

## TRAFİK AĞLARINDA ANOMALİ TESPİTİ

Özlem ÖRNEK<sup>1\*</sup>, Seval VATAN<sup>2</sup>, Serpil SARIOĞLU<sup>3</sup>, Ahmet YAZICI<sup>4</sup>

<sup>1</sup> Eskişehir Osmangazi Üniversitesi, Mühendislik Mimarlık Fakültesi, Batı Meşelik Yerleşkesi,  
Bilgisayar Mühendisliği Bölümü, Eskişehir  
e-posta : [ozlemornek@gmail.com](mailto:ozlemornek@gmail.com), ORCID No : <https://orcid.org/0000-0002-8775-8695>

<sup>2</sup> Eskişehir Osmangazi Üniversitesi, Mühendislik Mimarlık Fakültesi, Batı Meşelik Yerleşkesi,  
Bilgisayar Mühendisliği Bölümü, Eskişehir  
e-posta : [seval.vatan09@gmail.com](mailto:seval.vatan09@gmail.com), ORCID No : <https://orcid.org/0000-0002-1015-7445>

<sup>3</sup> Eskişehir Osmangazi Üniversitesi, Mühendislik Mimarlık Fakültesi, Batı Meşelik Yerleşkesi,  
Bilgisayar Mühendisliği Bölümü, Eskişehir  
e-posta : [serpil.sarioglu1995@gmail.com](mailto:serpil.sarioglu1995@gmail.com), ORCID No : <https://orcid.org/0000-0003-0702-1704>

<sup>4</sup> Eskişehir Osmangazi Üniversitesi, Mühendislik Mimarlık Fakültesi, Batı Meşelik Yerleşkesi,  
Bilgisayar Mühendisliği Bölümü, Eskişehir  
e-posta : [ayazici@ogu.edu.tr](mailto:ayazici@ogu.edu.tr), ORCID No : <https://orcid.org/0000-0001-5589-2032>

DOI : <http://dx.doi.org/10.31796/ogummf.440285>

Makale Geliş : 03.07.2018  
Makale Kabul : 07.11.2018  
Araştırma Makalesi

Article Received : 03.07.2018  
Article Accepted: 07.11.2018  
Research Article

### Trafik Ağlarında Anomali Tespiti

#### Öz

Trafik ağlarının izlenmesi ve kontrolü için veri üzerinden karar verilmesi önemlidir. Bu izlemenin sağlanmasında da anomali tespiti çok önemli bir yere sahiptir. Trafik ağlarında anomali tespiti yaklaşımları ile olaylar erkenden tespit edilerek hızlı müdahale imkanı sağlanır. Bu ise maliyet tasarrufu sağlar. Literatürde farklı alanlardaki problemler için anomali tespitinde sınıflandırma, kümeleme, istatistiksel vb. yaklaşımlar bulunmaktadır. Bu alanda destek vektör makineleri, bayes ağları, bulanık mantık, genetik algoritmalar, karar ağaçları vb. birçok yöntem anomali tespiti için kullanılmaktadır. Bu çalışmada karar ağacı algoritması ile trafik ağlarında anomali tespiti için bir yöntem önerilmiştir. Önerilen yöntem Britanya Kolumbiyası'na ait trafik veri seti kullanılarak test edilmiştir. Önerilen yöntem bayes ağları ile de karşılaştırılmıştır. Yapılan testlerde trafik ağındaki bazı anormal olayların önerilen yöntem ile tespit edilebileceği görülmüştür.

**Anahtar Kelimeler :** Anomali tespiti, karar ağaçları, sınıflandırma algoritmaları, trafik ağları.

### Anomaly Detection in Traffic Networks

#### Abstract

Monitoring and controlling of traffic networks using traffic data is very important. Anomaly detection approach is one of the tools to monitor the traffic network. In this way, events are detected earlier and a quick response become possible. This help decreasing the cost. In the literature, different approaches such as classification, clustering, statistical, etc. are used in the anomaly detection for problems in different domains. Support vector machines, Bayesian networks, fuzzy logic, genetic algorithms, decision trees etc. are some of the main approaches that used to detect anomalies. In this study, a decision tree algorithm is proposed to detect anomaly in traffic networks. The proposed method has been tested using the British Columbia traffic data set. The proposed approach is also compared Bayesian networks. As a result of the performed test, it was seen that some abnormal events in the traffic network could be detected by the proposed method.

**Keywords :** Anomaly detection, decision trees, classification algorithms, traffic networks.

## 1. Giriş

Artan nüfus ile ulaşım altyapısı ve trafik ağları büyümektedir. Bu büyüme ile beraber trafik ağlarının izlenmesi ve kontrolüne yönelik akıllı ulaşım sistemleri alanında ağ üzerindeki birçok noktadan veriler toplanmaktadır. Bazı kritik noktalar kullanıcılar tarafından göz ile izlenirse bile ağın bütünü izlenmesi zordur. Geliştirilen sistemlerin sürdürülebilmesi için ortamdan toplanan veriler kullanılarak olağandışı olayların tespiti önemlidir. Bu alanda literatürde farklı problemlerde kullanılan anomali tespiti yaklaşımları trafik ağlarının izlenmesi ve anormal olayların tespiti için kullanılabilir.

Literatürde trafik ağlarında anomali tespiti için farklı çalışmalar yapılmıştır. Chen vd. (2009), hız, yoğunluk, işgal süresi ve zaman aralığı verilerini kullanarak trafik ağlarındaki olay anomalilerinin tespiti için bir yöntem önermiştir. Bu çalışmada %80 başarı elde edilmiştir. Lu vd. (2014), ortalama hız, yoğunluk ve işgal süresi verileri ile trafik ağlarındaki anormal durumları tespit etmişlerdir. Bu çalışmada %98 başarı elde edilmiştir. Jiang vd. (2010), hız, yoğunluk ve işgal süresi verileri ile olay olan trafik durumlarını tespit etmişlerdir. Trafik ağlarındaki farklı olayların tespitine yönelik değişik yelpazedeki çalışmalar devam etmektedir (Ki vd., 2018; Kongkhaensarn vd., 2018). Trafik ağlarında hız, yoğunluk, işgal süresi ve zaman aralığı gibi durumlar incelenerek trafik ağlarında anomali tespiti yapılabilir.

Bu çalışmada trafik ağlarındaki bölgesel trafik durumuna ait trafik örüntüsü başlangıç enlem ve boylamı, trafik örüntüsü bitiş enlem ve boylamı, rota, alan numarası, yön, nereden, nereye ve tip verileri kullanılarak ulaşım ile ilgili 'Incident' (olay) ve 'Non Incident' (olay olmayan) vb. anomalilerin tespiti için karar ağacı algoritması tabanlı bir yöntem önerilmiştir. Önerilen yöntem Britanya Kolumbiyası'na ait trafik veri kümesi kullanılarak test edilmiştir.

Bölüm 2'de anomali tespiti problemi hakkında bilgi verilmektedir. Bu bağlamda anomali tipleri, anomali tespit problemine yönelik yaklaşımlar, sınıflandırma tabanlı anomali tespit yaklaşımları detaylandırılmaktadır. Bölüm 3'te bu çalışmada önerilen karar ağacı tabanlı anomali tespiti yaklaşımı verilmektedir. Bölüm 4'te test sonuçları başlığı altında uygulama veri kümesi bilgileri ve uygulama sonuçları verilmiştir. Son bölümde ise yapılan çalışmadan oluşan çıkarımlar verilmiştir.

## 2. Anomali Tespiti Problemi

Anormal olaylar seyrek görülür, ancak ortaya çıktıklarında sonuçları oldukça olumsuz olabilir (Chandola vd., 2007). Günümüzde artan dijitalleşme ile anomali tespiti, veriler kullanılarak beklenen davranışa uymayan anormal durumların belirlenmesini sağlar. Bu

alanda literatürde yapılan çalışmalarda anomali tipleri ve tespiti yaklaşımları alanında farklı ontolojiler oluşmuştur.

### 2.1. Anomali Tespiti Yaklaşımları

Anomali tipleri; nokta anomalileri, bağlamsal anomaliler, toplu anomaliler olmak üzere üçe ayrılabilir. Nokta anomalilerinde belli bir veri üzerinde anormal durum incelenir. Bağlamsal anomalilerde bağlam içindeki veri örneği üzerinde inceleme yapılır. Bunlar, koşullu anomaliler olarak da adlandırılırlar. Toplu anomalisinde ilgili veri örneklerinin bir alt kümesi anomali incelemesinde kullanılır (Chandola vd., 2007).

Nokta anomali tespitinde sınıflandırma tabanlı teknikler, en yakın komşu bazlı teknikler, kümeleme tabanlı teknikler, istatistik tabanlı vb. teknikler kullanılmaktadır.

En yakın komşu tabanlı tekniklerde iki adım vardır. Birinci adım her veri kaydı için komşuluğu hesaplamaktır. İkinci adım veri kaydının anormal olup olmadığını belirlemek için komşuluğu analiz etmektir. En yakın komşu tabanlı teknikler iki kategoride incelenebilir. Bu kategorilerden uzaklığa dayalı metotta, normal noktalar yakın komşulara sahipken, anomaliler diğer noktalardan uzaktadır. Yoğunluk tabanlı metodunda ise, anomaliler düşük yoğunluklu bölgelerdeki veri noktalarıdır.

Kümeleme tabanlı tekniklerde normal veri kayıtları büyük ve yoğun kümelerle aitken, anomaliler herhangi bir kümeye ait değildir veya çok küçük kümelenebilir. Kümeleme tabanlı yöntemler kullanılarak anomaliler, herhangi bir kümeye ait olmaması, nesne ve en yakın kümesi arasında büyük mesafe olması, küçük veya seyrek bir kümeye ait olması şeklinde tespit edilebilir.

İstatistiksel tabanlı tekniklerde veri noktaları, stokastik dağılım kullanılarak modellenir. Noktaların bu model ile ilişkilerine bağlı olarak noktanın aykırılığı belirlenir. Çeşitli dağılım türlerini modellemek için mevcut istatistiksel modelleme tekniklerinden yararlanılır. Yüksek boyutlardaki dağılımları tahmin etme zorluğu ve parametrik varsayımların genellikle gerçek veri kümeleri için geçerli olmaması istatistiksel tabanlı tekniklerin olumsuz yanlarıdır. İstatistiksel teknikler; parametrik ve parametrik olmayan teknikler şeklinde ikiye ayrılabilir. Parametrik tekniklerde normal verinin, temel bir parametrik dağılımdan üretildiği varsayılır. Anomalileri tespit etmek için test örneğinin olasılığı bu dağılımdan belirlenir. Parametrik olmayan tekniklerde parametreler hakkında herhangi bir bilgi alınmaz. Dağılımı öğrenmek için parametrik olmayan teknikler kullanılır.

Sınıflandırma tabanlı tekniklerde ana fikir, probleme ait verilerden normal ve anormal veriler etiketlenerek eğitim yapılması daha sonra ise bu eğitim modeli kullanılarak anomali tespiti yapılmasıdır. Bu çalışmada da kullanılan bu yöntemle ilgili detay takip eden alt bölümde verilmektedir.

## 2.2. Sınıflandırma Tabanlı Anomali Tespit Yaklaşımları

Sınıflandırma tabanlı anomali tespitinde etiketli eğitim verilerine dayanan normal ya da anormal olaylar için bir sınıflandırma modeli oluşturulmaktadır. Sınıflandırma modelleri çarpık sınıf dağılımları durumunda çalışabilmelidir. Sınıflandırma tabanlı anomali tespiti iki kategori altında incelenebilir. Kategorilerde denetimli sınıflandırma teknikleri (supervised) ve yarı denetimli sınıflandırma teknikleri (semi-supervised) bulunmaktadır. Denetimli sınıflandırma teknikleri hem normal hem de anormal sınıf bilgisi gerektirir. Normal ve bilinen anomalileri ayırt etmek için sınıflandırıcı oluşturulur. Yarı denetimli sınıflandırma teknikleri ise sadece normal sınıf bilgisi gerektirir. Normal davranışı öğrenmek için modifiye sınıflandırma modeli kullanılır ve normal davranışlardan sapmalar anormal olarak kabul edilir (Chandola vd., 2007).

Denetimli sınıflandırma teknikleri, kolay anlaşılabilen modeller içermesi ve birçok bilinen anomaliyi tespit etmede yüksek doğruluk sağlaması bakımından avantaj; hem normal hem de anormal sınıftan iki etiket gerektirmesi ve bilinmeyen anomalilerin tespit edilememesi bakımından ise dezavantaj sağlar. Yarı denetimli sınıflandırma teknikleri ise kolay anlaşılabilen modeller içermesi ve normal davranışın doğru bir şekilde öğrenilebilmesi bakımından avantaj; normal sınıftan etiket gerektirmesi ve daha önce görülmeyen veri kayıtlarının anomaliler olarak algılanması bakımından ise dezavantaj sağlar.

Literatürde sınıflandırma ile anomali tespiti yapan bazı yöntemler şunlardır:

- Sinir ağı temelli yaklaşımlar
- Destek vektör makineleri
- Bayes ağları temelli yaklaşımlar
- Kural tabanlı teknikler
- Bulanık mantık
- Genetik algoritmalar.

La-inchua vd. (2013), trafik sıklığının başlıca nedenleri arasında bulunan şerit kapanma trafik olaylarını tespit etmek için bir sistem sunmaktadır. Önerilen sistem, trafik durumunu normal ve anormal olarak tanımlamak için bulanık mantık kullanmaktadır. Ortalama hız ve bir aracın gelişi ile bir sonraki aracın gelişi arasındaki zaman miktarının standart sapması bulanık çıkarım sistemine giriş olarak kullanılır.

Algılama oranını ve tespit için geçen ortalama süreyi geliştirmek üzere bulanık çıkarım sistem çıkışlarına çoğunluk oyu uygulanır. Chen vd. (2010), otoyol için destek vektör makinesine (SVM) dayalı otomatik olay tespit algoritması önermiştir. SVM'nin girişi, yukarı akış hızı, olay noktası hızı, aşağı akış hızı, yukarı akış doluluk oranı, olay noktası doluluk oranı ve aşağı akış doluluk oranı olarak seçilir. SVM çıkışı için ise trafik durumu (olay veya olay dışı) seçilmiştir. Chen vd. (2009), trafik kazası tespiti için karar ağacı öğrenme tekniğini uygulamıştır. Test için yoğunluk, hız, zaman aralığı, yukarı akış ve aşağı akış dedektörlerinde işgal süresi içeren trafik verileri bir trafik benzetim sistemi ile oluşturulmuştur. Bu çalışmada, otomatik olay tespiti için karar ağacı öğrenmesi uygulanmıştır.

Karar ağaçları böl ve yönet stratejisini kullanan denetimli öğrenme (supervised learning) sınıfına ait hiyerarşik bir ağaç yapısıdır (Alpaydin, E., 2010). Diğer bir tanımla bir karar ağacı, verilen çıktı sınıfı etiketleri için verilen bir girdinin sınıflandırma sürecini grafik olarak gösteren bir karar modelleme aracıdır (Sam Drazin vd., 2012). Karar ağacı algoritması, hedef değişkenin tahmin edilmesi için kurallar üretir (Gaganjot Kaur vd., 2014). Literatürde sınıflandırma amaçlı; ID3, C4.5, C5.0, THAID, CART, FACT, CHAID, CTree, QUEST, GUIDE ve CRUISE karar ağacı algoritmaları vardır.

Bu algoritmalar kök düğüm, iç düğüm ve yaprak düğümlerinden oluşur. Her bir iç düğüm bir öznitelik üzerinde test anlamına gelir, her bir dal testin bir sonucunu temsil eder ve her bir yaprak düğümü bir sınıf etiketine sahiptir.

## 3. Karar Ağacı Tabanlı Anomali Tespiti

Karar ağaçları içerisinde sürekli ve ayrık veri içeren problemlerde anomali tespiti için kullanılabilir. Karar ağacı modelinin okunabilir olması kavramsal geliştirmelerde de önemli avantajlar sağlamaktadır. Karar ağacı modeli elde edildikten sonra budama işlemi ile verimlilik optimize edilebilir. Budama işlemi sonucunda ağacın boyutu küçülür. Gereksiz karmaşıklık önlenir. Sonradan budama tekniğinde genellikle ağaç oluştuktan sonra önemli olmayan dalları kaldırarak budama işlemi yapılır. Karar ağacı algoritmasında budama tekniklerinden Reduced-error pruning (REP) kullanılır. REP, ağaçların doğruluğunu denetler. Doğruluk azalmazsa, düğüm budama yapılır. Prosedür daha fazla budama, doğruluğu azaltıncaya kadar devam eder (Lior, 2014). Karar ağacı algoritmasında arama yöntemi olarak greedy search-hill climbing yöntemi kullanılır.

Karar ağaçlarında eğitim veri kümesinin sınıfların dağılımının düzensizliği daha doğru sonuç almak için önemlidir. Karar ağaçlarında bilgi kazanımı veri

kümesinde özniteliklerin alt gruplarına göre entropi azalması göstergesidir. Seçilen yaprak özelliğinin tek tek diğer özelliklere göre dağılımı hesaplanır. Hesaplanan sonuçlar toplam entropiden çıkarılarak bilgi kazanımı bulunur.

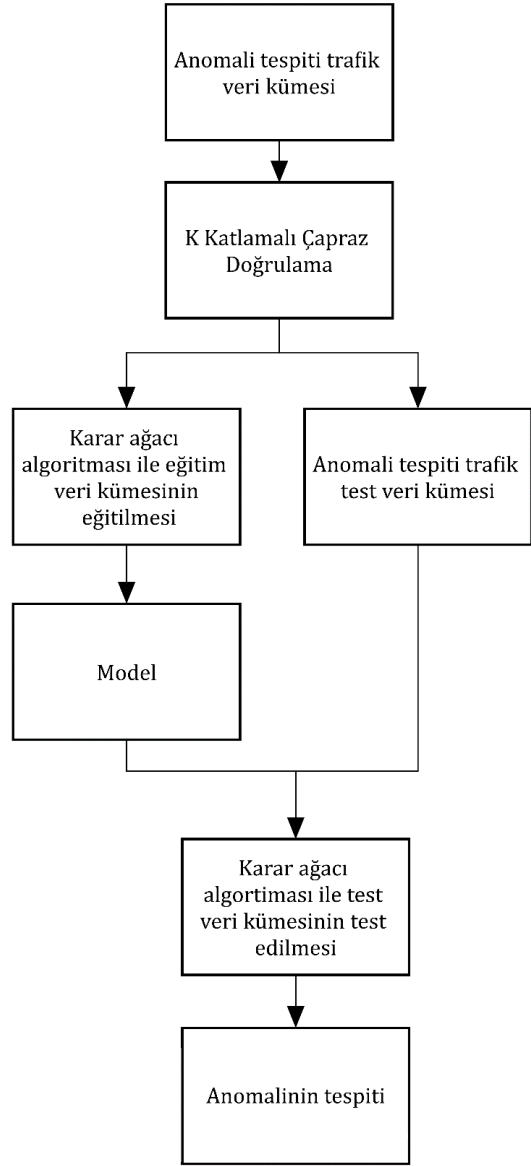
Karar ağaçlarında her yaprak için bir kural üretilir. Kökten yapağa giden yoldaki her düğüm bir koşul içerir. Kuralın sonucu yaprak tarafından atanan sınıftır. (Witten vd, 1999).

Bu çalışmada trafik ağlarındaki anomali tespiti için kullanılan veri setinin tüm öznitelikleri Tablo 1’de verilmektedir.

**Tablo 1. Veri Kümesi Öznitelikleri**

Öznitelik Adı	Örnek Veri
Id	204892
Bölge	Rocky Mountain District
Durum	Ongoing
Derece	Major
Zaman	01/02/2016 08:57:47
Trafik Örüntüsü	20 minutes delay
Trafik Örüntüsü Başlangıç Enlem	54.224.876
Trafik Örüntüsü Başlangıç Boylam	-125.754.118
Trafik Örüntüsü Bitiş Enlem	54.051.574
Trafik Örüntüsü Bitiş Boylam	-125.756.769
Rota	Highway 35 Both directions
Alan Numarası	10
Yön	north
Nereden	Francois Lake
Nereye	'Junction with Highway 16, in Burns Lake'
Tip	Non Incident

Şekil 1’de önerilen karar ağacı tabanlı anomali tespiti yaklaşımı eğitim ve test süreçleri verilmiştir.



**Şekil 1. Anomali Tespiti Akış Diyagramı**

Yapılan çalışmalarda veriler veri setinden alındığı gibi aynen kullanılmıştır. Test için  $k$  katlamalı çapraz doğrulama kullanılmıştır. Burada  $k$  değeri 10 olarak seçilmiştir. Daha sonra karar ağacı algoritması ile oluşturulan model ile anomali tespit edilmektedir.

#### 4. Test Sonuçları

##### 4.1. Uygulama Veri Kümesi

Bu çalışmada Britanya Kolumbiyası'na ait yıllık olarak güncellenen veri kümesinden 2016 yılına ait yol

koşullarını, trafik kazalarını, mevcut ve planlanan yol çalışma faaliyetlerine ait bilgileri içeren veri kümesi test amaçlı kullanılmaktadır (British Columbia Ministry of Transportation and Infrastructure-Business Management Services, 2018). Veri kümesinde Tablo 1’de verilen 16 adet öznitelik bulunmakta olup toplamda 123061 adet veri vardır. Bu çalışmada Tablo 2 ile verilen öznitelikler kullanılmıştır.

**Tablo 2. Eğitim ve Test Veri Kümesi Öznitelikleri**

Öznitelik Adı
Trafik Örüntüsü Başlangıç Enlem
Trafik Örüntüsü Başlangıç Boylam
Trafik Örüntüsü Bitiş Enlem
Trafik Örüntüsü Bitiş Boylam
Rota
Alan Numarası
Yön
Nereden
Nereye
Tip

Britanya Kolumbiyası yollarına ait veri kümesinde bulunan ‘Incident’ (olay) ve ‘Non Incident’ (olay olmayan) sayısının mevsimsel olarak değişiklik göstermektedir. Kış aylarında daha çok ‘Incident’ sayısı bulunurken yaz aylarında ‘Non Incident’ sayısı daha fazla bulunmaktadır.

#### 4.2. Uygulama Sonuçları

Uygulamada karar ağaçları için Weka ortamında bulunan J48 algoritması anomali tespiti için kullanılmıştır. J48 algoritması, Weka veri madenciliği aracında C4.5 karar ağacı algoritmasının açık kaynaklı bir Java uygulamasıdır. Ayrıca yine Weka’da bulunan bayes ağları ile de sonuçlar karşılaştırılmıştır. Tablo 3’te J48 ve bayes ağları algoritması sonuçları verilmektedir.

**Tablo 3. Anomali Tespiti Çalışma Sonuçları**

		Karar Ağaçları	Bayes Ağları
Model Oluşturma Zamanı		2.45 saniye	1.45 saniye
Doğru Sınıflandırılmış Örnekler		97.6938 %	93.9623 %
Doğru Sınıflandırılmış Pozitif Örnek Oranı	Olay Var	0,768	0,888
	Olay Yok	0,993	0,944
Yanlış Sınıflandırılmış Pozitif Örnek Oranı	Olay Var	0,007	0,056
	Olay Yok	0,232	0,112
Kesinlik	Olay Var	0,902	0,555
	Olay Yok	0,982	0,991
Hassasiyet	Olay Var	0,768	0,888
	Olay Yok	0,993	0,944

J48 algoritması ile %97.6938 oranında ve bayes ağları algoritması ile %93.9623 oranında örnekler doğru sınıflandırılmıştır. Algoritmaların model oluşturma süreleri farklıdır. J48 algoritmasının model oluşturma süresinin bayes ağları algoritmasından daha fazla olduğu görülmektedir. Doğru sınıflandırılmış pozitif örnek sayısı, yanlış sınıflandırılmış pozitif örnek sayısı, kesinlik ve hassasiyet değerleri algoritmalarda farklılıklar göstermektedir. Örnek olarak, doğru sınıflandırılmış örnek oranı “olay var” sınıfı için bayes ağları algoritmasında J48 algoritmasından daha büyüktür.

#### 5. Tartışma

Trafik ağlarında sürdürülebilirliğin sağlanması önemlidir. Bu nedenle trafik ağları için veri üzerinde anomali tespiti yapılmaktadır. Britanya Kolumbiyası’na ait 2016 yol verileri kullanılarak anomali tespit yöntemlerinden nokta anomalileri alanında bulunan sınıflandırma tabanlı yöntemlerden karar ağacı algoritması kullanılarak anomali tespiti yapılmıştır. Literatür incelendiğinde bu veri seti için anomali tespiti çalışmasına rastlanılmamıştır. Yapılan çalışmanın

sonuçları incelendiğinde farklı veri setlerinde anomali tespiti yapan çalışmalar ile benzer sonuçlar elde edilmiştir. Karar ağacı modelinin okunabilir olması, yeni kavram geliştirilmesi yapılan konularda önemli avantaj sağlamaktadır.

### Teşekkür

Bu çalışmada desteklerini sağlayan, Araş. Gör. Dr. Sinem BOZKURT'a ve Araş. Gör. Elif DEĞİRMENCİ'ye teşekkür ederiz.

### Çıkar Çatışması

Yazarlar tarafından herhangi bir çıkar çatışması beyan edilmemiştir.

### Kaynaklar

Alpaydın, E. (2010). *Introduction to machine learning*. İkinci Baskı, MIT press, 579s.

Barria, J. A., & Thajchayapong, S. (2011). Detection and classification of traffic anomalies using microscopic traffic variables. *IEEE Transactions on Intelligent Transportation Systems*, 12(3), 695-704.

Brijain, M., Patel, R., Kushik, M., & Rana, K. (2014). A survey on decision tree algorithm for classification. *International Journal of Engineering Development and Research*, 5(4).

British Columbia Ministry of Transportation and Infrastructure-Business Management Services. Historical DriveBC Events. <https://catalogue.data.gov.bc.ca/dataset/historical-drivebc-events> (erişim tarihi: Temmuz 2018).

Chandola, V., Banerjee, A., & Kumar, V. (2007). Anomaly detection: A survey. *ACM computing surveys (CSUR)*, 41(3), 15.

Chen, L., Cao, Y., & Ji, R. (2010). Automatic incident detection algorithm based on support vector machine. *IEEE 2010 Sixth International Conference on Natural Computation (ICNC)*, 864-866.

Chen, S., & Wang, W. (2009). Decision tree learning for freeway automatic incident detection. *Expert Systems with Applications*, 36(2), 4101-4105.

Drazin, S., & Montag, M. (2012). Decision tree analysis using weka. *Machine Learning-Project II*, University of Miami, 1-3.

Friedman J., Kohavi R., and Yun Y., (1996). Lazy decision trees. *In Proceedings of the Thirteenth National Conference on Artificial Intelligence*, 717-724.

Grabczewski, K. (2014). Meta-learning in decision tree induction. *Studies in Computational Intelligence*, Springer International Publishing, 349s.

Hodge, V., & Austin, J. (2004). A survey of outlier detection methodologies. *Artificial intelligence review*, 22(2), 85-126.

Jiang, G., Niu, S., Li, Q., Chang, A., & Jiang, H. (2010). Automated incident detection algorithms for urban expressway. *IEEE 2nd International Conference on Advanced Computer Control (ICACC)*, 70-74.

Ki, Y. K., Heo, N. W., Choi, J. W., Ahn, G. H., & Park, K. S. (2018). An incident detection algorithm using artificial neural networks and traffic information. *IEEE Cybernetics & Informatics (K&I)*, 1-5.

Kinoshita, A., Takasu, A., & Adachi, J. (2014). Real-time traffic incident detection using probe-car data on the Tokyo Metropolitan Expressway. *2014 IEEE International Conference on Big Data (Big Data)*, 43-45.

Kongkhaensarn, T., & Piantanakulchai, M. (2018). Comparison of probabilistic neural network with multilayer perceptron and support vector machine for detecting traffic incident on expressway based on simulation data. *2018 15th International Joint Conference on Computer Science and Software Engineering (JCSSE)*, 1-6.

La-inchua, J., Chivapreecha, S., & Thajchayapong, S. (2013). A new system for traffic incident detection using fuzzy logic and majority voting. *IEEE 2013 10th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON)*, 1-5.

- Lazarevic, A., Banerjee, A., Chandola, V., Kumar, V., & Srivastava, J. (2008). Data mining for anomaly detection. *Tutorial at the European Conference on Principles and Practice of Knowledge Discovery in Databases*.
- Lior, R. (2014). *Data mining with decision trees: theory and applications*. İkinci Baskı, World Scientific Publishing Co., Inc., Amerika Birleşik Devletleri, 328s.
- Liu, Q., Lu, J., Chen, S., & Zhao, K. (2014). Multiple Naïve bayes classifiers ensemble for traffic incident detection. *Mathematical Problems in Engineering*.
- Lu, J., Liu, Q., Yuan, L., & Chen, S. (2014). Grafted Decision Tree for Freeway Incident Detection. *CICTP 2014: Safe, Smart, and Sustainable Multimodal Transportation Systems*, 467-477.
- Payne, H. J., & Tignor, S. C. (1978). Freeway incident-detection algorithms based on decision trees with states. *Transportation Research Record Journal of the Transportation Research Board*, (682).
- Quinlan, J. R. (2014). *C4. 5: programs for machine learning*. Birinci Baskı, Elsevier, 302s.
- Raiyn, J., & Toledo, T. (2014). Real-time road traffic anomaly detection. *Journal of Transportation Technologies*, 4(03), 256.
- Sewaiwar, P., & Verma, K. K. (2015). Comparative study of various decision tree classification algorithm using WEKA. *International Journal of Emerging Research in Management & Technology*, 4, 2278-9359.
- Witten, I. H., & Frank, E. (1999). *Data mining: Practical machine learning tools and techniques with java implementations*. İkinci Baskı, Elsevier, Morgan Kaufmann Publishers, San Francisco, 558s.