uzmanlarca belirlenen kriterler de eklenerek sınıflandırma yapılır. Yukarıda ifade edilen yöntemlerin hiçbiri parçaların birbirleriyle ilişkisini yani parçaların birbirlerine bağımlılıklarını (birlikte tüketimini) dikkate almamaktadır.

Bakım ve stok yönetiminin en önemli olduğu işletmeler arasında şüphesiz araç filoları en önde gelmektedir. Filolardaki bakım yöneticileri, farklı üreticilerden alınan farklı yakıt ve yaşlardaki araçlardan dolayı çok çeşitli arızalar ile karşılaşmaktadırlar ve binlerce yedek parçayı yönetmek durumundadırlar. Araç filoları içinden en çok araca sahip olan filolar genellikle şehir içi ulaşımı sağlayan belediyelere ait otobüs filolarıdır.

Günümüzde şehir içi ulaşımın büyük bir kısmı yerel belediyeler tarafından sağlanmaktadır. Bu ulaşım araçlarının büyük kısmı otobüs ve metrolardır. Her geçen yıl artan şehirleşme ve nüfus artışı ile beraber ulaşım talebi artmaktadır. Bu faaliyeti gerçekleştiren belediyeler veya özel işletmeler talebi karşılamak için araç parkını genişletmektedir. Ancak artan talebin sürekli yeni ve daha yüksek kapasiteli araçların artışı ile karşılanması mümkün değildir. Bu talebi karşılamamanın yolu var olan

araçların sürekli vatandaşa hizmet verecek şekilde hazır olması ve sürekli hizmet sağlamasıyla mümkündür.

Şehir içi ulaşım faaliyetlerini gerçekleştiren otobüs filolarındaki araçların emre amadelik oranlarının yüksek olması önemlidir. Belirlenmiş bir sürede daha fazla sefer gerçekleştirmek, sefer başına düşen işletme maliyetlerinin düşmesini sağlar. Yani otobüslerin çalışır olma sürelerinin arttırılması ve çalışır olmadığı sürelerin en aza indirilmesi arzu edilir. Otobüslerin seferler için kullanım sürelerinin maksimize etmek, otobüslerin faal olmasına engel olan sebeplerin araştırılması ve azaltılmasıyla mümkündür.

Otobüslerin sefere çıkmasına engel olan çeşitli sebepler olabilmektedir. Otobüslerin faal olmasına engel olan sebeplerden ikisi bakım ve arızadır. Arızalar işletmelerdeki araçların faaliyetlerini durdurduğundan verimlilik, zaman, maliyet ve hizmet kalitesi kaybına neden olur (Çakır, 2019). Bakım ve arızalardan kazanılacak her süre, araçların hazır ve çalışır olma süresini arttıracak bir kazanımdır. Aksi takdirde, otobüslerin herhangi bir sebeple planlanan görevlerini yerine getirmemesi önemli maliyetlere ve müşteri memnuniyetsizliklerine yol açmaktadır (Güner, 2019).

Arızalar arasındaki ilişkilerin araştırılarak bulunması arızaların azaltılması için önemlidir. Bu ilişkilerin araştırılması literatürde sıralı örüntü madenciliği olarak geçen bir alanın konusudur. Sıralı örüntü madenciliği, belirli bir zaman dilimi içerisinde belirli bir sıklıkla meydana gelen sıralı olayları ifade eder. Sıralı örüntü madenciliği ile arıza örüntü bilgisini geçmiş arıza kayıtlarından edinen bakım yöneticisi, otobüsler arıza vermeden önce gerekli aksiyonları alarak gelecek arızaları önleyebilir. Arıza önlenemezse bile ardışık arıza bilgisi ile ilişkili yedek parça bilgisini edinerek arızada kullanılacak yedek parçaların doğru zaman ve miktarda bakım operasyon alanında olmasını sağlayacaklardır.

Bu tez çalışmasında, Ankara Büyükşehir Belediyesi EGO Otobüs İşletmesindeki CNG (Compressed Natural Gas) yakıtlı otobüslerin şanzıman arıza verileri kullanılmıştır. Arızalar arasındaki sıralı örüntüler araştırılmıştır. Daha sonra bu örüntülerden hareketle ilişkili yedek parça bilgisiyle birlikte bir sonraki arızayı tahmin edecek bir yaklaşım geliştirilmiştir.

İlk olarak çalışmanın uygulanacağı otobüs grubu seçilmiştir. Daha sonra bu otobüs grubunda hangi arıza sınıfına uygulanacağına bakım yöneticileri ile karar verilmiştir. Ardından çalışma için kullanılacak arıza kayıtları toplanmıştır. Arıza kayıtları içinden modelimizde kullanacağımız nitelikler seçilmiştir. Daha sonra veri setimizi algoritmanın çalışmasına uygun hale getirmek için veri ön işleme ve dönüştürmesi faaliyetleri gerçekleştirilmiştir. Ardından (Hirata ve Yamana, 2006)' ın geliştirdikleri

sıralı örüntü madenciliği algoritması uygulanmıştır. Belirlenen destek değerlerini sağlayan sıralı örüntüler elde edilmiştir. Ardından seçilen en iyi destek değerlerine sahip sıralı örüntülerden bir sonraki arızayı bulmak için kurallar geliştirilmiştir. Daha sonra ise kurallarda yer alan arızalarda kullanılan sık yedek parça kümeleri belirlenmiştir. Son olarak ise sıralı örüntüler ve yedek parça bilgileri birleştirilmiştir. Bu çalışmadaki amaç arızalar arasındaki sıralı arıza örüntülerini ilişkili yedek parça bilgisiyle ortaya çıkarmak ve gelecek bir sonraki arızayı tahmin etmektir.

Çalışma yedi bölümden oluşmaktadır. Birinci bölüm giriş bölümü olup bakımın işletmeler için önemi, bakım ile yedek parça arasındaki ilişkisi, arıza bakımlarının azaltılmasının gerekliliği, stok sınıflandırma yöntemlerinden ve sıralı örüntü madenciliğinden bahsedilmiştir. Ardından tezin uygulanma süreci ve amacı anlatılmıştır.

İkinci bölümde, tezin uygulama alanı olan bakım yönetimi ele alınmıştır. Bakım tanımları ve bakım organizasyonun ana hedefleri açıklanmıştır. Bakım stratejilerinin sınıflandırılması yapılmıştır. Düzeltici, Önleyici, Arıza ve Kestirimci bakım stratejileri detaylı olarak ifade edilmiştir. Ayrıca bakım maliyeti ve bakım sayısı arasındaki ilişkiler yorumlanmıştır.

Üçüncü Bölümde, bakım yönetiminde veri madenciliği çalışmaları incelenmiştir. Veri madenciliği çalışmalarının bakım sürelerini tahmin etme, arıza tespiti, arıza sebeplerinin tahmini, ekipmanları önceliklendirme, arıza tespiti gibi birçok konuda yürütüldüğü gözlemlenmiştir. Literatür taramasında sıralı örüntü madenciliği, birliktelik kuralları ve yaygın (sık) yedek parçaların belirlenmesi ile ilgili yapılan çalışmaların detaylarına değinilmiştir.

Dördüncü bölümde çalışmada kullanılacak methodlar açıklanmıştır. İlk olarak veri tanımlamaları yapılmıştır. Ardından verilerin büyük hacimlere ulaşmasının sebeplerine değinilmiştir. Daha sonra bilgi keşfi sürecinin aşamaları detaylı olarak açıklanmıştır. Veri madenciliğinin hakkında bilgiler verilmiştir. Tahmin edici ve tanımlayıcı veri madenciliği methodları anlatılmıştır. Ardından yaygın öge madenciliği yaklaşımına değinilmiştir. En çok kullanılan yaygın öge madenciliği ve birliktelik kuralı algoritması olan Apriori bir örnekle anlatılmıştır. Ardından sıralı örüntü madenciliğinin amacına değinilmiştir. Son olarak çalışmamızda kullandığımız (Hirata ve Yamana, 2006)'da geliştirdiği algoritma örnek verilerle açıklanmıştır.

Beşinci bölümde, çalışmanın yapıldığı işletme hakkında bilgiler verilmiştir. Ardından çalışmanın uygulandığı otobüs grubundan bahsedilmiştir. Uygulamanın yapıldığı otobüs grubunun seçilme nedeni ifade edilmiştir. Daha sonra ise çalışmanın yapıldığı arıza sınıfı anlatılmıştır.

Altıncı bölümde modelin tasarlanması ve uygulanması anlatılmıştır. İlk olarak çalışmanın metodolojisi anlatılmıştır. Ardından bilgi keşif sürecinin her aşaması sırası ile uygulanarak veriler algoritmaların çalışma formatına uygun hale getirilmiştir. Daha sonra sıralı örüntü madenciliği algoritmalarını içinde barındıran yazılımla algoritma uygulanarak sıralı örüntüler elde edilmiştir. Ardından belirlenen örüntüler için kurallar oluşturulmuştur. Ve daha sonra sık (yaygın) yedek parça kümeleri bulunmuştur. Son olarak ise sıralı örüntüler ve sık geçen yedek parça kümeleri birleştirilmiştir.

Yedinci bölümde çalışmanın sonuçları değerlendirilmiş ve çalışmanın sağlayacağı faydalara değinilmiştir. Son olarak ise gelecekteki çalışmalar için öneriler ve dikkat edilmesi gereken noktalar sunulmuştur.



2. BAKIM YÖNETİMİ

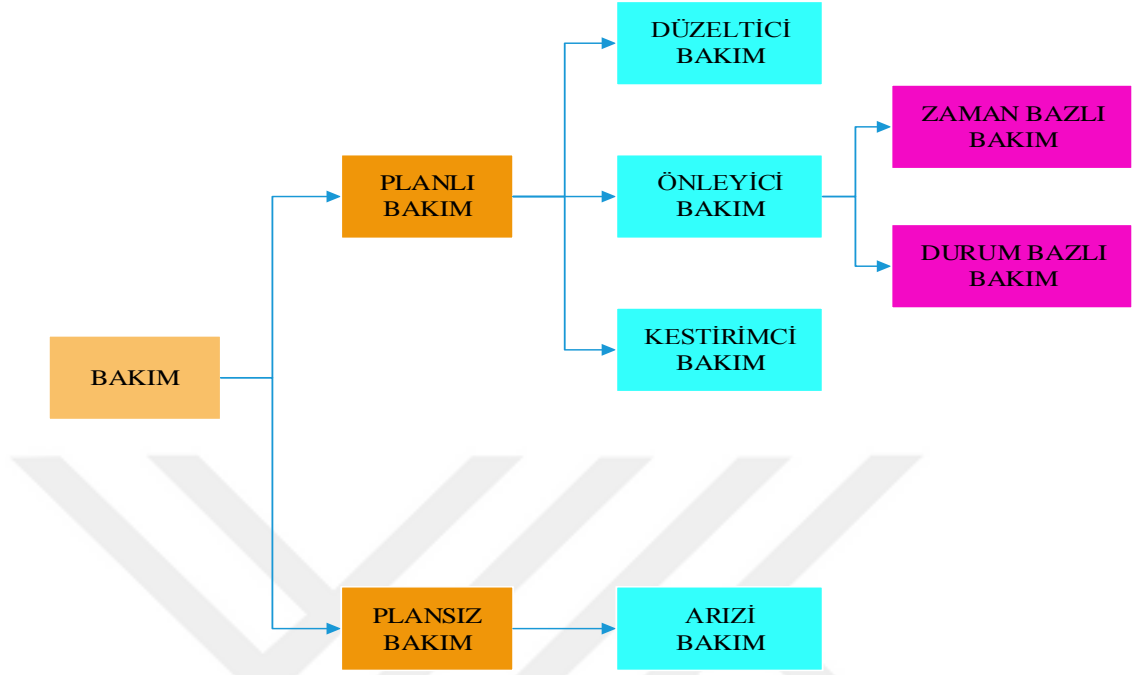
İşletmelerde bulunan her türlü makine, ekipman ve araç da markası, yaşı, kullanım şartları gibi niteliklere bakılmaksızın arıza olabilmektedir. Bu nedenle bu arızaların giderilmesi ve planlı bakımların yapılabilmesi için bir bakım organizasyonuna ihtiyaç duyulmaktadır.

Bakımın ilgili literatürde birçok tanımı bulunmaktadır. Kılıçay (2005) tarafından bir makine veya aracın performansını istenen düzeyde tutmak ya da performans düşüklüğü olanı istenen düzeye getirmek için yapılan faaliyetlerin tümü olarak tanımlanmaktadır. Özdoğan (2011) tarafından sistemlerin planlanan programda çalışmasını sağlayan teknik fonksiyon olarak tanımlanır. Bülbül (2014) tarafından bir ekipman veya aracı çalışır halde tutmak için yapılan bir takım aktiviteler olarak tanımlamıştır. Köksal (2015) ise tesis ve ekipmanların kalite ve üretim performanslarını istenen seviyede tutmak için gerçekleştirilen faaliyetlerin tümü olarak tanımlamıştır. Bakım üretkenlik, kalite ve operasyon güvenliği için gereklidir (Aydınel,2020) .

Bakım organizasyonun ana hedefleri aşağıdaki gibi sıralanabilir (Corder,1976):

- İşletmenin sahip olduğu makine, ekipman ve araçların ömrünü uzatmak,
- Performans düşüklüğünü en düşük düzeyde tutarak sürekliliği sağlamak,
- Makine, ekipman ve araçların üretim veya hizmet için emre amadelik oranını en yüksek düzeyde tutmak,
- Hata toleranslarını en düşük düzeyde tutarak üretim veya hizmet kalitesini arttırmak,
- Acil durumlarda ihtiyaç duyulacak olan parça ve ekipmanları hazır bulundurmak,
- Yukarıdaki hedefleri yerine getirmek için iş sağlığı ve güvenliği kurallarını dikkate alarak personel emniyetini sağlamak,
- Bütün bu hedefleri işletmenin kısıtlı kaynaklarını göz önünde bulundurarak en düşük maliyetle gerçekleştirmektir.

İşletmelerin sürekliliğini sağlamak için yapılan çeşitli bakım stratejileri vardır. Uygulanacak bakım stratejisinin seçimi bakım planlamasının en önemli faaliyetlerinden biridir (Gedikli, 2019). Bakım stratejisinin seçimi işletmenin sahip olduğu makine/araçlara, üretim süreçlerine, yönetim yaklaşımına ve işletmelerin sahip olduğu işgücü, zaman ve maliyet kısıtlarına bağlıdır (Karabağ, 2017). Bu farklılıklardan dolayı literatürde birçok bakım stratejisi bulunmaktadır. Tüm bu bakım stratejilerinin hedefinde kayıpların azaltılması ve sürekli iyileştirme vardır.



Şekil 2.1. Bakım Stratejileri

Bakım stratejileri genel olarak Şekil 2.1.'de görüldüğü üzere planlı ve plansız olmak üzere ikiye ayrılır. Planlı bakımlar içerisinde önleyici, düzeltici ve kestirimci bakım vardır. Önleyici bakım stratejisi, zaman bazlı ve durum bazlı bakımlardan oluşur. Plansız bakımda ise arızı bakım bulunmaktadır.


Düzeltilici bakım, işletmelerin sahip olduğu makine veya araçların belirlenen performans göstergelerinin altına düşmesine sebep olan arızaların düzeltilerek tekrar hedef performans göstergelerine getirmek için yapılan faaliyetlerdir. Yani düzeltici bakımda makine veya aracın tamamen arıza vermesi beklenmez. Hata veya performans düşüklüğü olduğunda bakım yapılır. Arızı bakıma göre avantajı arızanın oluşması beklenmeden bakım yapıldığından ekipman ömrünün uzatılmasıdır.

Önleyici bakımlardan ilki olan zaman bazlı bakım, makine veya araçların arızalanması beklenmeden üreticilerin veya bakım ekipleri tarafından belirlenmiş bir takvime göre periyodik olarak yapılması işlemidir. Durum bazlı bakım, tecrübelerden ve istatistikî verilerden hareketle çalışma koşullarında meydana gelen değişikliklere göre yapılan faaliyetlere denir. Belirlenen alt veya üst değerlerin aşılması durumunda bakım yapılır.

Kestirimci bakım araç veya makinelerin arızalanmalarına sebep olan değişkenler arasındaki ilişkileri modelleyerek arıza zamanını, arıza türünü veya arızalar arasındaki süreleri tahmin eden bir bakım stratejisidir. Kestirimci bakımın temeli her arızaya sebep olan bir değişken olduğu fikridir. Bu nedenle her değişkeni değil arızaya sebep olan değişkenleri izlemek ve çıkarım yapmak gereklidir. Kestirimci bakımın önleyici bakım stratejisine göre avantajı bir makine veya araç iyi durumda ise bu makine veya araçların planlanmış bakımı varsa yapılmasına gerek kalmayacaktır.

Makine veya araçta arıza meydana geldikten sonra yapılan bakıma arıza bakım denir. Arıza, bir ekipmanın istenen fonksiyonu yerine getirememesine denir. Bu stratejinin en büyük avantajı parçaların kullanım ömürlerinin sonuna kadar kullanılmasıdır. En büyük dezavantajı ise arıza giderilene kadar oluşabilecek kayıplardır.

Bakım yönetiminde, çok sık bakım yapılması ile güvenilirlik seviyeniz artar ancak bakım maliyetlerinde ciddi bir artışla karşılaşmanızda muhtemeldir. Az bakım yapılması da bakım maliyetinizi azaltırken, arıza artışı ile ciddi arıza maliyeti ile karşılaşabilirsiniz. Şekil 2.2. 'de bakım maliyeti ve bakım sayısı arasındaki ilişki gösterilmiştir.



Şekil 2.2. Bakım maliyeti ve bakım sayısı arasındaki ilişki

Şekil 2.2.'de görüldüğü gibi bakım sayısı artarsa arıza sayısı ve maliyeti azalmaktadır. Ancak bakım maliyeti de artmaktadır. Bakım sayısının azaltıldığı durumda arıza maliyeti artmakta, bakım maliyeti ise azalmaktadır (Gedikli, 2019). Dolayısıyla bu durum bize kısıtları düşünerek optimum bir bakım stratejisi geliştirmemiz gerektiğini vurgulamaktadır.

3. LİTERATÜR TARAMASI

Literatürde bakım yönetiminde veri madenciliği uygulamaları bakım sürelerini tahmin etme, arıza tespiti, ekipmanları önceliklendirme, arıza olasılığı tahmini, arıza sebeplerinin tahmini ve arıza trendleri gibi birçok konuda yürütülmüştür. Ancak bakım yönetiminde sıralı örüntü madenciliği çalışması kısıtlı sayıdadır. Bu bölümden bakım yönetiminde sıralı örüntüler ile ilgili var olan çalışmalar açıklanmıştır. Ayrıca sıralı örüntülerin uygulandığı farklı alanlardan da örnek çalışmalara da yer verilmiştir.

Han vd. (2009) çalışmasında Kore hava kuvvetlerine ait savaş uçaklarında arıza örüntüleri elde etmek için ardışık birliktelik kuralları uygulaması yürütmüşlerdir. Uçak tipi, lokasyon, görev ve sezon gibi verilerle çeşitli senaryolar oluşturarak arıza örüntülerini bulmayı hedeflemiştir. Senaryolar ile çeşitli sorulara cevap aramışlardır. Bunlardan biri, iç bölgelerde uçuş yapanlar ile kıyaslandığında, kıyı bölgelere uçuş yapan uçaklarda hava ve motor sistemlerinde daha fazla arıza görüldüğüdür. 2004-2005 yıllarına ait dört farklı tip uçağın verileri kullanılmıştır. Senaryo 1 için uçak tipi (F4), lokasyon (iç bölge), görev (muharebe) olarak belirlenmiştir. Senaryo 1'de ilkbahar sezonu için % 91,89 destek ve %97,14 güven değerinde elde edilen ardışık kurallardan biri Navigasyon→ Ateşleme sistemi→ Navigasyon 'dur. Yani ilkbahar sezonunda F4 tipi uçakta iç bölgede görev uçuşu gerçekleştiği durumda navigasyon arızası görüldüğünde % 91,89 destek değerinde bir sonraki arıza Ateşleme sisteminde görüleceğini ifade eder. Ateşleme sistemindeki arızadan sonra ise yine navigasyon arızası görüleceği anlamına gelir. Bu ardışık örüntü incelendiğinde bu örüntülerde yer alan sistemlerin farklı sistemler olması arıza sebeplerini araştırmayı çok zorlaştırmaktadır. Dolayısıyla gerçek hayatta uygulanması zordur.

Karlı (2010) çalışmasında bir araştırma hastanesinde laboratuvar biyokimya hasta tahlil verilerini kullanmıştır. Veriler 6850 hastaya yapılan 156.099 tahlilden oluşmaktadır. Hastaneye geldiğinde A testi yaptıran bir hasta diğer gelişinde hangi testi yaptıracığı öngörüsü elde edilmeye çalışılmıştır. Kullanılan değişkenler, hasta no, cinsiyet, doğum tarihi, işlem tarihi, test adı ve R değeri olarak belirlenmiştir. Çalışmada kullanılan Fp-Growth ve Fp-Growth tabanlı yazar tarafından geliştirilen algoritma karşılaştırılmıştır. Elde edilen örüntüler değerlendirildiğinde karaciğer fonksiyon testi istenen hastalarda aynı zamanda böbrek fonksiyon testleri de istenmiştir. Böbrek fonksiyon testleri yapılan hastaların bir sonraki gelişlerinde yine böbrek fonksiyon testleri istendiği görülmüştür.

Mokfi ve Sedighi (2011) çalışmalarında bir hastanede bakım numarası, ekipmanın bölümü, ekipman ismi, ekipmanın arıza numarası, sebebi, alınan aksiyon, Arıza tarihi ve bitiş tarihi, kimin tarafından tamir edildiği gibi bakım verilerini kullanarak kurallar çıkarmışlardır. Örneğin; % 100 güven değerinde kurallardan biri arıza kodu: A1 ise Bakım Aksiyonu: B1 şeklinde kurallar bulmuşlardır.

Turna (2011) çalışmasında bir tramvay işletmesinde sefere engel olan arızalarla ilgili kural çıkarımı yapılmıştır. İki farklı tramvay hattında 2008-2011 yılları arasında meydana gelen 10.000'e yakın arıza kaydı verisi kullanılmıştır. Toplanan verilerde bulunan değişkenler araç tipi, arıza tarihi, arıza saati, hava sıcaklığı, çığ noktası, nem oranı, deniz seviyesi basıncı, rüzgar hızı, hava olayı, vatman, cinsiyet, arıza bölgesi, arıza kodu, ekipman adı, hat, hız ve sefere engel mi? (evet/hayır) olarak belirlenmiştir. Rosetta programı ile özellik indirgeme yapılmıştır. Özellik indirgeme ile 67 alt küme elde edilmiştir. Kural bulmak için Jrip, NNge, Ridor, Decisiontable, ZeroR, PART, oneR, DTNB ve ConjunctiveRule algoritmaları kullanılmıştır. Bu algoritmalar için en yüksek doğruluğa sahip olan algoritma 65 nolu küme kullanılarak Jrip algoritması ile elde edilmiştir. Jrip algoritması ile elde edilen kurallardan biri şu şekildedir: Eğer arıza tarihi =Ağustos ve hava sıcaklığı ≤ 26 ve hava olayı=yağmur ise sefere engel var şeklinde kurallar bulmuşlardır.

Maquee vd. (2012) bir şehir içi otobüs filosunda bakım aktivitelerinin etkinliğinin değerlendirilmesi amaçlanmıştır. İlk olarak eksik veya hatalı veriler ön işlemlerden geçirilmiştir. Daha sonra kümeleme için değişkenler belirlenmiştir. Bu değişkenler: otobüs no, model, arızalar arası geçen süre, kilometre, arıza bakım sayısı, önleyici bakım sayısı, her atölyede gerçekleşen operasyon sayısıdır. Kümeleme için K-means algoritması kullanılmıştır. 604 adet otobüs beş farklı kümeye ayrılmıştır. Her bir küme için Öklid uzaklık fonksiyonu kullanılarak her küme çok iyi, iyi, normal, kötü ve çok kötü olarak etiketlenmiştir. Daha sonra çok kötü gruptaki araçlar için araçların neden çok kötü gruba atandığını bulmak için birliktelik kuralları çıkarılmıştır. Birliktelik kuralları için Apriori algoritması kullanılmıştır. Spss clementine yazılımı kullanılmıştır. Minimum % 100 güven değeri ve minimum % 8 destek değerinde dört kural elde edilmiştir. Kurallar bakım yöneticileri tarafından doğrulanmış ve bakım politikalarını düzenlemek için kullanılacağı ifade edilmiştir.

Aytaç ve Bilgin (2014), çalışmalarında özel bir bankanın internet bankacılığında yaptığı işlemleri veri seti olarak kullanmıştır. Çalışmada, müşterilerin havale, fatura ödemesi gibi işlemlerinde nasıl bir davranış örüntüsü izlediklerini ve bankanın yeni akıllı modül veya işlemlerini kullanıp kullanmadıklarını bilgilerinin çıkarılması amaçlanmıştır. Sıralı örüntü madenciliğinden en yaygın kullanılan Prefixspan

algoritması kullanılmıştır. Çalışma için müşteri numarası, modül adı, işlem, istek tipi, İşlem tarihi, makine adı gibi veriler toplamışlardır. Müşterilerin genellikle her oturumda bir işlem yaptığı ve işlem dekontlarını görüntülemedikleri görülmüştür. Ayrıca müşteriler bankacılık işlemlerini minimum % 50 destek değerinde tüm işlemler butonuna tıkladıktan sonra minimum % 20 destek değerinde akıllı menü butonunu kullanarak gerçekleştirdikleri görülmüştür.

Moharana ve Sarmah (2015) çalışmalarında birliktelik kurallarını kullanarak bakım aktivitelerinde kullanılan yedek parçaların bağılıklarını temel olarak optimal bir tamir kiti çalışması yürütmüşlerdir. İlk olarak beş farklı ekipmanın yedek parça tüketim bilgileri, birim fiyatları, elde tutma maliyetleri bilgileri toplanır. Daha sonra bu ekipmanların tamiri için sık kullanılan yedek parça grupları bulunmuştur. Eğer bir yedek parça ihtiyaç anında bulunmaz ise bir ceza maliyetine katlanılır. Ek Ceza maliyeti ise yedek parça grupları arasındaki bağılılık oranına göre belirlenmiştir. Elde edilen yedek parça gruplarının bakım aktiviteleri için optimal kit olarak değerlendirilmesi için bir toplam maliyet fonksiyonu oluşturulmuştur. Bu toplam maliyet fonksiyonu elde tutma maliyeti, ceza maliyeti ve ek ceza maliyetinden oluşur.

Djatna ve Alitu (2015) ahşap kapı imalatı yapan bir firmada kalıplama makineleri için toplam üretken bakım temelli bakım ve üretim politikaları geliştirmişlerdir. İlk olarak kalıplama makinesinin genel ekipman etkinliği hesaplamışlardır. Daha sonra bu etkinliği düşüren sebepler araştırılmış olup balık kılçığı diyagramları alt sebepler belirlenmiştir. Günlük hazırlık ve ayarlama süreleri, Malzeme gecikmesi, Günlük arıza süresi vb. değişkenler ile genel ekipman etkinliği skorları etiketlenerek uygun bakım ve üretim stratejisi için birliktelik kuralları çıkarılmıştır. Örneğin; Makinenin kullanılabilirliği % 60-80 ve genel ekipman etkinliği % 40-60 arasında ise bu makineden tek tip ürün üretilmelidir. Kullanılabilirlik % 40-60 arasında ise planlı bakım yapılmalıdır gibi kurallar bulunmaktadır.

Xiao vd. (2016) çalışmalarında birliktelik kurallarına Bayes ağlarını entegre ederek karar vericilerin odaklanması gereken önemli kuralları belirlemişlerdir. Çalışma, tarım makineleri bakım servisinde gerçekleştirilmiştir. Bakım verilerinden arıza durumu ve arıza çözüm verilerini kullanmışlardır. Bayes yaklaşımı ile birliktelik kurallarının gerçekleşme olasılıklarını hesaplamışlardır. Daha sonra kuralları değerlendirmek için bakım etkinliği olarak bir fonksiyon geliştirdiler. Bu fonksiyonun girdileri hesaplanan olasılık değerleri ve bakım maliyetlerinden oluşmaktadır.

Lasiritaworn vd. (2016) çalışmalarında bir motor tamir atölyesinde yedek parça deposunun iyileştirilmesi için depodan hangi parçaların birlikte istendiğini bularak parçalara raf ataması yapmayı amaçlamışlardır. İlk olarak süreçteki sorunları bulmak için iş akış şeması oluşturulmuştur. Ana problem, depoda parça arama ve parçayı geri

alma işlemlerinin çok uzun sürdüğü olarak tespit edilmiştir. Mevcut sistemde yedek parçalar bir kod sistematığına göre raflara atanmaktadır. Bunun için beraber çekilen yedek parçaların belirlenmesi gerektiğine karar verilmiştir. Veri olarak depoya gönderilen yedek parça istek dokümanları kullanılmıştır. Beraber çekilen parçaları bulmak için birliktelik kuralları kullanılmıştır. Kurallar RapidMiner yazılımında Fp-Growth algoritması uygulanarak elde edilmiştir. Birliktelik kuralları için minimum % 35 destek ve % 80 güven değerleri seçilmiştir. En yüksek değerlere sahip olan birliktelik kurallarından başlanarak parçalar raflara yan yana atanmıştır. İki durum karşılaştırıldığında yeni durumun arama ve bulma zamanını azalttığı gözlemlenmiştir.

Yıldız (2017) çalışmasında 240 adet yağlı tip güç transformatorünü benzer arıza verenleri kümeleyerek uygun bakım stratejisi geliştirmeyi amaçlamıştır. Benzer özellikteki güç transformatorlerine aynı bakım stratejisini uygulayarak zamandan ve iş gücünden tasarruf edilmesi hedeflenmiştir. İlk olarak güç transformatorlerde meydana gelen arızalar incelenerek hata ağacı diyagramı oluşturmuştur. Hata ağacı için 1995-2007 yıllarında gerçekleşmiş arıza kayıtları veri olarak kullanılmıştır. Kümeleme için arıza istatistiği bilgileri (kısa devre arıza sayısı, sargı arızası sayısı vb.), yaş, ortalama yüklenme oranı ve güç değişkenleri girdi olarak belirlenmiştir. Yöntem olarak K-ortalamlar kullanılmıştır. Dört küme elde edilmiştir. Kümelerdeki transformatorler analiz edildiğinde genç transformatorlerin bir ve dördüncü kümede, 35 ve üzeri transformatorlerin ikinci ve üçüncü kümelerde toplandığı görülmüştür. İkinci ve dördüncü kümede daha düşük transformatorler yer alırken birinci ve üçüncü kümeden daha güçlü transformatorler bulunmaktadır. Bakım stratejilerini hata ağacındaki analizlere göre olası arızalar ve kümelerdeki transformatorlerin yaş, güç ve yüklenme oranları ortalamaları dikkate alınarak belirlenmiştir.

Rachburee vd. (2017) bir işletmenin ATM (Automatic Teller Machine) bakım verilerini kullanarak arıza veren parçalar arasında birliktelik kuralları bulmayı hedeflemişlerdir. 2013-2016 yılları arasındaki bakım verilerini kullanılmıştır. Çalışmada Apriori ve Fp-Growth algoritmaları uygulanmıştır. İki farklı yöntem kullanılarak algoritmaların performansları karşılaştırılmıştır. Fp-Growth algoritmasının işlem süresi bakımında Apriori'den daha iyi olduğu gözlenmiştir. Ayrıca elde edilen birliktelik kurallarının bakım yöneticilerine bir sonraki arıza veya arıza verecek parça konusunda öngörü verebileceğini ifade etmişlerdir.

Moharana ve Sarmah (2018) çalışmalarında bakım aktivitelerinde kullanılan yedek parçaların birbirleri arasında bağılıkları olduğunu ifade etmiştir. Bu sebeple yedek parçaları gruplayarak ortak stok yenileme modeli önermişlerdir. Yedek parçaları gruplamak için hiyerarşik kümeleme metodu kullanılmıştır. Bağımsız ve kümeleyerek stok yenileme modelini karşılaştırmak için bir matematiksel model tasarlamışlardır.

Uygulama 10 adet tamir edilemez parça ve bir yıllık parça tüketim verisi kullanılarak yapılmıştır. Uygulamada küme sayısı ile stok yenileme maliyeti arasında bir ilişki olduğu görülmüştür. Yapılan çalışma sonucunda, parçaları bağımsız yenileme yaklaşımına nazaran, bağılıkları bulunan parçaları gruplayarak ortak stok yenileme yaklaşımının daha düşük toplam maliyete sahip olduğu tespit edilmiştir.

Atlı (2019) çalışmasında veri madencilikleri teknikleri kullanarak bir telekomünikasyon şirketine ait baz istasyonunda arıza tahmini yapmıştır. Arıza sınıfı, Problem sebebi, Ay, İlçe ve saha kodu girdi değişkenleri olarak belirlenmiştir. Çıktı değişkeni olarak kesinti olup olmadığı belirlenmiştir. WEKA yazılımında Ibk instance-based classifier, Naive bayes, J48, Kstar, Destek vektör makineleri ve Yapay sinir ağları algoritmaları kullanılmıştır.

Moharana vd. (2019) çalışmalarında bir maden şirketine ait bant konveyörlerinin düzeltici bakım verilerini kullanarak yedek parça bilgisi ile ardışık örüntüler elde ederek kural bazlı sınıflandırma yaklaşımı geliştirmişlerdir. Kural bazlı sınıflandırma yaklaşımı ile bir sonraki arıza tahmin edilmeye çalışılmıştır. Bant konveyörlerinin yedi farklı bakım aktivitesi çalışmada kullanılmıştır. Bu bakım aktivitelerinde kullanılan parçalar belirlenmiştir. 2006-2012 yılları arası dört yıllık düzeltici bakım verileri toplanmıştır. Daha sonra bu verilerden ardışık örüntüler elde etmiştir. Ardından en iyi örüntüleri seçerek kurallar oluşturulmuştur. Son olarak ise bu kurallar içerisinde yer alan bakım aktivitelerinin önceden belirlenen destek değerlerini kullanarak en sık kullandığı parça grupları bulunmuştur. Ardışık örüntüleri bulmak için GSP (Generalized Sequential Pattern) algoritması kullanılmıştır. Çalışmaların da, bu yaklaşımın arıza bakımları için geliştirilmesinin arıza kök sebeplerini bulmada faydalı olacağını söylemişlerdir.

Çelik (2019) çalışmasında bir üretim işletmesinde 12 adet farklı makineye ait mekanik arızaların sebeplerini analiz etmek için birliktelik kuralları oluşturmuşlardır. İlk olarak mekanik arızalara ait duruş kodlarına pareto yöntemi uygulanarak A grubuna ait duruş kodları belirlenmiştir. Çalışmada kullanılan değişkenler, makinede arıza anında çalışan ürün çeşidi, makinenin çalışma sıcaklığı, Makine tipi, Makine üreticisi firma, makine besleme tipi ve duruş kodu olarak belirlenmiştir. Çalışmadan SPSS Clementine yazılımı kullanılmıştır. En yaygın kullanılan birliktelik algoritması olan Apriori algoritması kullanılmıştır. Elde edilen birliktelik kurallarından birisi şu şekildedir: Eğer Makine türü =S1 ve Makine besleme tipi=K1 ve Makine çalışma sıcaklığı=150-200 ve Makine markası=C1 ise duruş sebebi besleme burğu hatasıdır. Minimum % 50 güven değeri ve minimum % 5 destek değeri ile 17 birliktelik kuralı elde edilmiştir.

Bakım yönetiminde sıralı örüntü madenciliği ile ilgili incelenen literatür çalışmalarından elde edilen bilgileri göz önünde bulundurarak yapılan çalışmanın önemi ve literatüre sağlayacağı faydalar şu şekildedir.

- Han vd. (2009) yaptıkları çalışmada arıza olarak genel arıza kategorileri almışlardır. Örneğin, navigasyon, ateşleme sistemi vb. Bu durum gerçek hayatta problemin uygulanmasını zorlaştırmaktadır. Bu genel arıza kategorilerinden çıkan örüntüler ile arızaya karşı önlem almak ve sebebini araştırmak çok zordur. Çünkü ateşleme sisteminin, alt arıza sayısı yüzlerce olabilir. Bu tezde, şanzıman arızalarının alt arıza verileri kullanarak çalışma yapılması literatüre genelden özele geçiş bakımından fayda sağlayacaktır. Elde edilen örüntülerin gerçek hayatta kullanılabilirliğini artıracaktır.
- Moharana vd. (2019) düzeltici bakım faaliyetleri arasındaki örüntüler ile yedek parçalar ilişkilendirdiği çalışmasında arıza bakım için çalışmanın geliştirilebileceğini ifade etmiştir. Dolayısıyla yedek parça bilgisi ile arıza bakım örüntülerinin birlikte ele alınacağı çalışma özelliği ile de literatüre katkı sağlayacaktır.
- Problemin gerçek bir sistem üzerinden tasarlanması ve gerçek veriler kullanılarak çözülmesi çalışmanın önemli özelliklerinden biridir.
- Zaman etiketi olarak daha önceki çalışmalarda hafta/ay/yıl gibi periyotlar kullanılmıştır. Bu çalışmada zaman etiketi olarak kilometre bilgisi kullanılmıştır. Kilometreler belirli kategorilere ayrılarak zaman ifadesi olarak kullanılmıştır. Bunun sebebi otobüs filolarında arıza nedeniyle bekleyen bir araç da zaman sürekli ilerlediğinden tahminlerde sapsmalara neden olabilmektedir. Ancak bir araç arızalandığında kilometre bilgisi arıza giderilene kadar değişmeyip sabit kalacağından herhangi bir sapmaya neden olmayacaktır. Dolayısıyla sıralı örüntülerde kilometre bilgisini kategorik olarak kullanması da çalışmanın önemli katkılarından biridir.

4. VERİ MADENCİLİĞİ

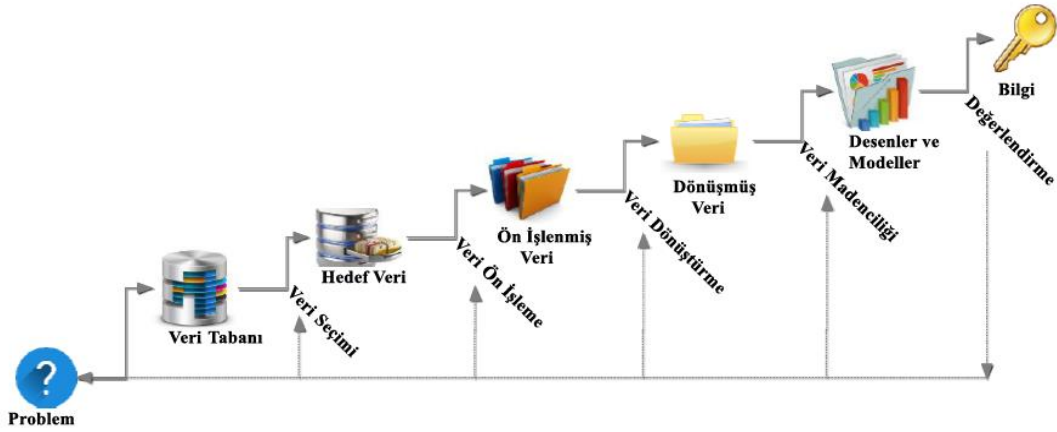
Veri, tek başına bir anlam ve değer ifade etmeyen, belirlenen amaç doğrultusunda işlenip anlamlı hale gelen bilgidir (Atlı, 2019). Verinin amaç doğrultusunda işlenmiş şekline bilgi denir. Yani bir soruyu yanıtlamak için veriden çıkartılan anlamlı sonuçlara denir.

Son yıllarda teknoloji ve veri iletişimde yaşanan büyük değişimler insanların teknolojik ürünlere erişimini kolaylaştırmıştır. Hemen hemen her cihazdan veri üretimi olması depolanan veri miktarlarında çok büyük hacim artışına neden oldu. Bir insan gündelik hayatında farkında olmadan çok miktarda veri üretebilmektedir. Örneğin, Instagram’da beğendiği bir fotoğraf, Youtube’da izlediği bir video, arama motorlarında gün içinde arattığı kelimeler, akıllı telefonundaki adım sayar, telefon konumu vb. birçok veri farkında olmadan üretilmektedir.

Veri hacimlerinin çok büyümesi de anlamlı bilgilerin elde edilmesini zorlaştıran bir süreçtir. Mevcut yöntemlerle bu sorunun çözülememesi araştırmacıları yeni yöntemler bulmaya yöneltmiştir. Bu noktada büyük hacimli verilerden anlamlı bilgiler elde etmek için bir veri çözümlene metodu olarak veri madenciliği kavramı ileri sürülmüştür. Veri madenciliğini açıklamadan önce bilgi keşif sürecinin açıklanması gerekir. Çünkü veri madenciliği, bilgi keşif sürecinin önemli bir adımıdır.

4.1. Bilgi Keşif Süreci

Bilgi keşif süreci (BKS), verilerden anlamlı ve faydalı bilgilerin keşfedilmesi sırasındaki tüm süreçleri ifade eder. Veri madenciliği, makine öğrenmesi, uzman sistemler vb. BKS’ nin uygulama kısmında kullanılan yöntemler topluluğudur. Yani bunlar BKS’ nin sadece bir adımını oluşturur. BKS sürecinin adımları Şekil 4.1. ‘de gösterilmiştir.



Şekil 4.1. BKS sürecinin adımları (Han vd. 2011)

Şekil 4.1.'de görüldüğü gibi BKS sürecindeki ilk adım problemin tanımlanmasıdır. Problemin tanımlanması BKS sürecinin sağlıklı yürüyebilmesi için en önemli adımdır. Problemin yanlış veya açık ifade edilmediği durumlarda zincirleme hatalardan dolayı elde edilen bilgilere göre alınan kararlar ciddi kayıplara yol açabilir. Bu nedenle problem açık ve net olarak ifade edilmelidir. Çalışmada, araştırılacak olan durumlar soru olarak ifade edilmeli ve bir grup ile beyin fırtınası gerçekleştirilmelidir. Problem tanımlandıktan sonra araştırmacı belirlediği probleme etki eden tüm verileri toplaması gerekir.

İkinci adım problem çözümünde kullanılacak olan verilerin seçimidir. Probleme etki eden verilerin seçimi kritik bir süreçtir. Çünkü çalışmanızda kullanacağınız yöntemle verdiğiniz veriler direkt nihai sonuçları etkilemektedir. Dolayısıyla uzman kişiler ile toplantılar ve gözlemler yaparak probleme etki eden veriler seçilmelidir. Seçilen veriler hedef veri adını alırlar ve genelde bir veri tabanı oluşur (Kokoç, 2017).

Üçüncü adım ise hedef verilerin ön işleme tabi tutulmasıdır. Ön işleme adımında eksik- hatalı veriler düzeltilerek veya silinerek kaldırılır. Özellikle hatalı veriler direkt nihai sonucu etkisi olduğundan tespiti önemlidir. Ayrıca bazı algoritmaların eksik veri ile çalışmaması nedeniyle eksik verilerin tahmin edilmesi veya silinmesi gerekir. Eksik verilerin tahmin edilebilmesi için literatürde birçok yöntem bulunmaktadır.

Dördüncü adım ön işleme tabi tutulmuş verilerin dönüştürülmesi aşamasıdır. Bunun nedeni genel olarak tasarlanan algoritmaların belirli bir formattaki verilerle çalışmasıdır. Bazı algoritmalar sadece nicel değerlerle çalışırken bazıları ise nitel-nicel melez olarak çalışabilmektedir. Genel olarak veriler sayısal veya kategorik değerler olarak dönüştürülür.

Beşinci adım ise veriler dönüştürüldükten sonra var olan veya geliştirilen bir modelin uygulanması aşamasıdır. Problemi çözmek için hangi modelin seçileceği kritik bir adımdır. Çünkü her bir model veya algoritma belirli varsayımlar ve kısıtlar dahilinde belirli bir amaca yönelik çalışmaktadır. Yanlış seçilen bir model olası yararlı bilgileri veya örüntüleri eleyebilir veya yakalayamayabilir.

Altıncı adım ise model uygulandıktan sonra sonuçların değerlendirilmesi ve yorumlanmasıdır. Elde edilen sonuçlar uzman kişiler ile değerlendirilir ve doğruluğu kontrol edilir.

4.2. Veri Madenciliği Yöntemleri

Literatür incelendiğinde veri madenciliği ile birçok tanım bulunmaktadır. Bunlardan bazıları aşağıda ifade edilmiştir.

Veri madenciliği, çeşitli analiz araçları kullanarak büyük miktardaki veri yığınlarından önceden keşfedilmemiş örüntüleri, ilişkileri ve bilgileri araştıran süreçlere denir (Celementine, 2002).

Veri madenciliği, veri dağları altındaki hazine veya altın külçelerini özel programlar aracılığı ile bulmadır (Atlı, 2019).

Veri madenciliği, büyük hacimli verilerden gelecek ile ilgili öngörü yapmaya olanak sağlayan anlamlı örüntü ve bilgilerin çeşitli algoritmalarla yararlanılarak keşfedilmesidir. Ancak unutulmamalıdır ki veri madenciliği tek başına çözüm değildir. Karar vericinin doğru karar verebilmesini gereken bilgileri sağlayan bir araçtır. (Karalök,2019)

Veri madenciliği, Tek başına bir anlam ifade etmeyen verilerin belirli algoritmalar kullanılarak işlenmesiyle anlamlı bilgiler keşfedebilen ve elde ettiği sonuçları istatistiksel olarak ispat edebilen bir süreçtir.

Veri madenciliği teknikleri genel olarak tahmin edici ve tanımlayıcı modeller olmak üzere iki kategoriye ayrılmaktadır. Tanımlayıcı veri madenciliği hazırlanmış bir veri setinde karar vericiye yardımcı olacak yeni ve daha önce keşfedilmemiş bilgiler sağlar. Tahmin edici veri madenciliği, tahmin yapabilmek için verilerden çıkarımlar yapmayı amaçlamaktadır. Çıktıları belirli verilerden model üretir. Üretilen model ile çıktısı bilinmeyen veriler kullanılarak tahminlerde bulunulur. Şekil 4.2.'de tahmin edici ve tanımlayıcı veri madenciliği tekniklerinin sınıflandırılması gösterilmiştir.

Ek olarak veri madenciliği yöntemleri denetimli ve denetimsiz olarak sınıflandırılabilir. Denetimli yöntemler veri setinden çıkarsamalar yapmaya çalışırlar.

Eđitim verilerinden öğrenilen model ile test verileri tahmin edilir veya sınıflandırılır. Denetimsiz yöntemler ise verileri anlamaya ve örüntü bulmaya çalışır.



Şekil 4.2. Veri madenciliđi yöntemlerinin sınıflandırılması

4.2.1. Tahmin Edici Yöntemler

Tahmin Edici veri madenciliđi, geçmiş verileri kullanarak bir model oluşturulması ve bu model ile geleceđe yönelik sonuçları belli olmayan veriler için tahmin yapmak için kullanılır (Akpınar 2000). Örneđin; bir banka kaybettiđi müşterilerin verilerini analiz ederek bir model geliştirebilir. Ardından mevcut müşterilerine bu modeli uygulayarak kaybedebileceđi müşterileri belirleyebilir. Bu müşterileri kaybetmemek için özel kampanyalar geliştirilebilir.

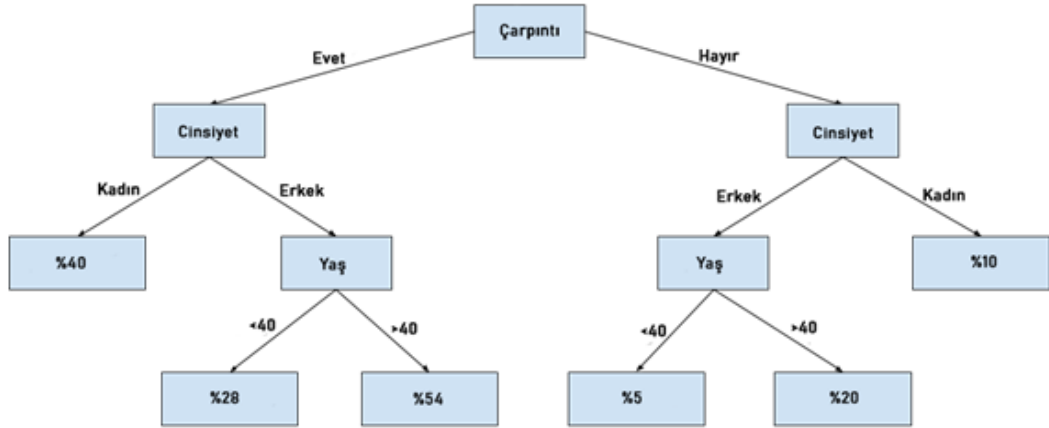
4.2.1.1. Sınıflandırma

Sınıflandırma kelime anlamı olarak tasnif etmek ve ayırmak anlamına gelir. Sınıflandırma bir nesnenin niteliklerini analiz ederek, bu nesneyi önceden belirlenmiş gruplara atamaya denir. Bir denetimli öğrenme yaklaşımdır. Sınıfları belirli olan atanmış nesnelere hareketle sınıfları belirlenmemiş olan nesnelere sınıfları tahmin edilmeye çalışılır. Bir başka deyişle, önceden belirli sınıflara atanan durumların benzer özelliklerinden hareketle sınıflara atama yapılır. Bu durumda sınıflandırma önceden

bir eğitim verisine ihtiyaç duyar. Sınıflandırma modellerinin doğruluğunu karşılaştırmak için bir test verisine ihtiyaç duyulur. Sık kullanılan sınıflandırma modelleri;

- Karar Ağaçları
- K-en yakın komşu
- Naive-Bayes
- Destek Vektör Makineleri
- Yapay Sinir Ağları
- Genetik Algoritma

Karar ağaçları bir sınıflandırma ve örüntü algoritmasıdır. Çıkarım kurallarını kullanmaktadır. Kurallar kökten yaprağa doğru yazılır. Kuralların açık ve anlaşılır olması bu yöntemin çok kullanılmasını sağlar. Karar ağaçları dallar ve düğümlerden oluşur. Veri setindeki her bir boyut bir düğüme karşılık gelmektedir. Modelde en üst düğüme kök, en alt düğüme yaprak adı verilmektedir. Dal ise kök ve yapraklar arasındaki kısımdır. Her dal bir kuralı simgelemektedir. Şekil 4.3' de kalp yetmezliği hastalığı riski ile ilgili bir karar ağacı yapısı gösterilmektedir.




Şekil 4.3. Kalp yetmezliği karar ağacı yapısı (Algi, 2020)

Şekil 4.3 ' de bir kişinin çarpıntısı var ve cinsiyeti kadın ise kalp yetmezliği riskinin % 40 olduğunu ifade eder. Yine çarpıntısı var ve cinsiyeti erkek ve yaşı 40'dan büyük ise kalp yetmezliği riskinin % 54 olduğunu ifade eder.

Karar ağacında sınıflandırma işlemi iki aşamada yürütülür. İlk olarak eldeki veri seti kullanılarak model oluşturur. Bu aşama öğrenme aşaması olarak ifade edilir. İkinci aşamada öğrenmiş model test edilir. Belirlenmiş test verisi ile model doğrulanırsa yeni veriler için sınıflandırma yapılabilir.

Naive-Bayes, karar teorisini temel alan bir olasılıksal sınıflandırma modelidir. İngiliz matematikçi Tomas Bayes tarafından ileri sürülmüştür. Önceden sınıflara atanmış verileri kullanarak, yeni bir nesne geldiğinde hangi sınıfa yakın olduğunu olasılıksal olarak belirleyen bir yöntemdir. Her sınıfın olasılıksal değeri vardır. Naive bayes görüntü ve sinyal işleme alanında yüksek doğruluk oranlarına sahip bir yöntemdir.

Yapay Sinir Ağları (YSA), insan beyninin biyolojik sinir sisteminin çalışma mantığını temel alarak geliştirilmiş bir yöntemdir. Ağın eğitimi için girdileri ve çıktıları belirli olan bir veri setine ihtiyaç vardır. Böylece girdi-çıkı arasındaki ilişkiyi anlayarak ağın eğitilmesi sağlanır. YSA, bir denetimli öğrenme yaklaşımıdır. Bir YSA mimarisi girdi, gizli ve çıktı olmak üzere üç katmandan oluşur. Bu katmanlarda nöronlar bulunmaktadır. Girdi katmanındaki nöron sayısı veri setindeki nitelik sayısı kadardır. Çıktı katmanındaki nöron sayısı ise probleme göre değişiklik göstermektedir. YSA sürecindeki en önemli adımlardan biride gizli katman sayısı ve gizli katmandaki nöron sayısının belirlenmesidir. Bu sayıların belirlenmesi için şu an literatürde herhangi bir formülasyon bulunmamaktadır. Bu sayılar genel olarak sistematik denemeler yaparak performans ölçütlerindeki değişimlere göre belirlenir. Diğer önemli olan hususlardan biri ise eğitim fonksiyonu ve öğrenme katsayısının belirlenmesidir. Eğitim fonksiyonu, literatürde belirli problemlerde iyi çözümler ürettiği gözlenen fonksiyon bilgilerinden hareketle belirlenebilir. YSA' da bilgi nöronlar arasındaki dallardaki ağırlıklardadır. Eğitim verisi kullanılarak en iyi ağırlıklar bulunmaya çalışılır. Şekil 4.4. 'de örnek bir YSA mimarisi gösterilmiştir.



Şekil 4.4. YSA mimarisi

Destek Vektör Makineleri (DVM), İlk olarak Vapnik tarafından ileri sürülmüştür. DVM, istatistiksel öğrenme teorisine dayalı bir sınıflandırma yöntemidir. Regresyonda kullanılan yaklaşıma Destek Vektör Regresyonu (DVR) denilmektedir. DVR, tahmin hatasını minimize eden bir fonksiyon bulmaya çalışır.

K-En yakın komşu denetimli öğrenme yaklaşımıdır. Bu yaklaşım temelde uzaklık ölçümünü esas alır. Örnek veri kümesindeki gözlemlerin herhangi bir gözlem değerine olan mesafesi hesaplanıp en yakın k sayıda gözlemin belirlenmesi fikrine dayanmaktadır. Mesafe hesaplamada genellikle Öklid kuramları kullanılır. Algoritmanın adımları:

- İlk olarak k parametresi belirlenir. k, belirlenen bir noktaya en yakın komşuların sayısını ifade eder.
- En yakın komşuların bulunabilmesi için belirlenen nokta ile diğer noktalar arasındaki mesafe hesaplanır.
- Bu mesafelerden en küçük k adeti seçilir.
- Belirlenen mesafelerin hangi sınıfa atanacağına karar verilir. En çok tekrarlanan kategori seçilir.
- Seçilen kategori ile tahmini yapılması istenen gözlem değerinin kategorisi olarak varsayılır (Özkan, 2008).

Bu yöntemde benzerlikler hesaplanmakta ve en yakın olduğu düşünülen k verinin ortalaması ile hesaplanan eşik değerlerine göre sınıflara atama yapılır. Yöntemin başarısını etkileyen kriterlerden bazıları; komşu sayısı, benzerlik değeri ve eşik değeridir.

Genetik algoritma, doğadaki evrimsel süreçten hareketle çalışan bir optimizasyon tekniğidir. Darwin'in evrim teorisinden hareketle 1970'li yıllarda John Holland tarafından ileri sürülmüştür. Genetik algoritma, kısıtlar tarafından belirlenmiş olan çözüm uzayındaki noktalar kromozom adı verilen dizi ile kodlanır. Her bir kromozomun bir uygunluk değeri vardır. Genetik algoritma Darwin'in evrim teorisine dayanarak çaprazlama ve mutasyon gibi operatörleri kullanarak yeni bir popülasyon oluşturan bir yöntemdir. Operatörler kullanılarak yeni popülasyonlarının sağlanması ile popülasyon içindeki bireylerin uygunluk değerleri artmaktadır. Genetik algoritma, kodlama, uygunlukların hesaplanması, çaprazlama, mutasyon, çoğalma adımlarını içermektedir. Çözüm uzayının belirli bir kısmını tarar. Bu şekilde verimli bir arama yaparak kısa sürede çözüme ulaşmayı hedeflemektedir.

4.2.1.2. Regresyon

Değişkenler arasındaki ilişkileri araştıran istatistiksel bir yöntem olarak tanımlanır. Bir başka tanımda ise iki veya daha fazla değişken arasındaki sebep-sonuç ilişkisini araştıran ve bu ilişkiyi matematiksel bir model olarak ifade eden yöntem olarak tanımlanmıştır. Regresyon analizinde bağımlı ve bağımsız değişkenler vardır. Örnek olarak bir yedek parçanın talep tahmini regresyon analizi ile yapılabilir.

4.2.1.3. Zaman Serileri Analizi

Zaman serisi, zamana bağlı olarak tekrarlayan ölçümlerle elde edilen verileri içerir. Bir niteliğin zamana bağlı olarak değişimleri izlenmektedir. Genellikle veriler gün, ay, yıl vb. sabit zaman aralıkları ile toplanır. Zamansal veri içerisindeki anlamlı trend ve örüntüleri keşfetmek için kullanılan bir yöntemdir. Zaman serileri ekonomik analizler, hisse piyasaları, kalite kontrol vb. birçok alanda uygulanmaktadır.

4.2.2. Tanımlayıcı Yöntemler

Tanımlayıcı veri madenciliği, büyük hacimli veri yığınlarından gizli örüntülerin keşfedilmesini hedefler.

4.2.2.1. Birliktelik Kuralları

Veriler arasındaki ilişkilerin belirlenmesi ilişki analizi olarak ifade edilir. İlişki analizinde veri tabanında bulunan verilerin birlikte olma olasılıkları araştırılır ve bu olasılıkların kuralları çıkarılır.

Sepet analizi, hastalık teşhisi vb. birçok konuda ilişki analizi uygulamaları bulunmaktadır. Örneğin sepet analizlerinde bazı ürünlerin beraber alınması bu ürünler arasındaki bağılılığı göstermektedir. Bu bağılıkların bulunması ve kural haline getirilmesi ilişki analizi alanıdır. İlişki analizinde elde edilen kurallara birliktelik kuralları denir.

Birliktelik kuralları, belirli bir veri kümesinde sıklıkla birlikte görülen durumlar arasındaki ilişki kuralları olarak tanımlanır. Birliktelik kuralları ile büyük hacimli verilerde gizli kalmış, faydalı ve ilginç ilişkiler bulunabilir.

İlk olarak 1993 yılında Agrawal, Swami ve Imeilinski tarafından ortaya atılmıştır. İsimlerin baş harfleri olan AIS algoritması ile birliktelik kuralları bulmuşlardır. Literatürde genel olarak birliktelik kuralları market sepet analizi ile birlikte ifade edilir. Market sepet analizinde müşterilerin hangi ürünleri birlikte aldığı, bir ürünü alan müşterinin hangi ürünü de beraber alma olasılığının olduğu, hangi gün/ay/yıl' lar da

hangi ürünleri alma eğilimlerinin olduğu gibi analizler ile geleceğe yönelik stratejiler belirlenir.

Agrawal ve arkadaşları tarafından geliştirilen birliktelik kurallarının matematiksel gösterimi:

Ürünler adı verilen $I = \{I_1, I_2, I_3, \dots, I_m\}$ kümesi ve işlemler adı verilen bir D kümesi olduğunu varsayalım. Her I farklı bir ürün veya iş anlamına gelir. D kümesinde tanımlanan her hareketi T ifade eder ve tanımlanması $T \subset I$ şeklindedir. TID her harekete özel verilen bir numarayı ifade eder.

X ve Y birer iş veya ürünlerin kümesini temsil ediyor olsun. Bir hareket kümesi olan T için, $X \subset T$ ise yani T kümesi X kümesini kapsıyor ise ve X ve Y kümeleri için $A \subset I$ ve $B \subset I$ ve $X \cap Y = \emptyset$ koşullarının hepsi sağlanıyorsa X kümesi ve Y kümesi için birliktelik kuralı $X \Rightarrow Y$ şeklinde ifade edilmektedir. Bu şekilde ifade edilen birlikteliklerde A öncül ve B ardıl olarak tanımlanmaktadır. Dolayısıyla birliktelik kuralı şu şekilde ifade edilir.

$$X_1, X_2, X_3, \dots, X_m \Rightarrow Y_1, Y_2, Y_3, \dots, Y_n$$

Verilerden birçok kural keşfedilebilir. Ancak bu kurallar önem arz etmeyebilir. Bu nedenle kurallar belirli ölçütlere göre değerlendirilmesi gerekir. Bu ölçütler; destek (support) ve güven (confidence) değerleridir. Elde edilen kurallar belirlenen destek ve güven değerlerine göre değerlendirilir. Minimum destek ve güven değerini sağlamayan kurallar elenir. Böylece önemsiz kurallar azaltılarak önemli olanlara yoğunlaşılır. Yani birliktelik kuralları gücünü destek ve güven değerlerinden alır.

Destek değeri, $X \Rightarrow Y$ şeklindeki bir kuralda X ve Y 'nin birlikte bulunduğu durum sayısının tüm işlem sayısına oranını ifade eder. Güven değeri ise X 'i bulunduğu durumlarda Y 'nin ne sıklıkla bulunduğunu ifade eder. $X \rightarrow Y$ kuralının güven değeri % 70 ise X 'i içeren durumların % 70'i Y 'de içerir anlamına gelmektedir.

Destek ve güven değerlerinin formülasyonları sırasıyla Eşitlik (4.1) ve (4.2)'de gösterilmiştir.

$$\text{Destek } (X \Rightarrow Y) = \frac{|X \cup Y|}{D} \quad (4.1)$$

$$\text{Güven } (X \Rightarrow Y) = \frac{|X \cap Y|}{|X|} \quad (4.2)$$

Bu formüllerdeki $|X \cup Y|$ ifadesi X ve Y 'nin birlikte görüldüğü durum sayısını ifade eder. $|X|$ ifadesi sadece X 'in görüldüğü durumları ifade eder. D ise toplam işlem veya durum sayısı anlamına gelir.

Destek ve güven ölçütlerinin minimum (eşik) değerlerinin konunun uzmanlarınca değerlendirilmesi gerekir. Çok yüksek ve düşük değerler ciddi probleme yol açabilmektedir. Destek değerinin çok yüksek olması az kural bulunmasına, düşük olması ise önemli olmayan birçok kuralın bulunmasına neden olur. Güven değeri aynı olan kurallardan hangisinin daha önemli olduğunu bulmak için Kaldıraç (lift) ölçütü kullanılmaktadır. Kaldıraç değeri, X ile Y' nin bağımsız olup olmadığını gösteren bir ölçüttür. İki ürün veya iş birbirinden bağımsız ise bunlardan ilişki kuralı çıkarılması zordur. Eğer kaldıraç değeri 1'den büyükse değişkenler birbirine bağımlıdır. Kaldıraç değeri ilginç kuralların elde edilmesini sağlar. Azevedo ve Jorge (2007) 'ın kuralları değerlendirmek için tanımladıkları kaldıraç (lift) ve X^2 (Ki-kare) formülleri sırasıyla Eşitlik (4.3) ve (4.4)' de verilmiştir.

$$\text{Kaldıraç (Lift)}(X \rightarrow Y) = \frac{|X \cup Y| * D}{|X| * |Y|} \quad (4.3)$$

$$X^2(X \rightarrow Y) = \frac{|D| * (N_{11} * N_{22} - N_{12} * N_{21})^2}{N_1 * N_2 * N_1' * N_2'} \quad (4.4)$$

$$N_{11} = |X \cup Y| \quad N_{22} = D - |X| - |Y| + |X \cup Y| \quad N_{12} = |X| - |X \cup Y| \quad N_{21} = |Y| - |X \cup Y|$$

$$N_1 = |X| \quad N_2 = D - |X| \quad N_1' = |Y| \quad N_2' = D - |Y|$$

X^2 testi kurallardaki öncül ve ardıl arasındaki korelasyonu değerlendirmez. Sadece öncül ve ardıl arasındaki bağımsızlığa karar vermede yardımcı olur. Kurallar için serbestlik derecesi = n- (parametre sayısı)-1 formülünden 1 olarak bulunur. Kuralların önemini test etmek için aşağıdaki hipotez kurulur.

H_0 = Kural önemsizdir (Öncül ve ardıl bağımsızdır).

H_1 = Kural önemlidir (Öncül ve ardıl bağımlıdır).

α , testin önem derecesi olmak üzere $P(X^2 > X^2_{1-\alpha}) < \alpha$ ise kural önemlidir. Bir başka deyişle, $X^2 > X^2_{1-\alpha}$ ise H_0 hipotezi red edilir. H_1 kabul edilir.

Elde edilen kuralların test edilmesi gerekir. Bunun için (Han ve Kamber, 2006) kuralların tahmin başarısını belirlemek için iki kritere bakılması gerektiğini ifade etmişlerdir. Bu kriterler Kapsam (Coverage) ve Doğruluk (Accuracy)'dur. Kapsam ve Doğruluk formülleri sırasıyla Eşitlik (4.5) ve (4.6)'da verilmiştir.

$$\text{Kapsam} = \frac{n_{\text{kapsam}}}{D} \quad (4.5)$$

$$\text{Doğruluk} = \frac{n_{\text{doğru}}}{n_{\text{kapsam}}} \quad (4.6)$$

Kuralımız R diyelim. $n_{doğru}$, kural R tarafından sınıflandırılan örneklerin sayısını ifade eder. n_{kapsam} , kural R tarafından kapsanan örneklerin sayısı anlamına gelir. D ise test verisi sayısını ifade eder.

Büyük hacimli verilerde birliktelik kuralı uygulaması iki adımda gerçekleşir:

- Eldeki veri tabanından sık tekrarlanana ürünler veya işler bulunur. Bulunan ürün veya nesnelere belirlenen minimum destek değerine göre elenir.
- Elde edilen sık tekrarlanan öğeler için birliktelik kuralları çıkarılır. Belirlenen birliktelik kurallarının güçlü olabilmesi için belirlenen minimum destek ve minimum güven değerleri olan eşik değerlerini aşmalıdır.

4.2.2.1.1. Yaygın Öğeler Madenciliği

Yaygın (sık) öğeler literatürde birçok algoritma ile elde edilebilmektedir. Burada çalışma da kullanacağımız Apriori algoritmasından bahsedeceğiz. Yaygın öğelerin ve birliktelik kurallarının temelini oluşturması nedeniyle algoritmalar arasında en yaygın bilinen ve kullanılan algoritma Apriori'dir. İlk olarak bir veri seti içerisinde yaygın geçen öğeleri bulmaya çalışır. Daha sonra bu yaygın öğelerden hareketle kurallar oluşturur. Agrawal ve arkadaşları tarafından 1993 yılında geliştirilmiştir.

Algoritma sık geçen öğeler bulabilmek için verileri birçok kez taramaktadır. İlk taramada bir öğeli durumları bulur. Daha sonraki adımda bu öğeleri aday kümeler olarak bir sonraki kümeyi bulmak için kullanır. Tarama sırasında minimum destek değerini sağlayamayan öğeler aday kümeye giremez ve elenirler. Tarama yeni bir öğe kümesi bulunmayana kadar devam edilir. Apriori algoritmasına göre bir öğe kümesi sık öğe kümesindeyse öğe kümesinin tüm alt kümeleri de öğe kümesindedir.

Bir marketten yapılan alışverişin fiş numaraları ve alışverişlerde alınan ürünleri Çizelge 4.1. 'de verilmiştir. Minimum destek oranı %30 ve güven oranı %60 olacak şekilde Apriori algoritması anlatılmıştır.

Çizelge 4.1. Satın alınan ürün verileri

Fiş No	Alınan Ürünler
1	A1,A2,A3,A4
2	A1,A2,A4
3	A4,A5
4	A5,A6
5	A1,A2
5	A1,A2,A5

Algoritmada ilk olarak her ürünün destek sayısı bulunur. Algoritma, her ürünün sayısını bulmak için tüm alışverişleri taramakta ve elde edilen sonuçlar Çizelge 4.2' de destek sayısı hesaplanmıştır. Çizelge 4.2. 'de görüldüğü gibi A1 ürününden 4, A2 ürününden 4, A3 ürününden 1, A4 ürününden 3, A5 ürününden 3, A6 ürününden de 2 adet alındığı görülmektedir.

Çizelge 4.2. Tekli kombinasyonların destek değerleri

Ürün	Destek sayısı	Destek Oranı
A1	4	67%
A2	4	67%
A3	1	17%
A4	3	50%
A5	3	50%
A6	1	17%

Minimum destek değerinden daha düşük desteğe sahip olan öğeler çıkarılmıştır. A3 ve A6 ürünlerinin destek oranları %17, minimum destek değeri %30' dan küçük olduğu için elenmiştir. Hangi ürünlerin ikili olarak sık tekrarlandığını belirlemek için ürünlerin ikili kombinasyonları üretilmiştir ve Çizelge 4.3' te görüldüğü gibi destek oranları hesaplanmıştır.

Çizelge 4.3. İkili kombinasyonların destek değerleri

Ürünler	Destek sayısı	Destek Oranı
A1,A2	4	67%
A1,A4	2	33%
A1,A5	1	17%
A2,A4	2	33%
A2,A5	1	17%
A4,A2	1	17%

(A1, A5) , (A2,A5) ve (A4,A2) ürün çiftlerinin destek oranları %17'dir. Minimum destek değeri %30'dan küçük olduğu için bu çiftler elenmiştir. Hangi ürünlerin üçlü olarak sık tekrarlandığını belirlemek için ürünlerin üçlü kombinasyonlar oluşturulmakta ve destek oranları bulunmaktadır. Üçlü kombinasyonlar için elde edilen destek oranları Çizelge 4.4 'de görüldüğü gibidir.

Çizelge 4.4. Üçlü kombinasyonların destek değerleri

Ürünler	Destek sayısı	Destek Oranı
A1,A2,A4	2	33%

Sık tekrarlanan öğeleri bulduktan sonraki aşamada birliktelik kurallarını oluşturulmasıdır.

- $A1 \rightarrow (A2, A4)$
A1 ürününü alanlar, A2 ve A4'ü de alırlar. Bu kuralın destek değeri %33 ve güven değeri % 50'dir.
- $A2 \rightarrow (A1, A4)$
A2 ürününü alanlar, A1 ve A4'ü de alırlar. Bu kuralın destek değeri %33 ve güven değeri % 50'dir.
- $A4 \rightarrow (A1, A2)$
A4 ürününü alanlar, A1 ve A2'İ de alırlar. Bu kuralın destek değeri %33 ve güven değeri % 67'dir.
- $(A1, A2) \rightarrow A4$
A1 ve A2 ürününü alanlar, A4' de alırlar. Bu kuralın destek değeri %33 ve güven değeri % 50'dir.
- $(A1, A4) \rightarrow A2$
A1 ve A4 ürününü alanlar, A2' de alırlar. Bu kuralın destek değeri %33 ve güven değeri % 100'dir.

Elde edilen birliktelik kurallarına göre minimum destek değeri %30 ve güven değeri %60 şartını sağlayan iki adet birliktelik kuralı elde edilmiştir. Bunlar;

- $A4 \rightarrow (A1, A2)$
- $(A1, A4) \rightarrow A2$ dir.

4.2.2.2. Kümeleme

Kümeleme, veriler için önceden belirlenmiş sınıfların olmadığı bir sınıflandırma yaklaşımı olarak ifade edilir. Dolayısıyla bir denetimsiz öğrenme yaklaşımıdır. Kümelemede sınıflar önceden tanımlanmaz, sınıf sayısını kullanılan veri ile ilişkilidir. Kümelemede önceden belirlenmiş niteliklere göre benzer verilere sahip olanlar aynı kümeye atanır. Her nesne mevcut kümelerdeki nesnelere karşılaştırılmaktadır. Nesne en benzer kümeye atanmaktadır. En uygun çözüm bulunana kadar iterasyon yapılır. İyi bir kümeleme metodu sınıf içi benzerliği yüksek, sınıflar arası düşük olan kümeler oluşturur.

4.2.2.3. Sıralı Örüntü Madenciliği

Sıralı örüntü analizi, belirli bir zaman dilimi içerisinde belirli bir sıklıkla meydana gelen sıralı olayları ifade eder. Olay ve zaman arasındaki ilişki iki eksenli bir veri matrisinde gösterilir. X eksenini referans alınmış belirli bir zaman başlangıcını ya da süresini, Y eksenini ise bu zaman aralığında meydana gelen davranış biçimlerini ortaya çıkarmak için kullanılır (Cemaloğlu ve Duykuluoğlu, 2020).

Sıralı örüntülerin, birliktelik kurallarından temel farkı zamansal sırayı dikkate almasıdır. Yani birliktelik kuralları eş zamanlı çalışırken, sıralı örüntüler eş zamansız çalışmaktadır. Amaç veriler içinde zamanı dikkate alarak belirli destek değerini aşan örüntülerin ortaya çıkarılmasıdır. Bu sayede gelecek ilişkiler tahmin edilir. Yani birbirini izleyen zamanlarda gerçekleşen olayların birbiriyle ilişkisi olduğu durumların belirlenmesinde sıralı örüntüler kullanılır. Sıralı örüntülere ait örnekler:

- Çadır alan müşterilerin % 20'si iki ay içerisinde sırt çantası almaktadır.
- Bilgisayar alan müşterilerin % 10 'u bir ay içerisinde yazıcı almaktadır.
- X ameliyatı yapılan bir hastada bir hafta içerisinde Y iltihabı görülebilir.

Bir dizi veri tabanı, zaman bilgisi olsun veya olmasın birbiri ardı gelen ürün veya işlerin sıralı öğe dizilerinden oluşur. $I = \{l_1, l_2, l_3, \dots, l_p\}$ tüm öğelerin kümesi olsun. S dizisi $\langle e_1, e_2, e_3, \dots, e_n \rangle$ olduğunu varsayalım. S dizisinde, e_2 olayı e_1 'den sonra. e_2 olayı da e_3 'den önce meydana gelir. Yani sıralı ilişkilidir. Bir ardışık dizinin, sık ardışık dizi olabilmesi için belirlenmiş eşik değerinin üstünde olması gerekir.

Literatürde birçok popüler sıralı örüntü algoritması vardır. En popülerlerinden bazıları:

- Generalized Sequential Pattern (GSP) (Srikant ve Agrawal, 1996)
- Apriori-Based Vertical Data Format Sequential Pattern Mining (SPADE) (Zaki, 2000)
- Sequential Pattern Mining (SPAM) (Ayres vd. 2002)
- PrefixSpan (Pei vd. 2001)

Yukarıdaki algoritmalar zaman bilgisi olmadan ardışık örüntüler bulur. Zaman bilgisi de bazı problemler için kritik önem teşkil etmektedir. Bunun için Hirata ve Yamana (2006) zaman bilgisi ile ardışık örüntüler bulan bir algoritma geliştirmiştir. Onların geliştirdiği algoritmada beş adet parametre vardır. Bunlar:

- Minimum destek değeri (%) : Veri tabanından bulunulacak sıralı örüntülerin tüm örüntüler içindeki oranını ifade eder. Bu oran altındaki örüntüler çıkarılır.
- Minimum aralık: Örüntüdeki iki ardışık ürün/iş arasındaki minimum aralığı (zamanı) ifade eder.
- Maksimum aralık: Örüntüdeki iki ardışık ürün/iş arasındaki maksimum aralığı (zamanı) ifade eder.
- Minimum tam aralık: Örüntüdeki ilk ürün/iş ile son ürün/iş arasındaki minimum aralığı (zamanı) ifade eder.
- Maksimum tam aralık: Örüntüdeki ilk ürün/iş ile son ürün/iş arasındaki maksimum aralığı (zamanı) ifade eder.

Çizelge 4.5.'de zaman etiketli dizi veri tabanı gösterilmiştir. Veri tabanında verilen zaman bilgisini ay olarak varsayalım. 10' nolu dizide ilk olarak a durumu gerçekleşmiştir. Bir ay sonra (a,b,c) durumları ardından 2 ay sonra (a,c) durumu gerçekleşmiştir diyebiliriz.

Çizelge 4.5. Zaman etiketli dizi veri tabanı

Dizi no	Diziler	Zaman Bilgisi
10	< a, (a,b,c), (a,c) >	< 0, 1, 2 >
20	< a, (a,b), (a,b,c),(a,b,c) >	< 0, 1, 2, 3 >
30	< (a,b), (a,b) >	< 0, 1 >
40	< b, (a,b,c) >	<0, 1 >

Hirata ve Yamana (2006) geliştirdikleri algoritmaların parametreleri; Minimum destek değeri % 55, Minimum aralık = 0, Maksimum aralık =2, Minimum tam aralık =0 ve Maksimum tam aralık =2 olarak aldığımızda Çizelge 4.6'daki sonuçları elde ederiz.

Çizelge 4.6. Zaman etiketli örüntüler

Örüntü No	Örüntüler	Destek (%)
1	(0,c)	75
2	(0, (b,c))	75
3	(0,b)	100
4	(0,(a,b,c))	75
5	(0,(a,b))	100
6	(0,(a,c))	75
7	(0,a)	100
8	(0,b)→(1,c)	75
9	(0,b)→(1,(a,b))	75
10	(0,b)→(1,(a,c))	75
11	(0,b)→(1,a)	100
12	(0,b)→(1,b)	75
13	(0,a)→(1,(a,b))	75
14	(0,a)→(1,a)	75
15	(0,a)→(1,b)	75
16	(0,(a,b))→(1,a)	75

Çizelge 4.6' da girilen parametrelere göre elde edilen ardışık örüntüler görülmektedir. Sekiz nolu örüntüyü incelediğimizde;

- İlk olarak b faaliyeti bir ay sonra c faaliyeti gerçekleşmiştir.
- Destek değeri % 75 olduğunda göre dört diziye sahip veri tabanında üç kez görüldüğü anlamına gelir.
- Çizelge 4.5. incelendiğinde 10, 20 ve 40 nolu dizilerde (0,b)→(1,c) örüntüsünün bulunduğu görülür.
- Çizelge 4.6' daki örüntülerin tamamı, model çözümünden önce belirlenen beş parametreyi de sağladığı görülür.

5. ÇALIŞMA ALANI

Bakım ve stok yönetiminin en önemli olduğu işletmeler arasında şüphesiz araç filoları en önde gelmektedir. Filolardaki bakım yöneticileri, farklı üreticilerden alınan farklı yakıt ve yaşlardaki araçlardan dolayı çok çeşitli arızalar ile karşılaşmaktadırlar ve binlerce yedek parçayı yönetmek durumundadırlar. Araç filoları içinden en çok araca sahip olan filolar genellikle şehir içi ulaşımı sağlayan belediyelere ait otobüs filolarıdır. Günümüzde şehir içi ulaşımın büyük bir kısmı yerel belediyeler tarafından sağlanmaktadır. Şehir içi ulaşım faaliyetlerini gerçekleştiren otobüs filolarındaki araçların emre amadelik oranlarının yüksek olması önemli bir konudur. Belirlenmiş bir sürede daha fazla sefer gerçekleştirmek, sefer başına düşen işletme maliyetlerinin düşmesini sağlar. Yani otobüslerin çalışır olma sürelerinin artırılması ve çalışır olmadığı sürelerin en aza indirilmesi arzu edilir. Otobüslerin seferler için kullanım sürelerinin maksimize etmek, otobüslerin faal olmasına engel olan sebeplerin araştırılması ve azaltılmasıyla mümkündür. Ek olarak ihtiyaç duydukların parçaların istenilen miktar ve zamanda olmasıyla mümkün olacaktır.

Bu bölümde çalışmanın yapıldığı işletme hakkında bilgiler verilmiştir. Daha sonra uygulamanın yapıldığı otobüs ile ilgili bilgiler verilmiştir. Ardından çalışmanın yapıldığı arıza sınıfına değinilmiştir.

5.1. İşletme Hakkında

Ankara Belediyesi Otobüs İşletmesi, 1.10.1935 tarihinde Sovyetler Birliği'nden alınan 100 adet otobüs ile toplu taşımacılık hizmetine başlamıştır. 1946 yılında özel teşebbüslerin girişimi ile ulus-cebeci, ulus-sihhiye gibi kentin en yoğun yerlerine ilk dolmuş hatları kurulmuştur. 1.1.1950 tarihinde itibaren Ankara Elektrik Havagazı ve Otobüs İşletmesi (EGO) adını almıştır. 1950 yıllarındaki gelişmelerle birlikte kamu ve özel girişimlerin araç kapasitesi artmıştır. 1969 yılında 140 adet yeni otobüs alınarak araç parkı arttırılmıştır. 1982 yılında özel halk otobüsleri şehir içi ulaşımına katılmıştır. 1983'de EGO 119'u normal 25'i ekspres 144 hatta hizmet sağlamaktaydı. 1984 yılında Macaristan'dan Ikarus marka körüklü otobüsler alınmıştır. Kamunun taşımacılıkta payı %32'e yükselmiştir.

1989 yılında İlk metronun temeli atılmıştır. 1993 yılında 32 hatta 2134 minibüs-dolmuş, 17 hatta 200 özel halk otobüsü şehir içi ulaşımında hizmet vermektedir. Kamunun payı % 28,7'dir. 1996 Ağustos'da Dikimevi-Aşti hafif raylı toplu taşıma hizmete girmiştir. 1999 yılında 70 adet körüklü, 194 adet Solo Mercedes otobüs alınmıştır. 2005 yılında 50 adet dizel, 400 adet doğalgazlı otobüs, 2006 yılında ise 70 adet dizel Man otobüs alınmıştır.

2008, 2009, 2010,2011 yıllarında sırasıyla 90, 350, 210 ve 40 adet Man marka solo CNG hizmete sunulmuştur. 2012 yılında ilk defa 125 adet körüklü Man marka CNG otobüs alınırken 124 adet de Mercedes marka dizel otobüs alınmıştır. 2013 yıllarında da 75 adet körüklü CNG ve 56 adet Mercedes dizel otobüs alımına devam edilmiş ve sürekli alımlar yapılarak artan talep karşılanmaya çalışılmıştır. Ve şuan yaklaşık 1540 araç ile hizmet vermeye devam etmektedir.

EGO İşletmesi altında görev yapan Araç-Bakım Onarım daire başkanlığının temel görevi filoda bulunan tüm araçları faal halde tutabilmek için teknik destek sağlamaktır. Araç-Bakım Onarım Daire Başkanlığının ana görev ve yetkileri aşağıdaki gibidir:

- Kaza veya kaza sonrası araçların bakımını yapmak
- Araçların periyodik bakımlarını zamanında ve eksiksiz yaparak arızalanma sayılarını azaltmak
- Seferde iken arızalanan otobüslerin arızı bakımlarını yapmak
- CNG istasyonlarının bakımını yapmak
- Bakım-onarım giderlerini azaltmak ve araçların ömrünü uzatmak için sürekli iyileştirme çalışmaları yapmak
- Çalışanlarına araçlarda meydana gelen teknolojik gelişmelere bağlı olarak eğitim vermek
- Araçların akaryakıt tedarikini yapmak
- Yedek parça, yağ vb. malzemelerin stok kontrollerini yapmak ve muhafaza etmektir.

Araç-Bakım Onarım Daire başkanlığı Merkez, 1.bölge, 3.bölge ve 5.bölge olmak üzere 4 farklı kademedede hizmet vermektedir. Türkiye'deki en büyük otobüs bakım-onarım atölyesine sahip olan EGO, 296 deneyimli çalışanıyla hizmet vermektedir.

Farklı üreticilerden farklı modellerde çok miktarda araca sahip olan filonun bakım-onarım işlerini yönetmek için bir bakım-onarım yönetim sistemi kullanmaktadır.

5.2. CNG Otobüsler

Sıkıştırılmış Doğal Gaz (CNG-Compressed Natural Gas), doğalgazın bir formu olup en çevreci yakıt olarak bilinir. Fiyat, performans ve doğa dostu olması avantajlarının yanı sıra yakıt istasyon sayısı ve dönüşüm maliyetleri gibi dezavantajları da bulunmaktadır.

Doğalgazın kullanımı her geçen yıl artmaktadır. Toplumların doğalgazı tercih etmelerinin sebepleri:

- Çevre kirliliğini azaltmak
- Petrol rezervlerinin azalması
- Petrolün fiyatının artması

Günümüzde artan çevre kirliliği nedeniyle dünyanın pek çok yerinde otobüs, taksi ve toplu taşıma araçlarında doğal gaz kullanımını giderek artmaktadır. CNG, araçlardaki farklı boyutlardaki tüplerde depolanır. CNG genellikle büyük ticari araçlarda ana yakıt olarak kullanılmaktayken bazı binek araçlarda alternatif yakıt olarak da kullanılmaktadır.

CNG avantajları aşağıda ifade edilmiştir:

- CNG benzinle veya LPG ile çalışan araçlara göre % 50-60 daha tasarrufludur.
- Diğer yakıtları kullanan araçlara göre yağ değişimi daha azdır.
- Doğal gaz temiz yanan bir yakıt olmasından dolayı diğer yakıtlarla karşılaştırıldığında çevreye çok daha az zarar verir.
- Doğalgaz boru hatlarıyla taşındığından, diğer yakıtlardaki gibi karayoluna zarar verme riski yoktur. Ve taşıma maliyeti daha düşüktür.
- Temiz bir yakıt olduğundan araç bakım sayılarını azaltmaktadır.
- Dışarı çekilerek yakıtın çalınma riski yoktur.
- Diğer yakıtlar ile kıyaslandığında daha az azot ve karbon monoksit ürettiğini görülmüştür.
- Diğer yakıtlara göre tutuşma sıcaklığı daha yüksektir.
- Diğer yakıtlarla çalışan motorlara göre daha az gürültülüyle çalışmaktadır.

Tüm bu avantajlarıyla CNG' li araçlar dünyanın birçok ülkesinde toplu taşıma ve servis araçlarında zorunluluk haline getirilmiştir. Şekil 5.1.'de bir CNG otobüs gösterilmektedir.

Bu çalışmada, CNG'li otobüslerin seçilmesinin sebebi toplam otobüs filosunun yaklaşık % 83'ünü CNG'li araçlardan oluşması ve yönetimin ileriki yıllarda CNG araç parkının büyütme stratejisinin devam edecek olmasındandır. En son yapılan ihalede 377 aracın 273 adedinin CNG'li araç olması bunun bir göstergesidir.




Şekil 5.1. CNG Otobüs

5.3. Şanzıman

Şanzıman motorun gücünü kademeli olarak tekerleklere ileten bir aktarım organıdır. Şanzıman dişliler, miller ve vitesten oluşur. Viteslerin küçülmesini ve büyümesini sağlayarak aracın hızını ayarlayan yapıdır. Şanzıman aracın durur konumda iken harekete geçmesini, hareket halinde iken durma konumuna, ileri doğru giderken geri gitmesini ve geri giderken ileri gitmesini sağlar. Şekil 5.2. 'de örnek bir otobüs şanzımanı gösterilmektedir.

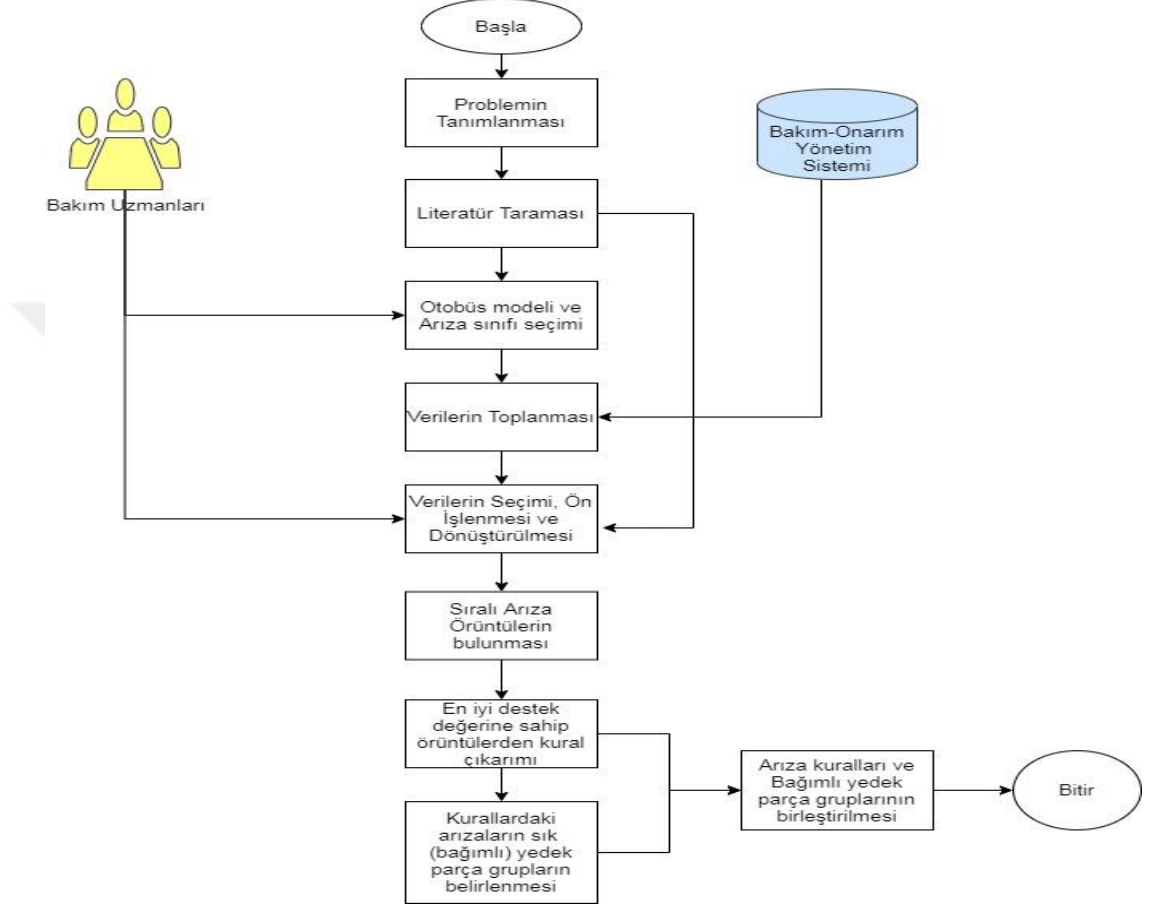
Bakım yöneticileri ve mavi yaka ile yapılan toplantılar neticesinde çalışmada CNG yakıtlı otobüslerin şanzıman arıza verilerinin kullanılmasına karar verilmiştir.



Şekil 5.2. Otobüs Şanzımanı

6. MODELİN TASARLANMASI VE UYGULANMASI

Çalışmanın yapılacağı otobüs grubu ve arıza sınıfı seçildikten sonra modelin tasarlanması ve uygulanması adımına geçilmiştir. Şekil 6.1.'de çalışmanın metodolojisi gösterilmiştir.



Şekil 6.1. Methodoloji

Şekil 6.1' de gösterildiği gibi çalışma ilk olarak problemin tanımlanmasıyla başlar. Daha sonra ilgili literatürdeki çalışmalar incelenmiştir. Bakım uzmanları ile toplantılar yaparak uygulamanın yapılacağı otobüs modeli ve arıza sınıfı seçimi yapılmıştır. İşletmenin sahip olduğu bakım-onarım yönetim sisteminden arıza kayıtları verileri toplanmıştır. Daha sonra bu arızalardan eksik veya hatalı veriler çıkarılmıştır. Veriler çalışmanın yapılacağı veri madenciliği yazılımına uygun girdi formatına dönüştürülmüştür. Ardından seçilen sıralı örüntü algoritması uygulanarak sıralı örüntüler bulunmuştur. Bu örüntüler içerisinde en iyi destek değerlerine sahip olanlar seçilerek bir sonraki arızayı tahmin etmek için kurallar oluşturulmuştur. Geçerliliği

test edilen kurallarda yer alan arızalara ait sık (bağımlı) yedek parçalar bulunmuştur. Son adımda ise sıralı kurallar ve sık (bağımlı) yedek parçalar birleştirilmiştir.

6.1. Verilerin Seçimi

Uygulamada, işletmenin kullandığı Bakım Onarım Yönetim Sistemi (BOYS) ‘den alınan CNG otobüslere ait şanzıman arızaları kullanılmıştır. Haziran-2017 ve Mart-2021 tarihleri arasında gerçekleşen yaklaşık dört yıllık arıza verisi ile çalışılmıştır. 1487 adet araca ait 32.489 satır ham arıza verisi bulunmaktadır. Ham verilerde bulunan boyutlar şunlardır;

- İş emri no
- Görev no
- Otobüs kodu
- Bölge kodu
- Kilometre bilgisi
- İş tipi
- Bildirim tarihi
- Bitiş tarihi
- Yapan birim
- Arıza sınıfı
- Arıza kodu
- Parça No
- Parça Adı

Çalışmamızda bakım uzmanlarıyla yapılan toplantılar ile karar verilen boyutlar Otobüs kodu, Kilometre bilgisi, Arıza kodu, Bildirim Tarihi, Parça no ve parça adıdır. Filo içerisinde her otobüse yaşı, çalıştığı bölge ve filoya katılma numarasını baz alan beş haneli bir kodlama sistemi bulunmaktadır. Kilometre bilgisi arızanın hangi kilometrede gerçekleştiğini ifade eder. Bildirim tarihi arızanın bildirildiği tarih anlamına gelmektedir. Parça no, BOYS sisteminde tanımlanmış her kullanılan yedek parçaya verilen kodu ifade eder. Parça adı ise kod ile belirtilen parçanın açık ismidir. Kullanılacak boyutların ham hali Şekil 6.2.’de görülmektedir.

OTO_KOI	KMBILGI	BILDIRIM_TARIHI	ARIZA_SIN	ARIZA_KODU	PARÇA_NO
12-569	257162	3.07.2017 20:00:28	SANZUMAN	ŞANZUMAN YAĞ KAÇIRIYOR	
12-569	257162	3.07.2017 20:00:28	SANZUMAN	ŞANZUMAN YAĞ KAÇIRIYOR	150.13.03.07.06.01.69
12-569	257162	3.07.2017 20:00:28	SANZUMAN	ŞANZUMAN YAĞ KAÇIRIYOR	150.13.03.07.06.01.75
12-569	257162	3.07.2017 20:00:28	SANZUMAN	ŞANZUMAN YAĞ KAÇIRIYOR	150.13.03.07.06.34.82
12-569	257162	3.07.2017 20:00:28	SANZUMAN	ŞANZUMAN YAĞ KAÇIRIYOR	150.13.03.07.06.08.38
12-569	257162	3.07.2017 20:00:28	SANZUMAN	ŞANZUMAN YAĞ KAÇIRIYOR	150.13.03.07.06.35.01.18
12-569	257162	3.07.2017 20:00:28	SANZUMAN	ŞANZUMAN YAĞ KAÇIRIYOR	150.13.03.07.06.08.37
12-569	257162	3.07.2017 20:00:28	SANZUMAN	ŞANZUMAN YAĞ KAÇIRIYOR	150.13.03.07.06.28.08
12-569	257162	3.07.2017 20:00:28	SANZUMAN	ŞANZUMAN YAĞ KAÇIRIYOR	150.13.03.07.06.28.09
12-569	257162	3.07.2017 20:00:28	SANZUMAN	ŞANZUMAN YAĞ KAÇIRIYOR	150.13.03.07.06.01.68
12-569	257162	3.07.2017 20:00:28	SANZUMAN	ŞANZUMAN YAĞ KAÇIRIYOR	150.13.03.07.06.01.70
12-569	257162	3.07.2017 20:00:28	SANZUMAN	ŞANZUMAN YAĞ KAÇIRIYOR	150.13.03.07.06.28.10
10-420	588635	4.07.2017 06:13:50	SANZUMAN	ŞANZUMANDA VURUNTU VAR	
09-223	641059	4.07.2017 09:06:35	SANZUMAN	SEYİR HALİNDE VİTES BOŞA ÇIKIYOR	
12-213	334245	4.07.2017 18:44:02	SANZUMAN	DUZENSİZ VİTES DEĞİŞTİRİYOR	
10-317	576679	5.07.2017 06:43:11	SANZUMAN	ARAÇ HAVA DÜŞÜRÜYOR, PROP VENTİLİ ARIZA	150.13.03.07.06.34.70
11-104	498515	5.07.2017 08:00:13	SANZUMAN	PROF VENTİLİ HAVA DÜŞÜRÜYOR	
09-311	618580	5.07.2017 10:58:46	SANZUMAN	ARAÇ HAVA DÜŞÜRÜYOR, PROP VENTİLİ ARIZA	150.13.03.07.06.34.70
09-441	667786	5.07.2017 15:22:32	SANZUMAN	ŞANZUMAN SICAKLIĞI YÜKSEK	
10-247	590111	6.07.2017 07:01:14	SANZUMAN	DUZENSİZ VİTES DEĞİŞTİRİYOR	
13-224	230019	6.07.2017 08:12:58	SANZUMAN	MOTOR ONARIM SONRASI BÜYÜK BAKIM	
10-326	560190	6.07.2017 10:59:57	SANZUMAN	ARAÇ HAVA DÜŞÜRÜYOR, PROP VENTİLİ ARIZA	150.13.03.07.06.34.70
07-546	952322	6.07.2017 15:56:21	SANZUMAN	ŞANZUMANDA SES VAR	150.13.03.10.10.10.18
07-546	952322	6.07.2017 15:56:21	SANZUMAN	ŞANZUMANDA SES VAR	150.13.03.10.10.07.48
07-546	952322	6.07.2017 15:56:21	SANZUMAN	ŞANZUMANDA SES VAR	150.13.03.10.10.04.05
09-360	615645	7.07.2017 08:48:22	SANZUMAN	MOTOR ONARIM SONRASI BÜYÜK BAKIM	150.13.03.10.10.07.47
09-550	68799	7.07.2017 10:45:22	SANZUMAN	RETARDER ÇALIŞMIYOR / DEVRE DIŞI	
09-550	68799	7.07.2017 10:54:20	SANZUMAN	RETARDER ÇALIŞMIYOR / DEVRE DIŞI	
07-352	850086	7.07.2017 14:34:16	SANZUMAN	MOTOR ONARIM SONRASI BÜYÜK BAKIM	
07-111	739460	7.07.2017 15:52:51	SANZUMAN	sanzuman binecek	150.13.03.07.06.08.14
08-204	623414	7.07.2017 17:38:09	SANZUMAN	RETARDER KAPMA YAPIYOR	

Şekil 6.2. Çalışmada kullanılan ham veri örneği

6.2. Verilerin Ön İşlenmesi ve Dönüştürülmesi

Ham veriler incelendiğinde birçok eksik veya hatalı durum görülmüştür. Bunlar;

- Birden fazla parça kullanılan arızalar için her parçaya bir arıza kaydı açılması,
- Aynı aracın aynı tarihteki arızalarının kilometrelerinin farklı olması,
- Aynı aracın aynı kilometredeki arızalarının tarihlerinin farklı olması,
- Aynı araçta iki veya üç günlük periyotlarla aynı arızanın tekrar olduğu durumlar,
- Çalışmada kullanılacak boyutlardan birinin eksik olması,
- Sadece bir tane arızası bulunan araçlar.

Yukarıda belirtilen durumların olduğu arıza kayıtları silinerek veriler ön işleme tabi tutulmuştur. Sadece bir tane arızası bulunan araçlar herhangi bir ardışık örüntü elde edilemeyeceği için çıkarılmıştır. Aynı araçta iki veya üç günlük periyotlarla aynı arızanın tekrar ettiği durumlarının çıkarılmasının sebebi arıza tanısının yanlış konulması veya bakımın düzgün yapılmamasından tekrar ettiği düşüncesidir.

Veriler incelendiğinden 46 farklı şanzıman arıza tipi olduğu tespit edilmiştir. Çizelge 6.1.'de görülen arıza tipleri ardışık örüntü madenciliğinde kullanmak için 1'den başlanarak sayısal olarak kodlanmıştır. İşletmenin veri politikası nedeniyle arıza tiplerinin tamamı Çizelge 6.1. 'de gösterilmemiştir.

Çizelge 6.1. Arıza tipleri ve kodları

Arıza Kod	Arıza Tipleri
1	Seyir halinde vites boşa çıkıyor.
2	Retarder kapma yapıyor.
...
4	Retarder çalışmıyor./Devre dışı.
5	Araç geri vitese geçmiyor.
...	...
7	Düzensiz vites değiştiriyor.
8	Araç vites yükseltmiyor.
.....	...
16	TCU (177)
....
23	TCU(2999)
...
27	Retarder zayıf tutuyor.
...
46	TCU (5055)

Çalışmada kullanılacak verilerin gereksiz verilerden arındırılmış ve arızaların sayısal kod olarak tanımlandığı şekli Çizelge 6.2.' de gösterilmiştir.

Çizelge 6.2. Ön işlemlerden geçirilmiş veri seti örneği

Otobüs Kodu	Km Bilgisi	Arıza Kodu
06-108	552525	5
06-108	552924	2
06-108	552924	6
06-109	300010	7
06-109	350032	3
06-110	379155	1
06-110	426222	4
06-110	446208	6
06-110	447219	6
06-302	486220	4
06-302	563552	6

Çizelge 6.2' e baktığımızda 06-302 nolu otobüsün 486.220' inci kilometre (km) 'de Retarder çalışmıyor/Devre dışı (4) arızası verdiği görülür. 77.332 km sonra 563.552' inci kilometrede Araç vitese geçmiyor (6) arızası verdiği görülür.

Veriler incelendiğinde iki arıza arasındaki maksimum kilometre farkı 205.000 olduğu görülmüştür. Bu nedenle km skalası 0-210.000 olarak belirlenmiştir. Çizelge 6.3.'de zaman etiketlerine karşılık gelen km bilgileri görülmektedir.

Çizelge 6.3. Zaman Etiketleri

Zaman Etiketi	Km aralık
0	-
1	0-30.000
2	30001-60.000
3	60.001-90.000
4	90.000-120.000
5	120.001-150.000
6	150.001-180.000
7	180.001-210.000

Otobüs filosunun şanzıman arızaları arası ortalama kilometre değeri yaklaşık 30.000 olması nedeni grup aralıkları bu değere göre tasnif edilmiştir.

SPMF yazılımında girdi verilerini txt formatında kabul etmektedir. Dolayısıyla verileri txt formatına dönüştürmek gerekir. Veriler Excel de yazılan makro kod ile txt formatına dönüştürülmüştür. Girdi verilerinin son şekli Şekil 6.3.'de gösterilmiştir. Çalışmada arıza kodları ve ilk arıza ile aralarında geçen kilometre farkları zaman etiketi olarak ele alınmıştır. Farklı kilometreler de gerçekleşen her arıza "-1" ayırıcı ile ayrılmıştır. Araca ait herhangi bir arıza kalmadığı "-2" ayırıcı ile belirtilmiştir.

```
train.txt - Not Defteri
Dosya Düzen Biçim Görünüm Yardım
<0> 1 -1 <2> 4 -1 <3> 6 -1 -2
<0> 4 -1 <3> 6 -1 -2
<0> 5 -1 <2> 6 -1 <3> 7 -1 <4> 9 -1 -2
<0> 15 -1 <1> 16 -1 <2> 17 18 -1 -2
<0> 16 -1 <2> 4 -1 -2
<0> 4 -1 <3> 6 -1 -2
<0> 23 -1 <1> 16 -1 <2> 11 24 -1 <4> 6
-1 -2
<0> 17 -1 <1> 16 26 -1 <2> 14 16 -1 <3>
23 -1 <4> 16 -1 <5> 4 -1 <6> 16 -1 -2
<0> 16 -1 <2> 23 5 -1 <4> 9 | 16 -1 -2
```

Şekil 6.3. (Hirata ve Yamana, 2006)'ın geliştirdiği algoritmanın girdi formatı

Şekil 6.3.'de gösterilen girdi verisindeki her bir satır bir araca ait arıza kayıtlarını içermektedir. Örneğin, birinci satırdaki araç ilk 1 nolu arıza vermiştir. Daha sonraki arızayı ilk arıza ile arasındaki km farkı hangi kategoriye denk gelirse o etiket ile etiketlenir. 30.001-60.000 km aralığına geldiği için iki etiketi verilmiştir. Satırda ki ardışık gelen tüm arızalar ilk arıza referans alınarak etiketlenir. Yani bir zaman serisi şeklinde etiket oluşturmanız gerekir. Dördüncü satırda 2 etiketi içinde bulunan 17, 18 nolu arızaların yan yana olması iki arızanın aynı kilometrede gerçekleşmesinden dolayıdır.

Verilerin ön işlenmesi ve dönüştürülmesinden sonra 1271 araca ait arızalar kalmıştır. Bu arızalarda % 70 eğitim ve % 30 test olmak üzere ikiye ayrılmıştır (Gholamy vd. 2018). 890 araca ait arızalar eğitimde kullanılırken, 381 araca ait arızalar test 'de kullanılmıştır.

6.3. Çalışmada Kullanılan Yazılım

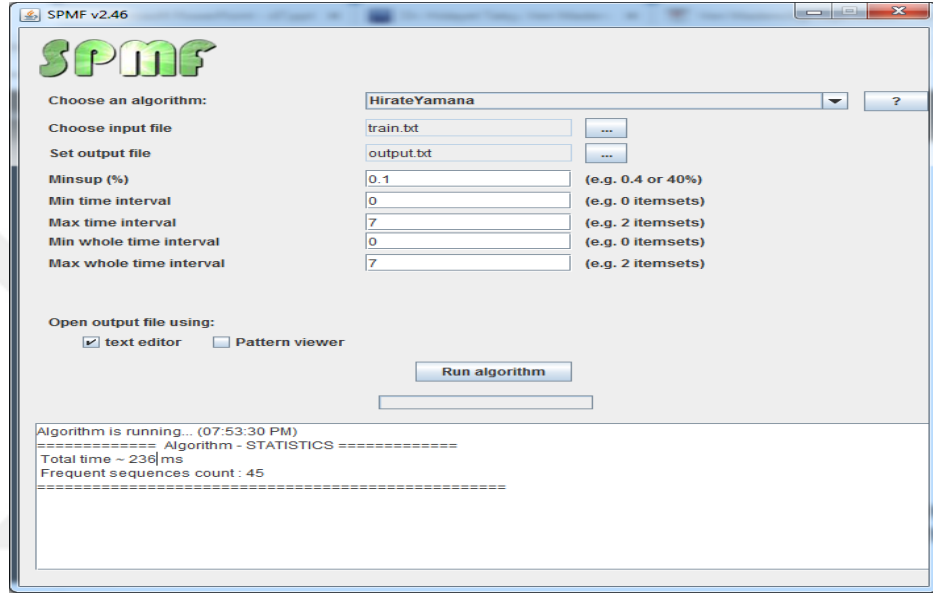
Veri madenciliği çalışmalarında verilerden anlamlı bilgiler çıkarmak için kullanılan birçok yazılım bulunmaktadır. Bu çalışmada içerisinde 210 farklı veri madenciliği algoritması bulunan SPMF (Sequential Pattern Mining Framework) yazılımı kullanılmıştır. SPMF, java ile yazılmış açık kaynak kodlu bir yazılımdır.

SPMF, ilişkisel veri madenciliği, ardışık örüntü madenciliği, zaman serisi madenciliği, kümeleme, sınıflandırma çalışmaları için birçok algoritma barındırmaktadır.

Bu çalışma, Windows 7 işletim sistemli Intel Pentium CPU 2117U, 1.80 GHz işlemci ve 4 GB RAM özelliklerin sahip bir bilgisayarda gerçekleştirilmiştir.

6.4. Sıralı Örüntülerin ve Kuralların Bulunması

Veriler algoritmaya uygun hale getirildikten sonra uygulama aşamasına geçilir. Uygulamada (Hirata ve Yamana, 2006)'ın zaman temelli sıralı örüntü madenciliği algoritması uygulanmıştır. Şekil 6.4. 'de SPMF yazılımının ara yüzü görülmektedir. Algoritmanın istediği beş parametre değeri bakım yöneticilerinin görüşleri doğrultusunda belirlenmiştir.



Şekil 6.4. SPMF programı ara yüzü

Şekil 6.4.' de görüldüğü gibi bakım yöneticileri yapılan görüşmelerde arıza bakım için destek değeri % 10 olmasına karar verilmiştir. İki ardışık arıza arasındaki minimum zaman farkı 0, maksimum zaman farkı 7 seçilerek örüntü sayısını azaltması istenmemiştir. Bu nedenle yine aynı şekilde ilk ve son arıza arasındaki minimum zaman farkı 0, iki arıza arasındaki maksimum zaman farkı 7 olarak belirlenmiştir.

Model çalıştırıldığında %10 destek değerinde 45 adet sıralı örüntü bulunmuştur. Bu model çıktılarının tamamı Çizelge 6.4.' de destek yüzdeleri hesaplanarak gösterilmiştir. % 10 destek değerinde 45, % 20 destek değerinde 29 ve % 30 destek değerinde 16 adet sıralı örüntü elde edilmiştir. Sayısal arıza kodlarının başına arıza anlamında "A" konulmuştur. Örneğin; "A1", 1 nolu arızayı ifade etmektedir.

Çizelge 6.4. Tüm örüntüler

Sıra No	Örüntü	Aralık (km)	Destek (%)
1	A9	-	48,31
2	A18	-	47,19
3	A4	-	46,07
4	A6	-	45,73
5	A31	-	44,49
6	A16	-	44,27
7	A36	-	43,03
8	A27	-	42,25
9	A23	-	40
10	A7	-	39,78
11	A11	-	37,98
12	A17	-	35,96
13	A31→A18	0-1	35,17*
14	A23→A16	0-1	32,02
15	A18→A9	0-3	31,46
16	A4→A9	0-2	31,01
17	A36→A18	0-3	28,54
18	A6→A18	0-4	27,87
19	A6→A9	0-1	25,39
20	A36→A9	0-2	23,15
21	A27→A18	0-1	23,03
22	A31→A9	0-2	22,81
23	A16→A17	0-3	22,58
24	A36→A31	0-2	22,13
25	A27→A9	0-2	21,8

Çizelge 6.4. (devam)

Sıra No	Örüntü	Aralık (km)	Destek (%)
26	A7→A9	0-2	21,12
27	A16→A4	0-3	20,45
28	A23→A4	0-4	20,22
29	A4→A6	0-3	20,11
30	A11→A9	0-4	19,66
31	A18→A7	0-1	19,1
32	A31→A6	0-1	18,88
33	A4→A18	0-2	18,2
34	A11→A23	0-2	17,98
35	A23→A16 →A4	0-1-4	17,42
36	A18→ A31 →A9	0-1-3	14,83
37	A23→A16 →A17	0-1-4	14,49
38	A36→A9→A18	0-2-3	14,16
39	A6→A31 →A18	0-3-4	14,04
40	A36→ A31→A18	0-2-3	13,82
41	A18→A7 →A9	0-1-3	13,6
42	A18→A7→A31	0-1-3	12,02
43	A7→A6 →A18	0-1-5	11,46
44	A31→ A6→A9	0-1-2	10,9
45	A18→ A6→A9	0-2-3	10,11

Çizelge 6.4’de modelin bulduğu tüm örüntüler görülmektedir. Bu sıralı örüntülerin destek yüzdeleri hesaplanmıştır. 22 nolu örüntü, % 22,81 destek değerinde 31 nolu arıza (A31) olduktan sonra ki 30.001-60.000 km içerisinde 9 nolu arıza (A9) ‘nın olabileceği anlamına gelir. Tekli örüntülerin hepsi modelden çıkarılır. Çünkü bir sonraki arıza hakkında bize herhangi bir bilgi vermez.

Çizelge 6.4.’de en uzun örüntü üçlüdür. Yani % 10 destek değerinde dört ve üzeri örüntü bulunamamıştır. Sıralı örüntülerinde genel olarak örüntülerin uzun olması istenmez. Takibi ve sebep-sonuç analizleri zor olmaktadır. Çizelge 6.4.’ de en iyi ikili sıralı örüntü %35,17 destek değeriyle A31→A18’dir. Üçlü sıralı örüntüler içerisinde en iyi örüntü %17,42 destek değeriyle A23→A16→A4’dür. Bu en iyi sıralı örüntülerden bir sonraki arızayı tahmin etmek için kurallar oluşturulacaktır.

İlk olarak A31 \Rightarrow A18 kuralı için destek, güven, kaldıraç ve X^2 değerleri sırasıyla Eşitlik (6.1), (6.2), (6.3) ve (6.4)'de hesaplanmıştır.

- Destek ($X \Rightarrow Y$) = $\frac{|XUY|}{D} = \frac{313}{890} * 100 = 35,17$ (6.1)

- Güven ($X \Rightarrow Y$) = $\frac{|XUY|}{|X|} = \frac{313}{396} * 100 = 79,04$ (6.2)

- Kaldıraç (*Lift*)($X \rightarrow Y$) = $\frac{|XUY|*D}{|X|*|Y|} = \frac{313*890}{396*420} = 1,67$ (6.3)

H_0 = Kural önemsizdir (Öncül ve ardıl bağımsızdır). H_1 = Kural önemlidir (Öncül ve ardıl bağımlıdır).

- $X^2(X \rightarrow Y) = \frac{|D|*(N_{11}*N_{22}-N_{12}*N_{21})^2}{N_1*N_2*N_1*N_2} = \frac{890*(313*387-83*107)^2}{396*494*420*470} = 290,4$ (6.4)

Serbestlik derecesi 1 ve % 95 güvenilirlik seviyesinde $X^2_{1-\alpha}$ değeri 3,84'dir. Hesaplanan X^2 değeri $> X^2_{1-\alpha}$ olduğundan H_0 red edilir. H_1 kabul edilir. Yani kural önemlidir.

İkinci olarak A23 \rightarrow A16 \Rightarrow A4 kuralı için destek, güven, kaldıraç ve X^2 değerleri sırasıyla Eşitlik (6.5), (6.6), (6.7) ve (6.8)'de hesaplanmıştır.

- Destek ($X \Rightarrow Y$) = $\frac{|XUY|}{D} = \frac{155}{890} * 100 = 17,42$ (6.5)

- Güven ($X \Rightarrow Y$) = $\frac{|XUY|}{|X|} = \frac{155}{285} * 100 = 54,38$ (6.6)

- Kaldıraç (*Lift*)($X \rightarrow Y$) = $\frac{|XUY|*D}{|X|*|Y|} = \frac{155*890}{285*410} = 1,18$ (6.7)

- $X^2(X \rightarrow Y) = \frac{|D|*(N_{11}*N_{22}-N_{12}*N_{21})^2}{N_1*N_2*N_1*N_2} = \frac{890*(155*350-130*255)^2}{285*605*410*480} = 11,68$ (6.8)

Serbestlik derecesi 1 ve % 95 güvenilirlik seviyesinde $X^2_{1-\alpha}$ değeri 3,84'dir. Hesaplanan X^2 değeri $> X^2_{1-\alpha}$ olduğundan H_0 red edilir. H_1 kabul edilir. Yani kural önemlidir.

Üçüncü olarak $A23 \Rightarrow A16 \rightarrow A4$ kuralı için destek, güven, kaldıraç ve X^2 değerleri sırasıyla Eşitlik (6.9), (6.10), (6.11) ve (6.12)'de hesaplanmıştır.

$$\bullet \text{ Destek } (X \Rightarrow Y) = \frac{|X \cup Y|}{D} = \frac{155}{890} * 100 = 17,42 \quad (6.9)$$

$$\bullet \text{ Güven } (X \Rightarrow Y) = \frac{|X \cup Y|}{|X|} = \frac{155}{356} * 100 = 43,54 \quad (6.10)$$

$$\bullet \text{ Kaldıraç (Lift)}(X \rightarrow Y) = \frac{|X \cup Y| * D}{|X| * |Y|} = \frac{155 * 890}{356 * 182} = 2,13 \quad (6.11)$$

$$\bullet X^2(X \rightarrow Y) = \frac{|D| * (N_{11} * N_{22} - N_{12} * N_{21})^2}{N_1 * N_2 * N_{\bar{1}} * N_{\bar{2}}} = \frac{890 * (155 * 507 - 201 * 27)^2}{356 * 534 * 182 * 708} = 194,45 \quad (6.12)$$

Serbestlik derecesi 1 ve % 95 güvenirlilik seviyesinde $X^2_{1-\alpha}$ değeri 3,84'dir. Hesaplanan X^2 değeri $> X^2_{1-\alpha}$ olduğundan H_0 red edilir. H_1 kabul edilir. Yani kural önemlidir.

Çizelge 6.5. En iyi sıralı örüntülerden elde edilen kurallar

No	Kurallar	Destek (%)	Güven (%)	Kaldıraç	X^2	Geçerlilik
1	$A31 \Rightarrow A18$	35,17	79,04	1,67	290,4	Geçerli
2	$A23 \rightarrow A16 \Rightarrow A4$	17,42	54,38	1,18	11,68	Geçerli
3	$A23 \Rightarrow A16 \rightarrow A4$	17,42	43,54	2,13	194,45	Geçersiz

Çizelge 6.5' de kuralların performans ölçütleri görülmektedir. Kaldıraç değerlerinin 1'in üzerinde olması öncül ve ardıl arasında bir pozitif ilişki olduğu anlamına gelir. Üç kuralda da kaldıraç değeri 1'in üzerindedir. X^2 bağımsızlık testi öncül ve ardıl arasındaki bağımlılığı ifade eder. X^2 bağımsızlık testinde üç kuralında önemli olduğu görülmüştür. Çalışmamızda minimum güven değeri % 50 olduğundan bir ve iki nolu kurallar tüm eşik değerleri karşılamaktadır. Üç nolu kural minimum güven değerini karşılamaz.

Bir sonraki arızayı tahmin için kurallar oluşturulduktan sonra, bu kuralları test etmemiz gerekir. Test verisi olarak 381 araca ait arızalar kullanılacaktır. Kuralların kapsam ve doğruluk oranları Çizelge 6.6' da gösterilmiştir.

Çizelge 6.6. Test verisiyle tahmin sonuçları

No	Kurallar	n _{kapsam}	n _{doğru}	Kapsam (Coverage) %	Kural Doğruluğu (Accuracy) %
1	A31⇒A18	110	83	28,87	75,45
2	A23→A16 ⇒A4	52	33	13,65	63,46

Çizelge 6.6’ da görüldüğü üzere en yüksek doğruluğa sahip kural bir nolu kuraldır. Bir nolu kural % 75,45, İki nolu kural ise % 63,46 doğruluk oranına sahiptir.

6.5. Sık (Bağımlı) Yedek Parça Gruplarının Bulunması

Uygulamanın diğer aşaması kurallardaki her arıza için Apriori algoritmasının ilk aşaması olan yaygın öge madenciliği yaklaşımını kullanarak sık kullanılan yedek parça gruplarını bulmaktır. SPMF programının yaygın nesne madenciliği bölümündeki Apriori algoritması kullanılmıştır. Minimum destek değeri % 30 alınmıştır. Minimum küme içindeki nesne sayısı iki ve yukarısı olan kümeler işleme dahil edilmiştir.. Çizelge 6.7.’ de 31 ve 18 nolu arızalarda kullanılan parçalar ve stok kodları gösterilmektedir. İşletmenin veri politikası nedeniyle parça isimlerinin tamamı Çizelge 6.7’ de gösterilmemiştir.

Çizelge 6.7.’de gösterilen yedek parçalara bazı arıza gruplarında her arıza olduğunda standart olarak kullanılan bakım kitleri eklenmemiştir. Çünkü bağımlılıkları % 100’dür.

Çizelge 6.7. 31 ve 18 nolu arızaların yedek parçaları ve kodları

Arıza Tipi	Stok Kodu	Yedek parça ismi
A31	S311	Selenoid vana ısıtma hattı
	S312	*
	S313	Kasnak rulman
	S314	*
	S315	Makaralı rulman
	S316	Manyetik ventil
	S317	*
	S318	*
	S319	*
	S3110	Türbin dişlisi
	S3111	*
A18	S181	Filtre
	S182	Aşırı basınç ventili
	S183	*
	S184	İç pleyt
	S185	*
	S186	Şanzıman yağ karteri
	S187	Tork balata diski
	S188	Türbin mili
	S189	Tork rulmanı
	S1810	Hub dişlisi
	S1811	*

Çizelge 6.8' de 31 nolu arızanın 396 adet arıza kaydına ait yedek parça tüketim bilgileri verilmiştir. Eğer yedek parça kullanıldıysa 1, aksi takdirde 0 olarak kodlanmıştır.

Çizelge 6.8. 31 nolu arıza yedek parça tüketim verileri

No	Arıza tipi	Yedek Parçalar										
		S311	S312	S313	S314	S315	S316	S317	S318	S319	S3110	S3111
1	A31	0	0	0	1	0	0	0	1	0	1	0
2	A31	0	1	0	0	0	0	1	1	0	0	0
3	A31	1	0	0	0	0	0	0	0	0	0	1
4	A31	0	0	1	0	1	0	1	0	0	0	0
5	A31	0	0	1	0	0	0	0	0	0	1	0
6	A31	0	0	0	0	0	1	0	0	0	0	0
...
396	A31	0	0	1	1	0	0	0	1	0	0	0

Çizelge 6.8 incelendiğinde 31 nolu arızanın üç nolu arıza kaydında {S311,S3111} yedek parçalarının beraber tüketildiği görülür.

Çizelge 6.9.'da görüldüğü gibi minimum % 40 destek değerini sağlayan üç parça kümesinin öge sayıları aynı olduğundan en yüksek destek değerine sahip olan {S317,S318} yedek parça kümesi seçilir. Minimum destek değeri % 30 olarak gevşetildiğinde üç küme daha eklenmektedir. Bu eklenen kümelerle birlikte minimum destek değerini sağlayan altı küme içinden öge sayısı fazla olan küme seçilir. Eğer öge sayısı aynı olan birden fazla küme var ise en yüksek destek değerine sahip küme seçilir. Bu durumda minimum % 30 destek değerinde {S315,S317,S318} yedek parça kümesi seçilir. Öge sayısı fazla olan kümenin seçilme nedeni arıza anında parça bulunmama olasılığını azaltmaktır. Yani maksimum kapsama (Maximum coverage) sağlamaktır.

Çizelge 6.9. 31 nolu arıza sık kullanılan yedek parça kümeleri

Arıza Tipi	Yedek parça grupları	Destek (%)
A31	S317,S318	46,15*
	S314,S315	41,25
	S314,S319	40,2
	S315,S317,S318	34,74
	S314,S315,S319	32,86
	S314,S315,S318	31,6

Çizelge 6.10'da 18 nolu arızanın 420 adet arıza kaydına ait yedek parça tüketim bilgileri verilmiştir. Eğer yedek parça kullanıldıysa 1, aksi takdirde 0 olarak kodlanmıştır.

Çizelge 6.10. 18 nolu arıza yedek parça tüketim verileri

No	Arıza tipi	Yedek Parçalar										
		S181	S182	S183	S184	S185	S186	S187	S188	S189	S1810	S1811
1	A18	0	0	0	0	1	0	0	1	1	0	0
2	A18	1	1	0	0	0	0	0	0	0	1	0
3	A18	1	0	0	0	0	0	0	0	1	0	1
4	A18	0	0	0	1	1	0	0	0	0	0	0
5	A18	1	0	0	0	0	1	0	0	0	0	0
6	A18	0	0	0	0	0	0	1	0	0	0	1
...
...
420	A18	0	1	0	1	0	0	0	0	1	0	0

Çizelge 6.10. incelendiğinde 18 nolu arızanın iki nolu arıza kaydında {S181,S182,S1810 } yedek parçalarının beraber tüketildiği görülür.

Çizelge 6.11’de görüldüğü gibi minimum % 40 destek değerinde {S181,S186} yedek parça kümesi beraber tüketilmektedir. Minimum destek değeri % 30 olarak gevşetildiğinde üç küme daha eklenmektedir. Bu eklenen kümelerle birlikte minimum destek değerini sağlayan dört küme içinden öge sayısı fazla ve yüksek destek değerine sahip olan {S181,S184,S185} yedek parça kümesi seçilir. Öge sayısı aynı ise yüksek destek değerine sahip olan küme seçilir. Öge sayısı fazla olan kümenin seçilme nedeni arıza anında parça bulunmama olasılığını azaltmaktır. Yani maksimum kapsama (Maximum coverage) sağlamaktır.

Çizelge 6.11. 18 nolu arıza sık kullanılan yedek parça kümeleri

Arıza Tipi	Yedek parça grupları	Destek (%)
A18	S181,S186	42,84*
	S184,S185	38,45
	S181,S184,S185	35,5
	S181,S185,S186	30,65

Çizelge 6.12’ de 23, 16 ve 4 nolu arızalarda kullanılan parçalar ve stok kodları gösterilmektedir. İşletmenin veri politikası nedeniyle parça isimlerinin tamamı Çizelge 6.12. ’de gösterilmemiştir.

Çizelge 6.12. 23,16 ve 4 nolu arızaların yedek parçaları ve kodları

Arıza Tipi	Stok Kodu	Yedek parça ismi
A23	S231	Devir okuyucu sensör
	S232	*
	S233	*
	S234	*
	S235	Karter hareket sensörü
	S236	Retarder Müşürü
	S237	*
	S238	*
	S239	Küresel rulman yatak
	S2310	Şanzıman iç yağ borusu
	S2311	Şanzıman yağ filtre elemanı
	S2312	*
	S2313	*
A16	S161	Kablo demet kiti
	S162	*
	S163	Turbo Sensörü
	S164	İndüksiyon Bobini
	S165	*
	S166	*
	S167	Wastegate-7 CNG S300
	S168	İç disk
A4	S41	Retarder hava ventil
	S42	Dış disk
	S43	*
	S44	Düz rakor
	S45	CNG Retarder Kolu
	S46	*
	S47	*
	S48	Hava kurutucu soket
	S49	Hava müşürü
	S410	Basınç Şalteri
	S411	Kilometre müşürü

Çizelge 6.13’de 23 nolu arızanın 356 adet arıza kaydına ait yedek parça tüketim bilgileri verilmiştir.

Çizelge 6.13. 23 nolu arıza yedek parça tüketim verileri

No	Arıza tipi	Yedek Parçalar												
		S231	S232	S233	S234	S235	S236	S237	S238	S239	S2310	S2311	S2312	S2313
1	A23	1	0	0	1	0	1	0	1	0	0	0	0	1
2	A23	0	0	1	0	0	1	0	1	0	0	1	0	1
3	A23	1	1	0	1	0	1	0	1	0	0	0	0	0
4	A23	0	0	1	0	0	1	1	1	0	0	0	1	1
5	A23	0	0	1	1	0	1	0	1	0	1	1	0	0
6	A23	1	1	0	0	0	0	0	1	0	0	0	0	0
...
356	A23	0	0	1	0	1	0	0	0	1	0	1	0	0

Çizelge 6.13. incelendiğinde 23 nolu arıza kayıtları içerisinde bir nolu arıza kaydında {S231,S234,S236,S238, S2313} yedek parçalarının beraber tüketildiği görülür.

Çizelge 6.14’de görüldüğü gibi minimum % 40 destek değerinin üzerinde üç tane yedek parça grubu vardır. Bunlar arasında kümelerdeki öge sayısı fazla olan küme seçilir. %42,53 destek değeri ile {S231,S234,S2310} yedek parçaları beraber tüketilmektedir. Minimum destek değeri % 30 olarak gevşetildiğinde dört küme daha eklenmektedir. Bu eklenenlerle birlikte minimum destek değerini sağlayan yedi küme içinden öge sayısı fazla olan {S231,S234,S2310,S2311,S2313} yedek parça kümesi seçilir.

Çizelge 6.14. 23 nolu arıza sık kullanılan yedek parça kümeleri

Arıza Tipi	Yedek parça grupları	Destek (%)
A23	S231,S234	55,22
	S2310,S2311	54,46
	S231,S234,S2310	42,53*
	S234,S2310,S2311	32,81
	S231,S234,S2310,S2311	32,27
	S234,S2310,S2311,S2313	31,29
	S231,S234,S2310,S2311,S2313	30,48

Çizelge 6.15’de 16 nolu arızanın 394 adet arıza kaydına ait yedek parça tüketim bilgileri verilmiştir.

Çizelge 6.15. 16 nolu arıza yedek parça tüketim verileri

No	Arıza tipi	Yedek Parçalar							
		S161	S162	S163	S164	S165	S166	S167	S168
1	A16	0	1	0	0	1	0	0	0
2	A16	0	1	1	0	0	0	1	0
3	A16	1	0	0	0	1	0	1	0
4	A16	0	0	1	0	0	1	0	0
5	A16	0	0	1	0	0	1	0	0
6	A16	1	1	0	0	1	0	0	0
...
394	A16	1	0	0	0	1	1	0	0

Çizelge 6.15 incelendiğinde 16 nolu arıza kayıtları içerisinde bir nolu arıza kaydında {S162,S165} yedek parçalarının beraber tüketildiği görülür.

Çizelge 6.16’da görüldüğü gibi minimum % 40 destek değerinin üzerinde üç tane yedek parça grubu vardır. Bunlar arasında kümelerdeki eleman sayısı fazla olan küme seçilir. %40,21 destek değeri ile {S162,S163,S165} yedek parça kümesi beraber tüketilmektedir. Minimum destek değeri % 30 olarak gevşetildiğinde iki küme daha eklenmektedir. Bu kümelerle birlikte minimum destek değerini sağlayan beş küme içinden öge sayısı fazla olan {S161,S162,S163,S165} yedek parça kümesi seçilir. Öge sayısı aynı olan birden fazla küme var ise yüksek destek değerine sahip olan küme seçilir.

Çizelge 6.16. 16 nolu arıza sık kullanılan yedek parça kümeleri

Arıza Tipi	Yedek parça grupları	Destek (%)
A16	S162,S165	45,47
	S161,S162	42,73
	S162,S163,S165	40,21*
	S161,163,S165	38,35
	S161,S162,S163,S165	34,89

Çizelge 6.17’de 4 nolu arızanın 410 adet arıza kaydına ait yedek parça tüketim bilgileri verilmiştir.

Çizelge 6.17. 4 nolu arıza yedek parça tüketim verileri

No	Arıza tipi	Yedek Parçalar										
		S41	S42	S43	S44	S45	S46	S47	S48	S49	S410	S411
1	A4	1	0	0	1	0	0	1	0	0	1	0
2	A4	0	0	1	0	0	1	1	0	0	0	0
3	A4	0	0	1	1	0	1	0	0	0	0	0
4	A4	0	1	1	0	0	0	1	1	1	0	0
5	A4	0	1	0	1	0	1	0	0	0	0	0
6	A4	1	0	0	0	0	0	1	1	0	0	0
...
410	A4	0	0	0	0	1	0	1	0	0	1	1

Çizelge 6.17 incelendiğinde 4 nolu arıza kayıtları içerisinde 410 nolu arıza kaydında {S45,S47,S410, S411} yedek parçaların beraber tüketildiği görülür.

Çizelge 6.18’de görüldüğü gibi minimum % 40 destek değerinin üzerinde altı tane yedek parça grubu vardır. Bunlar arasında kümelerdeki öge sayısı fazla olan küme seçilir. %40,47 destek değeri ile {S41,S47,S48,S410} yedek parça kümesi seçilir. Minimum destek değeri % 30 olarak gevşetildiğinde iki küme daha eklenmektedir. Bu kümeler içinde minimum destek değerini sağlayan sekiz küme içinde öge sayısı fazla olan {S41,S47,S48,S410,S411} yedek parça kümesi seçilir.


Çizelge 6.18. 4 nolu arıza sık kullanılan yedek parça kümeleri

Arıza Tipi	Yedek parça grupları	Destek (%)
A4	S41,S49	50,21
	S47,S48	48,97
	S49,S410	46,65
	S41,S48,S49	44,23
	S45,S47,S48	42,85
	S41,S47,S48,S410	40,47*
	S47,S48,S49,S410	33,35
	S41,S47,S48,S410,S411	30,85

6.6. Sıralı Örüntü Kuralları ile Sık (Bağımlı) Yedek parça Gruplarının Entegrasyonu


Her arızaya özel bağımlı yedek parçalar belirlendikten sonra son olarak arıza sıralı örüntüleri ile bağımlı yedek parçalar eşleştirilmiştir.

Şekil 6.5.'de minimum % 10 destek seviyesinde elde edilen sıralı örüntülerden çıkarılan kural ve minimum % 40 destek ile bu kuralda yer alan arızalarda sık kullanılan (bağımlı) yedek parçalar görülmektedir. Kural daha önceden bahsedildiği gibi A31 arızası gerçekleştikten sonraki 30.000 km içinde A18 arızası gerçekleşeceğini ifade eder. Kuralın destek değeri % 35,17'dir. Minimum destek değerini sağlamıştır. A31 arızası meydana geldiğinde % 46,15 destek değeri ile {S317,S318} parçaları bakım için kullanılacaktır. A18 arızası meydana geldiğinde % 42,84 destek değeri ile {S181,S186} parçaları bakım için kullanılacaktır.



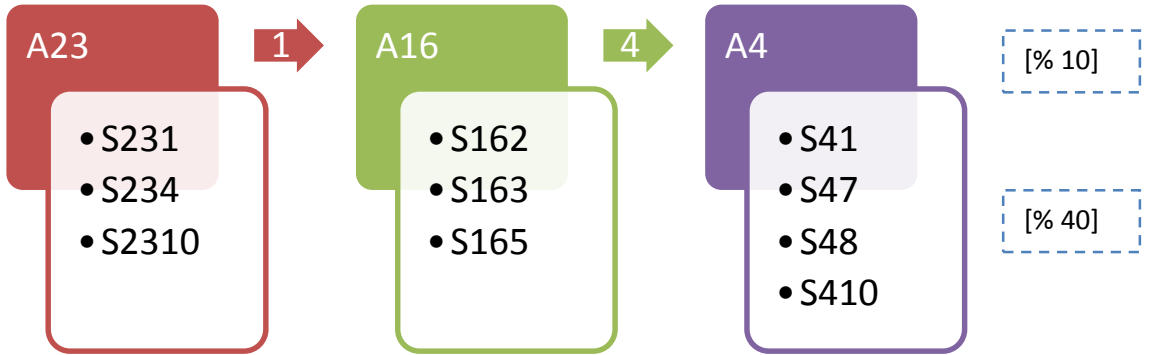
Şekil 6.5. Arıza örüntüleri ve Yedek parça grupları (%10-%40)

Şekil 6.6.'da minimum % 10 destek seviyesinde elde edilen sıralı örüntülerden çıkarılan kural ve minimum % 30 destek ile bu kuralda yer alan arızalarda sık kullanılan (bağımlı) yedek parçaları görülmektedir. Kural daha önceden bahsedildiği gibi A31 arızası gerçekleştikten sonraki 30.000 km içinde A18 arızası gerçekleşeceğini ifade eder. Kuralın destek değeri % 35,17'dir. Minimum destek değerini sağlamıştır. A31 arızası meydana geldiğinde % 34,74 destek değeri ile {S315,S317,S318} parçaları bakım için kullanılacaktır. A18 arızası meydana geldiğinde % 35,5 destek değeri ile {S181,S184,S185} parçaları bakım için kullanılacaktır. Bağımlı parçalar için destek değeri gevşetildiğinde yeni parçaların kümeye dahil olduğu veya var olan parçaların çıktığı durumlar görülebilir. Örneğin; A31 arızasında yedek parça kümeleri için destek değerinin % 30 yapılarak gevşetilmesi ile {S315} parçası kümeye dahil olmuştur.



Şekil 6.6. Arıza örüntüleri ve Yedek parça grupları (%10-%30)

Şekil 6.7’da minimum % 10 destek seviyesinde elde edilen sıralı örüntülerden çıkarılan kural ve minimum % 40 destek ile bu kuralda yer alan arızalarda sık kullanılan (bağımlı) yedek parçalar görülmektedir. A23 arızası gerçekleştikten sonraki 30.000 km içinde A16 arızası gerçekleşeceğini, ardından A16 arızasının gerçekleştiği km’den sonra ki 60.001-90.000 km aralığı içinde A4 arızasının gerçekleşeceğini ifade eder. Kuralın destek değeri % 17,42’dir. Minimum destek değerini sağlamıştır. A23 arızası meydana geldiğinde % 42,53 destek değeri ile {S231,S234,S2310} parçaları bakım için kullanılacaktır. A16 arızası meydana geldiğinde % 40,21 destek değeri ile {S162,S163,S165} parçaları bakım için kullanılacaktır. A4 arızası meydana geldiğinde % 40,47 destek değeri ile {S41,S47,S48,S410} parçaları bakım için kullanılacaktır.



Şekil 6.7. Arıza örüntüleri ve Yedek parça grupları (%10-%40)

Şekil 6.8’de minimum % 10 destek seviyesinde elde edilen sıralı örüntülerden elde edilen kural ve minimum % 30 destek ile bu kuralda yer alan arızalarda sık kullanılan (bağımlı) yedek parçalar görülmektedir. A23 arızası gerçekleştikten sonraki 30.000 km içinde A16 arızası gerçekleşeceğini, ardından A16 arızasının gerçekleştiği km’den sonraki 60.001- 90.000 km aralığı içinde A4 arızasının gerçekleşeceğini ifade eder. Kuralın destek değeri % 17,42’dir. Minimum destek değerini sağlamıştır. A23 arızası meydana geldiğinde % 30,48 destek değeri ile {S231,S234,S2310,S2311,S2313} parçaları bakım için kullanılacaktır. A16 arızası meydana geldiğinde % 34,89 destek değeri ile {S161,S162,S163,S165} parçaları bakım için kullanılacaktır. A4 arızası meydana geldiğinde % 30,85 destek değeri ile {S41,S47,S48,S410,S411} parçaları bakım için kullanılacaktır. Bağımlı parçalar için destek değeri gevşetildiğinde yeni parçaların kümeye dahil olduğu veya var olan parçaların çıktığı durumlar görülebilir. Örneğin; A23 arızasındaki yedek parça kümeleri için destek değerinin % 30 yapılarak gevşetilmesi ile {S2311,S2313} parçaları kümeye dahil olmuştur. Yine A16 arızasındaki yedek parça kümeleri için destek değerinin % 30 yapılarak gevşetilmesi ile {S161} parçası kümeye dahil olmuştur.



Şekil 6.8. Arıza örüntüleri ve Yedek parça grupları (%10-%30)

Arıza örüntüleri ve sık kullanılan yedek parça kümelerinin birleştirilmesiyle bir sonraki arıza ve arızada kullanılabilecek yedek parça kümeleri hakkında değerli bir bilgi sağlanmış olur.

7. SONUÇ VE ÖNERİLER

Günümüzde kaynak kullanımının planlanması en önemli etkinlik ve verimlilik artırıcı yollardan biridir. Yöneticilerin bu planlamaları yaparken karar alabilmesi için sistemi iyi tanımaları ve problemlerle ilgili teknik bilgilere sahip olmaları gerekir. Her sistemde var olan ve performansı mali ve zaman boyutunda etkileyen bakım onarım sürecinin de etkin ve verimli idaresi gerekmektedir.

Bu tez çalışmasında bir otobüs filosundaki şanzıman arızaları ve sebep oldukları kaynak kullanımının azaltılması, bir sonraki arızanın tahmin edilebilmesi ve etkin yedek parça yönetimi için veri madenciliği tekniği kullanan bir yaklaşım geliştirilmiştir. Filoda hangi şanzıman arızaları arasında sıralı ilişki olduğu ve bu arızalarda hangi yedek parçaların sıklıkla kullanıldığı ve bir sonraki arızanın tahminiyle farklı yönetim seviyelerine destek sağlayan modeli tasarlamak amaçlanmıştır.

Çalışma sonucunda şanzıman verileri üzerinden arızalar arasında 45 adet sıralı örüntü elde edilmiştir. Sıralı örüntüler incelendiğinde 12 tanesinin tekli, 22 tanesinin ikili ve 11 tanesinin üçlü örüntü olduğu gözlenmiştir. İkili ve üçlü sıralı örüntüler arasından en yüksek destek değerine sahip iki örüntü seçilerek bir sonraki arızayı tahmin etmek için kurallar geliştirilmiştir. Elde edilen kurallar test verisi ile geçerliliği kontrol edildiğinde %75,45 ve % 63,46 doğruluk oranına sahip olduğu görülmüştür. Arızalarda kullanılan yedek parçaların sıklığı incelendiğinde seçilen minimum % 30 ve % 40 destek değerlerini sağladığı gözlenmiştir. Kurallar ve sık kullanılan (bağımlı) yedek parçaların birleştirilmesiyle bir sonraki arıza ve arızada kullanılacak yedek parçalar hakkında bakım yöneticilerinin karar vermesine yardımcı olacak değerli bir bilgi sağlanmıştır.

Gerçek hayatta uygulanabilirliği olan çalışma, alt arıza tipleri arasındaki ilişkileri araştırması ve kritik yedek parçaları belirlemesi özellikleriyle literatüre metot olarak ve bakım onarım birimlerine çözüm yöntemi olarak katkı sağlamaktadır. Ayrıca çalışmanın diğer sektörler ve ilgili alanlardaki bakım onarım birimlerinde de uygulanabilir olması da önemini ve sürdürülebilirliğini arttırmaktadır. Bakım onarım birimleri bu çalışma sonuçlarından faydalanarak arıza örüntülerinden hareketle arızaların kök sebeplerini araştırarak arıza sayılarının azalmasına katkı sağlayabilir. Arızalarda sıklıkla kullanılan yedek parçalar için emniyet stok politikaları geliştirilebilir. Ayrıca bu yedek parçalar için ortak stok yenileme ve talep tahmini çalışmaları yapılabilir. Depo yönetiminde ise sık kullanılan (bağımlı) yedek parçalar bilgisi ile yerleşim düzenlemesi, raf tasarımı ile parça arama, bulma sürelerinde

iyileştirme sağlanabilir. Ek olarak, arızaların birbirleri ile ilişkisi tespit edilemezse bile öncül arıza gerçekleştiğinde ardıl arıza için düzeltici bakım planlanabilir. Sonuç olarak; arıza ve arızanın neden olduğu dolaylı/dolaysız maliyetlerde azalma sağlanabilir.

Bundan sonraki çalışmalarda, benzer uygulama yerleri için araçların yaş, çalıştıkları bölge ve coğrafya bilgileri vb. verilerinden hareketle sınıflandırma yapıp, farklı sıralı örüntüler elde edilebilecektir. Ayrıca sık kullanılan (bağımlı) yedek parçalara miktar bilgisi eklenebilecek olup arızaların önem derecesine göre ağırlıklandırılması düşünülebilir. Çalışma konusunun seçimine yönelik arıza sınıflarında yer alan destek değerleri incelenerek kararlaştırılması önemlidir. Her ne kadar bu konuda bilgi sistemlerindeki verilerden faydalanacak olsa da insan kaynaklarının öngörülerini de burada kritik öneme sahiptir. Diğer bir ifadeyle çalışmanın yapılacağı arıza sınıfının seçilmesinde dikkat edilmesi gereken nokta, işletmedeki mavi ve beyaz yaka çalışanlarla toplantılar yaparak onların tecrübe ve öngörülerinden faydalanarak arıza sınıfı seçimi yapılması olacaktır.

KAYNAKLAR

Akpınar, H., Veri Tabanlarında Bilgi Keşfi ve Veri Madenciliği. İ.Ü. İşletme Fakültesi Dergisi. 29 (1), 1-22, 2000.

Algı, M., Veri madenciliğinde karar ağaçları, <https://www.mshowto.org/veri-madenciliginde-karar-agaclari.html> . (Erişim tarihi: 28.06.2021)

Atlı, M.A., Veri madenciliği teknikleri yardımıyla baz istasyonu arızalarının tahmin edilmesi. Yüksek Lisan Tezi, Bahçeşehir Üniversitesi, İstanbul, 2019

Aydinel, Y., Investigating causal relationship among lean maintenance factors using fuzzy dematel method. Yüksek Lisan Tezi, Yaşar Üniversitesi, İzmir, 2020.

Ayres, J., Flannick, J., Gehrke, J., Yiu, T., Sequential pattern mining using a bitmap representation.. Proceedings of ACM SIGKDD. 02, 429-435, 2002.

Aytaç, E.B., Bilgin T.T., Sıralı örüntü madenciliği yöntemi kullanılarak internet bankacılığı kullanıcı davranışlarının modellenmesi. XVI. Akademik Bilişim Konferansı. 33-40, 2014.

Azevedo, P.J. and Jorge, A.M., Comparing rule measures for predictive association rules, Machine Learning: ECML. 4701,510-517, 2007.

Bülbül, P., An integrated model for preventive maintenance and spare part inventory planning. Yüksek Lisan Tezi, Orta Doğu Teknik Üniversitesi, Ankara, 2014.

Cemaloğlu, N., Duykuluoğlu A., Sosyal bilimlerde veri madenciliği. Pegem Akademi, Ankara, 2020.

Ceementine (2002), Users Guide, 45.

Corder, A.S., Maintenance Management Techniques. Mc-graw Hill, London, 1976.

Çakır, H.D., Otomotiv yan sanayinde güven odaklı bakım. Yüksek Lisan Tezi, İstanbul Ticaret Üniversitesi, İstanbul, 2019.

Çelik, B., Mekanik arızaların veri madenciliği apriori ile analiz edilmesi. Yüksek Lisan Tezi, Kocaeli Üniversitesi, Kocaeli, 2019.

Djatna, T. and Alitu, I.M., An application of association rule mining in total productive maintenance strategy: an analysis and modelling in wooden door manufacturing industry. Proceedings of International Conference on Industrial. Engineering and Service Science. 336-343, 2015.

Erbaş, M.A., Bir bakım organizasyonunda stok yönetimi optimizasyonu ve bakım planlaması ile entegre edilmesi üzerine bir uygulama. Yüksek Lisan Tezi, İstanbul Sabahattin Zaim Üniversitesi, İstanbul, 2018.

Gedikli, T.,Pisagor bulanık topsis ve bulanık topsis yöntemleri ile en uygun bakım stratejisinin seçimi: Bir gıda işletmesinde uygulama. Yüksek Lisan Tezi, Konya Gıda ve Tarım Üniversitesi, Konya, 2019.

Gholamy A., Kreinovich, V., Kosheleva, O., Why 70/30 or 80/20 relation between training and testing sets: A pedagogical explanation, Int. J. Intell. Technol. Appl. Stat., 11: 105-111, 2018.

Güner, G.G., Çok kriterli bir önleyici bakım yaklaşımı ve bir kamyon ve otobüs şirketinin satış sonrası servisinde uygulanması. Yüksek Lisan Tezi, Hacettepe Üniversitesi, Ankara 2019.

Han, H. K., Kim, H. S., Sohn, S. Y., Sequential association rules for forecasting failure patterns of aircrafts in Korean airforce.. Expert systems with applications. 36(2), 1129-1133, 2009.

Han, J., Pei, J., ve Kamber, M., Data mining: concepts and techniques. Elsevier, 2011.

Han, J. and Kamber, M., Data Mining: Concepts and Techniques, Morgan Kaufmann Publishers. 227-284, 2006.

Hirate, Y. and Yamana, H., Generalized sequential pattern mining with item intervals. Journal of Computers, University of Illinois at Urbana-Champaign.,1 (3):51-60, 2006.

Karabağ, K., Süreç yönetimi ile bakım performansının iyileştirilmesi ve otomotiv sanayinde bir uygulama. Yüksek Lisan Tezi, Dokuz Eylül Üniversitesi, İzmir , 2017.

Karalök, S.S., Alternatif sosyal katmanların bilişsel alışveriş sepetlerinin veri madencili ile incelenmesi ve uygulanması. Yüksek Lisan Tezi, Kırıkkale Üniversitesi, Kırıkkale, 2019.

Karlı, A.B., Nicel değerli veri kümelerinden sıralı örüntülerin çıkarılması için Fp-growth tabanlı bir yöntem. Yüksek Lisan Tezi, Fırat Üniversitesi, Elazığ, 2010.

Kılıçay, D. Bakım sistemlerinde envanter yönetimi. Yüksek Lisan Tezi, İstanbul Teknik Üniversitesi, İstanbul, 2005.

Kokoç, M., Acil servis yerleşim planlamasında veri madenciliği yaklaşımı: Kırıkkale Üniversitesi Tıp Fakültesinde bir uygulama. Yüksek Lisan Tezi, Kırıkkale Üniversitesi, Kırıkkale, 2017.

Köksal, M., Bakım planlaması. Seçkin Yayıncılık, 2015.

Lasiritaworn, W.S., Singtorn, N., Tapeng, P., Spare parts storage improvement with association rules. Proceedings of the World Congress on Engineering and Computer Science. (2): 19-21, 2016.

Maquee, A., Shojaie, A. A., Mosaddar, D., Clustering and association rules in analyzing the efficiency of maintenance system of an urban bus network.. International Journal of System Assurance Engineering and Management. 3(3), 175-183, 2012.

Moharana, U. C., Sarmah, S. P., Rathore, P. K., Application of data mining for spare parts information in maintenance schedule: a case study. Journal of Manufacturing Technology Management. 30(7),1055-1072, 2019.

Moharana, U. C., Sarmah, S. P., Determination of optimal kit for spare parts using association rule mining.. International Journal of System Assurance Engineering and Management. 6(3), 238-247, 2015.

Moharana, U.C. and Sarmah, S.P., Joint replenishment of associated spare parts using clustering approach. *International Journal of Advanced Manufacturing Technology*. 94 (5–8,):2535-2549, 2018.

Mokfi, T., Almaeenejad, M., Sedighi, M. M., A data mining based algorithm to enhance maintenance management: a medical equipment case study. In *2011 First International Conference on Informatics and Computational Intelligence*,4-80, 2011.

Özdoğan, A., *Bakım Parametrelerine Dayalı Üretim Politikaları Optimizasyonu*. Çukurova Üniversitesi, Adana, 2011.

Özkan, Y., *Veri Madenciliği Yöntemleri.. Papatya Yayıncılık , İstanbul, 2008*.

Pei, J., Han, J., Mortazavi-Asl, B., Pinto, H., Chen, Q., Dayal, U, Hsu, M.-C., PrefixSpan: mining sequential patterns efficiently by prefix-projected pattern Growth. *Proceedings of IEEE ICDE'01*. 215-224, 2001.

Rachburee N., Arunrek J., Punlumjeak W., *Failure Part Mining Using an Association Rules Mining by FP-Growth and Apriori Algorithms: Case of ATM Maintenance in Thailand*,. *IT Convergence and security*, 2017.

Srikant, R., Agrawal, R., Mining sequential patterns: Generalizations and performance improvements. In *International conference on extending database technology*. 1-17, 1996.

Turna, F., *Veri madenciliği teknikleriyle tramvay arıza kayıtlarından kural çıkarımı*. Yüksek Lisans Tezi, Erciyes Üniversitesi, Kayseri, 2011.

Xiao, S., Hu, Y., Han, J., Zhou, R., Wen, J., Bayesian networks-based association rules and knowledge reuse in maintenance decision-making of industrial product-service systems.. *Procedia Cirp*. 47, 198-203, 2016.

Yıldız, M.,Ş., *Güç transformatörlerinde K-ortalama kümeleme yöntemi ile bakım-onarım stratejilerinin belirlenmesi*. Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi, İstanbul, 2017.

Zaki, M., An efficient algorithm for mining frequent sequences. *Machine Learning*. 40, 31-60, 2000.