

Fabrika Ortamındaki Otonom Taşıyıcı Araçlar için
Durumsal Farkındalık Yöntemi Geliştirilmesi

Elif Değirmenci

YÜKSEK LİSANS TEZİ

Bilgisayar Mühendisliği Anabilim Dalı

Mayıs 2019

Developing Situational Awareness Method for
Autonomous Transport Vehicle in Factory Environments

Elif Değirmenci

MASTER OF SCIENCE THESIS

Department of Computer Engineering

May 2019

Fabrika Ortamındaki Otonom Taşıyıcı Araçlar için
Durumsal Farkındalık Yöntemi Geliştirilmesi

Elif Değirmenci

Eskişehir Osmangazi Üniversitesi
Fen Bilimleri Enstitüsü
Lisansüstü Yönetmeliği Uyarınca
Bilgisayar Mühendisliği Ana Bilim Dalı
Bilgisayar Bilimleri Bilim Dalında
YÜKSEK LİSANS TEZİ
Olarak Hazırlanmıştır.

Danışman: Doç. Dr. Ahmet Yazıcı

Bu tez TUBİTAK tarafından "116E731" no'lu projesi kapsamında desteklenmiştir.

Mayıs 2019

ONAY

Bilgisayar Mühendisliđi Anabilim Dalı Yüksek Lisans öđrencisi Elif Deđirmenci'nin YÜKSEK LİSANS tezi olarak hazırladıđı “Fabrika Ortamındaki Otonom Taşıyıcı Araçlar için Durumsal Farkındalık Yöntemi Geliştirilmesi” başlıklı bu çalışma, jürimizce lisansüstü yönetmeliđin ilgili maddeleri uyarınca deđerlendirilerek oybirliđi ile kabul edilmiřtir.

Danışman : Doç. Dr. Ahmet Yazıcı

İkinci Danışman : --

Yüksek Lisans Tez Savunma Jürisi:

Üye : Doç. Dr. Ahmet Yazıcı

Üye : Prof. Dr. Rifat Edizkan

Üye : Dr. Öğr. Üyesi Alper Kürřat Uysal

Fen Bilimleri Enstitüsü Yönetim Kurulu'nun tarih ve
..... sayılı kararıyla onaylanmıřtır.

Prof. Dr. Hürriyet Erřahan
Enstitü Müdürü

ETİK BEYAN

Eskişehir Osmangazi Üniversitesi Fen Bilimleri Enstitüsü tez yazım kılavuzuna göre, Doç. Dr. Ahmet Yazıcı danışmanlığında hazırlamış olduğum “Fabrika Ortamındaki Otonom Taşıyıcı Araçlar için Durumsal Farkındalık Yöntemi Geliştirilmesi” başlıklı YÜKSEK LİSANS tezimin özgün bir çalışma olduğunu; tez çalışmamın tüm aşamalarında bilimsel etik ilke ve kurallara uygun davrandığımı; tezimde verdiğim bilgileri, verileri akademik ve bilimsel etik ilke ve kurallara uygun olarak elde ettiğimi; tez çalışmamda yararlandığım eserlerin tümüne atıf yaptığımı ve kaynak gösterdiğimi ve bilgi, belge ve sonuçları bilimsel etik ilke ve kurallara göre sunduğumu beyan ederim. 27/05/2019

Elif Değirmenci
İmza

ÖZET

Endüstri 4.0 ile beraber akıllı fabrikaların veri üzerinden izlenmesi ve kontrolü öngörülmektedir. Fabrikalardaki anormal durumların insan müdahalesi olmaksızın veri üzerinden akıllı algoritmalar ile tespiti önemli bir ihtiyaçtır. Bu, akıllı fabrikalardaki durumsal farkındalık için de önemlidir. Bu çalışmada fabrika içi lojistikte kullanılabilecek otonom taşıyıcı araçların oluşturduğu trafikteki anomali tespitine yönelik yöntemler önerilmiştir. Geliştirilen yöntem fabrika içi trafik üzerinden anomali tespiti yaptığı için Automatic Guided Vehicle (AGV), forklift, Otonom Taşıyıcı Araç (OTA) vb. fabrika içi araçlar içinde kullanılabilecektir.

Önerilen yöntemde araçların fabrika içindeki hareketleriyle ilgili genel karakteristiğın kavşak bazında pekiştirmeli öğrenme ile öğrenilerek, daha sonra bu karakteristiğe uygun olmayan durumlar tespit edilerek anomali tespiti yapılmaktadır. Yapılan çalışmada kavşaklarla ilgili içeriksel anomali ve topluluk anomali olmak üzere iki durum ele alınmıştır. İlk durumda, kavşağın her bir giriş yönü için çıkış yönlerine ait akış, ortalama hız, yoğunluk vb. içerik bilgileri çok kollu slot makinesi problemi olarak modellenmiş ve öğrenilmiştir. Ardışıl veri kümesi içerisinde mevcut öğrenilen karakteristikte farklı bir içerik verisi olduğunda anomali tespiti yapılmaktadır. İkinci durum olarak, fabrika içerisindeki herhangi bir kavşağın komşu kavşaklardan farklı bir trafik karakteristiği göstermesi durumu topluluk anomalisi olarak ele alınmıştır. Bu çalışmada herhangi bir kavşak için çok kollu slot makinesi ile öğrenilen trafik karakteristiği komşu kavşakların verisi ile karşılaştırılarak anomali tespiti yapılmaktadır. Durumsal farkındalığa yönelik önerilen anomali tespit çalışmaları SUMO ortamındaki akıllı fabrika trafik verisi kullanılarak başarı ile test edilmiştir.

Anahtar Kelimeler: Durumsal farkındalık, akıllı fabrikalar, pekiştirmeli öğrenme, anomali tespiti.

SUMMARY

The monitoring and control of intelligent factories via data is foreseen with the Industry 4.0. Detection of abnormal events in factories by intelligent algorithms over data without human intervention is important. This also helps to develop situational awareness concepts for intelligent factories. In this study, anomaly detection methods are proposed for the traffic in intelligent factories. Since the proposed method developed using the traffic data, it can also be used for various vehicle such as Automatic Guided Vehicle (AGV), forklift, Autonomous Transport Vehicle (ATV) etc. in the factories.

In the proposed method, the general traffic characteristic of the intersection within the factory is learned by reinforcement learning, then anomalies are determined by comparing to the learned characteristic. In the study, contextual anomaly and community anomaly are developed for the intersection. In the first case, the context information for each enter the intersection and the exit directions of the entering direction information such as; flow, average velocity, density, etc. are learned and modeled with the multi armed bandit problem. In the sequential dataset, anomaly detection is made when there is a different context data in the learned characteristic. In the second case, the fact that any intersection in the factory showed a different traffic characteristic than the adjacent intersections was considered as a community anomaly. In this study, a multi-armed bandit problem model is used to learn the characteristic of any intersection, then it is compared with the neighboring intersection. The proposed anomaly detection studies for situational awareness have been successfully tested for the data generated by SUMO environment.

Keywords: Situation awareness, intelligent factories, reinforcement learning, anomaly detection.

TEŐEKKÜR

Tez alıőmam sırasında tım sabırlarıyla ve inanlarıyla beni destekleyen aileme, teknik konuda ve bu sũreteki destekleri iin zlem rnek'e ve her seferinde beni motive eden benimle beraber endiőelene arkadaőlarıma ok teőekkũr ederim.

Bu alıőma, Tũrkiye Bilimsel ve Teknolojik Araőtırma Kurumu'nun (TUBİTAK) 116E731 nolu "Akıllı fabrikalar iin otonom taőıyıcılar ve gerekli insan-makine ve makine-makine arayũzlerinin geliőtirilmeői" projesi tarafından desteklenmiőtir.



İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	vi
SUMMARY	vii
TEŞEKKÜR	viii
İÇİNDEKİLER	ix
ŞEKİLLER DİZİNİ	x
ÇİZELGELER DİZİNİ	xi
SİMGELER VE KISALTMALAR DİZİNİ	xii
1. GİRİŞ VE AMAÇ	1
2. LİTERATÜR ARAŞTIRMASI	3
2.1. Durumsal Farkındalık ve Anomali Tespiti.....	3
2.2. Pekiştirmeli Öğrenme.....	12
2.2.1 Markov karar süreçleri	13
2.2.2 Pekiştirmeli öğrenme çeşitleri.....	14
2.2.3 Çok kollu slot makinesi problemleri	16
2.3. Makine öğrenmesi ile anomali tespiti çalışmaları.....	22
3. MATERYAL VE YÖNTEM	25
3.1. Materyal	25
3.1.1. Akıllı fabrika ortamı.....	25
3.1.3. SUMO benzetim ortamı	27
3.1.4. Python programlama	32
3.2. Yöntem.....	33
3.2.1. Problemin modellenmesi.....	33
3.2.2. Bağlamsal slot makinesi tabanlı anomali tespiti	37
4. BULGULAR VE TARTIŞMA	41
4.1. İçerik Tabanlı Anomali Testi	42
4.2. Kavşaklar Arasındaki Anomali Tespiti.....	48
5. SONUÇ VE ÖNERİLER	51
KAYNAKLAR DİZİNİ	52

ŞEKİLLER DİZİNİ

<u>Sekil</u>	<u>Sayfa</u>
2.1. Durumsal Farkındalık Algısal Modeli.....	5
2.2. Üç Seviyeli Durumsal Farkındalık Modeli	6
2.3. Noktasal Anomali Örneği.....	8
2.4. Anomali Tipleri.....	8
2.5. Bağlamsal Anomali Örneği.....	9
2.6. Anomali Tespiti Yöntemleri Taksonomi.....	9
2.7. Makine Öğrenmesi Yaklaşımları	12
2.8. Pekiştirmeli Öğrenme Modeli	13
2.9. Pekiştirmeli Öğrenme Taksonomi.....	15
3.1. ESOGÜ AFAR-LAB Görseli.....	26
3.2. GAZEBO Sanal Fabrika Ortamı	27
3.3. Fabrika Ortamı SUMO.....	28
3.4. Rotalama Dosyası Örneği.....	29
3.5. Yapılandırma Dosyası Örneği.....	30
3.6. Kavşak Modeli	34
4.1. SUMO Ortamı Örnek Görüntü Görseli Kavşak Numaralandırılması	42
4.2. Birinci Test Sonuçları.....	44
4.3. İkinci Test Sonuçları	45
4.4. Üçüncü Test Sonuçları	46
4.5. Dördüncü Test Sonuçları.....	47
4.6. Beşinci Test Sonuçları.....	48
4.7. Kavşaklar Arası Anomali Tespiti için Odaklanılan Kavşaklar	49
4.8. Topluluk Anomali Tespiti	49

ÇİZELGELER DİZİNİ

<u>Cizelge</u>	<u>Sayfa</u>
3.1. Araç Tipi Özellikleri	29
3.2. Sumo Yol/Şerit bazında trafik verileri	31
3.3. Veri seti ayrıntıları	35
4.1. Kavşak Yön Benzerlikleri	49



SİMGELER VE KISALTMALAR DİZİNİ

<u>Kısaltmalar</u>	<u>Açıklama</u>
AFAR-LAB	Akıllı Fabrika ve Robotik Laboratuvarı
AGV	Automatic Guided Vehicle
ATV	Autonomous Transport Vehicle
BSD	Berkeley Software Distribution
CTR	Click Through Rate
DVM	Destek Vektör Makinesi
GPS	Küresel Yer Belirleme Sistemi (Global Positioning System)
MKS	Markov Karar Süreçleri
NASA	National Aeronautics and Space Administration
OTA	Otonom Taşıyıcı Araç
UCB	Üst Güven Sınırı (Upper Confidence Bound)
SUMO	Kentsel Hareketliliğin Benzetimi (Simulation of Urban Mobilty)

1. GİRİŞ VE AMAÇ

Endüstri 4.0'in 2011 yılında Almanya'nın stratejik yol haritasına girmesi ile üretim süreçlerinin dijitalleşmesi hız kazanmıştır (Zhou vd., 2015). Kagermann vd. (2013) raporunda akıllı fabrikalar, Endüstri 4.0'in anahtar özelliklerinden biri olarak geçmektedir. Akıllı fabrikalarda gerçek zamanlı olarak cihazlar içerisinden, fabrika içerisindeki üretimin durumu hakkında, tedarikçi bilgileri ve malzeme hareketlilikleri için veri odaklı izleme ve kontrol vardır. Bu veri ile üretilen ürünün iş istasyonundan alınıp yükleme noktasına götürülmesi sırasında fabrika içi hareketliliğin izlenerek fabrika içindeki süreçler ile ilgili durumsal farkındalık tanımlanabilir. Durumsal farkındalık, içinde olunan durumun algılanması, anlamlandırılması ve yakın gelecek durumlarının tahminidir (Endsley, 1995). Akıllı fabrikalarda, dijital dönüşüm ile durumsal farkındalığın insan müdahalesi olmaksızın veri üzerinden akıllı algoritmalar ile tespiti önemlidir. Özellikle sistemlerin çalışması sırasında oluşan veya oluşabilecek anomalilerin tespiti durumsal farkındalık için kritik bir konudur. Endüstri 4.0 ile beraber üretim sistemlerinin de otonom sistemlere geçiş ile anomali tespiti iyice ihtiyaç haline gelmiştir.

Literatüre bakıldığında durumsal farkındalık veya anomali tespiti ile ilgili havacılık (Tadema ve Theunissen, 2009; Endsley, 1995), liman (Riveiro vd., 2008), otonom araçlar (McAree vd., 2017), ağ trafiği ve siber güvenlik (Streilein vd., 2011) gibi farklı alanlarda uygulamalara rastlanmaktadır. Limandaki otonom taşıyıcı araçların liman içerisindeki taşıma alanında araçların konumlarıyla ilgili durumsal farkındalık ve anomali tespiti üzerine çalışılmıştır (Riveiro vd., 2008). Otonom araçların trafik içerisinde gelecek konumlarının tahmin edilmesi ile daha güvenli sürüş yapmaları ve gelecekteki konumlarının farkında olunması ile mantıklı rotalamaların yapılması üzerine çalışmalar yapılmıştır (McAree vd., 2017). Diğer taraftan literatürde akıllı fabrikalara yönelik durumsal farkındalık veya anomali tespiti çalışmaları oldukça yenidir (Örnek vd., 2018). Örnek vd., (2018) trafik olay enlem, boylamı, rotası gibi verinin özelliklerine bakılarak anomali tespiti yapmışlardır.

Bu çalışmada akıllı fabrikalarda taşımacılıkta görev alan otonom robotların oluşturduğu trafiğin izlenerek iç lojistik durumsal farkındalığının oluşturulmaktadır. Özellikle fabrika içi taşımacılıkta kavşaklarda farklı nedenlerle oluşacak anormal değişimler veya bazı kavşaklara olan anormal yığılma anomalilerinin tespiti hedeflenmektedir. Çalışmada fabrika içi araç hareketliliğinin karakteristiğini taşıyan kavşakların karakteristiğinin, her bir kavşak bazında kavşağa giriş yönleri ve çıkış yönlerine ait ortalama hız, ortalama işgal süresi, ortalama seyahat süresi gibi yönlerle ait bilgileri kullanarak çok kollu slot makinesi problemi ile öğrenilmesi amaçlanmıştır. Bir kavşağa ait kavşak karakteristiği modeli öğrenilirken, kavşağın yönlerinde oluşabilecek aykırı bir durum içeriksel anomali olarak kaydedilebilmektedir. Fabrika içerisindeki kavşaklara ait karakteristikler öğrenilirken, iki kavşaktan birinde oluşan karakteristiğe uymayan anormal bir durum topluluk anomalisi olarak kaydedilmektedir.

Takip eden bölümde, literatürde durumsal farkındalık, pekiştirmeli öğrenme ve makinesi öğrenmesi ile anomali tespiti ile ilgili çalışmaları anlatılmaktadır. Bölüm 3'te akıllı fabrika ortamı, SUMO benzetim ortamı, python programlama ve tezde kullanılan model ayrıntıları verilmiştir. Bölüm 4'de test için kullanılan veri ve test sonuçları anlatılmıştır. 5. bölümde, tez ile ilgili sonuç ve öneriler anlatılarak tamamlanmaktadır.

2. LİTERATÜR ARAŞTIRMASI

Bu tez çalışmasında izlenen yöntemler ve yöntemlerdeki kavramlar bu başlık altında incelenmiştir. Çalışmada odaklanılan üç ana konu durumsal farkındalık, pekiştirmeli öğrenme ve anomali tespiti olmak üzere başlıklar halinde anlatılmıştır. Bu çalışmada durumsal farkındalık yaklaşımı ile fabrika içerisindeki otonom taşıyıcı araçların oluşturduğu fabrika içi hareketliliğin karakteristiğinin öğrenilmesi, karakteristiği öğrenilmesi için fabrika içi trafik verilerinin pekiştirmeli öğrenme yöntemi ile öğrenilmesi ve bu karakteristiğe aykırı durumların ise anomali tespiti ile kaydedilmesi üzerine çalışılmıştır.

2.1. Durumsal Farkındalık ve Anomali Tespiti

Durumsal farkındalık, olayları anlamak için çevrede bulunan unsurların farkında olunmasıdır. Bu unsurların algılanması, anlamlandırılması ve gelecek durumlarda amaç ve hedefleri nasıl etkileyeceğinin değerlendirilmesi durumsal farkındalığın aşamalarıdır (Endsley, 1995). Durumsal farkındalık, Endüstri 4.0 ile hedeflenen tüm fabrika içerisindeki birimlerin birbirinden haberdar çalışmasının birimler için veya fabrika için gerçekleştirilmesi teorisi içerir. Durumsal farkındalık, otonom taşıyıcı araçların koordineli bir şekilde hareket etmesi, üretim hattındaki bir cihazın ne kadar zaman sonra hata sinyalleri vereceği veya çalışan sistemlerden (otonom araçların, iş istasyonlarının, sensörlerin vb.) gelen verilerin doğruluğunun kavranması, anlamlandırılması ve bahsedilen durumların gelecekteki durumları etkisinin anlaşılması için önemlidir.

Durumsal farkındalık alanında yapılmış birçok çalışma ve bu çalışmalarda durumsal farkındalığın birçok tanımlaması ve modeli vardır. Durumsal farkındalık tanımlamalarından bazıları şöyledir: Emerson vd. (1987) durumsal farkındalığı, mürettebatın, uçağın hem iç hem de dış durumlarının çalıştığı çevre hakkındaki bilgisi olarak tanımlanmaktadır. İç durumları, hidrolik, elektrik ve yakıt gibi sistemlerin çalışır durumlarının kontrolü olarak geçmektedir. Dış durumlar ise tehdit oluşturabilecek durumları, arazinin özelliklerini ve hava durumunu ifade etmektedir. Endsley (1988) durumsal farkındalığın tanımlaması olarak pilotun içinde bulunduğu zamanda çevresindeki dünyanın iç modelidir. Pilotun bireysel yetenekleri, deneyimi, eğitimi ve hedefleri gibi özellikler durumsal farkındalık seviyesini

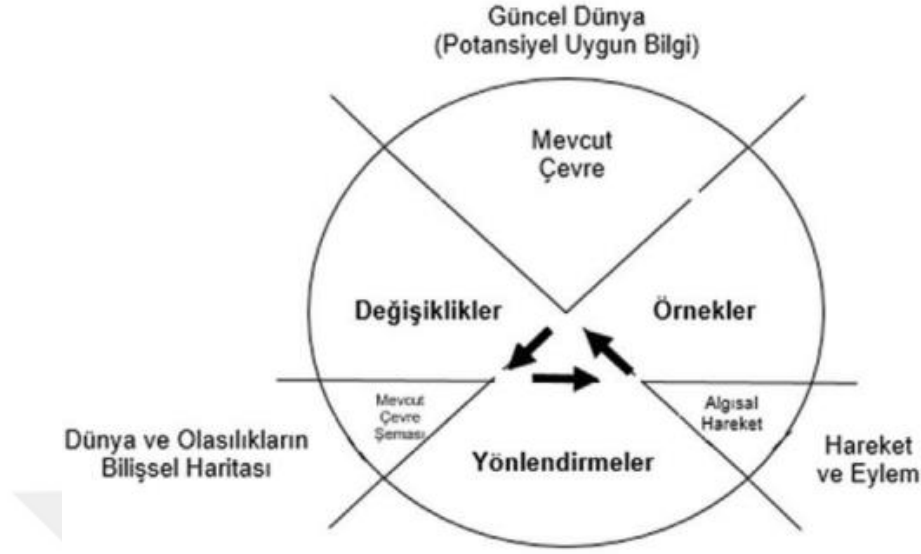
orta seviyede tutan özellikler olarak tanımlanmaktadır. Adam ve Pew (1990) durumsal farkındalık tanımlarını havacılık alanında yapmışlardır. Adam ve Pew (1990)'e göre durumsal farkındalığın farklı düzeyleri olabilir. Bilgi ne kadar fazla olursa durumsal farkındalık düzeyide o derece artmaktadır. Durumsal farkındalık arttıkça pilotun daha güvenli ve ileride olabilecek durumları ön görebilmesinin artacağı düşünülmüştür. Taylor (1990)'a göre durumsal farkındalık, muhtemelen belirsizlik içeren durumlarda, yani gerçekliğin doğrulayıcı bir modelinde uyarlayıcı kararlar almak için gerekli olan bilgi durumu olarak ve görevin güvenli, uygun ve etkin davranışını etkileyen olayların, faktörlerin ve değişkenlerin bilgisi, algı ve öngörüsü olarak tanımlanmıştır. Wickens (1992)'e göre durumsal farkındalık, bir uçuş sırasında gelişen bu özellikleri hızla bilinçlendirmek anlamına gelmesi olarak tanımlamışlardır. Biblings (1995)'e göre durumsal farkındalık değişen bir ortamda çalışan insanlarda gözlemlenen olayların tanımlamasının bir üst gözden soyutlanmasıdır.

Bu tanımlamalardan öne çıkan modellerden ikisi, algısal döngü (Smith ve Hancock, 1995) ve 3 seviyeli durumsal farkındalık (Endsley, 1995) modelleridir.

Smith ve Hancock, (1995)'e göre:

“Durumsal farkındalık, ürünleri dinamik bir ortamı hakkında bilgi sahibi olan ve o ortamda yönlendirilmiş eylem hakkında bilgi sahibi olan, dışa dönük, uyarlamalı bir bilinçtir.”

Smith ve Hancock, (1995), Nieser (1979)'in algısal modelini değiştirerek Şekil 2.1'de ki algısal döngü modelini yayınlamışlardır. Adaptasyon, bir ajanın görev ortamının dayattığı şartlar ve kısıtlamalar tarafından belirlenen hedeflere ulaşmak için bilgi ve davranışını yönlendirdiği süreç olarak değerlendirilmiştir. Bu modelde, durumsal farkındalık zaman içerisinde gelişmeye devam eden bir döngüyü oluşturur.



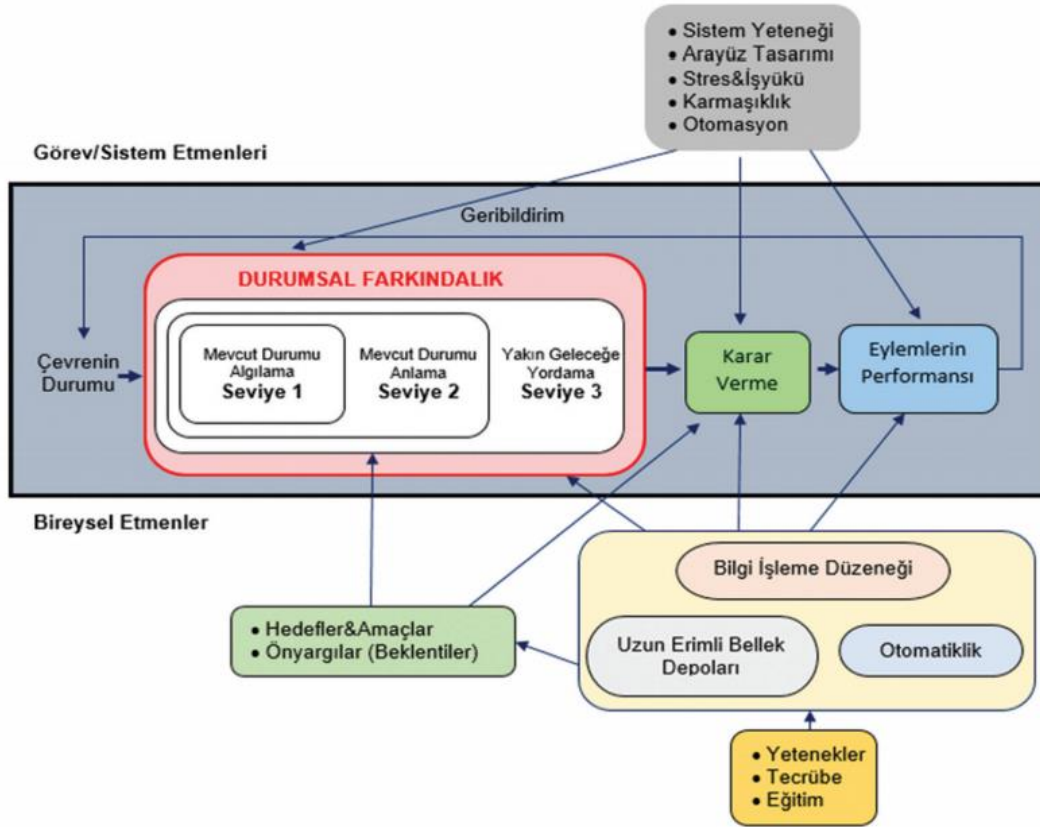
Şekil 2.1. Durumsal Farkındalık Algısal Modeli (Kahraman ve Zorba, 2018)

Öne çıkan bir diğer durumsal farkındalık tanımı Endsley (1995)'dir. Havacılık alanında pilotların hem içsel olarak hem de çevrelerinde olup bitenleri anlamaları üzerine yapılan bir çalışmadır.

Endsley'in (1995) durumsal farkındalık tanımına göre:

“Durumsal farkındalık, içinde olunan durumun algılanması, anlamlandırılması ve yakın gelecek durumlarının tahminidir.”

Endsley (1995) modeline göre durumsal farkındalık üç katmanlı bir yapıdır (Şekil 2.2). İlk katman: Çevrenin modelini oluşturmak için veri toplamak gerekir. Bunun için modelin ilk katmanı çevrenin algılanmasıdır. Bu katmanda ortamdaki öğelerin durumu, özellikleri ve dinamiklerinin algılanmaktadır. İkinci katman: Birinci katmanda algılanan bilgilerin anlamlandırılmasıdır. Mevcut operatörün hedeflerine göre ilgili unsurların öneminin vurgulanması katmanıdır. Üçüncü katman: Sonuncu katman ikinci katmandaki bilgilerin, yapılan eylemlerin gelecek durumlara etkisinin değerlendirilmesidir.




Şekil 2.2. Üç Seviyeli Durumsal Farkındalık Modeli (Kahraman ve Zorba'dan, 2018)

Literatürde farklı alanlara yönelik durumsal farkındalıkla ilgili sistem geliştirmeleri yapılmıştır. Durumsal farkındalık ile ilgili havacılık (Tadema ve Theunissen, 2009; Endsley, 1995), liman (Riveiro vd., 2008; Hyvonen vd., 2014), otonom araçlar (McAree vd., 2017), ağ trafiği ve siber güvenlik (Streilein vd., 2011), sağlık gibi alanlarda uygulamalara rastlanmaktadır.

Bir çalışmada zorlu şartlarda çalışan insanların kişisel koruma donanımlarının akıllı sensörlerle ve ürünlerle donatılarak durumsal farkındalık ile daha yüksek çevre bilinci oluşturulması üzerine çalışılmıştır (Kozlovsky vd., 2015). Burada sensörlerden elde edilen veriler ile ortam ve konum farkındalığı sağlanmıştır, bu verilerin arşivlenmesi kullanıcılar arasında karşılaştırmalı performans analizi veya gerektiğinde geriye dönük durum analizi yapılmıştır (Kozlovsky vd., 2015). Bir başka çalışmada Park vd. (2016) araç içi arttırılmış gerçeklik teknolojisi ile araçlarda durumsal farkındalığın arttırılması üzerine çalışmışlardır. Bu çalışmada arttırılmış gerçeklik tabanlı ekranlar kullanılarak sürücülerin güvenliğinin

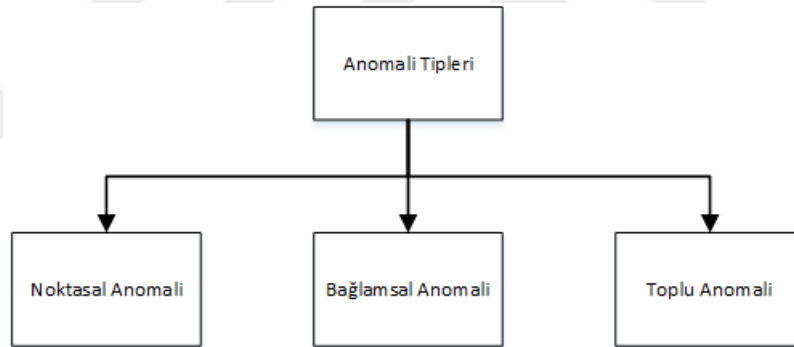
arttırılması için akıllı bir sistem kurulmuştur. Bu sistem sensör, araç ve yaya tanıma, araç durum bilgisi, çarpışma süresi, tehdit değerlendirmesi gibi alt parçalar barındırmaktadır ve sistem arttırılmış gerçeklik donanımlı bir araçta gerçek yol ortamında test edilmiştir. Bir diğer çalışmada Scholtz vd. (2005) kentsel arama ve kurtarma yarışmasında operatörlerin karşılaştığı zorlukların durumsal farkındalık eksikliğinden kaynaklanabileceği üzerine çalışılmıştır. Bunun için durumsal farkındalığın birinci katmanı olan algılama katmanında çalışılmıştır. Laser ve sonar sensörlerini kullanarak çevredeki engellerin algılanması ve robotu alanda iyi bir şekilde yönlendirmek için teknikler analiz edilmiştir. Bir başka çalışmada ise Hyvonen vd. (2014) limanlarda ki mobil araçların durumsal farkındalığı üzerine çalışmıştır. Limanlardaki taşımacılık sırasında birçok mobil araç kullanılır ve bu araçların birbirini göremeyecek konumlarda olması olası bir durumdur. Mobil araçların çalıştığı bu ortamlarda çarpışmanın önlenmesi ve daha güvenli bir ortak çalışma ortamının sağlanması için makineler arası iletişim ile araçların şimdiki konumları bilgisi ile gelecek konumlarının tahmini yapılarak çarpışmaların önlenmesi durumsal farkındalık ile sağlanmıştır. Otonom araçların trafik içerisinde gelecek konumlarının tahmin edilmesi ile daha güvenli sürüş yapmaları ve gelecekteki konumlarının farkında olunması ile mantıklı rotalamaların yapılması üzerine çalışmalar yapılmıştır (McAree vd., 2017).

Üç katmanlı durumsal farkındalık modelinin katmanlarının her birinde ölçülen değerlerin doğruluğunun değerlendirilmesi veya diğer durumsal farkındalık modellerinde durumsal farkındalığın arttırılması geliştirilmesi gerekir. Bu katmanlardaki normal durumların zamanla öğrenilip, katmanlarda oluşabilecek normalden farklı durumların tespit edilmesi anomali tespittir. Anomali tespiti, verinin üzerinden normal davranışın öğrenilmesi veya desenin öğrenilmesi ile buna uymayan durumların tespit edilmesidir (Chandola vd., 2009). Anomali tespiti sistemlerinde veri özelliklerinin tipi uygulanacak yöntemin seçilmesinde önemli bir rol oynayabilir. Özellikler ikili, devamlı ve kategorize gibi olabilirler. Veri karakteristiklerine göre anomaliler genellikle üç gruba ayrılır; nokta anomaliler, bağlamsal anomaliler ve toplu anomaliler (Hayes ve Capretz, 2015) (Şekil 2.3).




Şekil 2.3. Noktasal Anomali Örneği (Chandola'dan, 2009)

Veri setinin tamamına bakıldığında anormal olduğu düşünülen veri noktaları için noktasal anomalileri ortaya çıkarır. Şekil 2.4'de görüldüğü gibi O1, O2 ve O3 noktaları normal (N1) noktalarından farklı olarak gözlemlenir ve noktasal anomaliliye örnektir.



Şekil 2.4. Anomali Tipleri

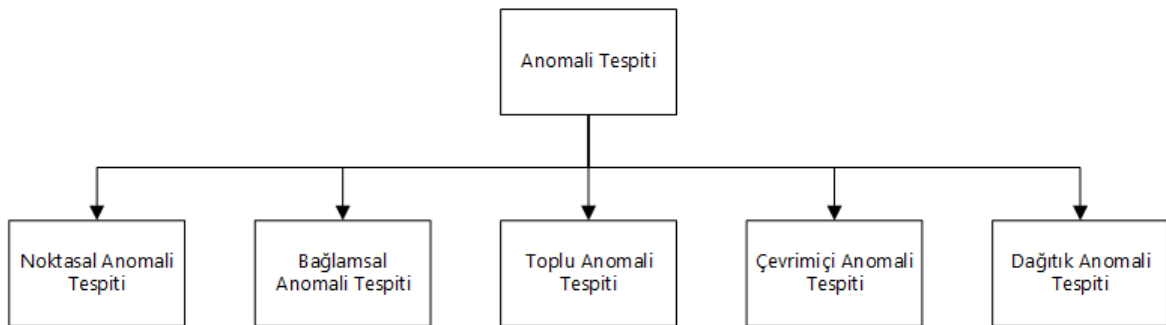
Bağlamsal anomalileri, veri noktalarının meydana geldiği bağlamı ve ilişkilerine bakıldığında anormal sayılan veri noktalarıdır (Şekil 2.5). Kredi kartı dolandırıcılıkları bağlamsal anomalilere örnek verilebilir. Bir hesabın hareketliliği özel günlerde normal harcamalarının üzerine çıkabilmesi anomali olarak kabul edilmezken, normal bir günde hesaptaki hareketliliğin üzerinde bir harcama anomali olarak değerlendirilmektedir.



Şekil 2.5. Bağlamsal Anomali Örneği (Chandola'dan, 2009)

Son olarak, toplu anomaliler, bir veri kümesinde bir grup veri içerisindeki verilerin tek tek gerçekleştiği durumlarda normal gibi görünmesine rağmen toplu olduğunda anomali olarak kabul edilen noktalardır. Bilgisayar ağlarında bir paketin gönderilmesi anormal bir durum değilken bunun hizmet reddi saldırılarında (Ahmed, 2018) kullanılması durumu toplu anomalilere örnek olarak verilebilir.

Anomali tiplerine göre anomalilerin tespit edilme yöntemleri de sınıflara ayrılmıştır. Anomali tespiti için oluşturulan taksonomilerde birçok farklı kategorileştirilme yapılmıştır. Lazerevic vd. sunum çalışmalarında paylaştıkları Şekil 2.6'de ki anomali tespiti taksonomisi uyarlanmıştır. Bu taksonomiye göre anomali tespiti algoritmaları anomalilerin yapısına göre sınıflandırılmıştır. Bunlar; noktasal anomali tespiti, bağlamsal anomali tespiti, toplu anomali tespiti, çevrimiçi anomali tespiti ve dağıtık anomali tespitidir.



Şekil 2.6. Anomali Tespiti Yöntemleri Taksonomi (Lazerevic'den 2019)

Noktasal anomaliler; sınıflandırma, kümeleme, en yakın komşu tabanlı yöntemleri vb. gibi yöntemler ile tespit edilebilirler. Sınıflandırma, etiketli veri setinden bir model çıkarılması ve bu öğrenilen model kullanarak bir test örneğini sınıflardan birine dahil etmek için kullanılır (Chandola vd., 2009). Sınıflandırma tabanlı teknikler; çok sınıflı anormallik saptamalarında sinir ağları tabanlı, bayes ağları tabanlı, destek vektör makineleri tabanlı, normal davranışı tanıyan kuralların oluşturulması ve bu kuralları kapsamayan durumların tespiti için kural tabanlı gibi yaklaşımları vardır. Kümeleme, etiketlenmemiş bir veri setinde kümelenmiş biçimdeki verileri bulmak için kullanılır. Kümeleme tabanlı teknikler ile en yakın komşu tabanlı teknikler birbirine benzer olsa da kümeleme tabanlı yaklaşımların daha hızlı çalıştığı en yakın komşu tabanlı tekniklerde her seferinde en yakın verilere bakılırken, kümeleme tabanlı yaklaşımlarda küme modellerinin örneklerine bakılmaktadır (Chandola vd., 2009).

Bağlamsal anomali tespiti, veri seti içerisindeki verilerin birbirleriyle olan ilişkilerinin iyi tanımlanması ve anlaşılması normal olmayan verininde bu ilişkili yapıya uymaması için kullanılan yöntemler bu anomali tipi tespit etmek için kullanılabilir. Verinin zamana bağlı görüntülenmesi, çalışma günlerinde veya çalışma saatleri dışında, hafta içi veya hafta sonu gibi, bu bilgilere göre verinin karşılaştırılması anomaliyi ortaya çıkarabilir (Hayes ve Capretz, 2015).

Toplu anomali tespiti, anormal olmaya aday durumların veya tek başlarına normal olarak değerlendirilen durumların bir araya geldiklerinde anomaliyi oluşturması gibi durumların tespit edilmesidir. Ardışık anomalilerin tespiti için anormal dizilerin algılanması, mekânsal anomalilerin tespit edilmesi için mekânsal veri setindeki anomali olan alt alanların bulunması, çizge anomalisi için çizge verilerindeki anormal alt-çizgelerin bulunması gibi yaklaşımlar ile anomaliler tespit edilebilir (Lazerevic vd., 2019).

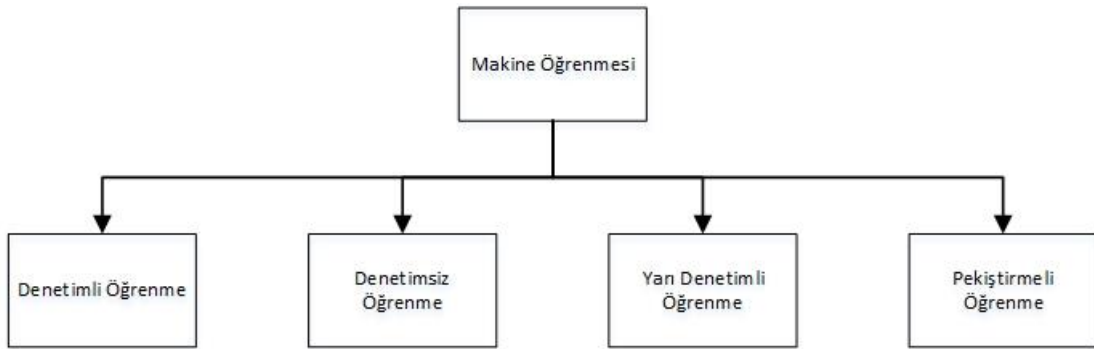
Çevrimiçi anomali tespiti yöntemleri veri akışı olan durumlardaki anomalileri tespiti için kullanılırlar. Bu yöntemler, zaman içinde verinin temel özelliklerinde oluşabilecek durumlara uyum sağlayabilir. Dağıtık anomaliler tespit yöntemleri birden fazla konumda oluşabilecek ve tek bir noktadan tespitinin zor olduğu gibi durumlarda kullanılabilir.

Literatür arařtırmalarında da örneklendirildiđi gibi makine öđrenmesi, pekiřtirmeli öđrenme, durumsal farkındalık gibi yaklařımlarla, sađlık, havacılık, kredi kartı kaçaķçılıđı, bilgisayar ađları, liman trafiđi, deniz, kara ve hava ulařımları gibi alanlarında anomali tespiti ile ilgili çalıřmalar vardır. Sađlık alanında anomali tümörlü bir alanın tespiti iken, havacılık alanında sensörlerden okunan deđerlerin normalden farklı olması veya açaık denizlerde rotası bilinen bir geminin rotasında olmaması durumu anomali olabilir. Wang ve Zhao (2014) çalıřmasında, bir sistem çalıřtırıldıđında alınan tedbirlere rađmen oluřabilecek anormal olayların oluřması ve oluřabilecek sorunların modelleri tanıtılmıřtır, gerçek zamanlı olarak bir güvenlik yönetimi stratejisi belirlenmiřtir ve güvenlik durumunun tespiti, durumun önceliđinin belirlenmesi ve acil müdahale zamanının önemi üzerine çalıřılmıřtır. Bu çalıřamda kavram bir durumsal farkındalık sistemi sunulmuřtur (Wang ve Zhao, 2014). Kara, hava ve deniz alanlarının güvenliđini sađlayan operatörler gelen bilgilerin çokluđu dolayısıyla durumsal farkındalık konusunda sıkıntı yařarlar (Riveiro vd., 2008). Riveiro vd. (2008) çalıřmalarında deniz trafiđindeki bilgilerin geçmiř bilgiler ile birleřimi ve gelecekte oluřabilecek durumların öngörülmesi için çevre farkındalıđının oluřturulması üzerinedir. Bu çalıřmada normal davranıřtan oluřturulan model ile anormal davranıř gösteren deniz tařıtlarının görselleřtirmesi yapılmıřtır. Castaldo vd. (2016) gemi trafiđi ile ilgili kullandıkları sistemde, gemilerin yörünge verilerini kullanarak davranıřların normal veya anormal olduđunun tespiti yapılmıřtır. Alan içerisindeki gemilerin t zamanında nerede oldukları ve bir sonraki t anında nerede olacakları ile ilgili tespitlerde durumsal farkındalık kavramları kullanılmıřtır ve anormal hareket eden gemilerin tespiti sađlanmıřtır (Castaldo vd., 2016). Ađ tehditlerinin üzerine bir çalıřmada hem durumsal farkındalık hem de anomali tespiti üzerine çalıřılmıřtır (Rapuzzi ve Repetto, 2018). Bu çalıřmada, ađ tehditlerinin en aza indirilmesi veya engellemesiyle ilgili zorluklar ele alınmıřtır. Bu konudaki anomali tespiti çalıřmalarında incelenmiřtir (Rapuzzi ve Repetto, 2018). Trafik ađlarındaki anomali tespiti üzerine bir çalıřmada (Özlem vd., 2018) trafik olay enlem, boylamı, rotası gibi verinin özelliklerine bakılarak makine öđrenmesi algoritmaları kullanılarak anomali tespiti yapılmıřtır.

2.2. Pekiştirmeli Öğrenme

Pekiştirmeli öğrenme, doğal öğrenme süreçlerine benzeyen öğrenme karakteristiği ile ortamdaki sürekli değişimin öğrenilme ihtiyacı olduğunda diğer makine öğrenmesi yaklaşımlarına göre daha fazla tercih edilmektedir. Makine öğrenmesi, veri ve bilgi arasındaki temel ilişkileri bağdaştırmak için algoritmalar uygulayan bir daldır (Awad ve Khanna,2015). Makine öğrenmesi, anomali tespitinin diğer yöntemlerine göre daha fazla kaynak tüketimi yapmasına rağmen, önceki öğrenme sonuçlarını ve elde edilen bilgilere bağlı olarak performans ve uygulama stratejisi geliştiren uyarlanabilir bir model oluşturmayı içerir (García-Teodoro vd., 2009).

Makine öğrenmesi yaklaşımları Şekil 2.7’de verildiği gibi denetimli öğrenme, denetimsiz öğrenme, yarı denetimli öğrenme ve pekiştirmeli öğrenme olarak dört gruba ayrılabilir(Moubayed vd., 2018). Denetimli öğrenmede ajan, etiketli bir şekilde verilen girdileri kullanarak öğrenmeyi gerçekleştirmektedir. Denetimsiz öğrenmede ise sadece etiketsiz girdiler bulunur ve ajan, veri yapısını tanımaya çalışmaktadır. Eğitim verisinin tam olarak geri bildirimleri bulundurmadığı durumlarda bu iki öğrenme yaklaşımının birlikte kullanıldığı yarı denetimli öğrenme yaklaşımları da vardır.

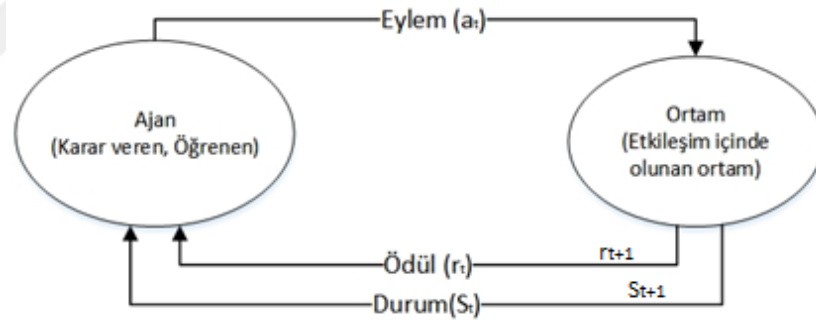


Şekil 2.7. Makine Öğrenmesi Yaklaşımları (Moubayed’den, 2018)

Pekiştirmeli öğrenme, dinamik bir ortamda deneme yanılma yöntemiyle davranışın öğrenilme problemidir (Kaelbling vd., 1996). Denetimli öğrenme etiketli bir eğitim veri seti üzerinden öğrenme gerçekleştirir. Denetimli öğrenmede eğitim veri setinden durumlar örnekler olarak kategorize edilmiş olur ve yeni gelen veri setini bu kategorilere göre doğru kategoriye aktarılır. Etkileşimli bir ortamda her bir durumun için örnek bir durum

bulunmasının zor olacağı durumlarda pekiştirmeli öğrenme kullanılabilir. Bu özelliği ile anomali tespiti gibi anormal verinin az olduğu ortamlarda kullanımını avantajlı hale getirmektedir. Denetimsiz öğrenme etiketsiz veri üzerinden öğrenir. Pekiştirmeli öğrenmede etiketsiz bir veri üzerinden öğreniyor olsa da; denetimsiz öğrenmede ki verinin yapısını öğrenilmesi, pekiştirmeli öğrenme de ise en iyi ödülü vermeye odaklanması konusunda farklılık göstermektedir (Sutton ve Barto, 2017).

Pekiştirmeli öğrenmede, ajan yaptığı eylemler sonucunda bulunduğu çevreden anlık ödül, gecikmeli ödül veya ceza benzeri geri bildirimler almaktadır. Ajan bu ödülleri istenilen seviyeye yani en uygun davranışlara veya en uyguna yakın davranışlara taşıyacak öğrenimi gerçekleştirebilmektedir (Russel ve Norvig, 2003). Ajan bir ortamda, t anında ve s durumunda, a eylemini gerçekleştirerek yeni duruma yani s_{t+1} 'e geçiş sağlamaktadır bu esnada ortamdan geri bildirim olarak R ödülü alır. Şekil 2.8'de bu etkileşim temsili olarak açıklanmaktadır (Sutton ve Barto, 2017).



Şekil 2.8. Pekiştirmeli Öğrenme Modeli

Pekiştirmeli öğrenme, genellikle ortam modeli bileşenleri Markov Karar Süreçleri (MKS) ile modellenir. MKS'de durum, eylem, ödül gibi bileşenlerin pekiştirmeli öğrenme modeli hali Şekil 2.8'de verilmiştir.

2.2.1 Markov karar süreçleri

Durumlar, eylemler, geçiş olasılıkları ve ödül birlikte MKS'leri oluşturmaktadır. MKS şimdiki durum için tüm sonuçların arasından en uygun sonucun bulunmasını sağlayan matematiksel bir çerçevedir.

MKS'leri dört bileşen ile ifade edilebilir:

S : Çevredeki durumların kümesi.

A : Çevreden alınabilecek eylemler kümesi.

T : Geçiş olasılık matrisi $T : S \times A \times S \rightarrow [0, 1]$

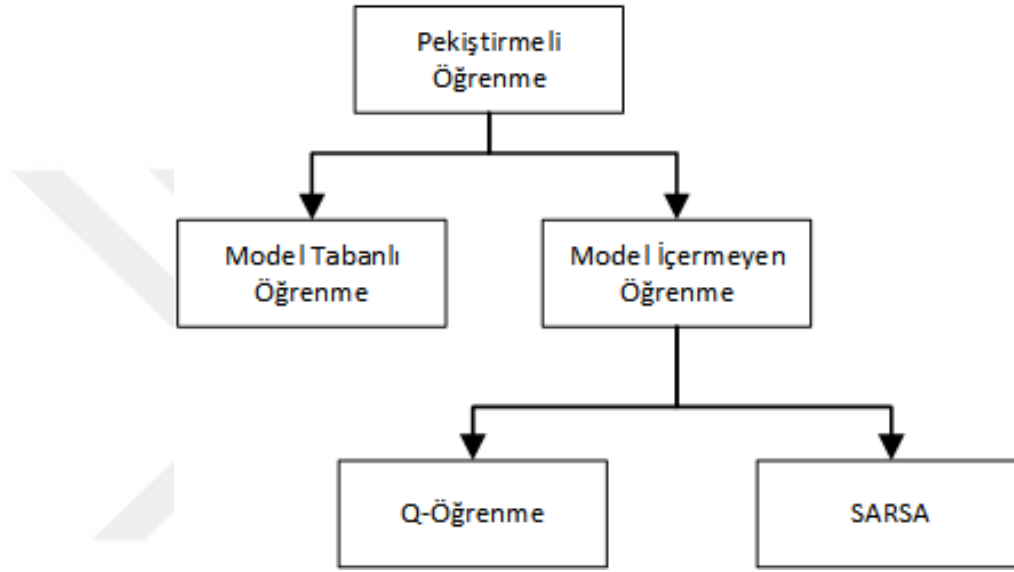
R : Her bir durum için alınan ödül.

MKS'de kararlar sadece şimdiki duruma bağlıdır. Politika, durumlar için hangi eylemin seçileceği politikaya göre belirlenir. MKS'de politika, en uygun sonucu bulmasıdır. Eylem-değer fonksiyonları, durumlarda yapılan eylem ve bir sonraki eylem için alınan ödüllerin hesaplarının tablosudur. Bu tabloda, alınan en iyi ödüller politikayı belirler. Eylem değer tablosu ile en uygun politikanın öğrenilmesi için dinamik programlama ve pekiştirmeli öğrenme gibi yöntemler kullanılabilir (van Otterlo ve Wiering, 2012). Dinamik Programlama, eylemler arası geçiş değerleri ve ödüllerin bilindiği, algoritma içerisinde her bir durum için başlangıçta sıfır ödül ile başlayarak eylemlerin tekrarlayan bir şekilde yeniden hesaplanmasıyla en uygun politika bulunur. Pekiştirmeli öğrenme, MKS'nin geçiş değerlerinin tamamen belirli olmadığı durumları çözebilir. Geçiş değerleri, rasgele başlangıç noktası seçimi ve bu noktadan birçok kez çalıştırılması ile erişilebilir. Dinamik programlamada geçiş olasılıkları bellidir ve politika çevrimdışı öğrenilebilir. Pekiştirmeli öğrenmede geçiş olasılıkları tamamen belli olmadığı için politika çevrimiçi öğrenilebilir.

2.2.2 Pekiştirmeli öğrenme çeşitleri

Pekiştirmeli öğrenme algoritmaları model tabanlı ve model içermeyen olarak iki gruba ayrılabilir (Şekil 2.9) (Dayan ve Niv, 2008). Model tabanlı yaklaşımlar, daha önceki deneyimleri ve çevreden alınan tüm bilgiler ile verilecek kararın uzun vadeli sonuçlara göre verildiği yaklaşımlardır. Model içermeyen yaklaşımlar ise, çevrenin modelinin tam olarak belli olmadığı yapılan eylem ile çevrenden adım adım gelen ödüller ile politikanın belirlendiği yaklaşımlardır. Bu iki yaklaşım gerçek hayattan bir örnek ile şöyle açıklanmıştır (Dayan ve Niv,2008). İşten eve gitmek isteyen birisi model tabanlı yaklaşıma göre çevrenin bilgilerinin kayıtlı olduğu bir haritadan o anki konumu ve gideceği yeri işaretlediğinde haritadaki daha önceki bilgilere göre en uygun rotayı bulur ve ona göre hareket etmeye başlar. Model içermeyen yaklaşımda ise yola çıktığında iş çıkış saati olması veya yoldayken

gördüğü bir yol çalışmasına göre gidiş yolunu değiştirebilir bu da hem politikayı hem de ödülü değiştirir. Model tabanlı yaklaşımlarda dinamik programlama algoritmaları kullanılabilir. Geçici fark öğrenmesi algoritmaları model tabanlı yaklaşımlardandır (Daw vd., 2005). Geçici fark ile öğrenme algoritmalarının ortak özelliği $Q(s,a)$ şimdiki yapılan eylemden (a) alınan ödül ve tahmini gelecekte alınacak ödülün hesaplanma kısmıdır. Geçici fark algoritmalarından yaygın olarak bilinen iki tanesi Q-öğrenme ve SARSA'dır.



Şekil 2.9. Pekiştirmeli Öğrenme Taksonomi

Q-öğrenme yönteminde çevrenden alınan dönütlere göre bir eylem yapılır ve ardından bu eylemin sonucunda alınan ödül ile bir sonraki durumun değeri gözlemlenir (Watkins ve Dayan, 1992). Q-öğrenme, politika dışı öğrenme algoritmasıdır. Politika dışı öğrenme, bir sonraki durum için eylem belirli politikaya bağlı olarak alınmaz ve bu politika dışı seçilen eylem ile açgözlü politikayı takip eder. Tüm durum eylem çiftleri için Q değerleri belirlenir ve Q değerleri Q-öğrenme yaklaşımı ile dögüsel olarak Denklem 2.1'de görüldüğü şekilde her öğrenme aşamasında güncellenir (Russel ve Norvig, 2003).

$$Q(s,a) \leftarrow Q(s,a) + \alpha(R(s,a) + \gamma \max_{a'} Q(s',a') - Q(s,a)) \quad (2.1)$$

Bu yöntem dögüsel bir şekilde öğrenmeye ve değerleri geliştirmeye devam eder. Denklem 2.1'de (α) değeri öğrenme katsayısıdır, sıfır ile bir arasında değer alabilir. Öğrenme katsayısı (α) sıfıra yakın değerler aldığıında eski Q değeri, yeni Q değerinden daha

önemli olur. Bu da önceden oluşan Q değer tablosundaki bilgilerin korunmasını sağlar. Öğrenme katsayısı değeri bire yaklaştıkça yeni gelen bilgi eski bilgiyi daha hızlı değiştirir böylece yeni gelen durumlara daha hızlı adapte olunur (van Otterlo ve Wiering, 2012). (γ) değeri ise azaltma faktörüdür. Azaltma faktörü, sıfır ile bir arasında değerler alabilir, sıfıra yakın değerler aldığı anda eylemi yapan anlık ödüle odaklanır, bire yakın değerler aldığı anda ise gecikmeli ödüle yönelir ve arada aldığı ödüllerin önemi azalır (Sutton ve Barto, 2017).

SARSA (State-Action-Reward-State-Action), politika içi öğrenme algoritmasıdır. Politika içi öğrenme, algoritma içerisindeki durum eylem çiftinin ve gelecek durum-eylem çiftinin politikaya göre hesaplanmasıdır. Belli bir davranışın sonucunda ödül alınmıyorsa, durumlar arasında eylemler ile geçişler varsa Q-öğrenme ve SARSA gibi algoritmalar kullanılabilir. SARSA algoritması denklemin 2.2'de gösterilmektedir. SARSA, gelecek ödülün hesaplanması kısmı ile Q-öğrenme yönteminden ayrılmaktadır.

$$Q(s,a) \leftarrow Q(s,a) + \alpha(R(s,a) + \gamma Q(s',a') - Q(s,a)) \quad (2.2)$$

Q öğrenmede, bir sonraki eylem hesaplanırken değer tablosundaki en yüksek ödül değeri seçilir, SARSA'da ise bir sonraki durum ödülü en uygun olmayabilir. SARSA, her zaman en uygunu seçmediği için değişen dinamik ortamlarda kullanılabilir. Q öğrenme ise en çok ödülün alınmasının hedeflendiği, keşfetmenin zamanla önemini azaldığı durumlarda kullanılabilir.

Pekiştirmeli öğrenmede bir sonraki durumun seçilmesinde değer tabloları kullanıldığı durumlar ve politika belirleyicisi bu başlıkta anlatılmıştır. Bir sonraki başlıkta tek durumlu pekiştirmeli öğrenmeyi bağlamsal slot makinesini içeren, çok kollu slot makinesi problemlerinden bahsedilmiştir. Eylemler sonucundan geri bildirim alınmadığı durumlarda çok kollu slot makinesi yaklaşımları kullanılabilir.

2.2.3 Çok kollu slot makinesi problemleri

Çok kollu slot makinesi problemi, kollu slot makinelerinde kullanıcının hangi makinede oynamasının ona daha çok kazanç getireceği kurgusu ile tanımlanmaktadır.

Burada anlık olarak verilen karar ortamı etkilemediği için sonrasında geçilecek durumlarında etkilememektedir. Çok kollu slot makinelerinde kullanıcı kollarından birini çeker ve ödülü kazanır. Bu problemde belli bir durum (s) için yapılan eylemlere (a) göre ödül değerleri alınır. Durum (s) tek olduğu için MKS'lerin tek durumlu modeli gibidir, ilk ortaya çıkışı MKS'den esinlenilmiştir (Robbins, 1952).

Politika (π), pekiştirmeli öğrenme modelinde durumlar için en iyi eylemlerin oluşturulmasıdır. Problemin yapısına göre MKS ve politika terimleri belirlenir ve farklılık gösterebilir. Bu problemdeki politika (π) toplam pişmanlığın en az olmasıdır. Ödülün en yüksek alınmasını hedefleyen bir politika belirlenebilir. Pekiştirmeli öğrenmede ödül sıralı bir şekilde alınırken, çok kollu slot makinesi probleminde ödül o anki eylem sonucunda hemen alınır durumların nasıl geldiğine bakılmaz.

Çok kollu slot makinesi problemlerinde daha önce denenmiş kollardan, en iyi sonuç verenin sürekli seçilmesi daha iyi bir sonucun hep kaçırılmasına yol açabilmektedir. Bu durumun karşısı olarak hep yeni durumların denenmesi bulunan iyi sonuçların kaçırılmasına yol açabilecektir. Bu durum keşfetme-sömürü (exploration-exploitation) ikilemi olarak geçmektedir. Keşfetme, ilk defa sonuçları denenecek durumlarda eylemlerin vereceği sonuçları öğrenmek için veya bir t zamanı için en uygun sonuç veren durumun seçilmemesi ve alınan geri dönüt ile en iyi durumdan daha iyi sonuç verebilecek durumlar için kullanılır. Sömürü ise t zamanına kadar bulunmuş en uygun durumun hep seçilmesidir. Sömürünün çok olduğu durumlarda en uygunu bulamadan alt en uygunda takılma ve en uygunu asla keşfedilememesi gibi sonuçlara neden olabilir. Keşif ve sömürü arasındaki dengeyi koruyabilecek politika seçilmelidir. Bu problem için politika t zamanında pişmanlığın en az olmasıdır. Pişmanlık (regret), en uygun stratejinin beklenen getirisi ile slot makinesinden en iyi kolun sürekli çekilerek beklenen getiri arasındaki farktır (Auer vd., 2002).

Çok kollu slot makinesi problemleri, çevreye göre, ödüllerin alınma yöntemlerine göre gibi farklı gruplandırmalar yapılmıştır. Çekişmeli çok kollu slot problemi ve olasılıksal çok kollu slot problemi, ödüllerin alınma yöntemleri bakımında farklılık gösteren problemlerdir. Çekişmeli çok kollu slot makinesi problemi, çekilen kol karşısında ödül değeri olasılıksal bir hesaplama yapılmadan alınır (Auer vd., 1995). Olasılıksal çok kollu slot makinesi problemi, slot makinesinde çekilecek kollardan hangi kolun daha yüksek ödül

değerleri vereceğinin ya da en az pişmanlığın alınmasının olasılıksal hesaplaması yapılarak tercih edilmesidir (Auer vd., 1995).

Çok kollu slot makinesi probleminin yaygın olarak uygulama alanları internet reklamcılığı ve öneri sistemleri olarak bilinse de, büyük ölçekli elektrikli araç şarjı (Yu vd., 2015) ve LTE-U ve WiFi birlikte bulunduğu alanlarda mobil data trafiğinin kullanımı üzerine (Sriyananda vd., 2016) çalışılmıştır.

Literatürdeki çalışmalarda olasılıksal çok kollu slot makineleri probleminin alt alanı olarak bağlam içermeyen ve bağlamsal çok kollu slot makinesi problemi olarak incelenmiştir. Çevreden gelen bilgilerin eylemler üzerinde etkisinin olmadığı durumlar bağlam içermeyen çok kollu slot makinesi problemi olarak adlandırılmıştır. Bağlamsal çok kollu slot makinesi problemi ise durumlar üzerinde çevre bileşenlerinin yani çevreden gelen içerik bilgilerinin etkisi olduğu yaklaşımlardır.

a) Bağlam içermeyen çok kollu slot makinesi problemi:

Bağlam içermeyen slot makinesi probleminde, çevreye ait hiçbir özelliğin bilgisi mevcut değildir. Modellerin durumunu belirleyen sadece eylemlerden gelen getiri değeridir. Bağlam içermeyen slot makinesi probleminde, eylem seçimleri için greedy, e-greedy, üst güven sınırı 1 (UCB1) ve Thompson örneklendirmesi gibi algoritmalar kullanılabilir.

Greedy algoritması, eylemlerin sonuçlarını denklem 2.3'deki Monte Carlo yaklaşımıyla hesaplar. Eylemde (a) en yüksek değere sahip olan eylemi seçtiği için denklem 2.4'de, yerel en yüksek değerde takılabilir, doğrusal pişmanlığı garantileyen bir algoritmadır (Sutton ve Barto, 2017).

$$\widehat{Q}_t(a) = \frac{1}{N_t(a)} \sum_{t=1}^T r_t 1(at = a) \quad (2.3)$$

$$a_t^* = \underset{a \in A}{\operatorname{argmax}} \widehat{Q}_t(a) \quad (2.4)$$

E-greedy algoritması, bağlam içermeyen çok kollu slot problemi algoritmalarından biridir. Epsilon değerine göre sonsuza kadar rasgele keşfetmeye devam edebilir. Keşif yüksek olacağı için en az pişmanlığı garanti eder. UCB algoritması, birbirine yakın değerlerin olduğu yerde karar verme gibi durumlarda kullanılabilir. Diğer algoritmalara göre ek olarak bir kolun kaç kere çekildiği ($N_t(a)$) bilgisini de tutar, bu bilgi sayesinde çok sayıda seçilmiş kolun $Q(a)$ değeri daha yüksek bir değer alır.

$$a_t = \underset{a \in A}{\operatorname{argmax}} Q(a) + \sqrt{\frac{2 \log t}{N_t(a)}} \quad (2.5)$$

Basit bir şekilde e-greedy algoritmasının sözde kodu aşağıdaki gibidir (Sutton ve Barto, 2017).

Algoritma 1 E-greedy sözde kodu

```

0: İlk kullanıma hazırlama, for a = 1 to k:
1:   Q(a) ← 0
2:   N(a) ← 0
3: Sonsuz döngü:
4:   A ← { (Argmaxa Q(a))   olasılık 1 - ε
         (Rastgele bir eylem)  olasılık ε
5:   R ← bandit(A)
6:   N(A) ← N(A) + 1
7:   Q(A) ← Q(A) +  $\frac{1}{N(A)}$  [R - Q(A)]

```

b) Bağlamsal slot makinesi problemi:

Bağlamsal slot makinesi problemi, birden çok makine olduğunda çevreye ait özelliklerin kararı etkilediği durumlardır. Birden çok kolun olduğu durumda hangi kolun çekilmesinin daha iyi sonuç vereceğinin hesaplanması gerekir. Bağlamsal slot makinesi problemi pekiştirmeli öğrenme ile çok kollu makinesi problemi arasında olarak

değerlendirilebilir. Bağlamsal slot makinesi problemi ise parametrelerin hangi bağlamda geldiği hangileri uygulandığında en iyi ödülün veya en az pişmanlığın alınacağı bilinmediği durumudur. Bağlamsal slot makinesi problemi çözümü için bağlamsal thomson örnekleme, Doğrusal üst güven sınırı (Lin-UCB), Bağlamsal thompson örnekleme algoritmaları kullanılabilir.

LinUCB algoritması, literatürde ilk olarak Li vd. (2011) çalışmasında önerilmiştir. Bu çalışmada haber içeriklerine sahip bir web sitesinin ön sayfasına getirilecek içeriklerin kullanıcıya göre özelleştirilmesi konusunda test edilmiştir. UCB algoritmasının tek bir noktaya göre güven aralığını belirlemesi, farklı kullanıcıların farklı özelliklerine göre değerlerinin birbirinden ayrı olması problemini tam karşılayamamıştır. Bunun için fonksiyona bağlı olarak güven aralığının hesaplanması, parametrelerdeki belirsizliğin hesaplanmasıdır.

LinUCB algoritması (Li vd. 2011) girdi olarak keşfetme ve sömürü katsayısı (α) almaktadır. Algoritma ilk olarak kişiselleştirilmiş haber makale önerisi (Li vd. 2011) için çalışılmıştır. Burada kollar (a) her bir makaleye karşılık gelmektedir. Beklenen geri ödeme (2.7) a 'ya bağlı içerik (x_a^T), a koluna bağlı katsayı vektörünün (θ_a^*) iç çarpımıdır.

$$E[r_a|x_a] = x_a^T \theta_a^* \quad (2.7)$$

Veri seti T kadar deneme içerir ve her bir deneme-kol'a ait içerik ($x_{t,a}$) olarak tanımlanmıştır. Algoritmada her bir içerik ($x_{t,a}$) için bütün kollar ($a \in A$) denenir ve kol seçimi (a_t) her bir deneme (t) için gözlemlenen içeriğe ($x_{t,a}$) ridge regression yapılmasıyla ($\hat{\theta}_a^T x_{t,a}$) tahmini kazanç ile model belirsizliğin azaltılmasını en çoklayan kol (a_t) olarak bulunur (2.8).

$$a_t = \operatorname{argmax}_{a \in A_t} \left(\hat{\theta}_a^T x_{t,a} + \alpha \sqrt{x_{t,a}^T A_a^{-1} x_{t,a}} \right) \quad (2.8)$$

LinUCB algoritmasındaki keşfetme-sömürü katsayısı (α) düşük olduğunda keşif oranı düşmektedir iyi makalelerin keşfedilmesinde düşmektedir, öte yandan çok büyük

olduğunda ise keşif oranı artmakta ve makalelerin tıklanma oranını arttırmak için bazı keşfedilen iyi makaleler daha iyi makaleler için kaçırılmış olur.

Algoritma 2 Doğrusal Modelli LinUCB Algoritması

- 1: Girdi: $\alpha \in R_+$
- 2: **for** $t: 1, 2, 3, \dots, T$ **do**
- 3: Her kol $a \in A$ kolu için içerik bilgisi: $x_{t,a} \in R^d$
- 4: **for all** $a \in A$ **do**
 - a. **if** yeni bir a için **then**
 - b. $A_a \leftarrow I_d$ (d boyutlu birim matris)
 - c. $b_a \leftarrow 0_{d \times 1}$ (d boyutlu sıfır vektörü)
 - d. **end if**
- 5: $\hat{\theta}_a \leftarrow A_a^{-1} b_a$
- 6: $p_{t,a} \leftarrow \hat{\theta}_a^T x_{t,a} + \alpha \sqrt{x_{t,a}^T A_a^{-1} x_{t,a}}$
- 7: **end for**
- 8: $p_{t,a}$ 'yı en çoklayan bir $a_t = \operatorname{argmax}_{a \in A_t} p_{t,a}$ değeri seçilsin ve gerçek – değerli r_t değeri gözlemlensin
- 9: $A_{a_t} \leftarrow A_{a_t} + x_{t,a_t}^T x_{t,a_t}$
- 10: $b_{a_t} \leftarrow b_{a_t} + r_t x_{t,a_t}$
- 11: **end for**

Li vd., (2012), bağlamsal slot makinesi probleminin değerlendirilmesi için bir politika değerlendirme algoritması önermişlerdir. Li vd. (2012) çalışmalarında bir önceki çalışmalarındaki (Li vd. 2011) gibi kişiselleştirilmiş haber önerileri üzerine çalışmışlardır. Bu çalışmada da web sitesinin ön sayfasında gösterilen makaleler, bağlamsal çok kollu slot makinesi problemindeki kollara denk gelmektedir ve tıklanan her bir makalenin geri ödemesi 1 olarak alınır, tıklanmaması durumunda ise 0 değerini alır. Bu tanımlamalara göre beklenen getiri (expected payoff) tıklanma oranına (CTR) eşittir ve en yüksek CTR kullanıcının makaleyi tıklanma ihtimalini çoklanmasıdır, bu durum aynı zamanda beklenen getirinin çoklanmasıdır. Algoritma 3 (Li vd. 2012) girdi olarak slot makinesi algoritmasını, L

uzunluğundaki olayları alır. Slot makinesi algoritması (A) politikası ve geçmiş bilgilere göre (h_{t-1}) aynı kol (a) seçilirse, olay geçmiş bilgilere eklenir ve toplam getiri değeri güncellenir.

Algoritma 3 Politika_değerlendiricisi Algoritması

```

1: Girdi: slot makinesi algoritması A; akan olaylar S
2:  $h_0 \leftarrow \emptyset$  {Başlangıç olarak boş bir geçmiş}
3:  $\widehat{G}_A \leftarrow 0$  {Sıfır geri ödeme}
4:  $T \leftarrow 0$ 
5: for t: 1, 2, 3, ..., L do
6:   S içersinden t sıradaki  $(x, a, r_a)$  olayı seçilir
7:   if  $A(h_{t-1}, x) = a$  then
8:      $h_t \leftarrow \text{TOPLAM}(h_{t-1}, (x, a, r_a))$ 
9:      $\widehat{G}_A \leftarrow \widehat{G}_A + r_a$ 
10:     $T = T + 1$ 
11:   else
12:      $h_t \leftarrow h_{t-1}$ 
13:   end if
14: end for
15: Output:  $\widehat{G}_A / T$ 

```

2.3. Makine öğrenmesi ile anomali tespiti çalışmaları

Makine öğrenmesi yaklaşımları artan veri boyutu ile beraber yaygın olarak farklı uygulama alanlarında anomali tespiti için kullanılmaktadır. Anomali tespiti için ilgili ağ saldırı tespit sistemleri (Shon ve Moon, 2007), sağlık (Arodz vd., 2005), yol durumu (Tai vd., 2010), trafik(Thaika vd., 2018; Özlem vd. 2018) gibi farklı alanlarda makine öğrenmesi destekli yöntemler geliştirilmiştir.

Makine öğrenmesinin denetimli, denetimsiz ve pekiştirmeli öğrenme yaklaşımlarıyla anomali tespiti yapılmasıyla ilgili literatürde çalışmalar vardır. Bunlardan denetimli öğrenme ile ilgili olanlarından Goodall vd., (2019) bilgisayar ağ trafiğindeki normal olmayan davranışların tespit edilmesi ve görselleştirilmesi üzerine çalışmışlardır. Bu

çalışmada mevcut güvenlik araçlarını tamamlayan ve analistlerin durumsal farkındalığı kazanmasına, anomaliye yol açabilecek durumların saptanmasına ve bu durumların içeriğinin anlamlandırılmasına yardımcı olan görsel bir analiz sistemi kurmuşlardır ve sentetik bir siber saldırı veri seti olan Skaion 2006 IARPA (SKAION, 2018) veri setini kullanmışlardır. Anomali tespiti için makine öğrenmesinin denetimsiz öğrenme yaklaşımı kullanmışlar ve her bir ip adresinin saldırı ihtimalleri için gerçek zamanlı basit bir Bayes güncellemesi kullanarak belirli eşik altında kalan durumları anomali olarak tanımlamışlardır. Denetimli öğrenme yaklaşımını kullanan bir başka çalışmada; ağ saldırı tespiti sistemlerinde anormal durumlarını makine öğrenmesi yaklaşımlarından Destek Vektör Makinesi(DVM) ile tespit etme üzerinedir (Shon ve Moon, 2007). Çalışmada denetimli DVM yerine hibrit bir DVM yöntemi önerilmiştir ve hem gerçek hem de deneysel ortam verilerine göre geliştirilmiş destek vektör makineleri yaklaşımı en güncel ağ tespit sistemlerine yakın bir sonuç verdiğini gözlemlemişlerdir. Bir diğer çalışmada Tai vd. (2010) motosiklet verilerine göre mobil cihaz ile yoldaki anomalilerin tespiti olasılığını incelemişlerdir. Makine öğrenmesinin denetim öğrenme modelinden olan DVM ile yoldaki anomalileri %78,5 doğru tespit etmişlerdir.

Literatürdeki denetimsiz öğrenme yaklaşımıyla anomali tespit çalışmalarından biri olan; Schwabacher (2005) roket itme gücünün test yatağında anomaliler daha oluşmadan, ortaya çıkabilecek anomalilerin denetimsiz öğrenme yöntemi ile tespiti üzerine çalışmıştır. İki farklı makine öğrenmesi algoritması kullanılmış ve veri setinde farklı anomalileri tespit edebildiklerini gözlemlemişlerdir, bu yüzden bir veri seti için birden çok makine öğrenmesi algoritmasının çalıştırılmasının yararlı olabileceği söylenmiştir. Bir başka çalışmada ise NASA gibi uzay mekiği üzerindeki cihazları izlenmesi insanlar tarafından takip edilirken yardımcı sistemler olan uzman sistemler üzerinedir (Salvador ve Chan, 2005). Bu sistemlerin izlediği cihazların veya sistemlerin zamana bağlı verilerinin kümelenmesi için makine öğrenmesinin kümeleme tabanlı yaklaşımlarına kendi ürettikleri Gecko adlı bir algoritmayı kullanmışlardır (Salvador ve Chan, 2005). Bu algoritma bir zaman serisini 3 aşamada kümelere ayırır, ilk aşamada kendi belirlediği sayıda kümelere ayırır, sonra en benzer kümeleri birleştirir ve en son döndürülecek küme sayısını belirlenir. Öğrenilen kümeler dışında gelen bir veri anomali olarak kabul edilir, Gecko algoritması ile normal öğrenildikten sonra kural üretiyor, gelen veri şimdiki veya sonraki durumun karakteristiğine uyuyorsa normal, bu ikisinde uymuyorsa anomali olarak kaydediliyor. Anomali tespiti için

NASA'dan gelen veriler üzerinde Gecko algoritmasıyla yapılan testlerde NASA uzmanlarıyla karşılaştırılabilir sonuçlar elde ettiğini gözlemlemişlerdir. Bir diğer çalışmada Thaika vd. (2018) taksilerin GPS bilgilerini kullanarak, Bangkok'un bazı bölgelerindeki anomali tespiti problemini makine öğrenmesinin temel bileşen analizi tabanlı yaklaşımıyla çözümlenmişlerdir.

Ding vd. (2019) pekiştirmeli öğrenme ile anomali tespiti üzerine çalışmışlardır. Bu çalışmada web sitelerinin kullanıcı verilerini kullanarak ve belirli bir adım sayısı kadar kullanıcıdan geri bildirim alarak bağlamsal slot makinesi ile öğrenme ve anomali tespiti yapılmıştır. Çizge üzerinde birbirine bağlantılı olduğu hesaplara göre farklılıklarının, çizge yapısına uymayan hesapların tespiti veya çizgede belirli gösterilen davranışa göre aykırı davranış sergileyen durumlar tespit edilmiştir. Anomali tespiti için kendi algoritmaları olan GraphUCB algoritmasını kullanmışlardır. GraphUCB algoritmasının, çok kollu slot makinesi problemlerinden kullanılan Epsilon-Greedy, LinUCB, LinTS algoritmasına göre daha iyi sonuçlar verdiği kaydedilmiştir.

3. MATERİYAL VE YÖNTEM

Bu tez çalışmasında ele alınan durum farkındalığı yaklaşımlarının denenmesi için Akıllı Fabrika benzetimleri kullanılmıştır. Önerilen yöntem verilmeden önce takip eden alt bölümde kullanılan materyaller verilmektedir.

3.1. Materyal

Çalışmada kullanılan test ortamı genel tanıtımı, kullanılan SUMO benzetim ortamı ve programlama dili aşağıdaki alt bölümlerde verilmektedir.

3.1.1. Akıllı fabrika ortamı


Akıllı fabrikalarda Endüstri 4.0 ile nesnelerin birbiriyle iletişimde olması ve insan müdahalesi olmaksızın tüm üretimin bir sistem içerisinde ilerlediği bir yapı beklenmektedir. Aksoy, 2017 çalışmasına göre insanların çalıştığı bir ortamda üretimde oluşan hata oranı ile tamamıyla insan müdahalesi olmaksızın akıllı fabrika olarak tasarlanan üretim ortamında yapılan hata oranından fazla olduğu gözlemlenmiştir. Hedef tamamen insansız çalışan fabrikalar olsa da mevcut fabrikalarda hibrit bir çalışma ortamı bulunmaktadır.

Fabrika ortamlar, OTA ve insanların birlikte çalıştığı bir alandır. Bu ortamda yaya yolları, yaya geçitleri, OTA park ve şarj istasyonları, iş istasyonları, iş istasyonlarına doldur-boşalt noktaları, ürünlerin koyulduğu raflar, hammadde rafları, tek şerit gidiş geliş araç yolları bulunmaktadır. Eskişehir Osmangazi Üniversitesi (ESOGU) Akıllı Fabrika ve Robotik Laboratuvarı (AFAR-LAB)'na akıllı fabrikalar için geliştirilen yöntemlerin Teknolojik Hazırlık Seviyesi(THS) 5 testi için Şekil 3.1 ile verilen bir ortam kurulmuştur. Bu ortamda OTA park alanında iken görev aldığı fabrika ortamına giriş yapar ve ilgili yolları kullanarak iş istasyonlarına ürün alır ya da bırakır. Ürünü bıraktıysa ve yeni bir görev atanmadıysa OTA park alanına doğru harekete geçer, eğer ürün aldıysa ürünü bir başka iş istasyonundan istenmediyse ürün raflarına götürür. Fabrika ortamına benzer yaya geçitleri, yaya yolları ve kullanılabilir. Dolayısıyla fabrika içinde hem yaya trafiği hem de otonom araç trafiği test edilebilmektedir.



Şekil 3.1. ESOĞÜ AFAR-LAB Görşeli

Otonom Araç geliştirme testleri için AFAR-LAB ortamı GAZEBO Benzetim ortamına da aktarılmıştır (Şekil 3.2). Bu sanal ortamda da gerçek ortamda da test edilebilecek bazı yeteneklerin ön testleri sağlanır. Benzetim ortamları daha düşük maliyet ile teste imkân verdiği için Fiziksel olan AFAR-LAB ortamına ek olarak GAZEBO benzetim ortamında geniş ölçek bir fabrika ortamı entegre olarak eklenmiştir. Gerçek ortam (Şekil 3.1) Şekil 3.2'deki GAZEBO ortamındaki dört duvar ile çevirili olan kısımdır.



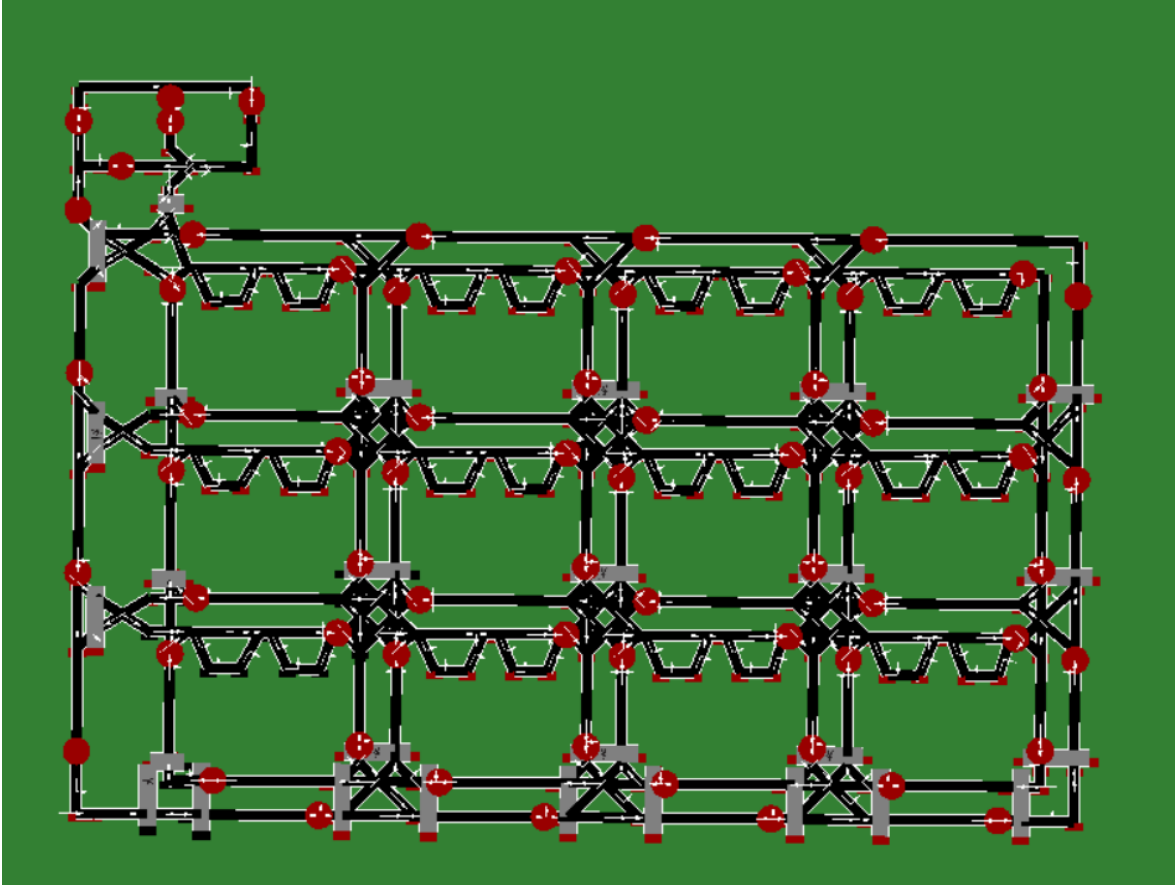
Şekil 3.2. GAZEBO Sanal Fabrika Ortamı

Şekil 3.2 ile verilen test ortamı OTA'lar ile ilgili birçok otonom davranışın testi için kullanılmaktadır. Bu tez çalışmasında geliştirilen OTA'lar için durumsal farkındalık yöntemleri daha çok fabrika için ulaşım verileri içermektedir. Bu anlamda mevcut benzetim ortamı yeterli olmayıp, literatürde GAZEBO ile bu anlamda entegre kullanılabilen (Garzón ve Spalanzani, 2018) takip eden alt bölümde verilen SUMO ortam modeli kullanılmıştır.

3.1.3. SUMO benzetim ortamı

SUMO, trafik benzetimi için geliştirilen açık kaynak kodlu bir platformdur. Kentsel Hareketliliğin Benzetimi (Simulation of Urban Mobility, SUMO), amaçlı 2001 yılından beri kullanıma açık olan, 2002 yılında açık kaynak kodlu yayınlanan trafik ağlarının yönetmek için tasarlanan bir benzetim programıdır (SUMO, 2019). SUMO'da bir yol ağının oluşturulması, rotaların ve araçların tanımlanması ile birlikte benzetim ortamındaki trafik oluşturulabilir.

Akıllı fabrika ortamında bahsedilen GAZEBO benzetim ortamıyla sanal ortama aktarılan fabrika ortamı haritası, burada SUMO benzetim ortamına dönüştürülmüştür (Şekil 3.3). Şekil 3.3 ile verile SUMO modelinin sol-üst tarafında AFAR-LAB'a ait ulaşım yol ağı bulunmaktadır.



Şekil 3.3. Fabrika Ortamı SUMO

SUMO'da Yol ağlarının tasarlanması ve rotalarının belirlenmesi gibi bilgiler için birden çok dosyanın tanımlanmasına ihtiyaç vardır. Yol ağlarının için kenar ve düğümlerin tanımlandığı bir çizge ile oluşturulur. “Netgen” adında bir uygulama ile de trafik ağları oluşturulabilir. “Netedit” programı çizge oluşturma için bir arayüz sağlıyor ve yollar, yolların bağlantıları, kesişim noktaları gibi çizimleri yaparak çizge oluşturulabilir.

SUMO, mikroskobik trafik benzetimi uygulamasıdır. Trafik oluşturulabilmesi için rotalar, araçların yine tanımlanan ortam bilgilerine göre oluşturulması gerekir. Rota dosyaları “.rou.xml” uzantılıdır. Rotalar oluşturulurken rotaya araçlar atanabilir ya da

araçlara rotalar atanabilir ve bu araçların veya rotaların tanımlaması aynı dosya içinde yapılabilir (Şekil 3.4). Araçlar tanımlanırken aracın numarası, tipi, rotası, rengi, ivmesi, en fazla hızı, araç boyutları, aracın yola çıktığı konum, aracın varış konumu gibi özellikler alabilir. Aracın tip tanımlamaları daha ayrıntılı bir şekilde yapılabilir (Çizelge 3.1).

```

1 <routes>
2   <vType accel="0.5" decel="5.0" id="Araba" length="2.0" maxSpeed="100.0" sigma="0.0" />
3   <route id="rota" edges="42"/>
4   <vehicle depart="1" id="arac" route="rota" type="Araba" />
5 </routes>

```

Şekil 3.4. Rotalama Dosyası Örneği

Çizelge 3.1. Araç Tipi Özellikleri (SUMO'dan 2019)

Özellik Adı	Değer Tipi	Varsayılan Değeri	Açıklaması
id	id (string)	-	Araç tipinin adı
accel	float	2,6	Bu tip araçların hızlanma kabiliyeti (m/s^2)
decel	float	4,5	Bu tür araçların yavaşlama kabiliyeti (m/s^2)
emergencyDecel	float	==decel	Araç için fiziksel olarak mümkün olan azami yavaşlama (m/s^2).
length	float	5,0	Aracın uzunluğu (m)
minGap	float	2,5	Öncü araçla aradaki en az mesafe
maxSpeed	float	55,55 (200 km/sa) her bir araç için, 1,39 (5 km/sa) yayalar için	Aracın en fazla hızı (m/s)
speedFactor	float	1,0	Şerit hız limitleri için beklenen çarpan değeri
speedDev	float	0.0	speedFactor değerinin sapması
color	RGB renk	"1,1,0" (sarı)	Araç tipinin rengi
width	float	1.8	Aracın genişliği (m)
laneChangeModel	Şerit değiştirme modeli ismi(string)	'LC2013'	Şerit değiştirmek için kullanılan model (genişletilebilir özellikleri ile)
carFollowModel	Araç takibi modeli ismi (string)	'Krauss'	Otomobil modellerinde kullanılan model (genişletilebilir özellikleri ile)
personCapacity	int	4	Aracın taşıyabileceği yolcu kapasitesi (sürücü hariç)
containerCapacity	int	0	Aracın taşıyabileceği konteyner sayısı
boardingDuration	float	0.5	Bir kişinin araca binmesi için gereken süre
loadingDuration	float	90.0	Bir konteynerın araca yüklenmesi için gereken süre

Yapılandırma dosyaları, rotaların, araçların ve yol ağları dosyalarının çağırıldığı ve birleştirildiği dosyadır (Şekil 3.5). SUMO’da yapılandırma dosyaların çalıştırılması için iki yöntem vardır, birincisi komut satırından dosyaların çalıştırılmasıdır, ikincisi ise SUMOGui grafiksel kullanıcı ara yüzünü kullanılabilir.

```

1 <configuration>
2   <input>
3     <net-file value="ornek.net.xml"/>
4     <route-files value="ornek.rou.xml"/>
5   </input>
6   <time>
7     <begin value="0"/>
8     <end value="10000"/>
9   </time>
10 </configuration>

```

Şekil 3.5. Yapılandırma Dosyası Örneği

SUMO’da ortam dosyalarının oluşturulmasının ardından yukarıda Şekil 3.3’deki fabrika ortamı haritasını oluşturulur. SUMO ortamında yukarıda bahsedilen araç rotalama tanımlamaları ile fabrika ortamında her bir araç için trafik ulaşım senaryoları üretilebilmektedir. SUMO programına verilen birden çok araçlı bir senaryonun gerçekleşmesi sonucunda haritadaki tüm yollara ait kaydedilen verilere ait örnek açıklama Çizelge 3.2 gibidir. Verilen örnek rotanın benzetim ortamındaki süresi 829 saniyedir. Örnek olarak “40078” numaralı yola ait kaydedilen veri şöyledir:

```

“<edge id="-40078" sampledSeconds="71.72" traveltime="9.68"
overlapTraveltime="35.86" density="2.20" occupancy="0.62" waitingTime="41.00"
speed="0.39" departed="0" arrived="0" entered="2" left="2" laneChangedFrom="0"
laneChangedTo="0"/>”

```

Çizelge 3.2. Sumo Yol/Şerit bazında trafik verileri

Adı	Tip	Açıklaması
begin	(benzetim) saniye	Değerlerin toplanma ilk adım zamanı
end	(benzetim) saniye	Raporlanan değerlerin toplanma son adım zamanı + DELTA_T
edge@id	(kenar) id	Rapor edilen kenarın adı
lane@id	(yol) id	Rapor edilen şeridin adı
sampledSeconds	s	Her saniye kenarda / şeritte bulunan araç sayısı, ölçüm aralığı boyunca toplanır.
traveltime	s	Kenarı / şeridi geçmek için gereken zaman, bunun araçların ihtiyaç duyduğu tam zamanı değil, sadece ortalama hıza dayanan bir tahmindir. Değer, aracın herhangi bir kısmının kenara girmesine dayanır.
overlapTraveltime	s	Kenardan / şeriden tamamen geçmek için gereken zaman, bunun sadece araçların ihtiyaç duyduğu süreye değil, ortalama hıza dayanan bir tahmindir. Değer, aracın herhangi bir kısmının kenara girmesine dayanır.
density	#araç/km	Şerit/Kenardaki araç yoğunluğu
occupancy	%	Şerit/Kenar işgal süresi
waitingTime	s	Araçların toplam saniye bazında durma süresi
speed	m/s	Rapor edilen aralıktaki şerit/kenardaki ortalama hız
departed	#araç	Tanımlanan aralıktaki şerit/kenardan ayrılan araç sayısı
arrived	#araç	Kenar şeridinde yollarını tamamlayan araçların sayısı
entered	#araç	Şerit/kenara araç akışının tersi yönünden gelerek giren araç sayısı
left	#araç	Araç akışı yönünde hareket ederek şeriti/kenarı terk eden araç sayısı
laneChangedFrom	#araç	Bu şeritten başka şeride değiştiren araç sayısı
laneChangedTo	#araç	Başka şeritten bu şerite gelen araç sayısı
vaporized	#araç	Kenarda kaybolan araç sayısı(sadece #araç > 0'dan büyükse)

3.1.4. Python programlama

Python, nesne yönelimli, yorumlamalı ve yüksek seviyeli bir programlama dilidir (McKinney, 2012). Diğer üst seviye dillere göre kod okunabilirliği yüksek tasarım sağlar. Dinamik kodlanabilmesi, değişenleri dinamik bağlanması sayesinde yüksek veri yapıları ve mevcut bileşenleri birbirine bağlamak için bir betik bir dil kullanılması tercih edilme nedenlerindedir.

Veri analizi, verinin okuması, görselleştirilmesi, verinin dizilerde tutulması gibi kodlar için yardımcı ve işlemleri azaltıcı Python kütüphaneleri vardır. Bunlardan bazıları NumPy, Pandas, Matplotlib'dir. Numpy, çok boyutlu dizilerin oluşturulması için kullanılabilir, Array dizilerine göre for döngüsü ile oluşturulabilecek bazı kodları da kısa tanımlamalar ile oluşturarak işlem sayısını azaltmaya yardımcı olur. Numpy dizileri, sayısal verilerin standart temsilidir ve sayısal hesaplamaların yüksek seviyede bir dilde etkin bir şekilde uygulanmasını sağlar (van der Walt,2011). Pandas kütüphanesi, Amerika merkezli bir yatırım yönetimi firması olan AQR'da 2008 yılında geliştirilmeye başlanmıştır (McKinney, 2012). Veri analizini ve verinin ön işleminde kolaylık sağlayan açık kaynak kodlu BSD lisanslı bir kütüphanedir. Bu kütüphane, CSV ve metin dosyalarını okumada çok büyük kolaylıklar sağlar. Dosyaları okurken etiketli olarak dosya yapısına uygun veriyi çevirir ve kod içerisinde etiketlerine göre veriye erişmeyi, bir etiket altındaki verilerin ortalamasını alma gibi aritmetik işlemleri, eksik verilerin yönetimini kolaylaştırmıştır (McKinney, 2012). Pandas'ta verileri tutmak için Series ve DataFrame veri yapıları vardır. Bu iki veri yapısında veriyi tutabilirken, series tek boyutlu dizileri tutar, DataFrame ise tek ve çift boyutlu dizileri tutabilir (McKinney, 2012). Pandas kütüphanesini Python kodu içinde kullanmak için "import pandas as pd" ile Pandas paketi eklenir. Matplotlib, açık kaynak kodlu bir grafik çizim kütüphanesidir. İlk geliştirilmesi John D. Hunter tarafından yapılmıştır sonrasında büyük bir ekip ile geliştirilmeye devam edilmektedir (McKinney, 2012). Matplotlib ile veriler görselleştirebilir, iki boyutlu ve üç boyutlu grafikler üretilebilir, bu grafiklerin görselleştirilmesinde yakınlştırılabilir veya üç boyutlu ise döndürme işlevi yapılabilir. Grafikler dış ortama jpg, png gibi formatlarında aktarılabilir.


3.2. Yöntem

Akıllı fabrikalarda OTA'lar iç lojistiğin karakteristiğini oluşturmaktadır. İç lojistikteki aksamalar veya gecikmeler üretimi de direk etkilediği için iç lojistikteki anomalilerin tespit edilmesi önemlidir. Bu anomali iç lojistik trafiğini oluşturan OTA trafiğindeki anomalinin izlenmesi ile mümkün olabilir. Önceki çalışmalarda (Özlem vd., 2018) araç-yol bazında öğrenilen trafik karakteristiği etiketli verisi ile anomali tespitlerine yönelik çalışma yapılmıştır. Bu çalışmada fabrika içi taşımanın karakteristiğinin temel noktalarından olan kavşaklardaki trafik karakteristiklerinin pekiştirmeli öğrenme ile öğrenilmesi ve buna bağlı oluşan anomalilerin tespiti hedeflenmektedir. Bir kavşaktaki sorun erken fark edilebilirse diğer kavşaklar daha etkilenmeden çözüm yollarının üretilmesi veya mevcut kavşağa gelen trafiğin alternatif rotalara yönlendirmesi ile olası bir büyük tıkanıklığın veya üretimde oluşabilecek aksamaların önüne geçilebilir.

Kavşakların trafik akış bilgileri kullanılarak kavşak karakteristiklerinin öğrenilmesi için kavşaklardaki trafik karakteristiği bağlamsal çok kollu slot makinesi ile aşağıdaki gibi modellenmektedir.

3.2.1. Problemin modellenmesi

Kavşak karakteristiğinin öğrenilmesi problemi pekiştirmeli öğrenmenin alt alanlarında biri olan bağlamsal slot makinesi yaklaşımı ile ele alınmıştır. En genel haliyle Şekil 3.6'daki gibi bir kavşakta herhangi bir yoldan giren araç üç farklı yönden çıkış yapabilmektedir. Fabrika içerisindeki kavşağın konumuna bağlı olarak, farklı giriş çıkış yönlerinde değişik yoğunluk karakteristikleri olabilmektedir. Örneğin fabrikanın uçlarında yer alan bazı kavşaklarda sağa veya sola dönüş karakteristiği varken fabrikanın ortasında yer alan bir kavşakta herhangi bir yönde direk geçiş öne çıkabilir. Günün belli zaman dilimleri için yine bu karakteristikler değişebilmektedir.



Şekil 3.6. Kavşak Modeli

Kavşaklardaki trafik karakteristiğine ait bağlam bilgisi için SUMO benzetim ortamında yol bazında ayrıntıları verilen kaydedilen verilerden (Bkz. Çizelge 3.2) aşağıdakiler ön işlemden geçirilerek kullanılmaktadır: "icLid", "ts", "foL", "avgS", "avgSSs", "avgTT", "avgOTT", "avgD", "avgO", "avgWT", "outLid1", "foL1", "avgS1", "avgSSs1", " avgTT 1", " avgOTT 1", "avgD1", "avgO1", "avgWT1", "outLid2", "foL2", "avgS2", "avgSSs2", "avgTT2", "avgOTT2", "avgD2", "avgO2", "avgWT2", "outLid3", "foL3", "avgS3", "avgSSs3", "avgTT3", "avgOTT3", "avgD3", "avgO3", "avgWT3". İşlemden geçirilen veri sonucunda tüm kavşaklara ait her bir giriş yönünden diğer yönlere ait bilgileri 15'er dakikalık zaman dilimleri için kullanılmaktadır.

Burada kavşağa girilen yön ve kavşaktan çıkılan; birinci, ikinci ve üçüncü yollara ait 15'er dklik zaman dilimine ait veri setinin etiketleri, açıklaması ve SUMO benzetim programının çıktısındaki etiket karşılığı Çizelge 3.3'de verilmektedir.

Çizelge 3.3. Veri seti ayrıntıları

Veri seti etiketleri	Açıklaması	SUMO Trafik Verisi
icLid	Kavşağa girilen yön	Edge id
ts	Zaman aralığı	--
foL	Kavşağa girilen yön akış bilgisi	left
avgS	Kavşağa girilen yön ortalama hız	speed
avgSSs	Kavşağa girilen yön ortalama örneklem zamanı	sampledSeconds
avgTT	Kavşağa girilen yön ortalama seyahat süresi	traveltime
avgOTT	Kavşağa girilen yön kesişen seyahat süresi	overlapTraveltime
avgD	Kavşağa girilen yön ortalama yoğunluk	density
avgO	Kavşağa girilen yön işgal süresi	occupancy
avgWT	Kavşağa girilen yön bekleme süresi	waitingTime
i	Kavşaktan çıkılan yön indeksi (i=1,2,3)	Edge id
foL _i	Kavşağa çıkılan i'nci yön akış bilgisi	left
avgS _i	Kavşağa çıkılan i'nci yön ortalama hız	speed
avgSSs _i	Kavşağa çıkılan i'nci yön ortalama örneklem zamanı	sampledSeconds
avgTT _i	Kavşağa çıkılan i'nci yön ortalama seyahat süresi	traveltime
avgOTT _i	Kavşağa çıkılan i'nci yön kesişen seyahat süresi	overlapTraveltime
avgD _i	Kavşağa çıkılan i'nci yön ortalama yoğunluk	density
avgO _i	Kavşağa çıkılan i'nci yön işgal süresi	occupancy
avgWT _i	Kavşağa çıkılan i'nci yön bekleme süresi	waitingTime

Örnek bir veri olarak: “2, 1530252900.0, 7.0, 1.04, 0.2, 4.99, 48.66, 0.94, 0.0, 34.94, 1.0, 2.0, 0.9, 0.17, 5.79, 16.14, 0.31, 0.0, 11.59, 2.0, 0.0, 0.0, 0.0, 0.0, 0.0, 0.0, 0.0, 3.0, 5.0, 1.03, 1.74, 6.85, 4.68, 0.69, 0.0, 34.27”. Kavşağa giriş yapan her yola ait bilgiler sırasıyla giriş yolu, birinci çıkış yolu, ikinci çıkış yolu ve üçüncü çıkış yolu için zaman aralığı ve girilen yön bilgisiyle kaydedilmiştir. Bunlar ayrıntılı olarak şöyledir; kavşağa gelinen yöne ait ortalama hız, gelinen yön ortalama örneklem zamanı, gelinen yön ortalama seyahat süresi, gelinen yön kesişen seyahat süresi, gelinen yön ortalama yoğunluk, gelinen yön işgal süresi, gelinen yön bekleme süresi, kavşaktan birinci çıkılan yön numarası, birinci çıkılan yön akış, birinci çıkılan yön ortalama hız, birinci çıkılan yön ortalama örneklem zamanı, birinci çıkılan yön ortalama seyahat süresi, birinci çıkılan yön kesişen seyahat süresi, birinci çıkılan

yön ortalama yoğunluk, birinci çıkılan yön işgal süresi, birinci çıkılan yön bekleme süresi, kavşaktan ikinci çıkılan yön numarası, ikinci çıkılan yön akış, ikinci çıkılan yön ortalama hız, ikinci çıkılan yön ortalama örneklem zamanı, ikinci çıkılan yön ortalama seyahat süresi, ikinci çıkılan yön kesişen seyahat süresi, ikinci çıkılan yön ortalama yoğunluk, ikinci çıkılan yön işgal süresi, ikinci çıkılan yön bekleme süresi, kavşaktan üçüncü çıkılan yön numarası, üçüncü çıkılan yön akış, üçüncü çıkılan yön ortalama hız, üçüncü çıkılan yön ortalama örneklem zamanı, üçüncü çıkılan yön ortalama seyahat süresi, üçüncü çıkılan yön kesişen seyahat süresi, üçüncü çıkılan yön ortalama yoğunluk, üçüncü çıkılan yön işgal süresi, üçüncü çıkılan yön bekleme süresidir (Çizelge 3.2). “2” kavşağa girilen yolun numarasıdır. “0,1530252900.0” timestamp formatında verinin kaydedildiği zaman aralığıdır. Satır içerisindeki kalan veriler bağlam verisidir, Çizelge 3.3’de gösterildiği şekilde etiketlere karşılık gelerek değerlerini almaktadır.

Burada, bağlamsal slot makinesi uygulaması için kullanılan LinUCB algoritma giriş değerleri olarak keşfetme-sömürü katsayısı (α) ve veri setini girdi olarak almaktadır. Veri setinin her satırı algoritmada bir deneme (T)’dir. Her bir deneme içerisinde, kavşağa giriş yön bilgisi (a) ve bağlam ($x_{t,a}$) bilgisini içermektedir. Algoritmada kavşağa giriş yön numaraları (a) 2.2.3’deki LinUCB algoritmasındaki kollara denk gelmektedir. LinUCB algoritmasındaki Li vd. (2011) çalışmasındaki makalelerin içerik bilgileri ($x_{t,a}$), bu çalışmada yola ait veriler, içerik ($x_{t,a}$) olarak alınmıştır. Algoritma her bir içerik ($x_{t,a}$) için bütün kavşağa giriş yönlerini (a) dener. Algoritmadaki her bir kol burada dört kavşağa giriş yönüne denk gelmektedir. İçerik bilgisi ($x_{t,a}$) ve önceki öğrenilen bilgilere göre denenen kavşağa giriş yönlerinden (a) en çoklanan yön kavşağa giriş yöndür (a_t).

Alt bölüm 2.2.3’de verilen LinUCB algoritmasındaki A ve b matrisleri makalelerin veya makinelerin bilgilerini tutar, bu çalışmada A ve b matrisleri kavşak giriş yönleri karakteristiklerini tutmaktadır. Bu problem için modellenen algoritmalarındaki keşfetme-sömürü katsayısı (α) alt bölüm 2.2.3’de verilen LinUCB algoritmasındaki α değeri gibi düşük olduğunda yeni içeriklerin keşfedilmesinin oranı düşmektedir. α değeri çok büyük olduğunda ise yeni içerikler denenmekte ve geçmişteki bilgiye uygun olan içeriğin es geçilebilmesine yol açabilir.

3.2.2. Bağlamsal slot makinesi tabanlı anomali tespiti

Fabrikalardaki kavşak trafik karakteristiği öğrenildikten sonra bu öğrenilen karakteristiğin değişmesi anomali olarak tespit edilebilir. Herhangi bir nedenle bir kavşakta oluşan öğrenilenden farklı anormal trafik içeriksel anomali (contextual anomaly) olarak ifade edilebilir. Diğer taraftan, birden çok kavşağın bulunduğu fabrika içi ortamlarda bir kavşağın trafik yoğunluğu ile komşu kavşak yoğunluğu arasındaki anormal fark topluluk anomalisi (community anomaly) olarak ifade edilebilir. Bu farklı nedenler ile olabilecek olup, fabrika içinde üretimin aksaması, teslimatların gecikmesi, planlamalarda aksamalara sebep olmaması için kavşaklara dengeli trafik oluşturacak şekilde planlama yapılabilir. Çalışma kapsamında kavşak karakteristiğini öğrenmeye bağlı önerilen içerik tabanlı ve topluluk tabanlı anomali tespit yöntemlerinin detayları aşağıda verilmektedir.

a) Kavşaklarda içerik tabanlı anomali tespiti

Kavşaklardaki her bir yönden gelen ve farklı yönlerde oluşan trafik karakteristiği bağlamsal slot makinesi problemi ile modellenip öğrenilebilir. Örneğin, karakteristiği öğrenilen bir kavşağın giriş veya çıkışındaki yaya yolundan normalin üzerinde yaya geçmesi veya herhangi bir OTA'nın geçişi tıkaması ile OTA geçiş trafiğinde normalin dışında bir karakteristik oluşturabilir. Oluşan bu anomali tespiti için içerik tabanlı anomali tespiti kullanılabilir. Buradaki yaklaşımda slot makinesindeki "bağlam bilgisi" ile anomali tespitindeki "içerik bilgisi" kavramları örtüşmektedir. Takip eden kısımlarda içerik ve bağlam değişmeli olarak kullanılacaktır. Kavşaklardaki içerik tabanlı anomali tespiti için önerilen LinUCB_IcerikselAT algoritması aşağıda verilmektedir:

Algoritma 4 LinUCB_IcerikselAT Algoritması

1. Girdi: $\alpha \in R_+$
2. **for** t: 1, 2, 3, ..., T **do**
3. *Her kavşağa giriş yönü $a \in A$ için kavşak giriş yönü içerik bilgisi:*
 $x_{t,a} \in R^d$
4. **for all** $a \in A$ **do**
5. **if** yeni bir a için **then**

```

6.       $A_a \leftarrow I_d$  ( $d$  boyutlu birim matris)
7.       $b_a \leftarrow 0_{d \times 1}$  ( $d$  boyutlu sıfır vektörü)
8.      end if
9.       $\widehat{\theta}_a \leftarrow A_a^{-1} b_a$ 
10.      $p_{t,a} \leftarrow \widehat{\theta}_a^T x_{t,a} + \alpha \sqrt{x_{t,a}^T A_a^{-1} x_{t,a}}$ 
11.     end for
12.      $P_{t,a}$  'yı enbüyükleyen bir  $a_t = \operatorname{argmax}_{a \in A_t} p_{t,a}$  yön bilgisi
        seçilsin ve gerçek – değerli  $r_t$  değeri gözlemlensin
13.     if  $a_t \neq a_{t,r}$  then
14.         Uyarı(“Anomali kavşak yön verisi”)
15.     end if
16.      $A_{a_t} \leftarrow A_{a_t} + x_{t,a_t}^T x_{t,a_t}$ 
17.      $b_{a_t} \leftarrow b_{a_t} + r_t x_{t,a_t}$ 
18. end for

```

Bu algoritma girdi olarak keşfetme-sömürü (α) katsayısını almaktadır. Her bir deneme (T) içerisinde yön bilgisi ($a_{t,r}$) ve içerik bilgisi içerik ($x_{t,a}$) bilgisine göre kavşak giriş yönü belirlenir. Algoritmada 12. Satırda $p_{t,a}$ 'yı en büyük yapacak içerik bilgisine ait yön (a_t) bilgisi bulunur. Algoritmada 13. satırda enbüyükleyen yön (a_t) ile kavşaktan gelen verinin yön bilgisi ($a_{t,r}$) aynı değilse içeriksel anomaliler (contextual anomaly) olarak anomali tespiti algoritma içinde yapılmaktadır. Algoritmanın 16. ve 17 satırlarında içerik ($x_{t,a}$) ve ödül (r_t) bilgisi ile kavşak karakteristiğinin tutulduğu A ve b matrisleri güncellenir. Tüm verilerin öğrenmeye katılması zamanla kavşak karakteristiğinde değişimlerinde öğrenilmesini sağlamaktadır. Fabrika iş planındaki bir değişiklik ilk başlarda anomali olarak kaydedilmiş olsada zamanla öğrenmeye katıldığı için yeni gelen karakteristik öğrenilir.

Karakteristiğin öğrenilme başarısını politika denetleyici algoritması ile ölçülmüştür. Politika denetleyicisi algoritmasının sözde kod parçacığı aşağıda verilmiştir. Politika denetleyicisi yeni bir kavşak verisi geldiğinde bu kavşağın her bir yönüne ait verilerin önceki öğrenilen bilgiyle karşılaştırılması ve önceki bilgideki yön içerik bilgisiyile ($x_{t,a}$) şimdiki

gelen içerik bilgisi ve yön numaralarının kontrolünü yapar. Eğer öğrenilen modelle aynı değerler geliyorsa toplam getiri (total payoff) değeri toplanır ve güncellenir.

b) Kavşaklarda topluluk tabanlı anomali tespiti

Fabrika içerisindeki herhangi iki komşu kavşakta normal durumda benzer trafik karakteristiğinin olması beklenir. Eğer komşu iki kavşak çok farklı trafik karakteristiği gösteriyorsa bunlar kendi içlerinde karşılaştırılarak topluluk tabanlı anomali tespiti yapılabilir. Yukarıda bahsedildiği gibi eğer iki komşu kavşak arasında bir anomali varsa fabrikaya ait iç lojistik planlamalarının gözden geçirilmesi gerekebilir. İç lojistik planlamaları dengeli bir trafik oluşturacak şekilde yapılmış olduğunda ortaya çıkacak anomali herhangi bir kavşağa ait farklı problemlerden kaynaklanabilir. Birden çok kavşaktaki anomalinin, topluluk anomalisinin tespiti için ToplulukAT algoritması önerilmiştir. ToplulukAT Algoritması aşağıdaki gibidir.

Algoritma 5 ToplulukAT Algoritması

1. Girdi: $\alpha \in R_+$, A_{kvs1} , b_{kvs1}
2. $h_o \leftarrow \emptyset$ {Başlangıç olarak boş bir geçmiş}
3. $c \leftarrow 0$ {Sıfır bir sayaç}
4. $A \leftarrow A_{kvs1}$
5. $b \leftarrow b_{kvs1}$
6. **for** t: 1, 2, 3, 4 **do**
7. Her kavşağa giriş yönü $a \in A$ için kavşak giriş yönü içerik bilgisi :
 $x_{t,a} \in R^d$
8. **for all** $a \in A$ **do**
9. $\hat{\theta}_a \leftarrow A_a^{-1} b_a$
10. $p_{t,a} \leftarrow \hat{\theta}_a^T x_{t,a} + \alpha \sqrt{x_{t,a}^T A_a^{-1} x_{t,a}}$
11. **end for**
12. $P_{t,a}$ 'yı enbüyükleyen bir $a_t = \operatorname{argmax}_{a \in A_t} p_{t,a}$ yön bilgisi seçilsin ve gerçek – değerli r_t değeri gözlemlensin
13. **if** $c \neq 4$ **do**

```

14.       $h_c \leftarrow a_t$ 
15.       $c = c + 1$ 
16.      else
17.      if  $\text{len}(\text{Set}(h)) \geq 3$  then
18.          Uyarı("Topluluk Anomali, kavşakların benzerlik oranı: ",
                 $\text{len}(\text{Set}(h)) / \text{len}(h)$ )
19.      end if
20.       $h_o \leftarrow \emptyset$ 
21.       $c \leftarrow 0$ 
22.      end if
23. end for

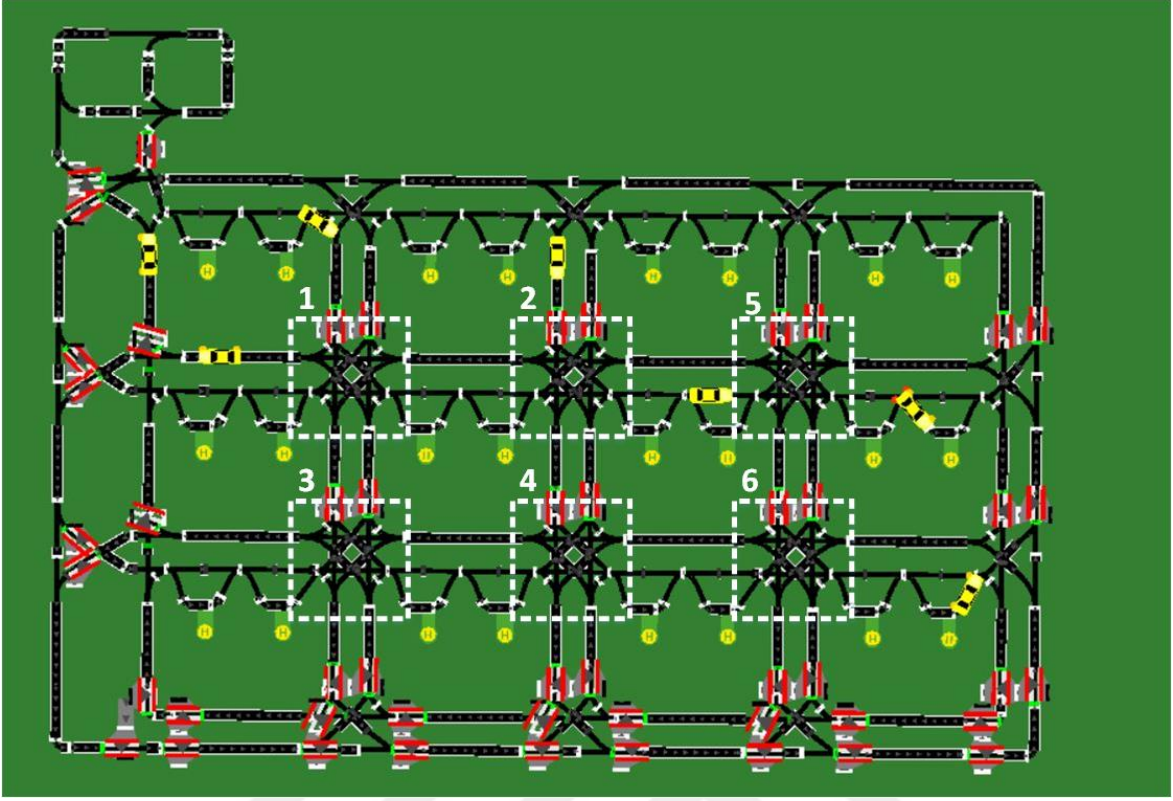
```

Bu algoritmada herhangi bir kavşak için öğrenilen karakteristik, A_{kvs1} ve b_{kvs1} matrisleri ile ifade edilmiş olsun. Bu kavşağa ait öğrenme matrisleri alt bölüm 3.2.1'deki gibi hesaplanabilir. Bu algoritma da girdi olarak keşfetme-sömürü (α) katsayısını, A_{kvs1} ve b_{kvs1} almaktadır. Bir başka kavşakta öğrenilen kavşak karakteristiği A_{kvs1} ve b_{kvs1} , veri içerisinde okunurken verinin geldiği yön ($a_{t,r}$) indeksine bakılmadan sadece içerik ($x_{t,a}$) bilgilerine göre Algoritmada 12. satırda $p_{t,a}$ 'yı en büyük yapacak içerik bilgisine ait yön (a_t) bilgisi bir kavşağın diğerine benzer olan yön indeksi olarak bulunmaktadır. Herhangi iki komşu kavşak için kavşak yönlerinin benzerliği yön indeksi üzerinden değil de bu yönlere ait içerik verilerin benzerliği üzerinden yapılmaktadır. Verinin dört yönlü bir kavşaktan geldiği bilinmektedir. ToplulukAT algoritmasında bir sayaç (c) tutulur, 13. satırda sayaç kavşağın tüm giriş yönleri sayısından küçük ise tüm yönlere ait geçmiş veriler geçmiş matrisine (h) kaydedilir ve sayaç (c) artmaya devam eder. 16. satırda sayaç kavşağa giriş yönleri sayısına geldiğinde, verinin geldiği kavşağın yön indekslerinin sayısı ile komşu kavşak karakteristiğine uygun yön indeksleri karşılaştırılır. Bu çalışmada referans kavşak içeriği dikkate alındığında komşu kavşağın en az üç yönünün benzer karakteristikler göstermesi normal durum olarak kabul edilmiştir. Eğer komşu kavşağın yönleriyle içerik olarak üçten az benzer yön bulunursa algoritmanın 18. satırında topluluk anomalisi olarak kaydedilir.

4. BULGULAR VE TARTIŞMA

Bu çalışmada akıllı fabrikalarda durum farkındalığına yönelik önerilen içeriksel tabanlı anomali tespiti ve topluluk tabanlı anomali tespiti yöntemleri SUMO benzetim ortamında oluşturulan trafik karakteristiği için test edilmiştir.

Fabrika içi trafik karakteristiğini benzetimini yapmak için Şekil 3.2’de verilen ortama ait belli taşıma görevleri için oluşturulan araç rotaları kullanılmıştır (Yazıcı, 2019). Burada fabrika içi ihtiyaç olan yük taşıma problemleri için 16 robota görev ataması yapılmış olup, herhangi bir robot için örnek bir rota; “<route id="route0" edges="-40842 -40846 -40298 -40300 -40266 -40302 -40306 -40312 -40314 -40590 -40554 -40594 -40606 -40228 -40226 -40222 -40162 -40836 -40838 -40834 -40830" />” şeklindedir. Bu taşıma görevi 13.86 dakikada bitmekte olup Şekil 4.1’de taşıma benzetimine ait örnek bir SUMO görseli bulunmaktadır. Şekil 4.1’deki her bir kavşak için yön numaralandırmaları (bkz.) Şekil 3.6’daki gibidir. Her gün için temsili olarak 8:00 ve 8:15 zaman dilimi için ortamda yakın karakteristik oluşturacak şekilde 250 gün ve 2500 gün olmak üzere iki veri kümesi oluşturulmuştur. Bu verilere ait Çizelge 3.3’deki bağlam bilgileri tüm kavşaklar için kaydedilmiştir. Bu zaman aralığı için kullanılan iş planlamaları birinci, ikinci, üçüncü ve dördüncü kavşakların yoğun bir şekilde kullanıldığı, beşinci ve altıncı kavşakların ise az yoğun bir trafik oluşturmaktadır.



Şekil 4.1. SUMO Ortamı Örnek Görüntü Görseli Kavşak Numaralandırılması

Takip eden alt bölümlerde oluşturulan veri kümesi için uygulanan anomali tespit yöntemlerinin testleri detaylandırılmaktadır.

4.1. İçerik Tabanlı Anomali Testi


İçerik tabanlı anomali yöntemlerinin testi için birinci, ikinci ve beşinci kavşaklar için üretilen veri kullanılmıştır. Testler için Çizelge 4.1’de verilen yedi farklı senaryo oluşturulmuştur. İlk üç test senaryosunda her bir kavşağa ait 250 günlük verinin öğrenilmesi ve anomali oluşup oluşmadığı test edilmiştir. Dördüncü ve beşinci testlerde ise birinci kavşak için olan 250 günlük verinin bazı günlerini içeriksel anomali oluşacak şekilde test verisi oluşturulmuştur.

Çizelge 4.1. Test Senaryosu Açıklamaları

	Açıklaması
Test 1	Birinci kavşağa ait 250 günlük trafik verisi
Test 2	İkinci kavşağa ait 250 günlük trafik verisi
Test 3	Beşinci kavşağa ait 250 günlük trafik verisi
Test 4	Birinci kavşağa ait 250 günlük trafik verisi(29. Gün trafik verisi anormal)
Test 5	Birinci kavşak 250 günlük trafik verisi (200-250. Gün arasında trafik karakteristiği değişmekte)

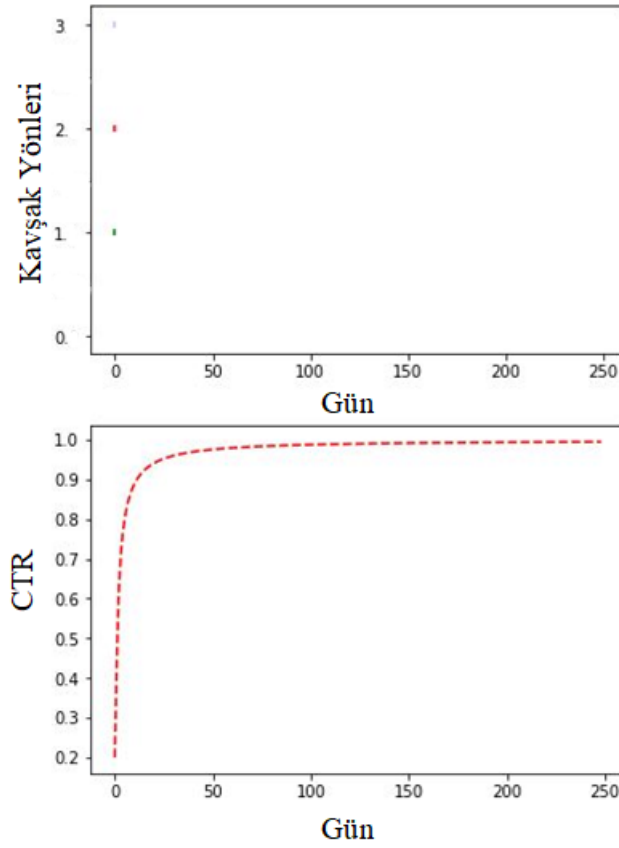
Çizelge 4.1’de verilen test senaryoları için LinUCB_IcerikselAT algoritması ile testler gerçekleştirilmiştir. Tüm testler için keşfetme ve sömürü katsayısı 0,01 alınmıştır. Testlere ait grafikler sırasıyla Şekil 4.2, Şekil 4.3, Şekil 4.4, Şekil 4.5, Şekil 4.6’da verilmektedir. Tüm grafiklerde x eksenini veri gün değeri, y eksenini ise ilgili kavşaklara ait bulunan anomaliler ve CTR değerlerini göstermektedir.

Birinci teste ait Şekil 4.2 incelendiğinde ilk iki gün anomali tespit edildiği sonraki günlerde ise öğrenmenin doğru gerçekleştirildiği görülmektedir. İlk iki günde tespit edilen anomali ilgili kavşağa ait gerçek bir anomali olmayıp öğrenme başlangıcı olarak değerlendirilmektedir. CTR değeri ise 250 gün sonunda 1 olmuştur.



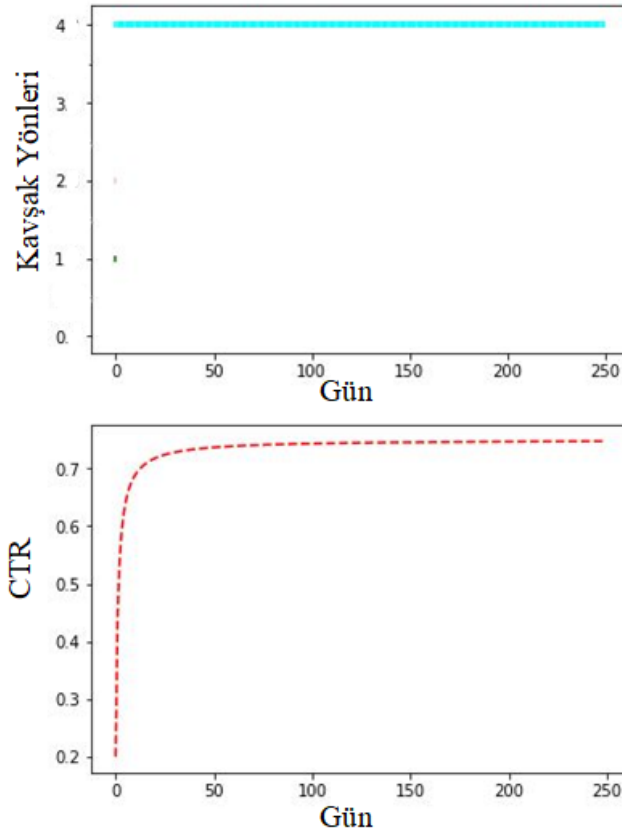
Şekil 4.2. Birinci Test Sonuçları

Kavşak ikiye ait ikinci teste ise Şekil 4.3'de görüldüğü gibi öğrenmenin olduğu ilk günlerde daha fazla anomali tespit edilmektedir. Yukarıda ifade edildiği gibi bunlarda öğrenme başlangıcı olarak değerlendirilebilir. Genel olarak CTR değerinin düşük olduğu günlerde ortaya çıkan anomali sonuçları değerlendirmeye alınmayabilir. Bu testte CTR değeri ise 250 gün sonunda 0,99 olmuştur.




Şekil 4.3. İkinci Test Sonuçları

Kavşak beşe ait üçüncü teste ise Şekil 4.4’de görüldüğü gibi ilk günlerde bazı anomaliler tespit edilmekle birlikte, dördüncü yöne ait öğrenmenin gerçekleşmediği görülmektedir. Buna bağlı olarak 250 günün sonunda CTR değeri 0,75 olmaktadır. Bu kavşak için önerilen anomali tespit algoritması sadece üç yön için çalışabilir. Diğer tarafta bu kavşağa ait trafik karakteristik verileri incelendiğinde diğer kavşaklara oranla trafik yoğunluğunun düşük olduğu ve iki yönde ise trafik karakteristiğine ait bağlam verilerinin birbirine çok benzer olduğu tespit edilmiştir.




Şekil 4.4. Üçüncü Test Sonuçları

Dördüncü testte, 250 günlük birinci kavşağa ait veri içerisinde bir günlük kavşak giriş yönlerinden birinde oluşan yaya yoğunluğu nedeni ile anomali durum barındıran bir veri seti kullanılmıştır. Burada 1 yönünden gelen normal bir veri; “1 1530252900 7 0 0 4 188 3 0 38 0 3 0 0 4 125 1 0 19 2 1 0 0 5 8 0 0 12 3 1 0 1 5 5 0 0 12” bu şekilde iken yaya geçidinde oluşan yaya yoğunluğu nedeni ile bu yöne ait karakteristik; “1 1530252900 1 0 0 3 53 0 0 8 0 0 0 0 0 0 0 0 2 0 0 0 0 0 0 0 3 1 0 0 6 7 0 0 13” şeklinde oluşmuştur. Bu içerik bilgisinden verinin geldiği yöndeki araç akışının azaldığı olduğu görülmektedir. Bu teste ait Şekil 4.5 incelendiğinde 30. Günde Şekil 4.2’den farklı olarak bir nolu yönde anomali tespit edildiği görülmektedir. İlgili güne ait CTR değerinde de bir düşme olduğu görülmektedir.



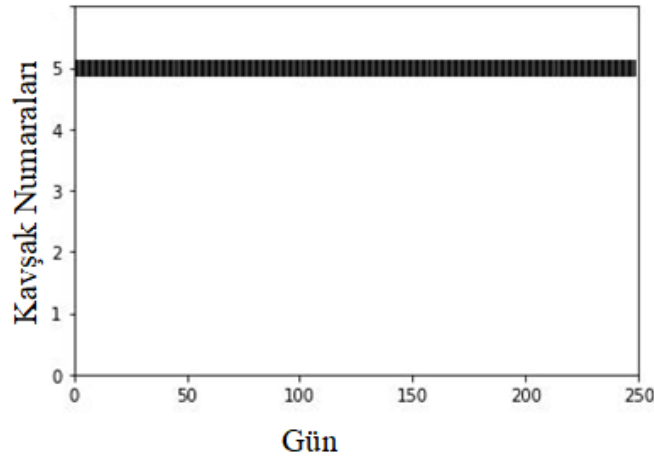
Şekil 4.5. Dördüncü Test Sonuçları

Beşinci testte ise birinci kavşağa ait 250 günlük verinin son 50 gününde önceki karakteristiğe benzemeyen test verisi oluşturulmuştur. Şekil 4.6 incelendiğinde 200. Günden itibaren yoğun bir şekilde anomali tespitlerinin olduğu, CTR değerinin düşmeye başladığı görülmektedir. Bu şekildeki 200- 250 gün arası olan 50 gün için oluşan toplam 200 tane trafik karakteristiğinin 52 tanesini doğru tespit etmiştir. Burada oluşan yeni trafik karakteristiğine bağlı olarak ilk başlarda yüksek anomali tespit edilmekle beraber daha sonraki günlerde bu oranın düştüğü görülmektedir. Bu oluşan yeni karakteristiğinin öğrenilmeye başladığı anlamına gelir. Eğer algoritmadaki keşfetme-sömürü katsayısı yüksek seçilirse buradaki öğrenme sürecinde daha hızlı olacağı beklenmektedir.



Şekil 4.7. Kavşaklar Arası Anomali Tespiti için Odaklanılan Kavşaklar

Şekil 4.8’de iki numaralı kavşağın referans olarak kullanıldığı ve bir - beş numaralı kavşakta öğrenilmiş veriye göre oluşan anomaliler verilmektedir. Birinci ve ikinci kavşaklar birbirine komşu ve benzer yoğunlukta trafiğe sahiptirler. Şekil 4.8’de beş numaralı kavşağın iki numaralı referans kavşağa göre her gün için anomali oluşturduğu gözlemlenmektedir. Bu şekilde bakarak ToplulukAT algoritmasına göre bir numaralı kavşağın iki numaralı kavşağa benzerlik gösterdiği gözlemlenmiştir.



Şekil 4.8. Topluluk Anomali Tespiti

Kavşaklardaki yönlere ait trafik karakteristikleri benzerliklerinin detayları incelenmek istendiğinde Çizelge 4.2 kullanılabilir. Çizelge 4.2’deki bir numaralı kavşağın, iki numaralı kavşakla yön benzerlikleri incelendiğinde kavşak birdeki bir ve üç numaralı yönün kavşak ikideki bir numaralı yöne benzediği görülmektedir. Anomali tespitinde kullanılan %75 benzerlik oranından dolayı burada bir anomali gözlenmemektedir. Diğer taraftan beş numaralı kavşağın bir – iki numaralı yönünün, iki numaralı kavşaktaki bir numaralı yöne benzediği, üç – dört numaralı yönün ise iki numaralı yöne benzediği

gözlemlenmektedir. Burada benzerlik oranı %50 olduğu için anomali olarak değerlendirilmiştir.

Çizelge 4.2. Kavşak Yön Benzerlikleri

Kavşak 2 (Referans Kavşak)	Kavşak 1	Kavşak 5
1	1, 3	1, 2
2	2	3, 4
3	-	-
4	4	-

5. SONUÇ VE ÖNERİLER

Bu çalışmada akıllı fabrikalardaki iç lojistik trafik karakteristiğinin veri üzerinden izlenerek, oluşan farklı anomalilerin tespitine yönelik kavramlar geliştirilmiş ve önerilen yöntem deneysel çalışma ile desteklenmiştir. Kavşaklarla ilgili içeriksel anomali ve topluluk anomalisi olmak üzere iki tip anomalinin tespitine odaklanılmıştır. Fabrika içerisindeki kavşakların karakteristiklerinin öğrenilmesi için bağlamsal slot makinesi problemi modeli kullanımı önerilmiş olup, kavşak bazında yönlerde oluşabilecek içeriksel anomalilerin tespiti için bu model üzerine iki yaklaşım sunulmuştur. Önerilen LinUCB_IcerikselAT algoritması ile herhangi bir kavşaktaki trafik karakteristiğindeki anormal değişim otuz beş adet trafik parametresi değerlendirilerek tespit edilebilmektedir. Yapılan deneysel çalışmalarda kavşak karakteristiğinin değişmeye başladığı durumlarda ilk olarak bu durumları anomali olarak kaydetmiş daha sonra öğrenmeye devam ettiği için kavşak karakteristiğini yeni gelen duruma zamanla uyum sağlamış ve anomali tespiti uyarıları azalmıştır. Önerilen ToplulukAT algoritması ile komşu kavşaklar arasında trafik karakteristiği açısından anormal olup olmadığı test edilmiştir. Yapılan testlerde trafik yoğunluğunun benzer olduğu kavşaklarda önerilen yöntem anomali üretmemiş olup farklı trafik karakteristiği olan kavşaklar arasında anomali tespiti yapılmıştır. Önerilen içeriksel anomali tespiti algoritması fabrikalardaki OTA'ların görevleri sırasında oluşan ve trafik karakteristiğini etkileyen anomalilerin tespiti için kullanılabilir. Önerilen topluluk tabanlı anomali tespiti algoritması ise OTA'ların görevlerinin planlanması sırasında fabrika içi trafiğinde dengeli olacak şekilde yapılmasında kullanılabilir.

Gelecek çalışmalarda, sadece kavşaklarda değil fabrika içi yollarda ve doldur boşalt noktalarında karakteristiklerini öğrenerek anomali tipleri detaylandırılabilir. Ayrıca fabrika içi taşıma görevleri ile oluşan trafik karakteristiği beraber öğrenilerek planlama algoritmalarının mevcuttan farklı bir yük dağılımına göre planlama yapması gibi farklı tip anomali tespitleri yapılabilir.

KAYNAKLAR DİZİNİ

- Adams, M. J., Pew, R. W., Situational awareness in the commercial aircraft cockpit: a cognitive perspective. In 9th IEEE/AIAA/NASA Conference on Digital Avionics Systems, IEEE, doi: 10.1109/dasc.1990.111342
- Ahmed, M., 2018, Collective Anomaly Detection Techniques for Network Traffic Analysis. *Annals of Data Science*, 5(4), 497–512, doi: 10.1007/s40745-018-0149-0
- Aksoy, S., 2017, Değişen teknolojiler ve endüstri 4.0: endüstri 4.0'ı anlamaya dair giriş. *SAV Katkı*, 2017 (4): 34-44
- Arodź, T., Kurdziel, M., Sevre, E. O. D., Yuen, D. A., 2005, Pattern recognition techniques for automatic detection of suspicious-looking anomalies in mammograms. *Computer Methods and Programs in Biomedicine*, 79(2), 135–149, doi: 10.1016/j.cmpb.2005.03.009, erişim tarihi: 17.02.2019
- Auer, P., Cesa-Bianchi, N., Freund, Y., Schapire, R. E. (n.d.), 1995, Gambling in a rigged casino: The adversarial multi-armed bandit problem. In *Proceedings of IEEE 36th Annual Foundations of Computer Science*. IEEE Comput. Soc. Press, doi: 10.1109/sfcs.1995.492488
- Auer, P., Cesa-Bianchi, N., Freund, Y., Schapire, R. E., 2002, The Nonstochastic Multiarmed Bandit Problem. *SIAM Journal on Computing*, 32(1), 48–77, doi: 10.1137/s0097539701398375
- Awad M., Khanna R., 2015, Machine Learning. In: *Efficient Learning Machines*. Apress, Berkeley, CA, doi: 10.1007/978-1-4302-5990-9_1, erişim tarihi: 17.02.2019
- Berglund, M., Karlton, J., 2015, Situation Awareness in production planning and scheduling, *Proceedings 19th Triennial Congress of the IEA, Melbourne 9-14 August 2015*
- Billings, C. E., 1995, Situation awareness measurement and analysis: A commentary. *Proceedings of the International Conference on Experimental Analysis and Measurement of Situation Awareness*, Embry-Riddle Aeronautical University Press, FL.
- Castaldo, F., Palmieri, F., A., N., Regazzoni, C. S., Bayesian Analysis of Behaviors and Interactions for Situation Awareness in Transportation Systems, in *IEEE Transactions on Intelligent Transportation Systems*, vol. 17, no. 2, pp. 313-322, Feb. 2016, doi: 10.1109/TITS.2015.2466695

KAYNAKLAR DİZİNİ (devam)

- Chandola, V., Banerjee, A., Kumar, V., 2009, Anomaly detection. *ACM Computing Surveys*, 41(3), 1–58, doi: 10.1145/1541880.1541882
- Chu, W., Li, L., Reyzin, L., Schapire, R., 2011, Contextual Bandits with Linear Payoff Functions. *Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics*, in PMLR 15:208-214
- Dayan, P., Niv, Y., 2008, Reinforcement learning: The Good, The Bad and The Ugly. *Current Opinion in Neurobiology*, 18(2), 185–196, doi: 10.1016/j.conb.2008.08.003
- Daw, N. D., Niv, Y., Dayan, P., 2005, Uncertainty-based competition between prefrontal and dorsolateral striatal systems for behavioral control. *Nature Neuroscience*, 8(12), 1704–1711, doi: 10.1038/nn1560
- Ding, K., Li, J., Liu, H., 2019, Interactive Anomaly Detection on Attributed Networks. In *Proceedings of the Twelfth ACM International Conference on Web Search and Data Mining - WSDM '19*. ACM Press, doi: 10.1145/3289600.3290964
- Endsley, M. R., 1988, Situation awareness global assessment technique (SAGAT). Paper presented at the National Aerospace and Electronic Conference (NAECON), Dayton, OH.
- Endsley, M. R., 1995, Toward a Theory of Situation Awareness in Dynamic Systems. *Human Factors: The Journal of the Human Factors and Ergonomics Society*, 37(1), 32–64, doi: 10.1518/001872095779049543
- Emerson, T. J., Reising, J. M., and Britten-Austin, H. G., 1987, Workload and situation awareness in future aircraft. SAE Technical Paper (No. 871803). Warrendale, PA: Society of Automotive Engineers.
- García-Teodoro, P., Díaz-Verdejo, J., Maciá-Fernández, G., Vázquez, E., 2009, Anomaly-based network intrusion detection: Techniques, systems and challenges. *Computers & Security*, 28(1–2), 18–28, doi: 10.1016/j.cose.2008.08.003
- Garzon, M., Spalanzani, A., 2018, An hybrid simulation tool for autonomous cars in very high traffic scenarios. In *2018 15th International Conference on Control, Automation, Robotics and Vision (ICARCV)*, IEEE, doi: 10.1109/icarvcv.2018.8581290

KAYNAKLAR DİZİNİ (devam)

- Goodall, J. R., Ragan, E. D., Steed, C. A., Reed, J. W., Richardson, G. D., Huffer, K. M. T., ... Laska, J. A., 2019, Situ: Identifying and Explaining Suspicious Behavior in Networks. *IEEE Transactions on Visualization and Computer Graphics*, 25(1), 204–214, doi: 10.1109/tvcg.2018.2865029
- Hayes, M., A., Capretz, M., A., 2015, Contextual anomaly detection framework for big sensor data. *Journal of Big Data*, 2(1), doi: 10.1186/s40537-014-0011-y
- Hyvonen, M., Rajala, M., Virtanen, A., Jankkari, J., Huhtala, K., & Ritala, R. (2015). Assistive Situation Awareness System for Mobile Multimachine Work Environments. *IEEE Transactions on Intelligent Transportation Systems*, 16(6), 3403–3413, doi: 10.1109/tits.2015.2453208
- Kaelbling, L. P., Littman, M. L., Moore, A. W., 1996, Reinforcement Learning: A Survey. *Journal of Artificial Intelligence Research*, 4, 237–285, doi: 10.1613/jair.301
- Kagermann, H., W. Wahlster, J. Helbig, 2013, Recommendations for implementing the strategic initiative Industrie 4.0: Final report of the Industrie 4.0 Working Group, eds., Frankfurt, 2013.
- Kahraman, S., Zorba, Y., 2018, Situational Awareness Analysis of Port Pilotage Services. *Journal of ETA Maritime Science*, 6(4), 333–347., doi: .5505/jems.2018.48569
- Kreipl, S., Pinedo, M., 2009, Planning and Scheduling in Supply Chains: An Overview of Issues in Practice. *Production and Operations Management - PROD OPER MANAG.* 13. 77-92, doi: 10.1111/j.1937-5956.2004.tb00146.x.
- Kozlovsky, M., Pavlinic, D. Z., Oder, A., Feher, G., Bogdanov, P., 2015, Situation and location awareness in harsh environment. In 2015 38th International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO), IEEE, doi: 10.1109/mipro.2015.7160288
- Lazarevic, A., Banerjee, A., Chandola, V., Kumar, V., Srivastava, J., 2019, Data Mining for Anomaly Detection.

KAYNAKLAR DİZİNİ (devam)

- Li, L., Chu, W., Langford, J., Schapire, R., E., 2010, A contextual-bandit approach to personalized news article recommendation. In Proceedings of the 19th international conference on World wide web - WWW '10. ACM Press., doi: 10.1145/1772690.1772758
- McAree, O., Aitken, J. M., Veres, S. M., 2017, Towards artificial situation awareness by autonomous vehicles * *Research in part supported by the EPSRC, grant numbers EP/L024942/1 and EP/J011843/1. IFAC-PapersOnLine, 50(1), 7038–7043, doi: 10.1016/j.ifacol.2017.08.1349
- McKinney W., 2012, Python for data analysis, O'Reilly Media, Inc.
- Moubayed, A., Injadat, M., Nassif, A. B., Lutfiyya, H., Shami, A., 2018, E-Learning: Challenges and Research Opportunities Using Machine Learning & Data Analytics. IEEE Access, 6, 39117–39138, doi: 10.1109/access.2018.2851790
- Neisser, U., 1979, The concept of intelligence. Intelligence, 3(3), 217–227, doi: 10.1016/0160-2896(79)90018-7
- Örnek, Ö., Vatan, S., Sarıoğlu, S., Yazıcı, A., 2018, Trafik Ağlarında Anomali Tespiti, Eskişehir Osmangazi Üniversitesi Mühendislik ve Mimarlık Fakültesi Dergisi 26 (2018): 132-138
- Park, B.-J., Yoon, C., Lee, J.-W., & Kim, K.-H. (2015). Augmented reality based on driving situation awareness in vehicle. In 2015 17th International Conference on Advanced Communication Technology (ICACT). IEEE, doi: 10.1109/ICACT.2015.7224865
- Rapuzzi, R., Repetto, M., 2018, Building situational awareness for network threats in fog/edge computing: Emerging paradigms beyond the security perimeter model, Future Generation Computer Systems
- Riveiro, M., Falkman, G., Ziemke, T., 2008, Improving maritime anomaly detection and situation awareness through interactive visualization. Proceedings of the 11th International Conference on Information Fusion, FUSION 2008. 1 - 8.
- Russell, J., S., Norvig, P., 2003, Artificial Intelligence: A Modern Approach., Malaysia; Pearson Education Limited.

KAYNAKLAR DİZİNİ (devam)

- Robbins, H., 1952, Some aspects of the sequential design of experiments. *Bulletin of the American Mathematical Society*, 58(5), 527–536, doi: 10.1090/s0002-9904-1952-09620-8
- Salvador, S., Chan, P., 2005, Learning States and Rules for Detecting Anomalies in Time Series. *Applied Intelligence*, 23(3), 241–255, doi: 10.1007/s10489-005-4610-3
- Scholtz, J., Antonishek, B., Young, J., 2005, A field study of two techniques for situation awareness for robot navigation in urban search and rescue. In *ROMAN 2005. IEEE International Workshop on Robot and Human Interactive Communication*, 2005. IEEE, doi: 10.1109/roman.2005.1513769
- Schwabacher, M., 2005, Machine Learning for Rocket Propulsion Health Monitoring. *SAE Transactions*, 114, 1192-1197, <http://www.jstor.org/stable/44682813>, erişim tarihi: 17.02.2019
- Shi, J., Wan, J., Yan, H., Suo, H., 2011, A survey of Cyber-Physical Systems. In 2011 International Conference on Wireless Communications and Signal Processing (WCSP), IEEE, doi: 10.1109/wcsp.2011.6096958
- Shon, T., Moon, J., 2007, A hybrid machine learning approach to network anomaly detection. *Inf. Sci.*, 177, 3799-3821.
- SKAION, 2018, Skaion_2006_IARPA_Dataset-20050903 (09/03/2005 to 10/18/2006) [Data set]. *IMPACT*, doi: 10.23721/112/1354736
- Smith, K., Hancock, P., A., 1995, Situation Awareness Is Adaptive, Externally Directed Consciousness. *Human Factors: The Journal of the Human Factors and Ergonomics Society*, 37(1), 137–148, doi: 10.1518/001872095779049444
- Sriyananda, M. G. S., Parvez, I., Guvene, I., Bennis, M., Sarwat, A. I., 2016, Multi-armed bandit for LTE-U and WiFi coexistence in unlicensed bands. In 2016 IEEE Wireless Communications and Networking Conference. IEEE, doi: 10.1109/wcnc.2016.7564899
- Streilein, W. W., Truelove, J., Meiners, C. R., Eakman, G., 2011, Cyber situational awareness through operational streaming analysis. In 2011 - MILCOM 2011 Military Communications Conference, IEEE, doi: 10.1109/milcom.2011.6127455

KAYNAKLAR DİZİNİ (devam)

- SUMO, 2019, Simülasyon/Çıktı/Şerit veya Kenar Tabanlı Trafik Ölçüleri, https://sumo.dlr.de/wiki/Simulation/Output/Lane-_or_Edge-based_Traffic_Measures, erişim tarihi: 26.04.2019
- Sutton, R. S., Barto, A. G., 2017, Reinforcement Learning: An Introduction, MIT Press. Retrieved, <http://www.cs.ualberta.ca/~sutton/book/the-book.html>, erişim tarihi: 16.02.2019
- Tadema, J., Theunissen, E., 2009, An integrated conflict avoidance concept for aviation. In 2009 IEEE/AIAA 28th Digital Avionics Systems Conference, IEEE, doi: 10.1109/dasc.2009.5347462
- Taylor, R. M., 1990, Situation awareness rating technique (SART): the development of a tool for aircrew systems design. In Situational Awareness in Aerospace Operations (Chapter 3). France: Neuilly-sur-Seine, NATO-AGARD-CP-478.
- Tai, Y., Chan, C., Hsu, J., 2010, Automatic road anomaly detection using smart mobile device.
- Thaika, M., Tasneeyapant, S., Cheamanunkul, S., 2018, A Fast, Scalable, Unsupervised Approach to Real-time Traffic Incident Detection. In 2018 15th International Joint Conference on Computer Science and Software Engineering (JCSSE), IEEE, doi:10.1109/jcsse.2018.8457338
- van der Walt, S., Colbert, S. C., & Varoquaux, G., 2011, The NumPy Array: A Structure for Efficient Numerical Computation, Computing in Science & Engineering, 13(2), 22–30, doi: 10.1109/mcse.2011.37
- van Otterlo, M., Wiering, M., 2012, Reinforcement Learning and Markov Decision Processes. In Adaptation, Learning, and Optimization (pp. 3–42), Springer Berlin Heidelberg, doi: 10.1007/978-3-642-27645-3_1
- Wang, X. ve Zhao T., 2014, A new approach of safety management: System safety situation awareness model and framework, 2014 10th International Conference on Reliability, Maintainability and Safety (ICRMS), Guangzhou, 2014, pp. 1056-1060.
- Watkins, C. J. C. H., Dayan, P., 1992, Q-learning. Machine Learning, 8(3–4), 279–292, doi:10.1007/bf00992698

KAYNAKLAR DİZİNİ (devam)

- Wickens, C. D., 1992, Workload and situation awareness: An analogy of history and implications. *Insight: The Visual Performance Technical group Newsletter*, 14(4), 1-3.
- Yazıcı, A., 2019, Proje Yöneticisi, “Akıllı fabrikalar için otonom taşıyıcılar ve gerekli insan-makine ve makine-makine arayüzlerinin geliştirilmesi”, TUBİTAK, 116E731 nolu proje
- Yu, Z., Xu, Y., Tong, L., 2015, Large scale charging of electric vehicles: A multi-armed bandit approach. In 2015 53rd Annual Allerton Conference on Communication, Control, and Computing (Allerton), IEEE, doi: 10.1109/allerton.2015.7447030
- Zhou, K., Taigang Liu, Lifeng Zhou., 2015, Industry 4.0: Towards future industrial opportunities and challenges. In 2015 12th International Conference on Fuzzy Systems and Knowledge Discovery (FSKD), IEEE, doi: 10.1109/fskd.2015.7382284