



## Motor vehicle inspection and error associations prediction

Gizem Çetin Yılmaz\*<sup>ID</sup>, Ömer Özgür Tanrıöver<sup>ID</sup>

Department of Computer Engineering, Faculty of Engineering, Ankara University, 06830, Ankara, Türkiye

### Highlights:

- Applying data mining to vehicle inspection data
- Vehicle inspection result estimation
- Vehicle defects association analysis

### Keywords:

- Vehicle inspection
- Machine learning
- Classification
- Association analysis

### Article Info:

Research Article

Received: 14.12.2021

Accepted: 23.03.2024

### DOI:

10.17341/gazimmfd.1036562

### Correspondence:

Author: Gizem Çetin Yılmaz

e-mail:

gizemcetin06@gmail.com

phone: +90 536 906 6304

### Graphical/Tabular Abstract

Vehicle inspection is a system in which the technical qualifications of motorized or non-motorized vehicles in traffic are measured and whether passenger and traffic safety is provided or not. In Turkey, periodic inspections of approximately 6 million vehicles are carried out every year in order to carry out technical inspections of vehicles traveling on the road more effectively and healthily and to ensure road traffic safety. In this research study, vehicle inspection result prediction and defect association analysis were performed by using vehicle inspection data, machine learning and deep neural networks (Figure A). With the apriori algorithm, which is one of the association rules extraction methods, the analysis of the defects seen as a result of the inspection of the vehicles was carried out and significant relationships were found between the vehicle defects. In addition, from machine learning prediction methods, Logistic Regression (LR), Naive Bayes (NB), Decision Trees (DT), Random Forest (RF), K-Nearest Neighbor (KNN), Gradient Boost (XGBoost), AdaBoost, Deep Neural Network (DNN) and Convolutional Neural Network (CNN) were used and each model was compared in terms of AUC, ROC curve, accuracy, precision, recall and F1 score values. LR %73.69, KNN %70.47, NB %73.01, DT %69.53, RF %70.94, XGB %79.73, ADA %78.46, DNN %79.66 and CNN %80 of the estimation of the examination result classified as slightly defective, severely defective and unsafe by machine learning methods. It has been concluded that with an accuracy of 80, certain defects can be seen together with the highest %90.

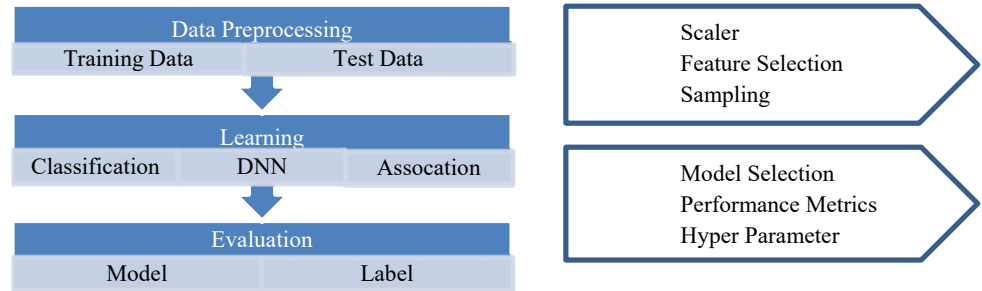


Figure A. Flowchart for the learning model

**Purpose:** It is aimed to predict the result of the inspection by using the vehicle inspection data and to contribute to the vehicle drivers and the vehicle inspection process by finding meaningful relationships between the defects found as a result of the inspection.

**Theory and Methods:** Vehicle inspection results were estimated using data mining algorithms (LR, NB, DT, RF, KNN, XGBoost, AdaBoost) and deep neural networks (DNN and CNN) using vehicle inspection data. Each model was compared in terms of AUC, ROC curve, accuracy, precision, recall and F1 score. In addition, the analysis of the defects seen as a result of the inspection of the vehicles was carried out by using the apriori algorithm, which is one of the association rules methods.

**Results:** The accuracy values of machine learning algorithms used for vehicle inspection data are LR 73.69%, KNN 70.47%, NB 73.01%, DT 69.53%, RF 70.94%, XGB 79.73%, ADA 78.46%, DNN 79.66% and CNN 80%. The result prediction has reached a high level of accuracy as almost all algorithms used are above 70%.

**Conclusion:** With this study, vehicle maintenance and reliability will increase and vehicle inspections will be carried out more effectively. Employees and vehicle owners at vehicle inspection stations will save time. With the association analysis made in the study, the defects that occur together in the inspection can be detected, the vehicle inspection can be made more effective and time can be saved.



## Motorlu araç muayene ve hata birliktelikleri tahmini

Gizem Çetin Yılmaz\*<sup>ID</sup>, Ömer Özgür Tanrıöver<sup>ID</sup>

Ankara Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 06830 Gölbaşı Ankara, Türkiye

### ÖNEÇIKANLAR

- Araç muayene verilerine veri madenciliğinin uygulanması
- Araç muayene sonucu tahmini
- Araç kusurları birliktelik analizi

#### Makale Bilgileri

Araştırma Makalesi  
Geliş: 14.12.2021  
Kabul: 23.03.2024

#### DOI:

10.17341/gazimmfd.1036562

#### Anahtar Kelimeler:

Araç muayene,  
makine öğrenmesi,  
sınıflandırma,  
birliktelik analizi

#### ÖZ

Araç muayenesi trafikte yer alan motorlu ya da motorsuz araçlar için teknik yeterliliklerinin ölçüldüğü, yolcu ve trafik güvenliğinin sağlanıp sağlanmadığının tespit edildiği sistemdir. Karayolunda seyreden araçların teknik muayenelerini daha etkin ve sağlıklı bir şekilde yapmak ve karayolu trafik güvenliğini sağlamak amacıyla her yıl yaklaşık 6 milyona yakın aracın periyodik muayenesi gerçekleştirilmektedir. Bu araştırma çalışmasında araç muayene verileri ile makine öğrenmesi ve derin sinir ağları kullanılarak araç muayene sonucu tahmin ve kusur birliktelik analizi yapılmıştır. Birliktelik kuralları çıkarım yöntemlerinden apriori algoritması ile araçların muayene sonucunda birlikte görülen kusurların analizi gerçekleştirilmiştir ve araç kusurları arasında anlamlı ilişkiler bulunmuştur. Ayrıca makine öğrenmesi tahmin yöntemlerinden Lojistik Regresyon (LR), Naive Bayes (NB), Karar Ağaçları (DT), Rastgele Orman (RF), K-En Yakın Komşu (KNN), Gradyan Yükseltme (XGBoost), AdaBoost, Derin Sinir Ağı (DNN) ve Evrimsel Sinir Ağı (CNN) kullanılmış olup her bir model AUC, ROC eğrisi, doğruluk, kesinlik, hatırlama ve F1 skor değerleri açısından karşılaştırılmıştır. Makine öğrenme yöntemleri ile hafif kusurlu, ağır kusurlu ve emniyetsiz olarak sınıflandırılan muayene sonucu tahmininin LR %73,69, KNN %70,47, NB %73,01, DT %69,53, RF %70,94, XGB %79,73, ADA %78,46, DNN %79,66 ve CNN %80 doğrulukta, belirli kusurların da birlikte en yüksek %90 oranında görülebildiği sonucuna ulaşılmıştır.

## Motor vehicle inspection and error associations prediction

### HIGHLIGHTS

- Applying data mining to vehicle inspection data
- Vehicle inspection result estimation
- Vehicle defects association analysis

#### Article Info

Research Article  
Received: 14.12.2021  
Accepted: 23.03.2024

#### DOI:

10.17341/gazimmfd.1036562

#### Keywords:

Vehicle inspection,  
machine learning,  
classification,  
association analysis

#### ABSTRACT

Vehicle inspection is a system in which the technical qualifications of motorized or non-motorized vehicles in traffic are measured and whether passenger and traffic safety is provided or not. In Turkey, periodic inspections of approximately 6 million vehicles are carried out every year in order to carry out technical inspections of vehicles traveling on the road more effectively and healthily and to ensure road traffic safety. In this research study, vehicle inspection result prediction and defect association analysis were performed by using vehicle inspection data, machine learning and deep neural networks. With the apriori algorithm, which is one of the association rules extraction methods, the analysis of the defects seen as a result of the inspection of the vehicles was carried out and significant relationships were found between the vehicle defects. In addition, from machine learning prediction methods, Logistic Regression (LR), Naive Bayes (NB), Decision Trees (DT), Random Forest (RF), K-Nearest Neighbor (KNN), Gradient Boost (XGBoost), AdaBoost, Deep Neural Network (DNN) and Convolutional Neural Network (CNN) were used and each model was compared in terms of AUC, ROC curve, accuracy, precision, recall and F1 score values. LR %73,69, KNN %70,47, NB %73,01, DT %69,53, RF %70,94, XGB %79,73, ADA %78,46, DNN %79,66 and CNN %80 of the estimation of the examination result classified as slightly defective, severely defective and unsafe by machine learning methods. It has been concluded that with an accuracy of 80, certain defects can be seen together with the highest %90.

\*Sorumlu Yazar/Yazarlar / Corresponding Author/Authors : \*gizemcetin06@gmail.com, Ozgur.Tanriover@ankara.edu.tr /  
Tel: +90 536 906 6304

## 1. Giriş (Introduction)

Ülkemizde uluslararası standartlara uygun şekilde yılda 6 milyona yakın aracın periyodik muayenesi gerçekleştirilmektedir. Amaç karayolunda seyreden motorlu ve motorsuz araçların teknik muayenelerini daha etkin ve sağlıklı bir şekilde yapmak, bu suretle araçlar bakımından karayolu trafik güvenliğini sağlamak olarak ifade edilir. Araç muayenesi belirli sınıflara göre ve belirli hususları kapsayan kontrol ve testleri içerir. Araç muayene sonuçları kusurlu, hafif kusurlu, ağır kusurlu emniyetsiz olarak değerlendirilir. Araç muayenesinin amacı trafikteki taşıtların kusurlarının giderilerek bunların sebep olacağı kazaların önüne geçilmesidir. Veriye dayanan tekniklerin hızlı bir şekilde büyümesi ve gelişmesiyle birlikte modern otomotiv endüstrisi için hata tespiti ve durum izleme yöntemlerini geliştirmek için yeni imkânlar ortaya çıkmaktadır.

Son yıllarda araç bakım ve onarımında birçok tespit sistemi geliştirilmiştir. Bu sistemler araçlardaki çeşitli arızaları önceden tahmin etmek için kullanılabilir. Bu çalışmada makine öğrenmesi algoritmaları yardımıyla araç hatalarının tahmini ele alınmıştır. Çalışmada araç muayene verileri ile makine öğrenmesi algoritmaları ve derin sinir ağları kullanılarak araç muayene sonucu tahmin yapılmıştır ve kullanılan modellerin performansı değerlendirilmiştir. Ayrıca birliktelik kuralları yöntemlerinden apriori algoritması kullanılarak araçların muayene sonucu birlikte görülen kusurların analizi gerçekleştirilmiştir. Arıza tahmin modeli araçlarda çıkabilecek hataların erken tespitlerinde yararlı olabilecektir.

Bu çalışmanın amacı karayolunda seyreden motorlu ve motorsuz araçların teknik muayenelerini daha etkin ve sağlıklı bir şekilde yapılmasına yardımcı olmaktır. Yapılan araştırmalar neticesinde araçların hata tahmini probleminde daha önceden yapılan çalışmalardan faydalanılarak araç muayene sonucunu doğru tahmin edebilmek amaçlanmıştır. Ayrıca kusur verileri üzerinde birliktelik analizi yapılarak araçlarda çıkabilecek hataların önceden keşfedilerek çıkabilecek arızaların erken tespitlerinde yararlı olacaktır. Birliktelik analizi ile araç muayene sonucunda çıkan kusurlar arasında anlamlı ilişkiler bulmak ve bu ilişkilerden faydalanarak araç sürücülerine ve araç muayene sürecine katkı sağlamak amaçlanmıştır.

Çalışmamızla ilgili olan literatürdeki benzer çalışmalar incelendiğinde Das vd. [1] Amerika Birleşik Devletleri'nin farklı eyaletlerinde araç muayene düzenleme programlarının etkinliğini belirlemeyi amaçlamışlardır. Çalışmada 2011-2016 yılları arası Ulusal Karayolu Trafik Güvenliği İdaresi'nin (NHTSA) araç şikâyet veri tabanı ve Ölüm Analizi Raporlama Sistemi (FARS) veri tabanını kullanılmıştır. Das ve arkadaşları araç kusurlarının modellerini anlamak için NHTSA şikâyet verilerinin metinsel içerikleri üzerinde metin madenciliği ve konu modellemesi yaparak ve devlet tarafından yürütülen araç muayenelerinin güvenlik etkinliğini araştırmak için istatistiksel anlamlılık testi uygulayarak iki önemli katkıda bulunmuştur. Bu çalışmada, araç şikâyetlerinin azaltılması için araç güvenliği denetimlerinin sürdürülmesine ihtiyaç olduğu sonucuna varmıştır.

Martín-delosReyes vd. [2] ise periyodik motorlu araç muayenelerinin karayolu çarpışmaları ve yaralanmaları üzerindeki etkisini belirlemeyi amaçlamışlardır. Çalışmada Medline, Web of Science ve Scopus veri tabanlarından 5065 adet çalışmanın sadece altısı kriterleri karşılayarak inceleme için seçilmiştir. İncelenen çalışmalarda karayolu kazaları ile geçerli bir araç muayene sertifikasının yokluğu arasında önemli bir ilişki olduğunu gösteren vaka-kontrol çalışması dışında, diğer çalışmalar çarpışma oranlarında küçük bir azalma (yaklaşık %9) göstermiştir. Talonen vd. [3] araç muayenelerinde reddedilme nedenlerinin temel bileşen analizine (PCA) dayalı ağ görselleştirmesini tanıtmışlardır. Bu çalışma ile farklı reddetme nedenleri ile arabalar arasındaki bağımlılıklar, yapılan ağ görselleştirmesi ile verimli bir şekilde incelenebilir. Çalışmanın

amacı, tüm bu verileri en yaygın ret nedenlerini içeren tek bir görselleştirmede toplamaktır. Verileri analiz ederken tamamen sürücülere bağlı olan bazı reddetme nedenleri çıkarılarak kullanıcıların kendi sonuçlarını çıkarmasına yardımcı olmuştur.

Literatürdeki diğer araç kusuru tahmini çalışmaları incelendiğinde tahmin çalışmalarından, motor arıza tespitine yönelik olanların çoğunlukta olduğu görülmektedir. Gang [4], gelişmiş yapay sinir ağlarına dayanan otomobil hata tespit sistemi geliştirmiştir. Motor arıza tipi ve arıza belirtileri analizlerine göre, 11 tip motor arıza bulgusu ve arıza sebepleri çıkarılmıştır. Artificial fish swarm algoritmasına dayanan optimize edilmiş BP (Back Propagation) yapay sinir ağı otomobil motor arızası tespitinde kullanılmıştır. Çalışmada BP sinir ağı için eksiklikleri için Artificial fish swarm BP sinir ağını optimize etmek için kullanılır, bu da BP sinir ağı performansını artırır. Deneysel sonuçları gelişmiş BP yapay sinir ağı için iyi genelleme kabiliyetine sahip olduğunu ve farklı arıza tiplerini etkili bir şekilde ele alabileceğini göstermektedir. Sonuçlar doğru ve güvenilir olup otomobil arıza tespit sistemi tasarımı için önemli bir referans sağlayabilir.

Yine Dejun vd. [5] SVM (Support Vector Machine) algoritmasına dayalı otomobil motorunun hata tespiti yapmışlardır. AMES'im yazılımı tarafından motor simülasyon datalarından özellik çıkarımı yapılmaktadır. Bu hata karakteristik parametreleri istatistiksel özellikleri sahiptir ve spesifik fiziksel bir anlamı vardır. PCA (Principal Component Analysis) ile veri fazlalıkları ve boyutları azaltılmaktadır. Daha sonra bu verilere SVM (Support Vector Machine) uygulanarak normalize edilmiştir. SVM tabanlı hata tespit metodu Yapay Sinir Ağlarına göre daha iyi performans göstermiştir. Sonuçlar SVM'nin az sayıda örnek olması durumunda doğru hata sınıflandırmasını başarabileceğini göstermektedir.

Son olarak literatürdeki yapay zekâ ve makine öğrenmesi yöntemlerini çeşitli tehlikeli arıza tespitine yönelik olarak kullanan çalışmalar da mevcuttur. Bunlardan, Bo [6] otomobil motor hata tespit modeli geliştirmiştir. Bu çalışmada kullanılan LSSVM (Least Squares Support Vector Machine) hata tespit modeli, normal durum, düşük dereceli kaza sonucu çıkan yangın ve ciddi kaza sonucu çıkan yangın da dahil olmak üzere otomobil motorunun üç durumu vardır. Otomobil motorundaki bu üç durumu tanımak için iki LSSVM modelini kullanılmıştır ve elde edilen sonuçlar kullanılan yöntemin otomobil motorunun arıza teşhisinde etkin olduğu şeklinde yorumlanabileceğini göstermektedir. Youjun vd. [7] motor, şasi sistemi ve elektrikli ekipmanların arıza teşhisi için Fault Tree – Neural Network (FTA-NNE) tabanlı araç arıza teşhis uzman sistemi ortaya koymuşlardır. Geliştirilen arıza teşhis sistemi ekonomik arabalar için büyük pratik değere sahip olduğu sonucuna varılmıştır. Kong vd. [8] titreşim parametresinin arıza tespit problemini çözmek için motor hata tespitine Adaptive Neural Network tabanlı bulanık çıkarım sisteminin (ANFIS) uygulanmasını önermektedirler. Sistem arıza teşhis modelinin motor testlerinin verileriyle doğrulanmasıyla, tanıma doğruluk oranının %98,99'a ulaştığı tespit edilmiştir. Murphey ve Chen [9] ise araç arıza teşhisi ve bakımı için geliştirilmiş bir multi-agent sistemi (MAS-VFD & HM) önermektedir. MAS-VFD & HM sistemi sinyal tespit ajanlarından, özel durum ajanlarından ve araç izleme ajanlarından oluşmaktadır. Satoh vd. [10] bulanık sistemlerin sinir ağlarının avantajlarından yararlanılarak hızlı ve doğru Sugeno'nun tip-1 bulanık sistemi (Tip – 1 bulanık sistemi) Gauss radyal tabanlı fonksiyon ağı (GP - RBFN) ve zaman gecikmeli sinir ağı (TDNN) kombinasyonu ile uygulanmaktadır. Bu sistem otomobil şanzıman dişli sistemi için arıza bulma deneysel olarak uygulanmaktadır. Luckow vd. [11] bilgisayar görme alanı içinde derin öğrenme için farklı otomotiv kullanım durumlarına değinmişlerdir. Bu çalışmanın ana katkısı, farklı araç özelliklerini öğrenip otomatik olarak tanımamıza olanak tanıyan bir otomotiv veri setinin oluşturulmasıdır. Lili vd. [12] tarafından yapılan çalışmada araç tanıda elektrikle kontrol edilen sistemden gelen veri akışının analizi,

sensör ve çalıştırıcı arızasının açık şekilde ayrılabilirliğini ve tanıma için sinir ağları ve D-S kanıtı bilgi birleştirme yöntemini kullandığını göstermektedir. Zheng vd. [13] tarafından yapılan çalışmada ESP sisteminde sensör hata tespitinde Support Vector Machines (SVM) uygulaması ele alınmıştır. Weijie vd. [14] tarafından yapılan çalışmada Wavelet Neural Network'lerine dayalı otomobil motor hata tespiti yapılmıştır. Kher vd. [15] tarafından yapılan çalışmada Neural Network'ler kullanarak otomobil motorunun hata tespiti ele alınmıştır. Gao vd. [16] tarafından yapılan çalışmada Elman Neural Network ile Genetik Algoritmalar kullanılarak motor hata tespiti yapılmaktadır.

Bu çalışma ile ilgili yapılan literatür araştırmasında daha çok otomobil arıza tespit sistemi ve otomobil motorunun hata tespiti üzerine yapılan çalışmalar yer almaktadır. İncelenen çalışmalarda yapay sinir ağları ve bulanık mantık otomobil arıza teşhis alanında çok kullanılan bir yöntemlerdir. Türkiye'de araç muayene verileri üzerinde makine öğrenmesi uygulanması ve muayene sonucunda çıkan kusurların birliktelik analizi çalışması daha önce gerçekleştirilmemiştir. Bu yapılan çalışma ile araç kusurları arasında anlamlı ilişkiler bulunmuştur. Bizim çalışmamız ile daha benzer olan Das ve arkadaşlarının yaptığı çalışmada araç muayene verileri ile kaza çarpışma verileri birlikte kullanılıp metin madenciliği modeli gerçekleştirilerek araç muayenelerinin güvenlik etkinliğini araştırılmıştır. Bu yapılan çalışmada ise sadece araç muayene verileri üzerinde çalışılmıştır. Elimizde kaza çarpışma verileri olmadığından dolayı hem araç muayene verisi hem de kaza çarpışma verileri ile ilgili bir çalışma yapılamamıştır. Ayrıca, bu çalışmada diğer çalışmalardan önemli bir fark olarak büyük veri ile (yaklaşık 7 milyon veri) çalışılmıştır.

## 2. Materyal ve Yöntem (Material and Method)

Bu bölümde veri hazırlama ve veri ön işleme aşamasını, sınıflandırma modeli için kullanılan algoritmalar ve son olarak modellerin değerlendirilmesinde kullanılan ölçümler tanımlanmaktadır. Makine öğrenmesi ve derin sinir ağı modelleri kullanılarak aracın kilometresi, modeli, yakıt tipi vb. özellikleri ve muayene sonucunda çıkan kusurları göz önüne alınarak araç muayene sonucunun tahmini ile muayene işlem sürecine yardımcı olmak amaçlanmıştır. Makine öğrenme tahmin yöntemi olarak LR (Lojistik Regresyon), KNN (K-Nearest Neighbors), NB (Naive Bayes), DT (Decision Tree), RF (Random Forest), XG Boost, Ada Boost, DNN (Deep Neural Network) ve CNN (Convolutional Neural Network) kullanılmıştır. Ayrıca Apriori algoritması kullanılarak birliktelik analizi gerçekleştirilmiştir. Araç kusurları üzerinde yapılan birliktelik analizi araçlarda çıkabilecek hataların erken tespitinde yararlı olabilecektir.

Makine öğrenimi tabanlı sınıflandırma, denetimli öğrenme olarak da adlandırılır. Denetimsiz öğrenmenin aksine, sınıflandırmada tipik olarak modelin eğitimi, veri örneklerinin halihazırda mevcut olan sınıf bilgilerine dayanarak yapılır. Denetimli öğrenme dört sınıflandırıcı

türünde gruplandırılabilir. Bunlar karar ağacı tabanlı, doğrusal, kural tabanlı ve olasılıksal sınıflandırıcılardır [17,18]. Bu nedenle yöntemi seçme nedenimiz, kural tabanlı hariç her türden en az bir sınıflandırıcıyı dahil etmektir.

Lojistik Regresyon çok değişkenli verileri gruplandırmada ideal bir yöntem olduğu için ve çok sınıflı problemlerde de kullanılabilirliği için tercih edilmiştir. Lojistik regresyon, varsayılan olarak, iki sınıflı sınıflandırma problemlerinde kullanılmaktadır. Fakat çok terimli (multinomial) lojistik regresyon, çok sınıflı sınıflandırma problemleri için de kullanılan lojistik regresyonun bir uzantısıdır. Bu çalışmada scikit-learn Python makine öğrenimi kütüphanesini kullanarak çok terimli (multinomial) bir lojistik regresyon modeli geliştirilip değerlendirilmiştir. KNN algoritması, uygulaması kolay olması, gürültülü verilere karşı dirençli olması ve eğitim aşamasına sahip olmaması sebebiyle kullanılmıştır. Fakat büyük verilerde kullanıldığında fazla bellek alanına gereksinim duyması sebebiyle çalışması uzun sürmektedir. Makine öğrenmesi algoritmalarından KNN sınıflandırıcısında en yakın komşu sayısı olan k parametresi 5 olarak belirlenip araç muayene verilerine uygulanmıştır. Naive Bayes algoritması yüksek boyutlu verilerde iyi performans göstermesi ve her özellik birbirinden bağımsız kabul edildiği için lojistik regresyon gibi modellerden daha iyi performans göstermesi sebebinden dolayı tercih edilmiştir. Karar Ağaçları algoritması hem sayısal hem de kategorik verileri işleyebilmesi ve çok sınıflı problemleri ele alabilmesinden dolayı tercih edilmiştir. Random Forest algoritması aşırı uyum (overfitting) problemini önleyebilmesi sebebiyle kullanılmıştır. XG Boost algoritması yüksek tahmin gücü elde edebilmesi, aşırı öğrenmeye karşı dirençli olması, karar ağacı tabanlı algoritmaların en iyisi olması ve hızlı çalışması sebebiyle tercih edilmiştir. Ada Boost algoritması aşırı öğrenmeye karşı dirençli olması ve yüksek doğruluk elde edebilmesi sebebiyle kullanılmıştır. Derin Sinir Ağlarının öğrenme ve genelleme kabiliyeti olması, eksik veya gürültülü veriyi çalışabilmesi, paralel çalışma prensibine sahip olması nedeniyle kullanılmıştır. CNN, fotoğraf verilerinde daha iyi sonuç vermektedir. Fakat araştırma bulgularına göre CNN, fotoğraf dışındaki verilere de uygulanabilirliği için bu çalışmada kullanılmıştır.

### 2.1. Veri Hazırlama ve Ön İşleme (Data Preparation and Preprocessing)

Çalışmada kullanılan veriler 2015, 2016 ve 2017 yılları Ocak, Şubat ve Mart aylarına ait araçların muayene bilgilerini içermektedir. Toplam 7.392.283 veri kullanılmıştır.

Veride bulunan MUAYENE\_SONUC\_KODU alanı kategorik bir alandır: AK (Ağır Kusurlu), HK (Hafif Kusurlu) ve EM (Emniyetsiz). Bu değişken için "HK" olan veri 0, "AK" olan veri 1 ve "EM" olan veri 2 olarak kodlanmıştır. Aynı düzenlemeler kategorik olan tüm alanlar için uygulanmıştır. Veri seti ile ilgili detaylı bilgi tablo 1'de gösterilmiştir.

Kusur alanı toplamda 15 kusur grubu altında incelenmiştir. Örneğin veri setinde bulunan "1" alanı için; Tablo 2.2'de verilen 1 alan adlı "Aracın Tespiti" kusur grubunun altında bulunan 47 kusurdan muayene

**Tablo 1.** Araç muayene verileri açıklaması (Vehicle inspection data description)

Öznitelikler	Veri Tipi	Açıklama
MUAYENE_ID	Nümerik	Aracın muayene id'si
CINSI	Kategorik	Aracın Cinsi
MODEL	Nümerik	Aracın Model Yılı
YAKIT_TIPI	Kategorik	Aracın Yakıt Türü
KM (Kilometre)	Nümerik	Kilometre
KULLANIM_AMACI	Kategorik	Aracın Kullanım Amacı
TESCİL_SEKLI	Kategorik	Aracın Tescil Şekli
DAHILI_ARAC_ID	Nümerik	Aracın id'si
MUAYENE_SONUC_KODU	Kategorik	Aracın Muayene Sonucu
KUSUR	Kategorik	Muayene Sonucunda Çıkan Kusurlar

sonucunda bunlardan herhangi birinde kusuru bulunan araç için 1 değeri, bu grupta kusuru bulunmayan araç için 0 değeri verilmiştir. Aynı düzenlemeler 15 adet kusur grubu için uygulanmıştır. Aşağıdaki tablo 2’de 15 adet kusur grubunun açıklamaları verilmiştir.

Tablo 3’de makine öğrenmesi algoritmalarında kullanılan araç muayene verisinin örnek 5 satırı gösterilmektedir.

Araç muayene veri setinde aykırı değerleri tespit etmek için IQR (Inter Quantile Range) ve kutu grafiği yöntemi kullanılmıştır. IQR yöntemi ile araç muayene verilerindeki değişimleri bularak aykırı değerler tespit edilip veri setinden çıkarılmıştır.

Veri ön işleme aşamasında araç muayene verilerine Python’da en çok kullanılan iki yöntem olan MinMaxScaler ve Standard Scaler uygulanmıştır. Label Encoder ve OneHot Encoder yöntemleri ile araç muayene verilerinde kategorik olan CINSI, YAKIT\_TIPI, KULLANIM\_AMACI, TESCİL\_SEKLI, MUAYENE\_SONUC\_KODU alanları için nümerik değerlere dönüştürme işlemi yapılmıştır.

Bu çalışmada kullanılan araç muayene verilerinin sınıfları dengesiz dağıldığından dolayı veri örnekleme yöntemi kullanılmıştır. Araç muayene verilerinin yaklaşık %73’i hafif kusurlu, %25’i ağır kusurlu, %2’si emniyetsiz sınıfına mensuptur. Hafif kusurlu sınıfı çoğunluk sınıfıdır, emniyetsiz ve ağır kusurlu sınıfı da azınlık sınıfıdır. Bu sebepten dolayı veriler dengeli değildir. Veriler üzerinde az örnekleme ve çok örnekleme yöntemleri kullanılarak makine öğrenmesi modelleri üzerinde karşılaştırma yapılmıştır. Az örnekleme yapılarak hafif kusurlu ve ağır kusurlu sınıfının bazı verileri veri setinden çıkarılarak sınıflar dengeli hale getirilmiştir. Emniyetsiz sınıfı sayısı kadar diğer sınıfların sayısı indirgenerek toplamda 264.642 adet veri elde edilmiştir. Çok örnekleme yapılarak azınlık sınıf olan ağır kusurlu ve emniyetsiz sınıfları verileri çoğaltılmıştır. Çok örnekleme ile sınıflar dengelenerek toplamda 161.90.493 veri

elde edilmiştir. Az örnekleme (undersampling) ve çok örnekleme (oversampling) yapılarak elde edilen verilere yedi adet makine öğrenme algoritması (LR, NB, KNN, DT, RF, XGBoost) ve DNN uygulayarak sonuçlar karşılaştırılmıştır.

### 3. Bulgular (Results)

#### 3.1. Sınıflandırma Algoritmaları (Classification Algorithms)

Araç muayene verileri ve örnekleme yapılarak elde edilen veriler üzerinde kullanılan makine öğrenmesi algoritmalarının doğruluk, kesinlik, duyarlılık, F1 Score ve AUC değerleri tablo 4’de verilmiştir. Tüm veride araç muayene sonuç tahmini doğruluk değeri en yüksek CNN, DNN ve XG Boost algoritmasından elde edilmiştir. Az örnekleme ile araç muayene sonuç tahmini doğruluk değeri en yüksek XG Boost algoritmasından elde edilmiştir. Çok örnekleme ile araç muayene sonuç tahmini doğruluk değeri en yüksek Random Forest algoritmasından elde edilmiştir (Tablo 4).

Araştırma bulgularına bakıldığında Lojistik Regresyonun tüm veride, az örnekleme ve çok örnekleme ile elde edilen verilerde AUC değerleri düşük olduğu için sınıfları tahmin edebilme beceresi iyi olduğu söylenemez. Ayrıca sınıflandırma raporuna göre Lojistik Regresyon ağır kusurlu ve emniyetsiz sınıflarını tahmin etmede başarısızdır. Bu sınıflara ait verilerin hepsini tüm veride hafif kusurlu olarak sınıflandırmıştır. Az örnekleme ve çok örnekleme yapılarak ağır kusurlu ve emniyetsiz sınıflarını tahmin etme başarısı artırılmıştır. Çok terimli (multinomial) lojistik regresyon kullanılmasına rağmen sınıfları azınlık sınıfları tahmin etme başarısı düşüktür.

KNN algoritması için tüm veride ve yetersiz örnekleme ile elde edilen verilerde sınıfları tahmin edebilme beceresi iyi olduğu söylenemez. Fakat çok örnekleme ile elde edilen veride ROC Eğrisi grafiğine bakıldığında AUC değerleri yüksektir ve sınıfları tahmine edebilme

**Tablo 2.** Kusur grupları (Defect groups)

Alan Adı	Açıklama
1	Araçın Tespiti ile ilgili kusurlar
2	Fren Sistemi ile ilgili kusurlar
3	Direksiyon Sistemi ile ilgili kusurlar
4	Görüş Alanı ile ilgili kusurlar
5	Aydınlatma ile ilgili kusurlar
6	Dingiller/Tekerlekler/Lastikler/Süspansiyon ile ilgili kusurlar
7	Şase/karoseri - bağlı parçalar ile ilgili kusurlar
8	Römork çeki sistemi ile ilgili kusurlar
9	Yükleme kasası ile ilgili kusurlar
10	Üst yapı ile ilgili kusurlar
11	Motor/Tahrik Debriyaj/Vites değiştirme ile ilgili kusurlar
12	Motosiklet, Motorlu Bisiklet ile ilgili kusurlar
13	Diğer Donanımlar ile ilgili kusurlar
14	Çevre Kirliliği: Gürültü oluşumu/ Parazit önleme/Yağ, Hidrolik, Sıvı kaçakları ile ilgili kusurlar
15	İlave kontroller ile ilgili kusurlar

**Tablo 3.** Araç muayene örnek veri (Vehicle inspection sample data)

CINSI	MODEL	YAKIT	TIPI	KM	KULLANIM	AMACI	TESCİL	ŞEKLİ	MUAYENE	SONUÇ	KODU	1	...	13	14	15
HTA1	2002	BEN		133202	YOL		HUS	HK				1	...	0	0	1
HTA1	1985	BEN		54812	YOL		HUS	AK				0	...	0	1	1
HTA3	2005	DIZ		241997	YUK		HUS	HK				1	...	0	0	1
HTA3	2013	DIZ		16770	YUK		HUS	HK				0	...	0	0	0
HTA1	2006	DIZ		171461	YOL		HUS	AK				1	0	1	1	

**Tablo 4.** Sınıflandırma algoritmalarının sonuçlarının karşılaştırılması (Comparison of results of classification algorithms)

Model	Doğruluk	Kesinlik			Duyarlılık			F1 Score			AUC		
		Sınıf 0	Sınıf 1	Sınıf 2	Sınıf 0	Sınıf 1	Sınıf 2	Sınıf 0	Sınıf 1	Sınıf 2	Sınıf 0	Sınıf 1	Sınıf 2
		HK	AK	EM	HK	AK	EM	HK	AK	EM	HK	AK	EM
LR	%73.69	0.74	0.00	0.00	1.00	0.01	0.00	0.85	0.00	0.00	0.59	0.58	0.61
KNN	%70.47	0.75	0.33	0.20	0.87	0.20	0.04	0.81	0.25	0.07	0.59	0.58	0.61
NB	%73.01	0.74	0.39	0.00	0.97	0.06	0.00	0.84	0.10	0.00	0.65	0.64	0.78
DT	%69.53	0.80	0.41	0.07	0.80	0.43	0.06	0.80	0.42	0.06	0.62	0.61	0.65
RF	%70.94	0.81	0.44	0.08	0.81	0.45	0.03	0.81	0.44	0.05	0.73	0.72	0.80
XGB	%79.73	0.83	0.66	0.00	0.93	0.44	0.00	0.88	0.53	0.00	0.81	0.80	0.92
ADA	%78.46	0.81	0.66	0.17	0.94	0.35	0.07	0.87	0.46	0.09	0.77	0.52	0.91
DNN	%79.66	0.84	0.66	0.00	0.92	0.45	0.00	0.87	0.54	0.00	0.70	0.68	0.50
LR	%48.74	0.51	0.42	0.56	0.44	0.54	0.48	0.47	0.48	0.52	0.65	0.56	0.71
KNN	%46.49	0.45	0.39	0.61	0.59	0.37	0.42	0.51	0.38	0.50	0.65	0.56	0.71
NB	%48.79	0.49	0.42	0.57	0.65	0.37	0.44	0.56	0.39	0.49	0.69	0.62	0.74
DT	%48.79	0.49	0.42	0.57	0.65	0.37	0.44	0.56	0.39	0.49	0.69	0.57	0.73
RF	%61.61	0.67	0.51	0.67	0.66	0.48	0.72	0.66	0.49	0.69	0.84	0.68	0.88
XGB	%65.82	0.68	0.58	0.69	0.78	0.43	0.77	0.73	0.49	0.73	0.87	0.73	0.90
ADA	%62.40	0.65	0.52	0.67	0.80	0.40	0.67	0.72	0.45	0.67	0.85	0.63	0.88
DNN	%59.18	0.71	0.64	0.73	0.73	0.34	0.71	0.72	0.44	0.72	0.79	0.62	0.79
LR	%47.41	0.46	0.42	0.57	0.51	0.44	0.47	0.48	0.43	0.52	0.62	0.61	0.67
KNN	%76.11	0.51	0.42	0.60	0.66	0.36	0.51	0.57	0.39	0.55	0.85	0.84	0.99
NB	%76.11	0.51	0.42	0.60	0.66	0.36	0.51	0.57	0.39	0.55	0.71	0.62	0.75
DT	%50.75	0.51	0.42	0.60	0.66	0.36	0.51	0.57	0.39	0.55	0.85	0.89	1.00
RF	%88.08	0.91	0.79	0.96	0.76	0.90	1.00	0.83	0.84	0.98	0.93	0.93	1.00
XGB	%65.76	0.68	0.58	0.69	0.79	0.42	0.77	0.73	0.49	0.73	0.87	0.73	0.90
ADA	%62.32	0.64	0.53	0.68	0.81	0.39	0.67	0.72	0.45	0.67	0.85	0.63	0.87
DNN	%59.53	0.73	0.62	0.73	0.69	0.39	0.71	0.71	0.48	0.72	0.78	0.63	0.80

yeteneği yüksektir. Sınıflandırma raporuna göre ağır kusurlu ve em niyetsiz sınıfları için duyarlılık, kesinlik ve F1 sokur değerleri hafif kusurlu sınıfa göre daha düşük çıkmıştır. KNN algoritması büyük verilerde bellek sorununa sebep olduğu için diğer algoritmalara göre çalışması uzun sürmüştür. Yaklaşık 30 dk. sürmüştür. Çalıştırılan bilgisayar özellikleri 16 GB Ram, AMD Ryzen 7 PRO 2700U w/ Radeon Vega Mobile Gfx 2.20 GHz işlemciye sahiptir.

Naive Bayes algoritması sınıfları tahmin edebilme becerisi Lojistik Regresyon ve KNN algoritmasına göre daha iyi olduğu söylenebilir. Fakat sınıflandırma raporuna göre az ve çok örnekleme ile elde edilen sonuçlar karşılaştırıldığında KNN algoritması ile aynı çıkmıştır. Tüm veride Naive Bayes algoritması emniyetsiz sınıfını hiç doğru tahmin edememiştir. Ayrıca Ağır kusurlu sınıfını tahmin etme başarısı da düşüktür.

Rastgele Orman algoritmasının sınıfları tahmin edebilme becerisi AUC değerine bakıldığında Karar Ağaçları algoritmasına göre daha iyi olduğu söylenebilir. Rastgele Orman algoritması karar ağaçlarının en büyük sorunu olan aşırı uyumu azaltmaktadır. Rastgele Orman algoritmasının sınıflandırma raporundaki kesinlik, duyarlılık ve F1 skor değerleri Karar Ağaçları algoritmasına göre daha iyi sonuçlar çıkmıştır. Rastgele Orman algoritması çok örnekleme ile elde edilen veride en %88.08 ile en yüksek doğruluk seviyesine ulaşılmıştır.


Araştırma bulgularına göre XG Boost algoritması sınıfları tahmin edebilme yeteneği diğer algoritmalara göre daha iyi olduğu ortaya çıkmıştır. XG Boost algoritması ile yüksek tahmin elde edebilir, aşırı uyumu önleyebilir, hızlıdır ve büyük veri setlerinde en kullanışlı modellerdendir. XG Boost algoritmasının AUC değeri diğer algoritmalar a göre daha yüksektir. XG Boost algoritması karmaşıklık matrisi ve sınıflandırma raporundan da anlaşılacağı üzere emniyetsiz sınıfa ait verileri doğru tahmin edememiştir. Fakat hafif kusurlu ve ağır kusurlu sınıflarını doğru tahmin etme başarısı diğer algoritmalara göre daha yüksek çıkmıştır. Çok örnekleme ve az örnekleme ile elde edil en doğruluk değerleri ise %65 oranı ile benzer çıkmıştır. Ada

Boost modeli XG Boost modeli ile karşılaştırıldığında doğruluk, kesinlik, duyarlılık ve F1 Score değerleri h emen hemen birbirine yakındır. Ada Boost modelinde XG Boost'un hiç doğru tahmin edemediği emniyetsiz sınıfa ait verileri doğru tahmin edebilme kabiliyeti vardır. Çok örnekleme ve yetersiz örnekleme ile elde edilen sonuçlar ise benzer çıkmıştır. XG Boost algoritması sınıfların AUC değeri Ada Boost algoritmasına göre daha yüksek tir.

Ağır kusurlu sınıfını tüm veride en çok %45 ile Random Forest ve DNN, %44 ile XG Boost algoritması belirleyebilmiştir (Tablo 4). Modellerin emniyetsiz sınıfını belirlemede başarısı düşüktür. Az örneklemede ağır kusurlu sınıfını en çok %48 ile RF, emniyetsiz sınıfını %77 ile XG Boost belirleyebilmiştir. Çok örneklemede ise ağır kusurlu sınıfını %90 ile Random Forest, emniyetsiz sınıfını %100 ile yine Random Forest belirleyebilmiştir.

DNN modeli tüm araç muayene verilerine uygulandığında muayene sonucunu %79,66, az örnekleme ile %59,18 ve çok örnekleme ile %59,53 oranında doğru bildiği tespit edilmiştir. Tüm veride ağır kusurlu sınıfı için duyarlılık kesinlik ve F1 sokur değerleri hafif kusurlu sınıfa göre daha düşük çıkmıştır. Emniyetsiz sınıfa ait verileri sınıflandıramadığı için kesinlik, duyarlılık ve F1 skoru değerleri 0'dır. Çok örnekleme ve az örnekleme ile elde edilen sonuçlar ise benzer çıkmıştır ve sınıfları tahmin etme oranı çok örnekleme ve az örnekleme ile elde edilen verilerde daha yüksek çıkmıştır.

CNN modeli tüm araç muayene verilerine uygulandığında muayene sonucunu %80 oranında doğru bildiği tespit edilmiştir. CNN, fotoğraf verilerinde daha iyi sonuç vermektedir. Fakat araştırma bulgularına göre CNN, fotoğraf dışındaki verilere de kullanılabilir. Araç muayene verileri, fotoğraf verilerindeki gibi üç boyutlu hale çevrilip CN N modeline verilmiştir. DNN ve CNN algoritmalarının doğruluk değerleri yüksek olmasına rağmen kayıp değeri epok sayısı ve katman sayısı artırılarak düşürülemedi. Şekil 1'de algoritmaların doğruluk oranlarının karşılaştırmalı grafiği verilmiştir. Şekil 1'de birinci grafik tüm veri, ikinci grafik az örnekleme ile elde edilen veri ve üçüncü



**Şekil 1.** Sınıflandırma algoritmaları doğruluk değerleri (Classification algorithms accuracy values)

grafik çok örnekleme ile elde edilen verilere makine öğrenmesi algoritmaları uygulanarak elde edilen doğruluk oranları verilmiştir. Tüm veride araç muayene sonuç tahmini doğruluk değeri en yüksek CNN, DNN ve XG Boost algoritmasından elde edilmiştir. Az örnekleme ile araç muayene sonuç tahmini doğruluk değeri en yüksek XG Boost algoritmasından elde edilmiştir. Çok örnekleme ile araç muayene sonuç tahmini doğruluk değeri en yüksek Random Forest algoritmasından elde edilmiştir (Şekil 1).

Bu araştırma çalışmasında tüm araç muayene verilerinde en iyi sonuç %80 doğruluk değeri ile CNN, %79,73 doğruluk değeri ile XG Boost, %79.66 doğruluk değeri ile DNN ve %79.46 doğruluk değeri ile Ada Boost algoritmasından elde edilmiştir. Az örnekleme ile elde edilen verilerde en iyi sonuç %65,82 doğruluk değeri ile XG Boost, %62,40 doğruluk değeri ile Ada Boost algoritmasından elde edilmiştir. Çok örnekleme ile elde edilen verilerde en iyi sonuç %88.08 doğruluk değeri ile Random Forest algoritmasından elde edilmiştir (Şekil 1).



### 3.2. Derin Öğrenme (Deep Learning)

Derin öğrenme, insan beyninin işleyişini, verileri işleme ve karar vermede işleminde kullanmak için modeller oluşturarak taklit eden yapay bir zekâ işlevidir. Derin sinir ağları, birden çok gizli katmana sahip olan yapay sinir ağlarıdır. Buradaki derinlik gizli katman sayısı artırılarak sağlanmaktadır [19].

#### 3.2.1. Derin sinir ağları (Deep neural networks-DNN)

Bu çalışmada, derin öğrenme kütüphanesi olan keras yardımı ile sinir ağı oluşturulmuştur. 1 adet giriş katmanı, 2 adet gizli katman ve 1 adet çıkış katmanı olmak üzere toplam 4 katmanlı, tam bağlantılı bir ağ oluşturulmuştur. İlk iki katmanda Relu aktivasyon fonksiyonu ve çıkış katmanında softmax aktivasyon fonksiyonu kullanılmıştır. SGD (Stochastic Gradient Descent) optimizasyon yöntemi kullanılmıştır. Epok sayısı 50 olarak alınmıştır. Çünkü epok sayısını artırdıkça doğruluk ve kayıp değerinde çok fazla değişim olmamaktadır. 50 epoktan sonra doğruluk oranında fazla değişiklik olmadığı gözlemlenmiştir. Kayıp (loss) fonksiyonu olarak ise categorical crossentropy kullanılmıştır. Öğrenme oranı 0.1 olarak alınmıştır ve optimizasyon algoritmalarının varsayılan olarak aldığı değerler kullanılmıştır.


Ağ çıkış değerleri 0 (Hafif Kusurlu), 1 (Ağır Kusurlu) ve 2 (Emniyetsiz)'dir. Toplamda 7.304.069 veri ve 21 adet öznitelik kullanılmıştır. İlk katman, giriş değişkenleri için 21 adet nörona sahiptir. Gizli katmanlar 64 ve 128 adet nöron ve çıkış katmanı 3 adet nöron oluşmaktadır. İlk iki katmanda relu aktivasyon fonksiyonunu ve çıkış katmanı için softmax fonksiyonu kullanılmıştır. Ağ çıkışı 3 adet nörona sahip olduğu için softmax aktivasyon fonksiyonu kullanılmıştır. Çalışmamızdaki modelde çıkış katmanında birden fazla nöron olduğu ve sınıf aidiyeti olasılıkları için çıkışta softmax fonksiyonu kullanılmıştır.

Relu aktivasyon fonksiyonu ise doğrusal olmama özelliği sayesinde karmaşık ilişkileri öğrenmesi, seyreklik özelliği ile diğer aktivasyon fonksiyonlarına göre hesaplama açısından daha verimli olması ve

fazla uyumu önlemesi ve daha iyi gradyan tabanlı optimizasyon sağlaması sebebiyle tercih edilmiştir. DNN modeli araç muayene verilerine uygulandığında muayene sonucunu %79,66 oranında doğru bildiği tespit edilmiştir. Az örnekleme yapılarak elde edilen verilere DNN uygulandığında muayene sonucunu %59,18, çok örnekleme yapılarak elde edilen verilerde ise %59,53 oranında doğru bildiği tespit edilmiştir. Tüm veri ile elde edilen sonuçlara göre Hafif Kusurlu sınıfı için kesinlik değeri 0.84, duyarlılık değeri 0.92 ve F1 skoru değeri 0,87 olarak çıkmıştır. Ağır Kusurlu sınıfı için kesinlik değeri 0.66, duyarlılık değeri 0.45 ve F1 skoru değeri 0.54'tür. Ağır kusurlu sınıfı için duyarlılık kesinlik ve F1 skor değerleri Hafif Kusurlu sınıfına göre daha düşük çıkmıştır. Bunun sebebi veri kümesinin yaklaşık %70'ini Hafif kusurlu verilerin oluşturmasıdır. Emniyetsiz sınıfı verilerini sınıflandırmadığı için kesinlik, duyarlılık ve F1 skoru değerleri 0'dır. Az örnekleme ve çok örnekleme ile elde edilen sonuçlar hemen hemen aynı çıkmıştır. Veride çok örnekleme ve az örnekleme yaparak emniyetsiz sınıfını doğru tahmin edebilme oranı artmıştır. DNN algoritması eğitim ve doğrulama verileri için kayıp ve doğruluk grafiği aşağıda Şekil 2'de verilmiştir.

Validasyon değerlerini iyileştirmek için bazı deneyler yapılmıştır. İlk olarak optimizasyon algoritması değiştirilmiş, Adam optimizasyon algoritması kullanılmıştır. Öğrenme oranı 0.1, decay değeri  $10^{-5}$  alınmıştır. Epok değeri artırılarak 100 olarak alınmıştır. Decay hiper parametresi kullanılarak aşırı öğrenmeyi (overfitting) engellemeye çalışılmıştır. 100 epok sonunda doğruluk değeri %78.44 olarak elde edilmiştir.

Diğer bir deney olarak da DNN modelinin katmanlarında en son katmana gelmeden bir Dropout katmanı daha eklenmiştir. Adam optimizasyon algoritması kullanılmıştır ve öğrenme oranı 0.1, decay değeri  $10^{-3}$  ve epok değeri 100 olarak alınmıştır. 100 epok sonucunda doğruluk değeri %75.81'e düşmüştür. Son olarak PCA (Principal Component Analysis) kullanılarak modelde kullanılan 21 öznitelik 10'a düşürülerek ve aynı parametreler ve adam optimizasyon algoritması kullanarak deney yapılmıştır. 100 epok sonucunda doğruluk değeri %77.28'e düşmüştür. Ancak yukarıda yaptığımız ek deneyler sonucunda kayda değer çok bir iyileşme sağlanamamıştır.



Şekil 2. DNN algoritması doğruluk kayıp grafiği (DNN algorithm accuracy loss graph)



### 3.2.1.1. Evrişimsel sinir ağları (Convolutional neural network-CNN)

Evrişimsel sinir ağı (CNN) modeli sınıflandırma için kullanılmıştır. Bu model görüntü tanıma, sınıflandırma, kümeleme problemlerinde kullanılan derin yapay sinir ağlarıdır. CNN modelimiz 4 katmandan oluşmaktadır: Convolutional Katmanı, Pooling (Havuzlamam) Katmanı, Flattening Katmanı ve Fully Connected Katmanı. Bu katmanlarda, farklı işlemlerden geçen veri derin sinir ağları modeline verilir.

Ağ çıkış değerleri 0 (Hafif Kusurlu), 1 (Ağır Kusurlu) ve 2 (Emniyetsiz)'dir. Toplamda 7.304.069 veri ve 21 adet öznitelik kullanılmıştır. CNN genelde çoklu ortam verilerine uygulanmaktadır. Fakat yaygın olmamakla birlikte kategorik verilerde de uygulanabilmektedir. CNN uygulanmadan önce veriler normalize edilmiştir. İlk önce Label Encoder kullanılarak kategorik veriler de sayısallaştırılmıştır. Kategorik veriler sayısal veriye dönüştürülmüştür. Daha sonra Standard Scaler fonksiyonu ile veriler ölçeklendirilerek 0-1 aralığına alınmıştır. Çıkış katmanı 3 adet nörona sahip olduğu için keras kütüphanesinden to\_categorical fonksiyonu uygulanarak sayısal bir diziye ikili değerlere ve kategori sayısına eşit sütunlara sahip bir matrise dönüştürülür. CNN algoritması kullanılırken 2 boyutlu sayısal bir veri ile uğraşıldığı için Keras'taki Conv1D katmanı tercih edilmiştir. Oluşturulan CNN modelinde 3 adet Convolution ve 1 adet Max Pool katmanı kullanılmıştır. Convolution katmanı için giriş değeri 21'dir ve bu katmanlarda relu aktivasyon fonksiyonu kullanılmıştır. Çıkış katmanında ise 3 tane etiket (HK, AK, EM) olduğu için 3 adet sinir node'u oluşturulmuştur ve softmax aktivasyon fonksiyonu kullanılmıştır. 50 epok sonucunda %80 doğruluk ve 0.4689 kayıp değerine ulaşılmıştır.

Bu model için optimizasyon olarak SGD (Stochastic Gradient Descent) kullanılmıştır. Öğrenme oranı (learning rate) 0.1, decay değeri  $10^{-6}$ , momentum değeri 0.9 olarak alınmıştır. Epok sayısı 50 alınmıştır. Bu değerler ile elde edilen sonuçlar neticesinde eğitim ve doğrulama verileri için kayıp ve doğruluk grafiği Şekil 3'de verilmiştir. Çalışmada kullanılan CNN ve DNN derin öğrenme algoritmaları sonucu üretilen doğruluk ve kayıp grafikleri karşılaştırıldığında CNN'nin daha iyi sonuç verdiği ortaya çıkmıştır.

### 3.3. Birliktelik Analizi (Association Analysis)

Veri madenciliğinin en önemli tekniklerinden biri olan birliktelik kuralı operasyonel veri tabanlarındaki veya diğer veri havuzlarındaki öğeler arasında ilginç korelasyonları sık kalıpları, birliktelik davranışlarını veya ilişkilendirmeleri ortaya çıkarmayı

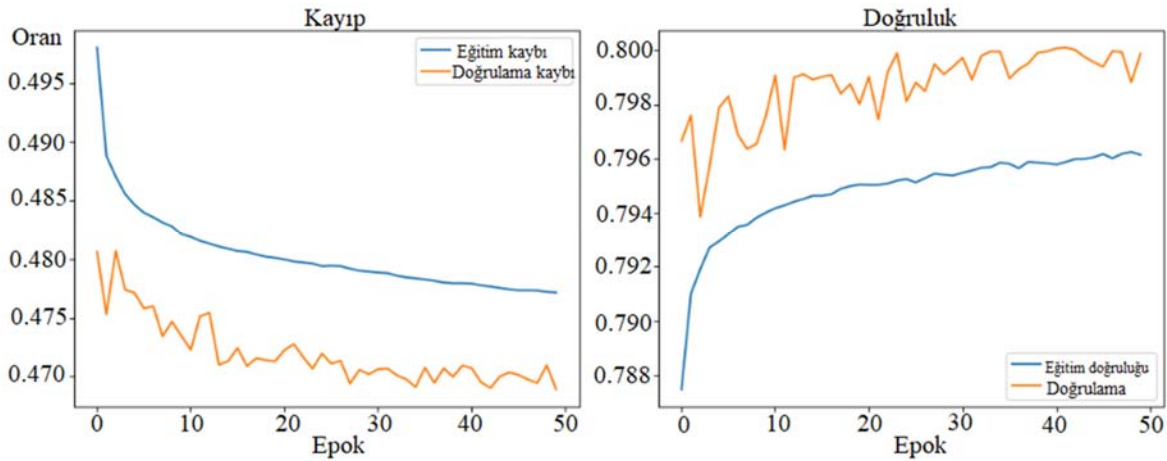
amaçlamaktadır [20]. Birliktelik kuralı veri madenciliği yöntemleri içinde Apriori algoritması en fazla bilinen ve uygulanan yöntemdir. Apriori algoritması, veri kümesi içerisinde herhangi bir olayın meydana gelme durumunu, diğer olayların meydana gelme olasılığına bakarak tahmin etmektedir [21].

Bu çalışmada 2015 Mart ayında muayene sonucu Ağır Kusurlu çıkan araçların kusur verileri kullanılmıştır. Apriori birliktelik analizi ile muayene sonucunda çıkan hatalarda sık geçen kusurlar bulunmuş olup diğer kusurlar ile arasında ilişkiler aranmıştır. 2015 Mart ayına ait veriler 232.717 adet muayene kusur verilerini içermektedir ve bu veri seti içerisinde toplamda 1457 farklı kusur tipi vardır.

Apriori modelinde minimum destek (support) parametresi için %20 eşik değeri seçilmiştir. Python'da "Association rules" fonksiyonu kullanılarak tablo 5'de kurallar tablosu oluşturulmuştur. %20 minimum confidence değeri seçilmiştir.

Apriori algoritması sonucu çıkan kurallara göre;

- Apriori algoritması sonucu birlikte çıkan kurallara göre en çok 5.3.3. kodlu "Kısa huzmeli far: yönü hatalı" kusuru ve 14.7.1 kodlu "Motor: yağ kaçakları var" kusuru birlikte %33 (support) olasılıkla görülmektedir (Kural 4 ve 5).
- 2015 Mart ayı araç muayene verilerinde en çok %68.90 olasılığı ile 5.3.3. kodlu "Kısa huzmeli far: yönü hatalı" kusuru görülmüştür.
- Kural 21'e göre 5.3.3. kodlu "Kısa huzmeli far: yönü hatalı" kusuru ve 14.7.2 kodlu "Şanzıman: yağ kaçakları var" kusuru görülenlerin (confidence) %90'ında 14.7.1 kodlu "Motor: yağ kaçakları var" kusuru da görülmektedir.
- Kural 3'e göre 14.7.2 kodlu "Şanzıman: yağ kaçakları var" kusuru görülenlerin (confidence) %90'ında 14.7.1 kodlu "Motor: yağ kaçakları var" kusuru da görülmektedir.
- 5.4.10 kodlu "Uzun huzmeli far: yönü hatalı" kusuru görülenlerin (confidence) %89.66'sında 5.3.3 kodlu "Kısa huzmeli far: yönü hatalı" kusuru da görülmektedir. (Kural 16)
- 15.16.3 kodlu "İlk yardım çantası: yok" kusuru görülenlerin (confidence) %89.11'inde 15.8.1 kodlu "Yangın söndürme tüpü: yok" kusuru da görülmektedir. (Kural 8)
- Birbiryle olan korelasyonları (conviction) en yüksek olan kusurlar: Conviction 6.91 değeri ile 15.16.3 kodlu "İlk yardım çantası: yok" kusuru ve 15.8.1 kodlu "Yangın söndürme tüpü: yok" kusurudur (Kural 8). Daha sonra conviction 6.27 değeri ile 5.3.3 kodlu "Kısa huzmeli far: yönü hatalı", 14.7.2 kodlu "Şanzıman: yağ kaçakları var" ve 14.7.1 kodlu "Motor: yağ kaçakları var" kusurudur (Kural 21).



Şekil 3. CNN algoritması doğruluk kayıp grafiği (CNN algorithm accuracy loss graph)

**Tablo 5.** Apriori algoritması sonucu çıkan kurallar (Rules resulting from the Apriori algorithm)

	Antecedents (geçmiş)	Consequents (sonuç)	Antecedent support (önceki destek)	Consequents support (sonuç destek)	Support (destek)	Confidence (güven)	Lift (kaldırma)	Leverage (kaldıraç)	Conviction (kanaat)
0	5.3.3	14.1.23	0.689034	0.264317	0.210367	0.305307	1.155081	0.028244	1.059005
1	14.1.23	5.3.3	0.264317	0.689034	0.210367	0.795890	1.155081	0.028244	1.523521
2	14.7.1	14.7.2	0.426037	0.340985	0.308937	0.725143	2.126612	0.163665	2.397663
3	14.7.2	14.7.1	0.340985	0.426037	0.308937	0.906015	2.126612	0.163665	6.106959
4	5.3.3	14.7.1	0.689034	0.426037	0.336250	0.488001	1.145444	0.042696	1.121025
5	14.7.1	5.3.3	0.426037	0.689034	0.336250	0.789250	1.145444	0.042696	1.475521
6	5.3.3	14.7.2	0.689034	0.340985	0.272950	0.396133	1.161733	0.037999	1.091326
7	14.7.2	5.3.3	0.340985	0.689034	0.272950	0.800474	1.161733	0.037999	1.558521
8	15.16.3	15.8.1	0.242281	0.247816	0.215910	0.891155	3.596035	0.155869	6.910606
9	15.8.1	15.16.3	0.247816	0.242281	0.215910	0.871252	3.596035	0.155869	5.885305
10	5.3.3	5.3.1	0.689034	0.313320	0.263595	0.382557	1.220976	0.047706	1.112134
11	5.3.1	5.3.3	0.313320	0.689034	0.263595	0.841295	1.220976	0.047706	1.959390
12	5.3.2	5.3.3	0.381717	0.689034	0.312852	0.819592	1.189479	0.049836	1.723680
13	5.3.3	5.3.2	0.689034	0.381717	0.312852	0.454044	1.189479	0.049836	1.132479
14	5.3.2	5.4.9	0.381717	0.277895	0.215687	0.565044	2.033297	0.109609	1.660179
15	5.4.9	5.3.2	0.277895	0.381717	0.215687	0.776144	2.033297	0.109609	2.761967
16	5.4.10	5.3.3	0.318468	0.689034	0.285557	0.896658	1.301325	0.066122	3.009087
17	5.3.3	5.4.10	0.689034	0.318468	0.285557	0.414431	1.301325	0.066122	1.163879
18	5.3.3	5.4.9	0.689034	0.277895	0.228741	0.331974	1.194600	0.037262	1.080952
19	5.4.9	5.3.3	0.277895	0.689034	0.228741	0.823120	1.194600	0.037262	1.758061
20	5.3.3, 14.7.1	14.7.2	0.336250	0.340985	0.248001	0.737550	2.162998	0.133345	2.511009
21	5.3.3, 14.7.2	14.7.1	0.272950	0.426037	0.248001	0.908596	2.132670	0.131714	6.279391
22	14.7.2, 14.7.1	5.3.3	0.308937	0.689034	0.248001	0.802754	1.165042	0.035132	1.576537
23	5.3.3	14.7.2, 14.7.1	0.689034	0.308937	0.248001	0.359925	1.165042	0.035132	1.079659
24	14.7.1	5.3.3, 14.7.2	0.426037	0.272950	0.248001	0.582111	2.132670	0.131714	1.739818

- İlk yardım çantası olmayan araçların olan araçlara göre muhtemelen (lift) 3.59 kat daha fazla 15.8.1 kodlu “Yangın söndürme tüpü: yok” kusuru görülecektir (Kural 8). Yine aynı şekilde yangın söndürme tüpü olmayan araçların olan araçlara göre muhtemelen (lift) 3.59 kat daha fazla “İlk yardım çantası: yok” kusuru görülecektir (Kural 9).

#### 4. Sonuçlar ve Tartışmalar (Results and Discussions)

Bu çalışmada araç muayene verileri ile makine öğrenmesi algoritmaları ve derin sinir ağları kullanılarak araç muayene sonucu tahmini yapılmış ve kullanılan modellerin performansı değerlendirilmiştir. Ayrıca araç muayene sonucunda çıkan kusurlar için birliktelik analizi gerçekleştirilmiştir.

Bu çalışmanın amacı karayolunda seyreden motorlu ve motorsuz araçların teknik muayenelerini daha etkin ve sağlıklı bir şekilde yapılmasına yardımcı olmaktır. Yapılan araştırmalar neticesinde araçların hata tahmini probleminde daha önceden yapılan çalışmalardan faydalanılarak araç muayene sonucunu doğru tahmin edebilmek amaçlanmıştır. Ayrıca kusur verileri üzerinde birliktelik analizi yapılarak araçlarda çıkabilecek hataların önceden keşfedilerek çıkabilecek arızaların erken tespitlerinde yararlı olacaktır. Birliktelik analizi ile araç muayene sonucunda çıkan kusurlar arasında anlamlı ilişkiler bulmak ve bu ilişkilerden faydalanarak araç sürücülerine ve araç muayene sürecine katkı sağlamak amaçlanmıştır.

Çalışma ile ilgili yapılan literatür araştırmasında daha çok otomobil arıza tespit sistemi ve otomobil motorunun hata tespiti üzerine yapılan çalışmalar yer almaktadır. Ayrıca bu çalışmalarda genellikle araç servislerine ait daha çok teknik bilgi içeren veriler ile araç arıza tespit sistemi uygulamaları üzerine çalışılmıştır. İncelenen çalışmalarda yapay sinir ağları ve bulanık mantık otomobil arıza teşhis alanında çok kullanılan bir yöntemlerdir. Son zamanlarda uzman sistemler (expert system), sinir ağları (neural network), doğrusal olmayan PCA yöntemi ve bulanık mantık yaklaşımları da dahil olmak üzere çeşitli

veriye dayanan hata tanıma algoritmaları önerilmiştir. İnsan uzmanlığını içeren uzman sistem (expert system) ve bulanık mantık yaklaşımları bu alanda başarıyla uygulanmıştır.

Türkiye’de ise araç muayene verileri üzerinde makine öğrenmesi uygulanması ve muayene sonucunda çıkan kusurların birliktelik analizi çalışması daha önce gerçekleştirilmemiştir. Bu yapılan çalışma ile araç kusurları arasında anlamlı ilişkiler bulunmuştur. Bu çalışma ile daha benzer olan Das ve arkadaşlarının yaptığı çalışmasında araç muayene verileri ile kaza çarpışma verileri birlikte kullanılıp metin madenciliği modeli gerçekleştirilerek araç muayenelerinin güvenlik etkinliğini araştırılmıştır. Bu yapılan çalışmada ise sadece araç muayene verileri üzerinde çalışılmıştır. Elimizde kaza çarpışma verileri olmadığından dolayı hem araç muayene verisi hem de kaza çarpışma verileri ile ilgili bir çalışma yapılamamıştır. Bu tez çalışmasında diğer çalışmalardan farklı olarak daha çok veri ile (yaklaşık 7 milyon veri) çalışılmıştır. Diğer yıllarda verileri elde edilerek daha kapsamlı bir çalışma yapılabilir. Ayrıca kullanılan veri setinde araç muayenesinde çıkan araç kusurları daha detaylı bilgiler içermektedir. Bu tez çalışmasında 1694 adet kusur türü vardır fakat bunları analiz etmek hem güç hem de yeterli bilgisayar donanımına sahip olunmaması sebebi ile 15 kusur sınıfı altında incelenmiştir.

Tahmin modeli için araç muayene verilerine Lojistik Regresyon (LR), Naive Bayes (NB), Karar Ağaçları (DT), Rastgele Orman (RF), K-En Yakın Komşu (KNN), Gradyan Yükseltme (XGBoost), AdaBoost ve derin öğrenme algoritmalarından Derin Sinir Ağı (DNN) ve Evrimsel Sinir Ağı (CNN) uygulanmıştır. Araç muayene veri setinde sınıflar dengesiz dağılmıştır. Araç muayene verisinin yaklaşık %73’ünü hafif kusurlu sınıfı, %25’ini ağır kusurlu sınıfı ve %2’sini emniyetsiz sınıfı oluşturmaktadır. Sınıfların dengesiz dağılımından dolayı araç muayene verisi üzerinde örnekleme işlemi yapılmıştır. Az örnekleme yapılarak hafif kusurlu ve ağır kusurlu sınıfının bazı verileri veri setinden çıkarılmış olup 264.642 adet veri elde edilmiştir ve sınıflar dengeli hale getirilmiştir. Çok örnekleme yapılarak azınlık sınıf olan ağır kusurlu ve emniyetsiz sınıfının verileri çoğaltılıp

161.90.493 veri elde edilmiştir. Tüm araç muayene verileri (yaklaşık 7 milyon veri), az örnekleme ve çok örnekleme işlemi yapılarak elde edilen verilere makine öğrenmesi algoritmaları (LR, NB, KNN, DT, RF, XG Boost) ve Derin Sinir Ağları (DNN) uygulanmıştır. Her bir model AUC, ROC eğrisi, doğruluk, kesinlik, hatırlatma ve F1 skor değerleri açısından karşılaştırılmıştır. Makine öğrenme modellerinin araç muayene verilerini kullanarak hafif kusurlu, ağır kusurlu ve emniyetsiz muayene sonucu tahmininin yüksek doğrulukla öngörebildiği sonucuna ulaşılmıştır. En yüksek doğruluk değerine çok örnekleme ile elde edilen verilere Rastgele Orman algoritması uygulanarak %88.08 doğruluk seviyesine ulaşılmıştır. Tüm veri ile elde edilen sonuçlara göre azınlık sınıf olan ağır kusurlu ve emniyetsiz sınıflarını tahmin etme oranı düşük çıkmıştır. Bunun sebebi verilerin dengesiz dağılımıdır. Fakat az örnekleme ve çok örnekleme yapılarak ağır kusurlu ve emniyetsiz sınıflarını tahmin etme oranı artırılmıştır. Azınlık sınıflarını tahmin etme oranı en yüksek XG Boost, Ada Boost, Derin Sinir Ağı ve Random Forest algoritmalarından elde edilmiştir. Ayrıca çok örnekleme ile elde edilen sonuçlar az örnekleme ile elde edilen sonuçlara göre daha başarılı çıkmıştır.

Ayrıca bu araştırma çalışmasında birliktelik kuralları çıkarım yöntemlerinden Apriori algoritması kullanılarak araçların muayene sonucuna göre görülen kusurların analizi gerçekleştirilmiştir. Apriori algoritması araç muayene veri kümesinde yer alan temel örüntüleri keşfetmek için kullanılmıştır. Apriori algoritması ile araç muayene verileri üzerinden istatistiksel teknikler ile tahmin edilemeyen çıkarımlar yapılmıştır ve bu sayede ileriye dönük analizler yapmak veya kararlar almak mümkün olacaktır. Birliktelik kuralları sonucuna göre kısa huzmeli far yönü hatası %68 oranla en çok görülen kusur olmuştur. İkinci en çok görülen kusur ise %48 oranla motorda yağ kaçaklarının olması kusuru olmuştur. Şanzımanında yağ kaçakları görülen araçların %90'ında motorunda da yağ kaçakları olduğu görülmüştür. Ayrıca bu iki kusur %30 olasılıkla birlikte en çok görülen kusurlardandır. Uzun huzmeli far yönü hatalı olan araçların %89'unda kısa huzmeli far yönünün de hatalı olduğu görülmüştür. İlk yardım çantası olmayan araçların %89'unda yangın söndürme tüpünün de olmadığı görülmüştür. Ayrıca bu iki kusur birbiriyle korelasyonları en yüksek olan kusurlardır. Araç muayene verisinde çıkan bu kurallar neticesinde araç sürücülerinin bu kusurlara daha çok dikkat etmesi ve önlemler alması gerektiği ortaya çıkmaktadır. Ayrıca araç üreticileri ve servisler bu kusurlara bakım sırasında daha önem verip ek önlemler alabilirler. Birliktelik analizi sonucu birlikte görülen kusurlar ile araç muayene istasyonlarında gerçekleştirilen muayene işleminde daha fazla dikkat edilecek hususlar belirtilmiştir. Araç muayene istasyonlarında muayene yapan personeller birliktelik analizi sonucunda çıkan hususlara dikkat edip bu bilgileri kullanarak araç muayenesini daha etkin ve güvenli bir şekilde yapabilirler.

Bu çalışmada araç muayene veri setinde 1694 tane kusur türü olduğundan ve bu kusurların hepsini makine öğrenmesi algoritmaları ile analiz etmek hem güç hem de yeterli bilgisayar donanımına sahip olunmaması sebebi ile veri toplam 15 kusur grubu altında incelenmiştir. Bir sonraki çalışmada tüm kusur tipleri kullanılarak detaylı bir çalışma yapılabilir. Araç muayene verilerinin Apriori algoritması ile birliktelik analizinde ise yeterli bilgisayar belleği olmamasından dolayı sadece 2015 Mart ayı verileri ile çalışılmıştır. Daha sonraki çalışmalarda daha fazla veri ile birliktelik analizi yapılabilir.

## Kaynaklar (References)

- Das S., Geedipally S. R., Dixon K., Sun X. ve Ma C., Measuring the Effectiveness of Vehicle Inspection Regulations in Different States of the U.S., *Transportation Research Record* 2019, 2673 (5), 208-219, 2019.
- Martín-delosReyes L.M., Lardelli-Claret P., García-Cuerva L., Rivera-Izquierdo M., Jiménez-Mejías E. ve Martínez-Ruiz V., Effect of Periodic Vehicle Inspection on Road Crashes and Injuries: A Systematic Review. *Int. J. Environ. Res. Public Health*, 18, 6476, 2021.
- Talonen, J., Sirola, M. ve Sulkava, M., Network Visualization of Car Inspection Data using Graph Layout. *The First International Conference on Data Analytics*, 39-42, 2012.
- Gang H., Automobile Fault Diagnosis System Based on Improved Neural Network," 2016 International Conference on Smart City and Systems Engineering (ICSCSE), 494-497, 2016.
- Dejun W., Tianliang X., Chengdong L. ve Lihua W., Fault diagnosis of automobile engine based on support vector machine. 2011 3rd International Conference on Advanced Computer Control, 320-324, 2011.
- Bo Q., Fault diagnosis method of automobile engine based on least squares support vector machine. 2010 2nd International Conference on Signal Processing Systems, V3-43-V3-46, 2010.
- Youjun Y., Xiang L. ve Qun Z., Development of automobile fault diagnosis expert system based on fault tree-Neural network ensemble. 2011 International Conference on Electronics, Communications and Control (ICECC), 2028-2031, 2011.
- Kong L. F., Zhu S. S. ve Wang Z., Gradient genetic algorithm-based oil fault diagnosis model for automobile engine. 2011 2nd International Conference on Artificial Intelligence, Management Science and Electronic Commerce (AIMSEC), 2127-2130, 2011.
- Murphy Y. L. ve Chen Z., A Multi-Agent System for Complex Vehicle Fault Diagnostics and Health Monitoring. 15th IEEE International Conference on Engineering of Complex Computer Systems. 52 (4), 1076-1098, 2010.
- Sato H., Yakuwa F. ve Dote Y., Combination of radial basis function (RBF) and time delayed neural networks (TDNN) for fault diagnosis of automobile transmission gears using general parameter learning and adaptation. *SMC'03 Conference Proceedings. 2003 IEEE International Conference on Systems, Man and Cybernetics. Conference Theme - System Security and Assurance*, 2, 1457-1462, 2003.
- Luckow A., Cook M., Ashcraft Weill, N. E., Djerekarov E. ve Vorster B., Deep learning in the automotive industry: Applications and tools. 2016 IEEE International Conference on Big Data (Big Data), 3759-3768, 2016.
- Lili Z., Jiangwei C. ve Bencun Z., Study of automobile electric controlled system fault diagnosis based on classification pattern recognition. *The 2010 IEEE International Conference on Information and Automation*, 2076-2081, 2010.
- Zheng S., Han Z., Tang H. ve Zhang Y., Application of support vector machines to sensor fault diagnosis in ESP system. *Proceedings of 2004 International Conference on Machine Learning and Cybernetics*, 6, 3334-3338, 2004.
- Weijie W., Yuanfu K., Xuezheng Z. ve Wentao H., Study of automobile engine fault diagnosis based on wavelet neural networks. *Fifth World Congress on Intelligent Control and Automation*, 1, 2, 1766-1770, 2004.
- Kher S. ve Chande P. K., Intelligent diagnosis of transparent faults in automobiles," *Proceedings of the 35th SICE Annual Conference. International Session Papers*, 1415-1420, 1996.
- Gao X. Z., Ovaska S. J. ve Dote Y., Motor fault detection using Elman neural network with genetic algorithm-aided training. *Smc 2000 conference proceedings. 2000 IEEE international conference on systems, man and cybernetics. 'cybernetics evolving to systems, humans, organizations, and their complex interactions'*, 4, 2386-2392, 2000.
- Amancio DR, Comin CH, Casanova D, Travieso G, Bruno OM. A Systematic Comparison of Supervised Classifiers. *PLOS ONE* 9 (4), 2014.
- M. Scholz, T. Wimmer, A comparison of classification methods across different data complexity scenarios and datasets, *Expert Systems with Applications*, 168, 2021.
- Olgun S., Yazılım Projelerinin Yönetiminde Maliyet Tahmini için Derin Öğrenme Tabanlı Yeni Bir Yaklaşım. *Doktora Tezi, İstanbul Üniversitesi Lisansüstü Eğitim Enstitüsü / Endüstri Mühendisliği Ana Bilim Dalı*, 25. İstanbul, 2020.
- Kotsiantas S. ve Kanellopoulos D., Association Rules Mining: A Recent Overview. *GESTS International Transactions on Computer Science and Engineering*, 32 (1), 71-82, 2006.
- Elabiad Z., Web Tabanlı Anket Sistemi İle Elde Edilen Verilerin Veri Madenciliği Yöntemi ile Analizi, Yüksek Lisans Tezi, İstanbul Aydın Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 18, 2013.

