KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ
ANABİLİM DALI

YÜKSEK LİSANS TEZİ

AKAN VİDEO GÖRÜNTÜLERİ ÜZERİNDEN, DAĞITIK, İŞBİRLİKÇİ VE GERÇEK ZAMANLI ARAÇ TANIMA VE BOYUTLARINA GÖRE SINIFLANDIRMA SİSTEMİ

SEDA KUL

KOCAELİ 2017

KOCAELİ ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ

ANABİLİM DALI

YÜKSEK LİSANS TEZİ

AKAN VİDEO GÖRÜNTÜLERİ ÜZERİNDEN, DAĞITIK, İŞBİRLİKÇİ VE GERÇEK ZAMANLI ARAÇ TANIMA VE BOYUTLARINA GÖRE SINIFLANDIRMA SİSTEMİ

SEDA KUL

Doç.Dr. Ahmet SAYAR
Danışman, Kocaeli Üniversitesi .....

Yrd.Doç.Dr. Orhan AKBULUT
Jüri Üyesi, Kocaeli Üniversitesi .....

Yrd.Doç.Dr. Seçkin ARI
Jüri Üyesi, Sakarya Üniversitesi .....

Tezin Savunulduğu Tarih: 19.12.2017

ÖNSÖZ VE TEŞEKKÜR

Bu tez çalışmasında, araçların sınıflandırılması ve sınıflandırılmış görüntülerin yayınla/kaydol sistemi ile istemcilere gönderilmesi amaçlanmaktadır. Sisteme kayıtlı kullanıcılara istedikleri özelliklere sahip araçlara ait bilgi/görüntülerin gerçek zamanlı olarak aktarılması gerçekleştirilmeye çalışılmıştır .

Tez çalışmamda desteğini esirgemeyen, çalışmalarıma yön veren, bana güvenen ve yüreklendiren, karşılaştığım her zorlukta desteğini ve zamanını esirgemeyen danışmanım Doç. Dr. Ahmet SAYAR'a sonsuz teşekkürlerimi sunarım.

Akademik çalışmalarım sırasında, birçok aşamada beni destekleyen Bilgisayar Mühendisliği Bölümü araştırma görevlilerine teşekkür ediyorum.

Hayatım boyunca tüm zorlukları benimle göğüsleyen ve hayatımın her evresinde bana destek olan, bana güç veren en büyük destekçilerim, her aşamada sıkıntılarımı ve mutluluklarımı paylaşan sevgili annem Aydan KUL, babam İsmail KUL, ablam Kübra YUMRUKUZ ve eşi Fırat YUMRUKUZ' a teşekkürlerimi sunarım.

Bu çalışma, 2016/004 kodlu proje kapsamında Kocaeli Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi (BAP) tarafından desteklenmiştir. Desteklerinden dolayı teşekkür ederiz.

Aralık – 2017 Seda KUL

İÇİNDEKİLER

ÖNSÖZ VE TEŞEKKÜR i
İÇİNDEKİLER ii
ŞEKİLLER DİZİNİ iii
TABLOLAR DİZİNİ iv
SİMGELER VE KISALTMALAR DİZİNİ v
ÖZET vi
ABSTRACT vii
GİRİŞ 1
1. ÖNERİLEN YÖNTEM 9
1.1. Arka Plan Çıkarma ve Araç Tespiti 11
1.2. Özellik Vektörünün Oluşturulması 17
1.3. Özellik Vektörü Boyut Azaltma 19
1.4. Araç Sınıflandırma 21
1.5. Java Native Interface (JNI) 25
1.6. Konu Tabanlı Yayınla/Kaydol Sistemi 26
2. SONUÇLAR VE ÖNERİLER 33
KAYNAKLAR 40
KİŞİSEL YAYIN VE ESERLER 46
ÖZGEÇMİŞ 47

ŞEKİLLER DİZİNİ

Şekil 1.1. Mimariye genel bakış 9
Şekil 1.2. Sistemin genel mimarisi 10
Şekil 1.3. Örnek veri setine ait görüntüler 11
Şekil 1.4. Elde Edilen Maskeleme Görüntüleri 13
Şekil 1.5. Uyarlanabilir Arka Plan Öğrenme Algoritması 14
Şekil 1.6. Arka Plan Çıkarma Algoritmasının Sözde Kod Gösterimi 15
Şekil 1.7. UyarlanabilirAP Öğrenme Algoritmasının Akış Şeması 16
Şekil 1.8. Referans çizgisi gösterimi 18
Şekil 1.9. Özellik Seçimi Sözde Kod Gösterimi 20
Şekil 1.10. DVM'nin Genel Mimarisi 22
Şekil 1.11. DVM Küçük-Büyük Sınıf Karşılaştırma 22
Şekil 1.12. DVM Küçük-Orta Sınıf Karşılaştırma 23
Şekil 1.13. DVM Orta-Büyük Sınıf Karşılaştırma 23
Şekil 1.14. Sınıflandırmada Kullanılan Yapay Sinir Ağı Modeli 24
Şekil 1.15. JNI Modeli 25
Şekil 1.16. JNI Mimarisinin sözde kod gösterimi 26
Şekil 1.17. Önerilen yayınla/kaydol modeli 26
Şekil 1.18. Önerilen yayınla/kaydol model diyagramı 27
Şekil 1.19. JMS API Genel Mimari 28
Şekil 1.20. Yayınla/Kaydol Mimarisi sözde kod gösterimi 30
Şekil 1.21. Yayımcı (Publisher) Mimarisi sözde kod gösterimi 31
Şekil 1.22. Abone (Subscriber) Mimarisi sözde kod gösterimi 32
Şekil 2.1. Örnek veri seti görüntüleri 34
Şekil 2.2. BIT veri seti üzerinden örnekler 37

TABLOLAR DİZİNİ

Tablo 1.1. BGSLibrary'nin en iyi skorlarına sahip algoritmaları 12
Tablo 1.2. Kullanılan veri setleri hakkında ayrıntılı bilgi 12
Tablo 1.3. BMC ve Changedetection veri setleri üzerinde BGS algoritmalarının performansı 14
Tablo 1.4. Öznitelik Çıkarım Yöntemlerinin Çalışma Süreleri 19
Tablo 1.5. Özelliklerin Değer Aralıkları 19
Tablo 1.6. Öznitelik Seçimi Sonrası Özellikler 21
Tablo 2.1. Çok Sayıda Sınıf İçin Karışıklık Matrisi 34
Tablo 2.2. Farklı sınıflandırma algoritmaları ve TPSdataset'nin farklı özellikleri ile araç sınıflandırma sonuçları 36
Tablo 2.3. Farklı sınıflandırma algoritmaları ve BIT-Vehicle veri seti üzerinde farklı özellikler ile araç sınıflandırma sonuçları 38

SİMGELER VE KISALTMALAR DİZİNİ

α	:	Öğrenme Oranı
T	:	Threshold

Kısaltmalar

ANN	:	Artificial Neural Networks (Yapay Sinir Ağları)
JNI	:	Java Native Interface (Java Yerli Arabirimi)
PUB/SUB	:	Publish/Subscribe (Yayınla/Abone Ol)
SIFT	:	Scale-Invariant Feature Transform (Ölçek Bağımsız Özellikler)
SURF	:	Speeded Up Robust Feature (Hızlandırılmış Gürbüz Özellikler)
SVM	:	Support Vector Machine (Destek Vektör Makineleri)

AKAN VİDEO GÖRÜNTÜLERİ ÜZERİNDEN, DAĞITIK, İŞBİRLİKÇİ VE GERÇEK ZAMANLI ARAÇ TANIMA VE BOYUTLARINA GÖRE SINIFLANDIRMA SİSTEMİ

ÖZET

Trafik yönetim ve bilgi sistemlerinin trafik akışını düzgün bir şekilde sağlayabilmesi için çeşitli algılayıcılar yardımıyla trafikle ilgili bilgileri elde etmesi gerekmektedir. Bu kapsamda, son yıllarda trafik gözlemi ve denetiminde video kameralarının kullanımı çok yaygınlaşmış ve aktif olarak kullanılmaktadır. Görüntü işleme tabanlı video izlemeye dayalı trafik sistemleri yardımıyla plaka tanıma, araç sayısı bulma, trafik yoğunluğu tespiti, araç hızı hesaplanması, şerit ihlalleri ve araç sınıflandırma gibi birçok çalışma yapılabilmektedir.

Gerçekleştirilen tez kapsamında iki temel işlem gerçekleştirilmiştir: (1) araç görüntülerinin sınıflandırması ve (2) sınıflandırılmış görüntülerin konu tabanlı olarak yayınla/kaydol sistemi ile istemcilere gönderilmesi. İlk olarak kamera parametrelerinden (kameranın yüksekliği, yolu görüş açısı vs.), kalibrasyonundan ve otoyola ait herhangi bir bilgiden (arabaların hareket yönü, şerit çizgileri vs.) bağımsız olarak otoyolunu yukarıdan görecek şekilde yerleştirilmiş herhangi sabit bir kamera ile elde edilen araç görüntüleri farklı sınıflandırıcılar ile araba, orta sınıf araç ve büyük sınıf araç olmak üzere üç sınıfa ayrılmıştır. Daha sonra sınıflandırılan görüntüler konu tabanlı (topic-based) yayınla/kaydol mesajlaşma protokolü yardımıyla istemcilere gönderilmesi gerçekleştirilmiştir. Otoyol üzerindeki sabit bir video kameradan alınan görüntüye, ilk olarak ön plan-arka plan çıkarımı (araç ve araç değil) uygulanmıştır. Elde edilen ön plan görüntüsü farklı filtreleme yöntemleriyle gürültülerinden arındırılarak ve hareket halindeki imge bölgeleri (araçlar) tespit edilmiştir. Ardından sınıflandırıcıda kullanılması için özellik vektörü oluşturulmuştur. Özellik vektörü; araçlara ait geometrik tabanlı (en, boy, yükseklik) özellikler, görünüm tabanlı özellikler (Ölçek Bağımsız Özellikler (SIFT) ve Hızlandırılmış Gürbüz Özellikler (SURF)) ve ikili imge özelliklerinden (alan oranı, en-boy oranı, majör ve minör eksen uzunluğu, çevre vs.) oluşmaktadır. Sınıflandırıcı olarak Destek Vektör Makineleri (Support Vector Machine - SVM), Yapay Sinir Ağları (YSA) ve AdaBoost kullanılarak ilgili görüntüler üzerinde araçlar küçük, orta ve büyük sınıf olarak etiketlenmiştir. Sınıflandırma başarısı; doğruluk (accuracy), hassaslık (recall), ve kesinlik (precision) metriklerine göre değerlendirilmiştir.

Anahtar Kelimeler: Akıllı Trafik Yönetimi, Araç Sınıflandırma, Destek Vektör Makinesi, Konu Tabanlı Yayınla/Kaydol, Yapay Sinir Ağları.

DISTRIBUTED, COLLABORATIVE AND REAL-TIME VEHICLE DETECTION AND SIZE CLASSIFICATION OVER THE VIDEO STREAMS

ABSTRACT

Traffic management and information systems need to obtain information about traffic with various sensors to control the traffic follow properly. In this context, videos are very actively used in traffic surveillance and control in recent years. With the help of image processing based video surveillance system in traffic management systems, many studies are done. Some of these are: license plate recognition, finding the number of vehicles, traffic density detection, vehicle speed calculation, detection of lane violations and vehicle classification.

Within the proposed thesis, two basic operations have been carried out: (1) classification of vehicle imaginaries and (2) transferring classified images to the registered/subscribed users via topic based publish/subscribe system. Firstly, vehicle images are obtained from videos which are taken from an uncalibrated camera which sees any highway from above. This camera is independent from some parameters (height of the camera, the viewing angle of the road etc.), calibration, and any highway information (direction of movement of the car, lane markings, etc.). Secondly, obtained vehicle images are divided into three classes (car, van or truck) using different classification algorithms. Finally, classified vehicle images are sent to registered users via topic based publish/subscribe system. In this thesis, moving blobs are detected by a background-foreground extraction algorithm, classification is done by extracting geometric features (width, length, height), appearance-based features (Scale-invariant feature transform (SIFT) and speeded-up robust features (SURF)) and binary features (area ratio, aspect ratio, major and minor axis length, diameter, etc.) of detected blobs and by giving those features to different classifiers such as support vector machine (SVM) classifier, artificial neural network (ANN), and AdaBoost classifier. Classification performance will be evaluated according to different metrics such as accuracy, recall, and precision.

Keywords: Intelligent Traffic Management, Vehicle Classification, Support Vector Machine, Topic Based Publish/Subscribe, Artificial Neural Networks.

GİRİŞ

Son yıllarda akıllı ulaşım sistemleri ve akıllı trafik yönetim uygulamaları, çeşitli devlet kuruluşları veya özel şirketler tarafından üzerinde titizlikle durulan konulardandır. Görüntü işleme yöntemleri de bu yazılım ve uygulamaları geliştirirken kullanılan temel algoritmalardandır. Genelde görüntü işleme temelli araç sınıflandırma sistemleri üzerinde literatürde birçok çalışma bulunmasına rağmen yaptığımız araştırmalar neticesinde sınıflandırılan araç görüntülerinin istemcilere konu tabanlı olarak servis edilmesi üzerinde herhangi bir çalışma yapılmamıştır. Önerilen sistemde kameralardan elde edilen gerçek zamanlı görüntüler, içeriklerine göre ilgili konulara bölütlenerek o konuya ait kanaldan yayımlanmaktadır. O kanala kaydolan istemciler gerçek zamanlı görüntünün sadece ilgili olan kısımlarını almaktadırlar. Bu şekilde ağ trafiği azalıp görüntü işleme uygulamalarında ölçekleme ve performans problemlerine çözüm sunulmuştur.

Trafik yönetim ve bilgi sistemlerinin trafik akışını düzgün bir şekilde sağlayabilmesi için çeşitli algılayıcılar yardımıyla trafikle ilgili bilgileri elde etmesi gerekmektedir. Bu kapsamda, son yıllarda trafik gözlemi ve denetiminde video kameralarının kullanımı çok yaygınlaşmış ve aktif olarak kullanılmaktadır. Görüntü işleme tabanlı video izlemeye dayalı trafik sistemleri yardımıyla plaka tanıma [1-3], otomatik araç tanımlama [4], yol kapasitesi [5], trafik yoğunluğu ölçümü [6], hız tespiti [7-9], trafik ihlal tespiti [10] ve araba kategorilerinin belirlenmesi [11-14] gibi birçok çalışma yapılabilmektedir.

Araç sınıflandırması, trafik yönetim sistemlerinde çok önemli bir süreçtir. Araç sınıflandırma sistemlerinden elde edilen sonuçlar, raporlama, istatistiksel analiz, asfalt kalınlığının belirlenmesi ve farklı boyuta, renge, hıza vb. sahip araçların aranması gibi farklı amaçlar için kullanılabilir.Gerçek zamanlı görüntü işleme teknikleri alanındaki ilerleme birçok uygulama alanında dikkat çekmektedir.

Akıllı trafik/araç yönetim sistemlerinde, trafik gözetim verilerinin daha sonraki işlemler için kaynaktan hedefe hızlı bir şekilde ulaştırmak çok önemli bir süreçtir.

Gözetim kameraları, sınırlı bir işlem gücü ve küçük depolama alanına sahiptir. Bu nedenle, yalnızca verileri yerel olarak yakalayıp depolayabilir ve bazı temel görüntü işleme işlemleri gerçekleştirebilirler. Hatta bazılarının depolama veya işleme yetenekleri yoktur. Sadece veri yakalar ve Internet bağlantıları yoluyla işlem birimlerine aktarırlar.Bununla birlikte, bazı acil trafik durum sistemlerinde, gerçek zamanlı görüntü işleme geçici görüntü dizileri üzerinde gerçekleştirilmektedir. Video verileri sürekli akış halinde olduğundan ve çok büyük boyutlara ulaşmasından dolayı, merkezi işleme teknikleri çok verimli olamayabilmektedir bu durum gerçek zamanlı senaryolar dahilinde daha da kötüleşmektedir. Bu tür sistemlerde, verilerin makul bir süre içinde işlenip analiz edilmeleri gerekir. Doğru kararların verilebilmesi için, doğru sınıflandırılan verilerin zamanında istenilen yerlere gönderilmesi gerekmektedir.

Gerçek dünyada, kullanıcı küçük boyutlu araçların (sedan gibi) bir resmini veya bir video parçasını almak isteyebilir, aynı bilgileri başka bir kullanıcı, büyük boy araçlar (kamyonlar gibi) için isteyebilir ve diğer bir kullanıcı şerit ihlali yapan bir araç hakkında bilgi almak isteyebilir. Böyle bir sistemi gerçekleştirmek için bir gözetleme kamerası, bir görev dağıtıcı ve son kullanıcılara ihtiyaç vardır. Gözetleme kamerası, video akışını görev dağıtıcısına aktarır, görev dağıtıcısı video akışını işler ve kayıtlı son kullanıcılara göre parçalara ayırır ve ardından ilgili video akışlarını kayıtlı son kullanıcılara aktarır.

Bu çalışmanın amacı, trafik gözetim kameraları tarafından sağlanan video akışları üzerinden dağıtık ve işbirliğine dayalı gerçek zamanlı araç algılama ve sınıflandırma sisteminin geliştirilmesidir. Sistemin mimarisi ilerleyen bölümlerde detaylı bir şekilde açıklanacaktır.

Birçok araç sınıflandırma yöntemi mevcuttur, bu yöntemler genel olarak donanım tabanlı ve yazılım tabanlı olarak ikiye ayrılabilir. Donanım tabanlı araç sınıflandırma yöntemleri radar (radar), kızılötesi detektörleri (infrared detectors), mikrodalga yöntemi (microwave method) gibi farklı sistemler üzerinde gerçekleştirilir. Radar teknolojisi hız ölçme ve araç tespiti işlemlerinde yaygın olarak kullanılmaktadır fakat özellikle araç sınıflandırılması üzerinde yapılan çalışmalar doğru analiz yapılamayacak kadar azdır. Ancak, Fang ve ekibi tarafından modülasyonsuz sürekli

dalgalar (CW) kullanılarak yapılan sistemde %95'e varan başarı yakalanmıştır [15]. Donanım tabanlı sistemlerin dezavantajları: detektörlerin boyutlarının büyük ve yönetiminin zor olması, kurulumunun pahalı ve yerleştirildiği yola zarar vermesi, detektörlerin pahalı olması ve elde edilen bilginin sınırlı olmasıdır.

Yazılım tabalı araç sınıflandırma yöntemleri, video tabanlı tanıma içerir. Video tabanlı tanıma sistemlerinin donanım tabanlı sistemlere karşı birçok avantajı bulunmakta bunlar, kolay kurulum yapılabilme, izleme yapılan çevreye herhangi bir zarar vermeme, düşük maliyetli olması, çevre dostu olması ve donanım tabanlı sistemlere göre çok daha fazla bilgi elde edilebilmesi, istenilen bilgi üzerinde kolay bir şekilde değişiklik yapılabilmesidir. Yazılım tabalı araç sınıflandırma yöntemlerinin dezavantajları ise, yavaş işleme, düşük gerçek zamanlı işlem yapma kapasiteleri gibi yazılım sorunlarına karşılık donanım tabanlı sistemlere göre çok daha iyi sonuçlar vermektedir [16]. Bununla birlikte, tek bir sınıfta dahi olsa, araç modellerinin ve boyutlarının artması ve çeşitlilik göstermesi nedeniyle çok zorlu bir süreçtir. Arka planın gürültülü olması, bölgelerin boyutundaki değişim, oklüzyon, kontrol edilemeyen hava koşulları (ör. sis, yağmur, ani aydınlanma ve pus) ve gölge gibi nedenlerle beraber sınıflandırma görevi daha da zorlaşmaktadır. Hareketsiz görüntüler üzerinden nesne tespitinde kullanılmak üzere çıkarılan özellikler iki kategoriye ayrılabilir: bunlar görünüme dayalı özellikler ve geometri temelli özelliklerdir. Görünüm tabanlı yöntemlerde nesneler (araçlar), yüksek boyutlu vektörler olarak sunulur. Ölçek Bağımsız Özellikler (SIFT) ve Hızlandırılmış Gürbüz Özellikler (SURF) en çok kullanılan görünüm temelli öznitelik çıkarma yöntemleridir. Geometri temelli özelliklerde genişlik, uzunluk, yükseklik, alan vb. özellikler dikkate alınır.

Avery ve diğerleri [17], uzunluk esaslı dijital görüntü işleme algoritması önerdiler. Kalibre edilmemiş kameralardan aldıkları görüntüleri kullanarak, kamyon hacimlerini tahmin etmek için farklı araçların uzunluğunu karşılaştırdılar ve karmaşık kalibre sistemlerine olan ihtiyacı ortadan kaldırmayı amaçladılar. Belirli koşullar altında %92 doğruluk elde etmeyi başarmışlardır.

Zhang ve diğerleri [18], uzunluk esaslı sınıflandırma tekniğinin ulaştırma planlaması için önem taşıdığını ancak bu veriler tek bir donanım detektörüyle ölçülemeyeceğini

açıkladı. Kamyonlarla ilgili verilerin toplanması için video tabanlı araç tespit ve sınıflandırma sistemi geliştirdiler. Algoritmaları, görüntülerin alınması, arka planın çıkarılması, araç tespiti, gölge çıkarımı ve uzunluk esaslı sınıflandırma adımlarından oluşmaktadır. Kamyonları sınıflandırmada %97 başarıyı yakaladılar ancak sistemleri uzun araç kuyrukları, kamera hareketi ve ışık yansıması sorunlarını çözememektedir.

Qin [19], videodan aldığı görüntüleri analiz ederek araçları sınıflandırdı. Farklı seri görüntüleri kullanarak arka planı oluşturdu, oluşturduğu arka planı kullanarak araçların değişmez özelliklerini tespit etti. Bu özellikler Geri Yayılımlı Sinir Ağlarına (Back Propagation Networks) girdi olarak verildi. Sinir ağı mimarisi hafif, ağır ve ara araç olarak üçe ayrıldı. Sinir ağı, araç türünü daha etkili bir şekilde sınıflandırmada yardımcı olduğunu göstermişlerdir.

Lai ve diğerleri [20], temel olarak araç bölgesi çıkarma, araç takip ve sınıflandırma adımlarından oluşan yöntem sundular. Ön plandaki nesnelerini elde edebilmek için öncelikli olarak arka plan çıkardılar, daha sonra gürültü verilerini (gölgele, ağaç dalı hareketi vs.) ortadan kaldırdılar. Araç tespitinden sonra, araç sınıflandırması, en-boy oranı ve yoğunluk seviyesi gibi iki metriği kullanarak gerçekleştirmişlerdir.

Kul ve diğerleri [21], trafik gözetleme durumlarında arka plan çıkarma yöntemlerinin ne kadar etkili olduğunu araştırdılar. Bunun için BGSLibrary algoritmalarını [22] analiz ettiler. Çalışmaları Uyarlanabilir Arka Plan Öğrenme Algoritmasının (AdaptativeBG Learning) diğer algoritmalara kıyasla daha hızlı çalıştığını ve gerçek zamanlı sistemler için daha uygun olduğunu tespit ettiler.

Kul ve diğerleri [23], dağıtık mimari ile gerçekleştirilen gerçek zamanlı araç algılama ve sınıflandırma sistemini geliştirmişlerdir. Çalışmaları arka plan çıkarımı, ön plan tespiti, özellik çıkarımı ve araç sınıflandırma adımlarından oluşmaktadır. Arka plan çıkarımını [21]'deki çalışmaya bağlı olarak Adaptative BG Learning algoritması ile gerçekleştirmişler ve ön plan nesneleri elde edilmiştir.

Araçların geometrik özellikleri çıkarılmış ve bu özellikler yapay sinir ağlarına giriş olarak verilmiştir. Yapay sinir ağı mimarisi, araçları küçük, orta ve büyük olmak üzere üç sınıfta kategorize edilmiştir. BIT-Vehicle veri seti üzerinde destek vektör

makineleri yöntemiyle en yüksek %97,3 doğruluk oranında sınıflandırma gerçekleştirmişlerdir.

Messelodi ve diğerleri [24] ile Buch ve diğerleri [25] araba tespiti için sırasıyla Kalman filtre ve Gauss dağılımına dayalı bir arka plan çıkarma yöntemi ve üç boyutlu modele dayalı bir sınıflandırma metodu kullanmışlardır. Önerilen yaklaşımlardaki sistemin çalışabilmesi için kameranın yüksekliği, bakış açısı vb. parametrelerinin bilinmesi gerekmektedir. Bunun yanında önerilen bu yöntemler hesapsal olarak oldukça karmaşık bir yapıya sahiptir. Sınıflandırma başarısı [24]'te %92,5 doğruluk (accuracy), [25]'te %90,4 hassaslık (recall), %87,9 kesinlik (precision) olarak belirtilmiştir.

Morris ve Trivedi [26,27] Gauss modellemeye dayalı arka plan çıkarımı ile araç tespiti yapmışlar ve tespit edilen imge bölgelerinin imge bölgesi özellikleri (alan, çevre, çevreleyen dikdörtgenin eni ve boyu vb.) çıkarılarak Temel Bileşen Analizi (Principal Component Analysis - PCA) ve doğrusal Lineer Diskriminant Analizi (Linear Discriminant Analysis - LDA) yardımıyla özellik vektöründe boyut düşürme gerçeklemişlerdir. K-En Yakın Komşu (KNN) sınıflandırması ile de araçların sınıflarını tespit etmişlerdir. Bu çalışmalardaki sonuçlar, sadece otoyolu yandan gören bir bakış açısında bir video üzerinde test edilerek verilmiştir. Sınıflandırma başarısı [26]'da %82,9, [27]'de %74,4 doğruluk olarak verilmektedir.

Chen ve Zang [28] ile Zang ve diğerleri [29] öğrenmeye dayalı olmayan video bölütleme metodu SPCPE (Simultaneous Partition and Class Parameter Estimation) algoritması ile araçları tespit etmişler ve onları çevreleyen dikdörtgenleri bulmuşlardır. Elde edilen araç bölgeleri normalize edilerek birbirleri arasında düzgün bir şekilde oranlanmaktadır. Chen ve Zang araç bölgesini çevreleyen dikdörtgenin içindeki piksel değerlerini özellik vektörü olarak kullanarak Bağımsız Bileşen Analizi (Independent Component Analysis - ICA) ile boyut düşürme uygulanmakta, Zang ve diğerleri çalışmalarında iki adet sınıflandırma algoritması sunmaktadırlar. İki çalışmada da sınıflandırıcı olarak SVM kullanılmaktadır. Sınıflandırma başarısı [28]' de yaklaşık %65 anımsama, %75 hassasiyet, [29]'da yaklaşık %70 anımsama, %50 hassasiyet olarak verilmektedir.

Gandhi ve Trivedi [30]'da Yönlü Gradyan Histogramı (Histogram of Oriented Gradients -HOG) özelliklerinin kullanıldığı araç içi bir sistem sunmuşlardır. Hareket halindeki araç içindeki tüm yönlü kamera ile elde edilen görüntülerde hareket tabanlı araç tespiti yapılmakta ve tespit edilen araçların HOG özellikleri çıkarılarak SVM ile sınıflandırılmaktadır. Sınıflandırma başarısı %64,3 doğruluk olarak verilmektedir. Zhang ve diğerleri [31] ise kamera kullanarak tespit ve sınıflandırma yöntemi sunmuşlardır; fakat kameranın, şerit çizgilerini paralel görecek şekilde şerit çizgileriyle aynı eksende yerleştirilmesi gerekmektedir. Ayrıca sistemin çalışabilmesi için kullanıcı tarafından piksel sayısı cinsinden uzun araç eşik değerinin ve bir gölge örneğinin sisteme girilmesi gerekmektedir. Çalışmada tespit doğruluğu %97 olarak verilirken sınıflandırma başarısına dair direkt bir bilgi verilmemiştir. Demet ve Gözde [32] ise otoyola ait herhangi bir bilgiye ve kamera parametre kalibrasyonuna ihtiyaç duymadan öğrenmeye dayalı bir sınıflandırma yöntemi sunmuşlardır. Önerilen yöntemi iki farklı video üzerinde test etmişler. İlk videoda sadece HOG özellikleri kullandıklarında %79,7 doğruluk, HOG ile beraber imge özellikleri kullandıklarında %80,6 doğruluk elde etmişlerdir. İkinci videoda ise sadece HOG özellikleri kullandıklarında %91,2 doğruluk, HOG ile beraber imge özellikleri kullandıklarında %96,4 doğruluk elde etmişlerdir. Önerilen yöntemde kullanıcıdan sadece görüntüde herhangi bir aracın tamamının görülebileceği bir tespit bölgesi belirlemesi istenmektedir. Ghada ise [33] yapmış olduğu çalışmada araç tipi sınıflandırmak için geometrik ve görünüm özelliklerini beraber kullanmıştır. Katmanlı bir sınıflandırma yapısı düşünülerek ilk katmanda araçlar küçük, orta ve büyük kategorisine ayrılmış, ikinci katmanda ise orta büyüklükteki araçlar kendi içinde tekrar sınıflandırılmıştır. Sınıflandırıcı olarak SVM seçilmiştir. Yapılan testler neticesinde ilk katmandaki sınıflandırma işleminin başarısı genişlik ve yükseklik özelliklerine göre (%96,7) ve sadece SIFT'e göre (%95,8) en yüksektir. İkinci katmandaki başarı ise yalnız SIFT (%89,6) kullanımında en yüksektir.

Araçların sınıflandırılmasına ilave olarak incelediğimiz diğer bir konu ise, konu tabanlı yayınla/kaydol (pub/sub) sistemi ile sınıflandırılan görüntülerin dağıtılmasıdır. Yayınla/kaydol etkileşimi, dağıtık ortamda mesaj temelli iletişim biçimidir. Bu iletişim türünde üreticiler (producers/publishers) bilgiyi yayınlarlar, tüketiciler (consumers/subscribers) ise almak istedikleri bilgiye kaydolarak alırlar.

Yayınla/kaydol sistemi mesaj kuyruklama paradigması ile yakından ilgilidir ve mesaj temelli orta katman (middleware) sisteminin bir parçasını oluşturur. Çoğu mesajlaşma sistemi de hem yayınla/kaydol hem de mesaj kuyruklama paradigmasını API'lerinde desteklerler. Java Mesaj Servisleri (JMS) de bunlardan biridir [36]. Yayınla/kaydol modelinde üretici tarafından yayınlanan bilgilerden tüketiciler bir kısmını almaktadır. Bu iş filtreleme veya kaydolma yöntemi olarak bilinmektedir. Genel olarak konu tabanlı, içerik tabanlı (content based) ve tip tabanlı (type based) filtreleme olmak üzere üç kısma ayrılmaktadır. Konu tabanlı Yayınla/kaydol modelinde mesajlar konulara (veya mantıksal kanallara) yayınlanır. İlgili konuya kaydolan tüketici o konuya yayınlanan tüm mesajları alır. Aynı mantıkla, aynı konuya kaydolan tüm alıcılar yayınlanan mesajlardan aynısını alırlar [37]. İçerik tabanlı modelde ise yayınlanan mesajlara ait niteliklerin veya içeriğin uyuşması/eşleşmesi halinde ilgili mesajlar tüketiciler tarafından alınır [38]. Tip tabanlı modeli ise nesne yönelimli programlama paradigmasından esinlenerek ortaya atılmıştır. Bu modelde; üretici haberleşme kanalında mesaj nesnelerini üretir, tüketici ise o haberleşme kanalına kaydolması kaydıyla ilgilendiği nesne tipindeki mesajları alır [39]. Literatürde konu tabanlı yayınla/kaydol sistemi ile yapılmış sınırlı sayıda yayın mevcuttur. Banno ve diğerleri [40] yerel olarak üretilen mesajların yerel olarak tüketilmesini sağlayan dağıtık olay tabanlı bir sistem geliştirmişlerdir. Gascon-Samson ve diğerleri [41] bulutta dinamik, ölçeklenebilir, kanal tabanlı standart bir yayınla/kaydol sisteminin gerçeklenebileceğini göstermişlerdir. Sistemin etkinliğini aynı anda aktif olan istemci sayılarına göre test etmişlerdir. Tüysüz ve diğerleri [42] kişisel aktiviteleri yönetmek için iş akışı tabanlı mobil rehber tasarlamışlardır. Kullanıcılar genelde gezgin olduklarından ağ kullanımını minimize etmek için konu tabanlı yayınla/kaydol modeli mesajlaşma alt yapısını kullanmışlardır. Veri akışı (data stream) üzerine yayınla/kaydol uygulamaları da bir diğer araştırma konusudur. Veri akışı uygulamalarında akış, genellikle coğrafik olarak dağıtık olan üretici ve onları sorgulayan tüketicilerden meydana gelmektedir.Yaptığımız araştırmalara göre sınıflandırılan araç görüntülerinin konu tabanlı olarak istemcilere/tüketicilere servis edilmesi üzerinde herhangi bir çalışma yapılmamıştır.

Akıllı ulaşım sistemlerinin ulaşımı kolaylaştırma çözümleri olduğu bilinmektedir [43]. Bu kapsamda bir AUS (Akıllı Ulaşım Sistemleri) sistemi referans alındığında

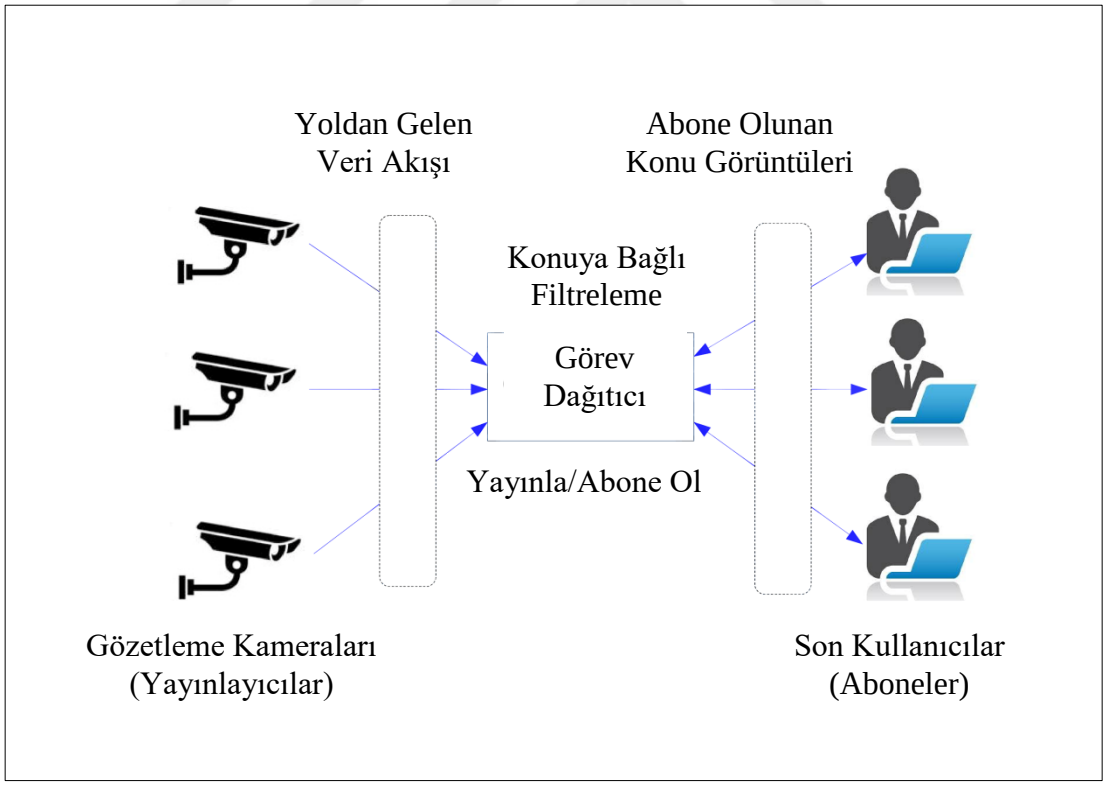
karşımıza sekiz tane temel konu başlığı çıkmaktadır. Bunlar; trafik yönetim sistemi, yolcu bilgilendirme ve rehberlik, toplu taşıma yönetimi, taşıt güvenlik ve kontrol, ticari taşıma yönetimi, afet ve acil durumların yönetimi, yol bakım yönetim, veri arşiv yönetimi diye sayılabilir [44]. Enerji ve Tabii Kaynaklar Bakanlığı tarafından 2012-2023 yılları için hazırlanan Enerji Verimliliği Strateji Belgesi'nde "Ulaşımda enerji verimliliğinin arttırılması ve ağ verimliliğinin sağlanması için bilgi ve iletişim teknolojilerinin kullanıldığı akıllı trafik yönetimi uygulamaları ve akıllı ulaştırma sistemlerinin yaygınlaştırılması" eylem olarak belirlenmiş ve UDHB sorumlu, Kalkınma Bakanlığı da işbirliği yapılacak kuruluş olarak belirlenmiştir [45]. Bir trafik yönetim sisteminde yeri geldiği zaman trafik videolarının analiz edilmesi ve istenen özelliklere sahip verilere ulaşılması gerekliliği kaçınılmazdır. Yukarıdaki eylem planı da göz önünde bulundurularak bu çalışmada araçların sınıflandırılması ve konu bazlı yayınla/kaydol modeli ile dağıtılması işlemini gerçekleyen açık kaynak kodlu yazılımın gerçeklenmesi hedeflenmektedir.

Geliştirilen sistemle aşağıdaki hedeflere ulaşmak planlanmıştır;

- Farklı tipteki araçların kamera görüntüleri üzerinden, görüntü işleme yöntemleri ve sınıflandırıcılar kullanılarak sınıflandırılması
- Yayınla/kaydol modeli ile sınıflandırılan araçların kaydolmuş kullanıcılara konu tabanlı olarak gönderilmesi,
- Tiplerine göre sınıflandırılan araçlar hakkında sayısal istatistikî bilgi toplama,
- Kayıp ve çalıntı gibi kaybolan araçların bulunmasında gerçek zamana yakın olarak mobese kameralar üzerinden arama yapılabilecek bir ürün geliştirme. Bu tür çalışmalarda insan, donanım ve zaman anlamında tasarruf sağlama,
- Yapılabilirlik ve başarım testlerinin literatürde var olan veri setleri ve kendi hazırlayacağımız veri setleri üzerinde sınanması.

1. ÖNERİLEN YÖNTEM

Tez kapsamında gerçekleştirilmiş sistemde, Şekil 1.1'de gösterildiği üzere iki aşama bulunmaktadır. Bunlar (1) araçların boyutlarına göre sınıflandırılması (küçük, orta ve büyük) ve (2) sınıflandırılmış görüntülerin konu tabanlı yayınla/kaydol sistemi yoluyla kayıtlı abone olan kullanıcılara aktarılmasıdır. İlk aşamada, karayolunda bulunan köprü üzerinde kalibresiz bir kamera yardımı ile elde edilen videoyu bir iş istasyonuna gönderir. Ardından, araç görüntüleri görüntü işleme ve araç çıkarma işlemleri ile videodan elde edilir. Son aşamada, araç görüntüleri sınıflandırılır ve konu tabanlı yayınla/kaydol mesajlaşma protokolü aracılığıyla kayıtlı kullanıcılara gönderilir. Konular araba, kamyonet ve kamyon gibi gerçek araç sınıflarına karşılık gelir.



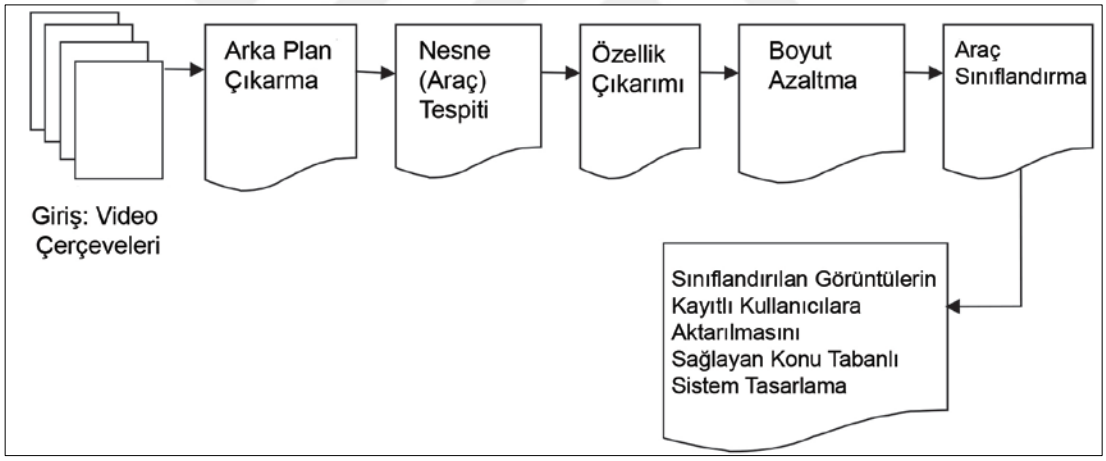
Şekil 1.1. Mimariye genel bakış

Araçların tespiti ve sınıflandırılması için öncelikle video çerçeveleri üzerinde arka-ön plan çıkarma algoritmaları kullanılarak hareketli alanlar tespit edildi. Çıkarılan

hareketli alanların geometrik özellikleri (genişlik, uzunluk, yükseklik) ve ikili özellikleri (alan oranı, en / boy oranı, majör ve minör eksen uzunluğu, çap, vb.) elde edildi ve bu özellikler farklı sınıflandırma algoritmalarına verildi: Destek Vektör Makinesi (DVM), Yapay Sinir Ağları (YSA) ve Ada-Boost. Sınıflandırma algoritmalarından elde edilen sonuçlar performans, doğruluk, geri çağırma ve hassasiyet gibi farklı metriklere göre değerlendirildi.

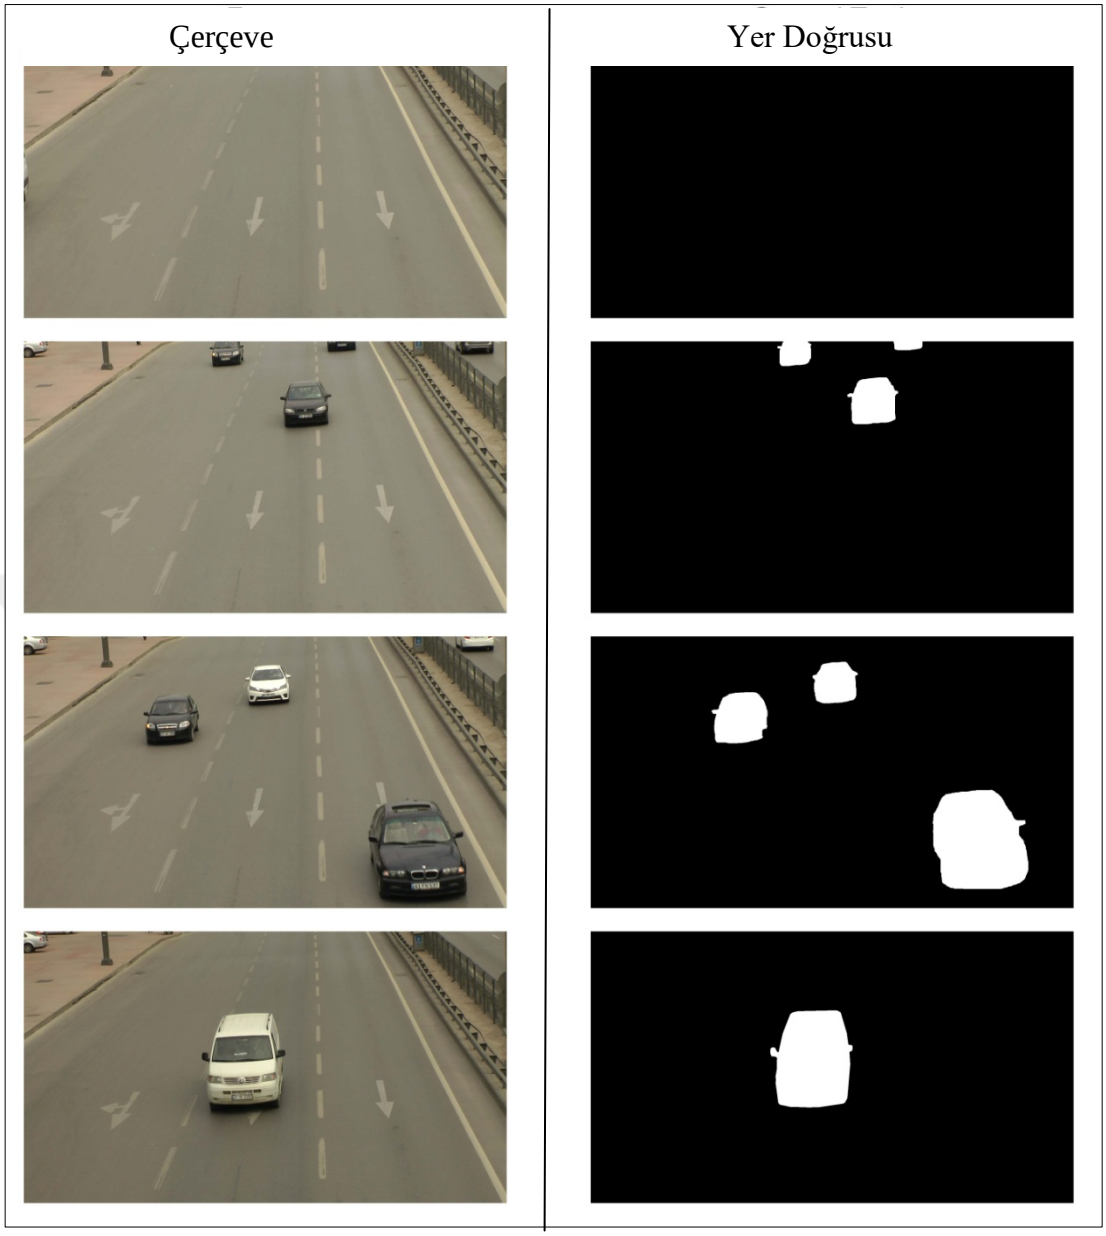
Şekil 1.2'de gösterildiği gibi, önerilen mimari aşağıdaki adımlarda özetlenmiştir:

- Arka plan çıkarma ve araçların tespiti
- Araçları temsil eden özelliklerin çıkarılması
- Bazı özelliklerin bağımlılıklarını azaltmak için boyut azaltma
- Araç sınıflandırması
- Sınıflandırılmış görüntülerin filtrelenmesi ve kayıtlı kullanıcılara aktarılması için dağıtık bir sistem tasarlama (Konu tabanlı yayınla/kaydol mimarisi).



Şekil 1.2. Sistemin genel mimarisi

Tez kapsamında, kendi veri setimizi ve yer doğrusu (ground truth) görüntülerimizi oluşturmak adına çekim gerçekleştirildi. Çekim sonunda 1920 x 1080 boyutunda 3071 çerçeve elde edildi, çerçevelerin yer doğrusu (ground truth) görüntüleri oluşturuldu. Şekil 1.3'de elde edilen veri seti ve bunlara ait yer doğrusu (ground truth) görüntüler verilmiştir.



Şekil 1.3. Örnek Veri Setine Ait Görüntüler

1.1. Arka Plan Çıkarma ve Araç Tespiti

Arka plan çıkarma, ön plan algılama olarak da bilinir; nesne algılama ve çıkarma ile ilgili uygulamaların çoğunda kullanılan görüntü işlemede önemli bir yöntemdir. Arka plan çıkarma işlemi, referans görüntü elde etmeye amacı ile bir arka plan modeli oluşturur. Bu arka plan modeli referans alınır ve gelen diğer çerçeveler ile karşılaştırma yapılarak hareketli alanlar tespit edilir. Modelleme, çevrenin dinamik doğası nedeniyle ön plan algılama için zor bir görevdir. Bu nedenle, doğru arka plan modelini bulmak için birçok yöntem önerilmiştir. Çoğu, aynı adımları

paylaşmaktadır. İlk olarak geçmiş çerçevelerin bilgilerini içeren bir arka plan modeli oluşturulur. Arka plan modeli oluşturulduktan sonra, geçerli çerçeveyi referans çerçeveyle (arka plan modeli) karar kurallarına göre karşılaştırılır vr arka plan modeli güncellenir. Gerçek zamanlı sistemler için BGSLibrary'de bulunan 32 arka plan çıkarma algoritma incelenmiştir [46]. Tablo 1.1'de gösterildiği üzere algoritmalar, benzerliklerine göre kategoriye ayrılmıştır.

Tablo 1.1. BGSLibrary'nin en iyi skorlarına sahip algoritmaları

Yöntem Adı	Yöntem Adı	Yazarlar
Adaptive BackgroundLearning	Adaptive BackgroundLearning	-
Fuzzy Choquet Integral	Fuzzy Choquet Integral	[47]
Gaussian Mixture Model	Gaussian Mixture Model	[48]
Fuzzy Choquet Integral	Fuzzy Choquet Integral	[49]
Type-2 Fuzzy GMM-UM	Type-2 Fuzzy GMM-UM	[50]
Multi-Layer BGS	Multi-Layer BGS	[51]
Pixel-Based Adaptive Segmenter	Pixel-Based Adaptive Segmenter	[52]
Eigenbackground / SL-PCA	Eigenbackground / SL-PCA	[53]

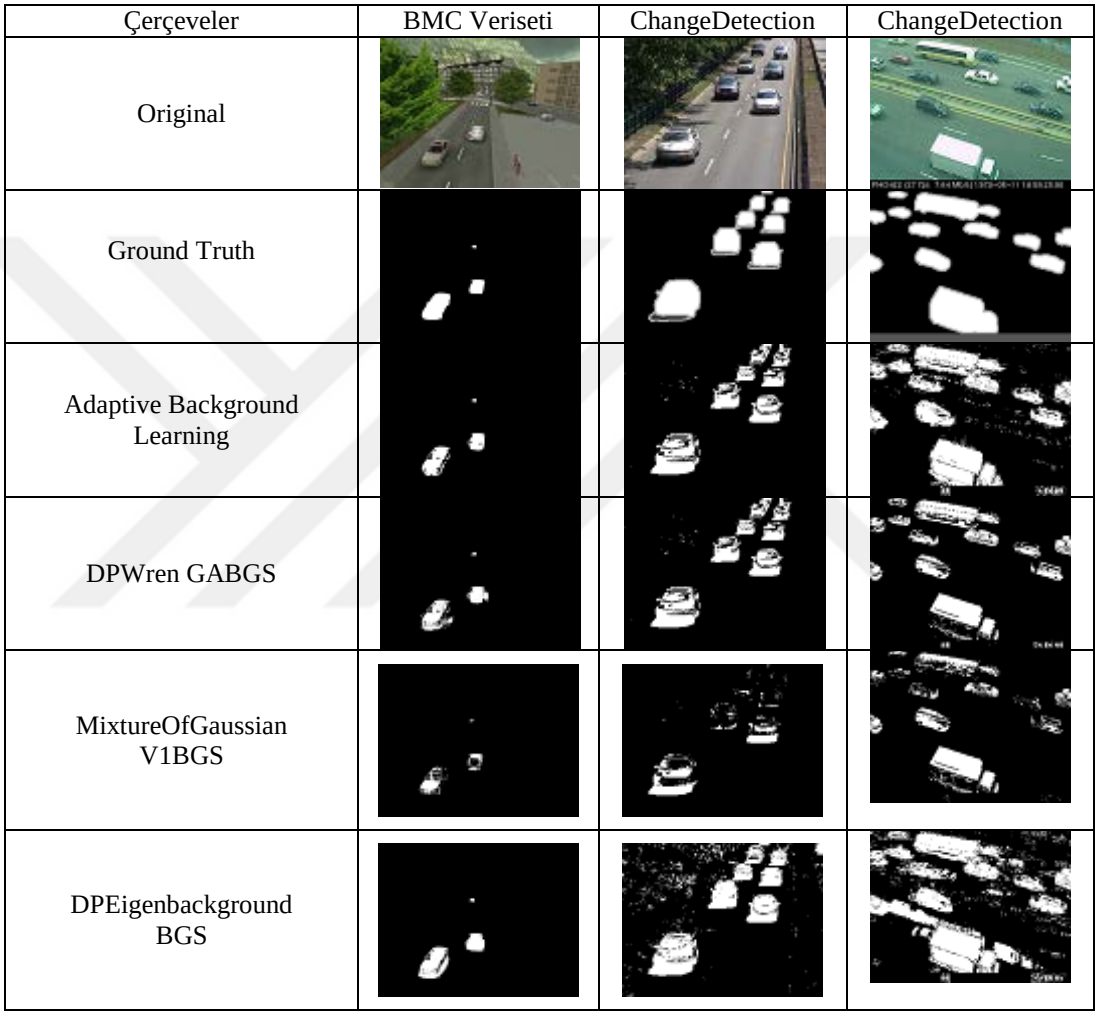
Bazı BGSLibrary algoritmalarını test etmek için ChangeDetection.net [54] ve Background Models Challenge (BMC) [55] veri setleri kullanıldı. BMC 20 sentetik hem de 9 gerçek veri seti içermektedir. ChangeDetection.net 31 gerçek dünya verileri içermektedir. Tablo 1.2, kullanılan veri kümelerini özetlemektedir.

Tablo 1.2. Kullanılan veri setleri hakkında ayrıntılı bilgi

Veri Setleri	Toplam Çerçeve Sayısı	Çözünürlük	Tip
BMC 111	1499	640 x 480	png
Changedetection Highway	1700	320 x 240	jpg
Changedetection Lowframe rate turnpike	1500	320 x 240	jpg

Background Models Challenge (BMC) [55] veri setleri kullanıldı. BMC 20 sentetik hem de 9 gerçek veri seti içermektedir. ChangeDetection.net 31 gerçek dünya verileri içermektedir. Tablo 1.2, kullanılan veri kümelerini özetlemektedir.

Şekil 1.4'te, BGS kütüphanesi kullanılarak elde edilen maskeleme görüntüleri verilmiştir.



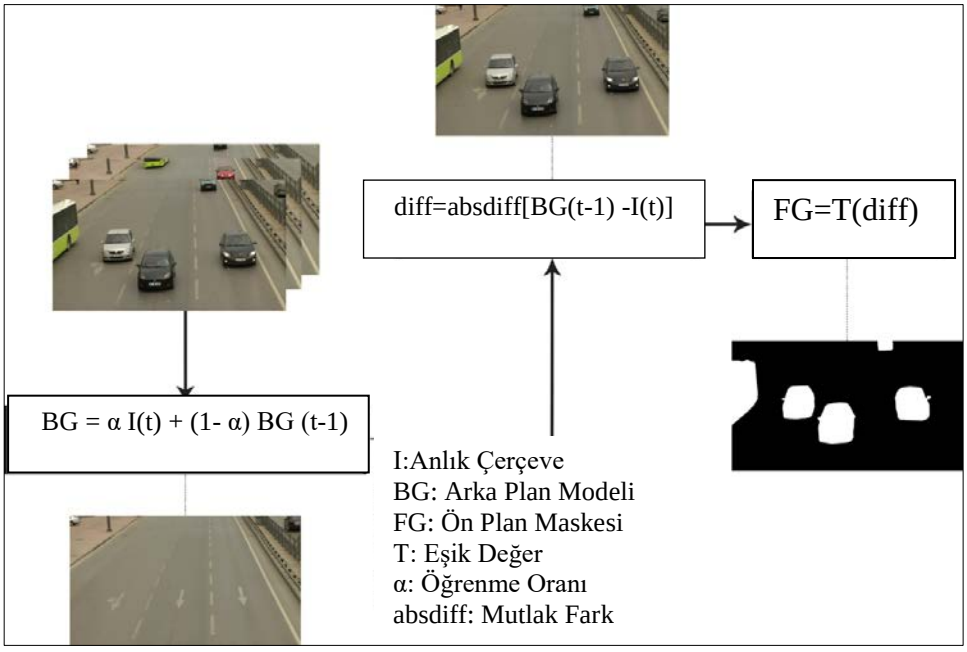
Şekil 1.4. Elde Edilen Maskeleme Görüntüleri

Bir arka plan çıkarma yöntemi seçilirken, gerçek zamanlı uygulamalar ve gömülü sistemler için arka plan çıkarma algoritmasının çalışma süresini göz önüne almak çok önemlidir. Performans analizi için Intel Core i5-3210M 2.5 GHz işlemci ve Windows 10 Pro x64 kullanıldı. Tablo 1.3, BGSLibrary'nin en iyi skorlanan algoritmalarının ortalama çalışma sürelerini göstermektedir ve sonuçlar "Adaptive Background Learning" algoritmasının uygun olduğunu göstermiştir.

Tablo 1.3. BMC ve Changedetection veri setleri üzerinde BGS algoritmalarının performansı

Method	Execution Time (ms/ frame)
Adaptive Background Learning	15
Fuzzy Choquet Integral	243
DPWren GABGS	20
MixtureOfGaussianV1BGS	16
T2FMRF_ UM	111
MultiLayer BGS	193
DPEigenbackgroundBGS	42

Uyarlanabilir Arka Plan Öğrenme Algoritması (UyarlanabilirAP Öğrenme-AdaptativeBG Learning), zaman içinde çerçevelerin ortalamasını alarak bir arka plan modeli oluşturur. Bu yaklaşım, geçerli görüntüyü arka plan modeline harmanlamak için parametreler kullanır. Algoritmanın matematiksel özeti Şekil 1.5'te, ayrıntılı açıklaması ise Şekil 1.6'da verilmiştir. Şekil 1.5, Şekil 1.6 ve Şekil 1.7'de geçen α,öğrenme hızıdır ve 1 ile 0 arasındaki değer, algoritmanın öğrenme hızını belirler. İki uç durum olarak, 0, arka plan modeli güncellenmediğini ve 1 arka plan modelinin önceki çerçeveyle güncellendiğini belirtir.

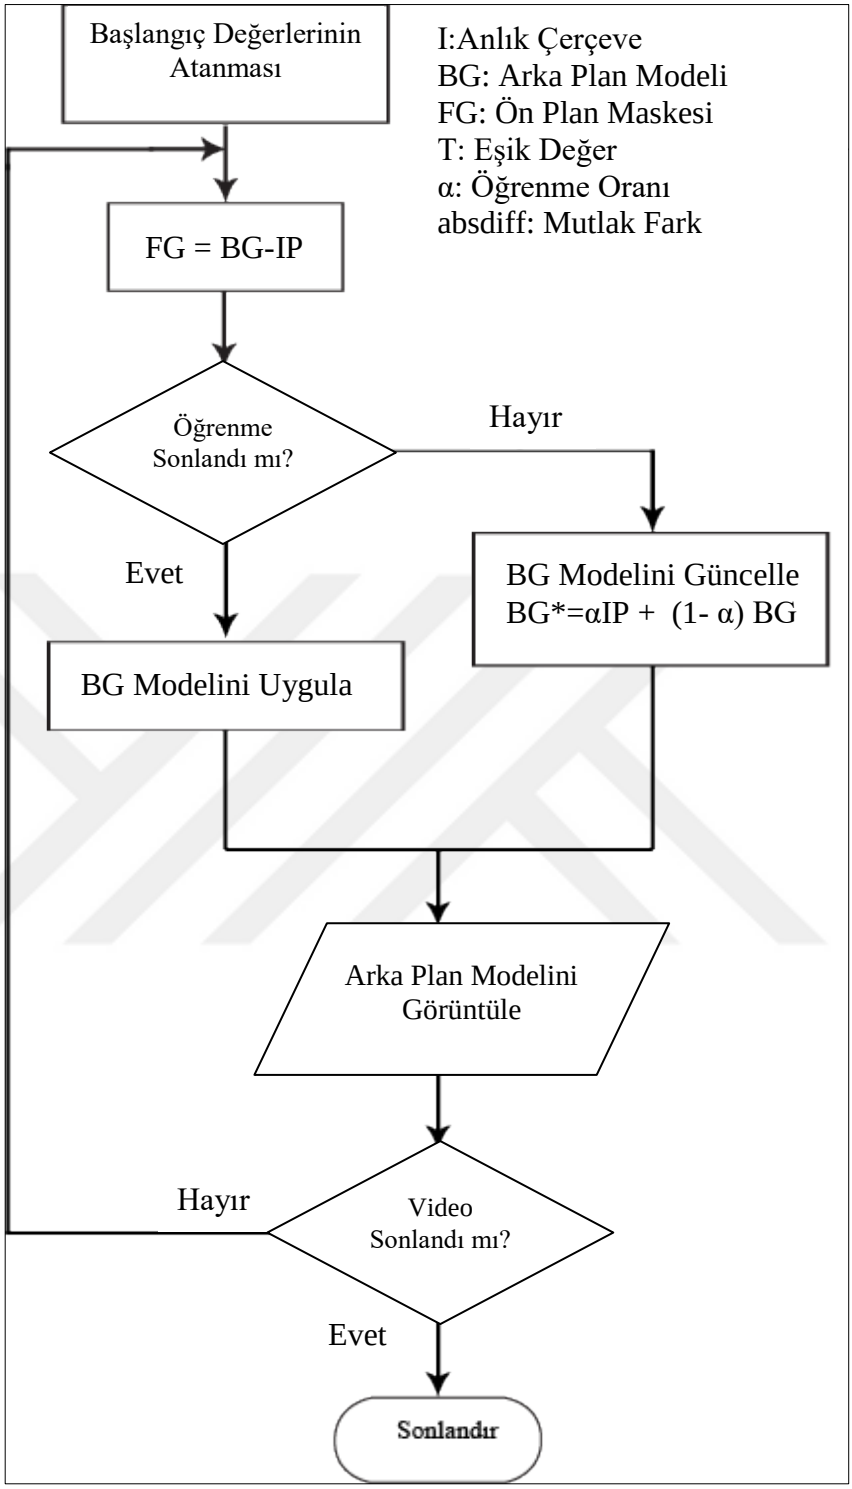


Şekil 1.5. Uyarlanabilir Arka Plan Öğrenme Algoritması

Algoritma 1. Arka Plan Çıkarma Algoritması [55]

```
1.  Adaptive Selective Background Learning
2.      Arka plan modelleme aşaması
3.      while(Öğrenme İterasyonu Duruncaya Kadar)
4.          IMG_background= μ * IMG_Input + (1 - μ) * IMG_background;
5.      end while
6.      Uyarlanabilir Seçici Güncelleme aşaması
7.      for i = 1, i++, while i < rows
8.          for j = 1, j++, while j < cols
9.              if( IMG_foreground(i, j)== 0)
10.                 IMG_background(i, j)= α * IMG_Input(i, j) +
11.                 (1 - α) * IMG_background(i, j)
12.             end if
13.         end for
14.     end for
```

Şekil 1.6. Arka Plan Çıkarma Algoritmasının Sözde Kod Gösterimi



Şekil 1.7. UyarlanabilirAP Öğrenme Algoritmasının Akış Şeması

Elde edilen maskelenmiş siyah-beyaz görüntüdeki hareketli imge bölgelerini netleştirmek, imge bölgeleri üzerindeki boşlukları doldurmak ve görüntüler üzerindeki gürültüleri yok etmek için bazı son görüntü işleme işlemleri yapılmaktadır. Bu son işlemleri şu yöntemler oluşturmaktadır:

- Gürültü giderme: İkili haldeki görüntü üzerindeki gürültülerin giderilmesi için 3x3 boyutundaki indisleri 1 değerinden oluşan maske ile açma (openning) işlemi yapılmıştır. Bu işlem sayesinde görüntü üzerindeki ön plan olmayan fakat ön plan olarak görünen küçük alanlar yok edilecektir. Ardından büyük ön plan imge bölgelerinin içini doldurmak ve kenar bölgelerini yumuşatmak üzere yine aynı 3x3 boyutundaki maske kullanılarak kapama (closing) işlemi yapılır[56].
- Bağlantılı bileşen analizi: Açma-kapama işleminden sonra elde edilmiş görüntüde hareket halindeki imge bölgelerini ayırmak, onları farklı objeler olarak işaretlemek ve 3x3 boyutundaki maske ile yok edilemeyen daha büyük boyuttaki gürültüleri yok etmek bağlantılı bileşen analizi (Connected Component Analysis - CCA) yapılmıştır. Bu işlemlerden sonra belli bir eşik değerinin altındaki bölgeler gürültü olarak alınmaktadır [57].

1.2. Özellik Vektörünün Oluşturulması

Araç sınıflandırma yaklaşımlarında, özellikler iki şekilde çıkarılabilir: geometri ve görünüş esaslı. Geometri tabanlı öznitelik çıkarma yöntemi, nesnenin uzunluğu, genişliği, alanı ve benzeri gibi çerçevede tespit edilen ölçümleri kullanır. [58] Diğer yandan, görünüş esaslı yöntemlerde nesneler (araçlar) vektörler olarak sunulur. En çok kullanılan görünüm tabanlı öznitelik çıkarma yöntemleri SIFT ve SURF algoritmalarıdır.

Araçların sınıflandırılmasında kullanılacak görüntülerden öznitelik vektörü elde edilmiştir. Şekil 1.8'de gösterildiği üzere vektörlerin elde edilmesi aşamasında görüntünün en uzak kenarında bulunan büyük sınıflı aracın küçük sınıflı araç ile karıştırılmaması için, referans çizgisine bağlı araçlar seçildi.



Şekil 1.8. Referans çizgisi gösterimi

Sınıflandırma için kullanılan özellikler aşağıda listelenmiştir.

- Farklı tipteki araçların kamera görüntüleri üzerinden, görüntü işleme yöntemleri ve sınıflandırıcılar kullanılarak sınıflandırılması
- İmge bölgesinin alanı,
- İmge bölgesini çevreleyen dikdörtgenin eni ve boyu,
- İmge bölgesinin alanının bölgeyi çevreleyen dikdörtgenin alanına oranı (extent),
- İmge bölgesine oturtulabilen elipsin ana ve ikincil eksendeki uzunluğu (major/minor axis length),
- İmge bölgesini çevreleyen dikdörtgen içindeki beyaz piksellerin siyah piksellere oranı

Sözü edilen öznitelik çıkarma yöntemleri, Tablo1.4'te gösterildiği üzere gerçek zamanlı görüntü işleme sistemlerinde performansları için test edilmiş ve değerlendirilmiştir. Sonuçlar SIFT ve SURF algoritmalarının gerçek zamanlı sistemler için uygun olmadığını göstermektedir. Çalışma, Intel Core i5-3210M 2.5 GHz işlemci ve Windows 10 Pro x64 ortamında gerçekleştirildi.

Tablo 1.4. Öznitelik Çıkarım Yöntemlerinin Çalışma Süreleri

Özellikler	Süre(ms/frame)
SIFT	2,15378e+9007
SURF	3362,86
İmge Alanı	0,08
İmge bölgesini çevreleyen dikdörtgenin eni ve boyu	0,60
İmge Bölgesini Çevreleyen Dikdörtgenin Alanı	0,082
İmge Bölgesine Oturtulabilen Elipsin Ana ve İkincil Uzunluğu	0,078
İmge Bölgesindeki Beyaz Piksellerin Sayısı	0,061

Tablo 1.5. Özelliklerin Değer Aralıkları

Özellik Numarası	Özellik Adı	Değer Aralığı
1	İmge Alanı	614 – 3852,5
2	İmge Bölgesini Çevreleyen Dikdörtgenin Eni	26–55
3	İmge Bölgesini Çevreleyen Dikdörtgenin Boyu	30 – 99
4	İmge Bölgesini Çevreleyen Dikdörtgenin Alanı	810 – 5445
5	İmge Bölgesine Oturtulabilen Elipsin Ana Uzunluğu	35,2 – 948,4
6	Elipsin İkincil Eksendeki Uzunluğu	25,9–487,2
7	İmge Bölgesindeki Beyaz Piksellerin Sayısı	660 - 3977

1.3. Özellik Vektörü Boyut Azaltma

Boyut azaltma yöntemleri, makine öğrenmesi yöntemlerinde yaygın olarak kullanılan veri seti boyutunun küçültülmesi alanında kullanılan süreçtir. Boyut azaltma yöntemleri ikiye ayrılabilir: özellik seçimi (feature selection) ve özellik çıkarımı (feature extraction). Özellik seçme yöntemi, hedeflenen sınıf üzerinde en büyük etkiye sahip olan alt veri seti örneklerini bulmak için kullanılır. Özellik çıkarma yöntemleri, özellik seçme yöntemlerinden farklı olarak veri seti üzerinden alt bir küme çıkarma yerine, özellik vektörünü farklı bir vektör uzayına geçirmeye çalışmaktadır. Örneğin, ana bileşen analizi (PCA) bu amaç için en çok kullanılan yöntemdir ancak birçok boyut azaltma yöntemi de mevcuttur [59,60]. PCA, özellik vektörü üzerinden, alt özellik seti oluşturmaz veya özellikleri ortadan kaldırmaz. Tüm özellikleri kullanarak yeni özellikler vektörü oluşturur. Bu makalede, boyut

azaltma için özellik seçme yöntemlerini kullanıyoruz. Özellik seçimi kullanmanın nedenleri, öğrenme modelini basitleştirmek ve hızlandırmak, daha kısa sınıflandırma süreleri sağlamak ve aşırı uyumsuzluklardan kaçınmaktır [61].

Önerilen sistemde, boyutsal azaltma tekniği, Tablo 1.5'te listelenen özelliklerden en iyi özellik alt kümesini oluşturmak için kullanılır. Bu özellik alt kümesinin doğru sınıflandırma oranını en yükseğe çıkarması ve en düşük hata ihtimaline sahip olması beklenmektedir. Özelliklerin sayısının azaltılması ile aşırı öğrenmenin önüne geçme ve sistemin daha hızlı çalışması amaçlanmaktadır.Literatürde önerilen bazı özellik seçim yöntemleri vardır. Modelin nasıl oluşturulduğuna bağlı olarak üç sınıfa ayrılabilirler: (i) filtre yöntemleri, (ii) sarmalayıcı (wrapper) yöntemler ve (iii) gömülü (embedded) yöntemler. Filtre yöntemleri ağırlıklı olarak ön-işlem metotları olarak kullanılır ve seçilen özelliklerin öğrenme algoritmasının performansı ne olursa olsun özellikleri seçerler. Sarmalayıcı yöntemler, öğrenme algoritmalarını kullanarak özniteliklerin iyi bir kombinasyonunu bulmaya çalışırlar. Gömülü yöntemler, sarmalayıcı ve gömülü yöntemlerin avantajlarını birleştirmeye çalışmaktadır. Hall ve Holmes [62], sarmalayıcı yönteminin en iyi özellik seçimi yöntemi olduğunu göstermektedir. Çalışmamızda boyut azaltım için sarmalayıcı yöntemi kullanılmaktadır. Sarmalayıcı yöntem olan ileriye yönelik arama (forward search algorithm) veri setleri üzerinde en iyi sonuçları veren algoritmalardan biridir. Özellik seçimi için sözde kod, Şekil 1.9'da gösterilmiştir.

Algoritma 2. Özellik Seçimi

1. Girdi: x - özellikler X
2. Çıktı: Hedeflenen veri seti F
3. Adım 1. Veri setine başlangıç değerini ata
4. F = ()
5. Minimum hatayı veren f değerlerini bul
6. **While** (istenilen özellik sayısına ulaşıncaya kadar devam et)
7. (F U xi) değerinin hatasını hesapla
8. min hatayı veren xi özelliğini listeye ekle
9. **end**

Şekil 1.9. Özellik Seçimi Sözde Kod Gösterimi

Tablo 1.5'te verilen özellik kümesinin alt kümesi, ileriye yönelik arama (forward search algorithm) algoritması ile hesaplanır ve sonuç kümesi F={1,3,4,5,7} elde edilir. Tablo 1.6'da gösterildiği üzere FSA ile iki özellik elimine edilmiştir.

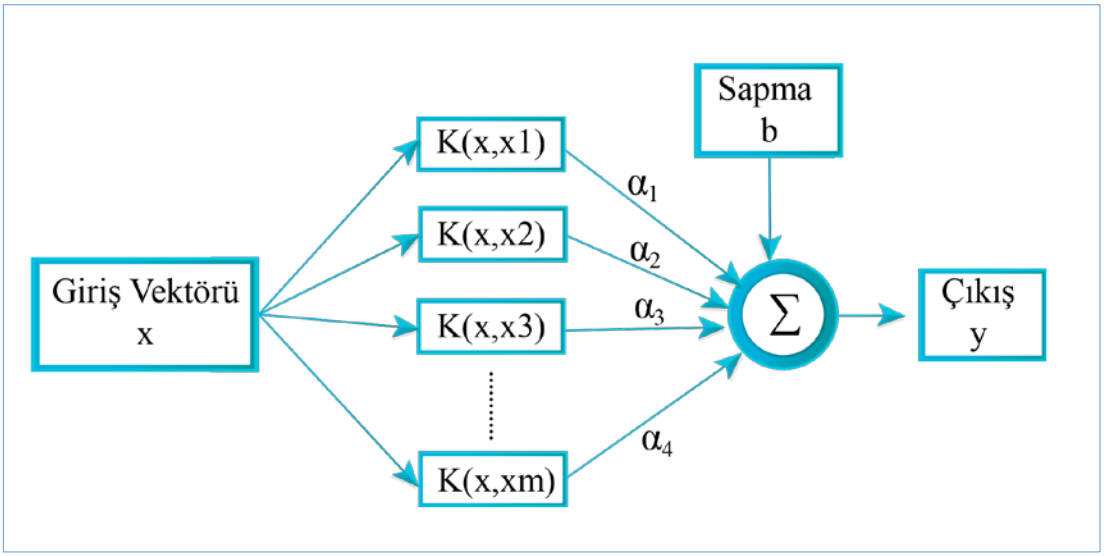
Tablo 1.6. Öznitelik Seçimi Sonrası Özellikler

Özellik Numarası	Özellik Adı	Değer Aralığı
1	İmge Alanı	614 – 3852,5
3	İmge Bölgesini Çevreleyen Dikdörtgenin Boyu	30 – 99
4	İmge Bölgesini Çevreleyen Dikdörtgenin Alanı	810 – 5445
5	İmge Bölgesine Oturtulabilen Elipsin Ana Uzunluğu	35,2 – 948,4
7	İmge Bölgesindeki Beyaz Piksellerin Sayısı	660 - 3977

1.4. Araç Sınıflandırma

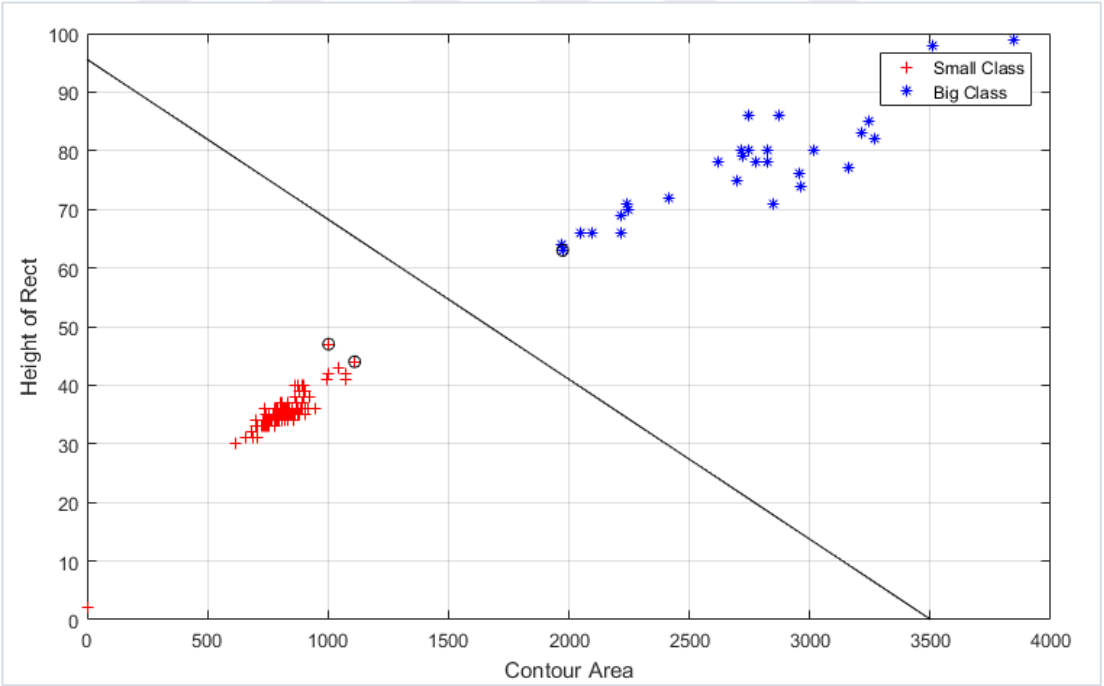
Nesne sınıflandırma, nesnenin önceden tanımlanmış sınıflara veya türlere göre sınıflandırılmasıdır. Bu çalışmada, önden tanımlanmış üç sınıfımız bulunmakta ve amacımız gelen görüntülerin bu üç sınıfa göre sınıflandırılmasıdır. Bu sınıflar küçük boyutlu araçlar, orta boy araçlar ve büyük boyutlu araçlardır. Bu çalışmada üç farklı sınıflandırma yöntemi kullanılmıştır: YSA, DVM ve AdaBoost. Kullanılan Yapay sinir ağlarının beş girişi ve üç çıktısı bulunmaktadır. Çıktılar küçük, orta ve büyük sınıf araçlar olarak üç sınıfta toplanmaktadır.

Destek Vektör Makineleri (DVM), verilerin sınıflandırılmasında yapısal riski en aza indirgeme temeline göre çalışan bir makine öğrenme metodudur. Veriye ilişkin herhangi bir birleşik dağılım fonksiyonu bilgisine ihtiyaç duymadığı için dağılımdan bağımsız öğrenme algoritmalarındandır [63]. Şekil 1.10'da verilen yapıda; K(xi, xj), çekirdek fonksiyonlarını ve α, Lagrange çarpanlarını ifade etmektedir. DVM sınıflandırma modelinde bir örneğe ilişkin sonucun değeri, girdilerin iç çarpımları ile Lagrange çarpanlarının bağımsız kombinasyonlarının toplamına eşittir. DVM modelinde amaç, sınıfları birbirinden ayıracak optimal ayırma hiper düzleminin elde edilmesidir. Başka bir ifadeyle, farklı sınıflara ait destek vektörleri arasındaki mesafeyi maksimize etmektir.

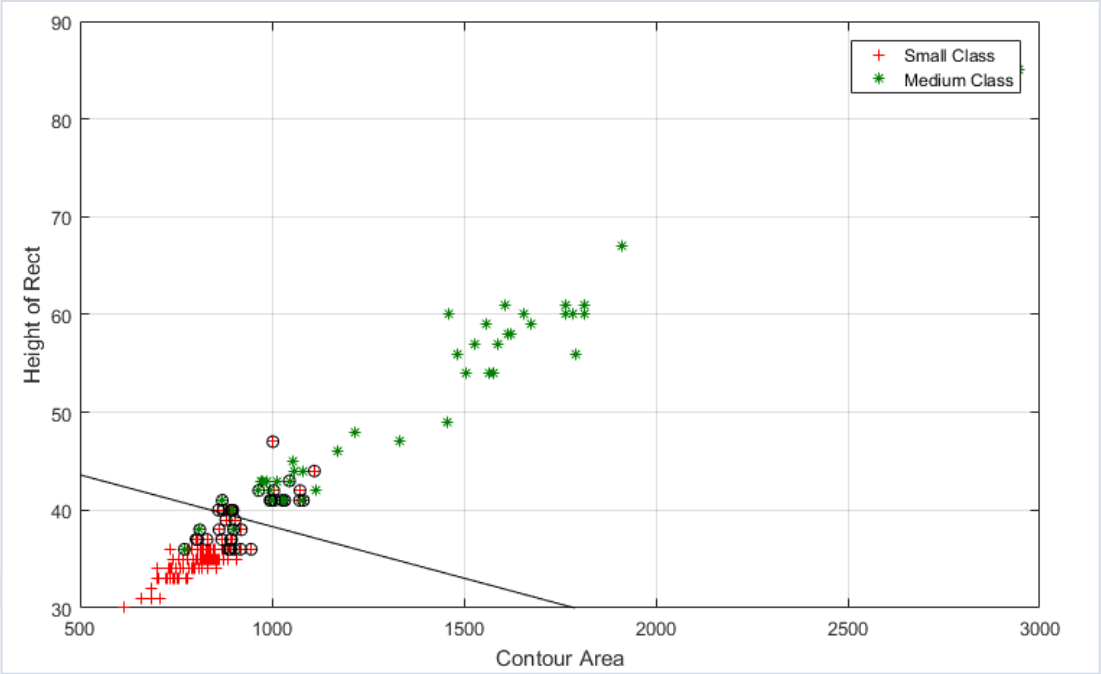


Şekil 1.10. DVM'nin Genel Mimarisi

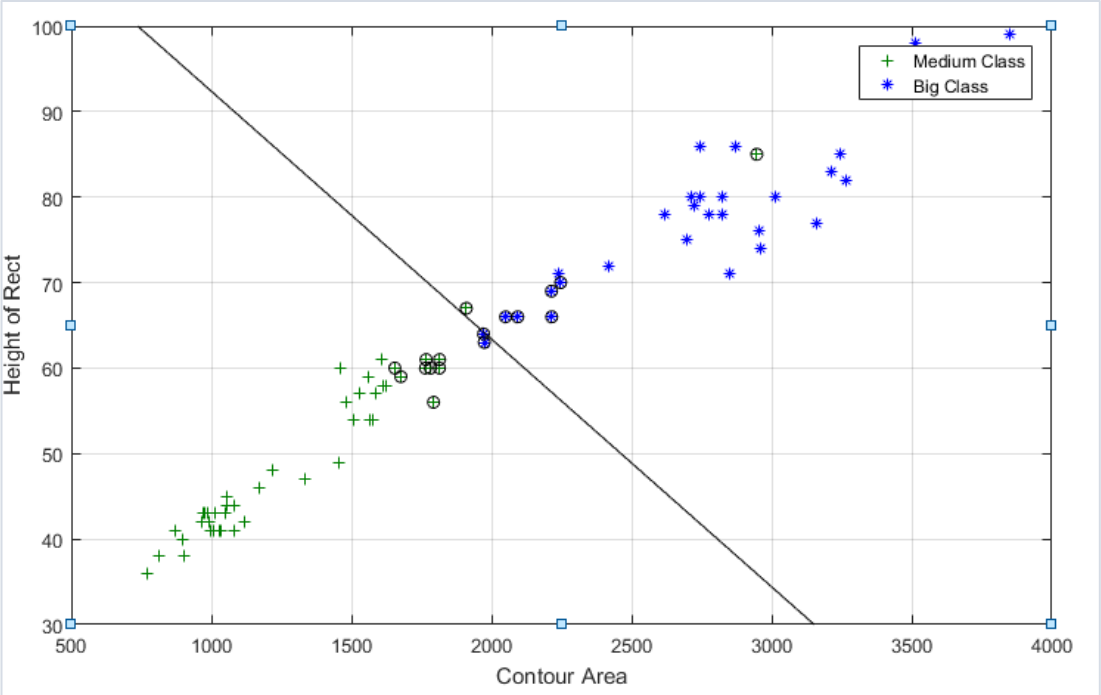
Çok sınıflı problemlerde, DVM iki farklı yaklaşım sunmaktadır. Bunlar bire karşı-bir ve birine karşı-hepsidir. Şekil 1.11, Şekil 1.12 ve Şekil1.13 geliştirilen bire-bir DVM yönteminin sonuçlarını göstermektedir.



Şekil 1.11. DVM Küçük-Büyük Sınıf Karşılaştırma



Şekil 1.12. DVM Küçük-Orta Sınıf Karşılaştırma

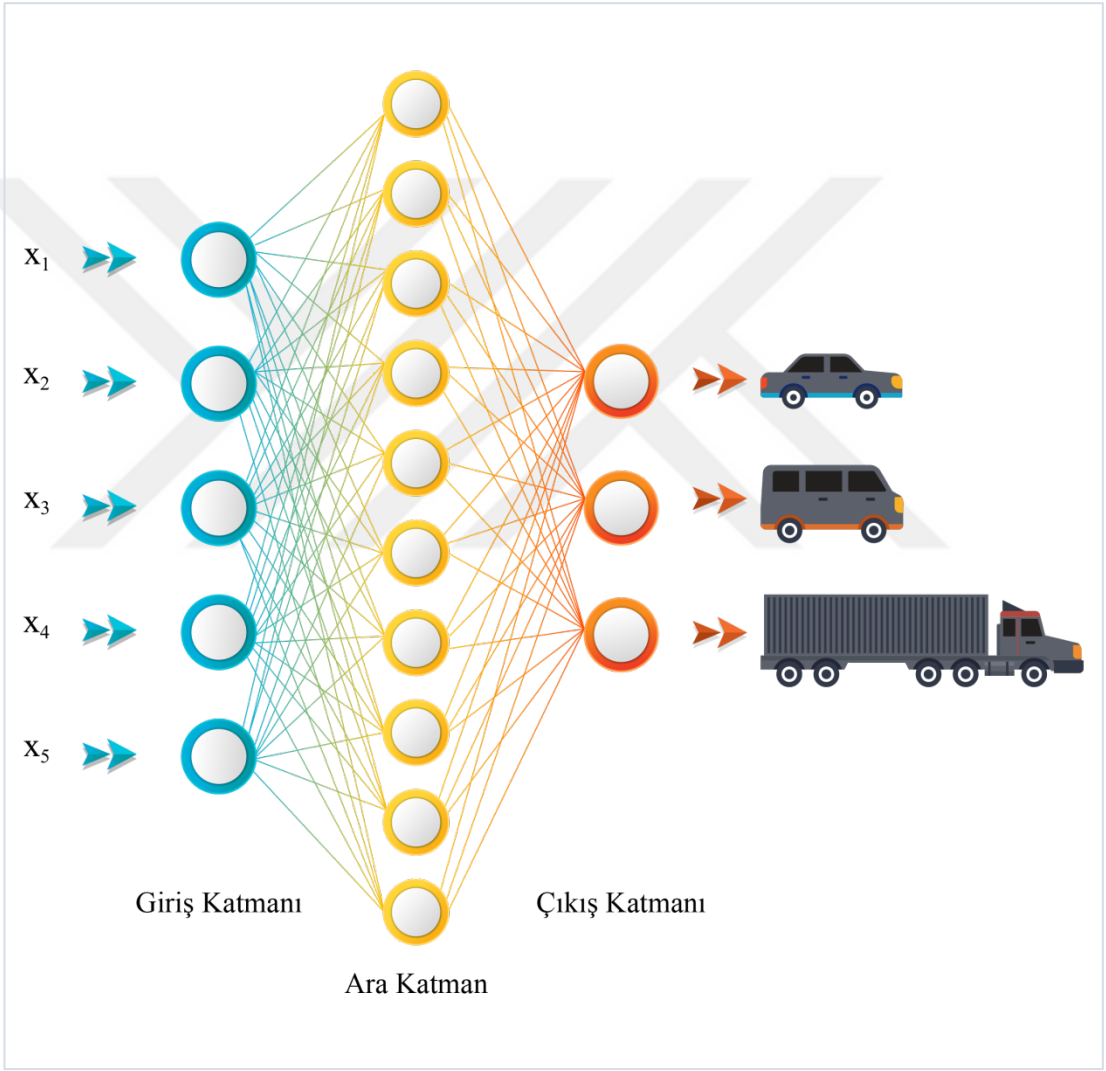


Şekil 1.13. DVM Orta-Büyük Sınıf Karşılaştırma

Sınıflandırma probleminde kullanılan bir diğer yaklaşım algoritması olan AdaBoost algoritması, eğitim veri seti üzerinden dağılıma bağlı olarak düşük hatalı hipotez üretmeye çalışmaktadır. Zayıf sınıflandırıcıların her bir öznitelik için karar sınırları, pozitif ve negatif örneklerin ağırlıklı ortalaması alınarak hesaplanır. Ardından, en

düşük hata oranına sahip en zayıf sınıflandırıcıları kullanarak güçlü bir sınıflandırıcı üretilir. Güçlü sınıflandırıcıda bulunmayan zayıf sınıflandırıcılarla ilgili öznitelikler (özellikler) elimine edilir.

Yapay sinir ağları, biyolojik nörondan esinlenerek geliştirilmiş öğrenme modelidir. Nöron temel yapıtaşını oluşturur. Şekil 1.14'te verilen Yapay Sinir Ağı Modeli kullanılmıştır. Sistemin 5 girişi ve 3 çıkışı bulunmaktadır.



Şekil 1.14. Sınıflandırmada kullanılan yapay sinir ağı modeli

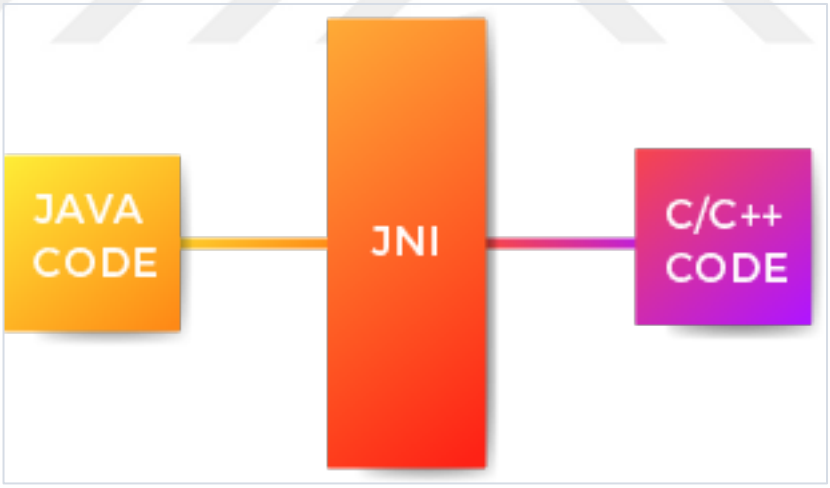
Veri setindeki tüm araçlar, boyutlarına göre üç kategoriye (küçük, orta ve büyük) ayrılmıştır. Her bir araç kategorisi için, rastgele seçilen örnekler %70 eğitim, %30 test olacak şekilde sisteme sunulmuştur. Bir son kullanıcı (abone) küçük tip araçların resimlerini istediğinde ilgili görüntüler konu tabanlı yayınla/kaydol sistemi yoluyla

kayıtlı kullanıcılara gönderilir. Bu üç sınıflandırma yönteminin veri kümemizdeki performans sonuçları ve analizi, ikinci bölümünde verilmiştir.

1.5. Java Native Interface (JNI)

Java Native Interface (JNI), Java Yazılım Geliştirme Seti'nin (SDK) bir parçası olan yerel bir programlama arabirimidir. JNI, Java kodunun C ve C ++ gibi diğer dillerde yazılmış kod ve kütüphanelerin, farklı ortamlarda kullanmasını sağlar [64].

Şekil 1.15'te gösterildiği üzere, JNI bir uygulamanın tamamıyla Java programlama dili ile yazılamaması durumunda, programlayıcıların durumları ele almak için yerel yöntemler yazmasına olanak tanır örneğin standart Java sınıfı kütüphanesi platforma özgü özellikleri veya program kitaplığını desteklemediği durumlarda. Var olan bir uygulamayı (başka bir programlama dili ile yazılmış olarak) Java uygulamalarının erişebileceği şekilde değiştirmek için de kullanılır. Çalışmamızda görüntü işleme için C++ dilinden faydalanıldı fakat bir sonraki konu olan Konu Tabanlı Yayınla/Kaydol Sisteminin Java ortamında geliştirilmesi durumunda JNI bir çözüm olarak kullanıldı.



Şekil 1.15. JNI Modeli [64]

Şekil 1.16'da Java ve C++ arasında nesne alışveriş örneği gösterilmiştir.

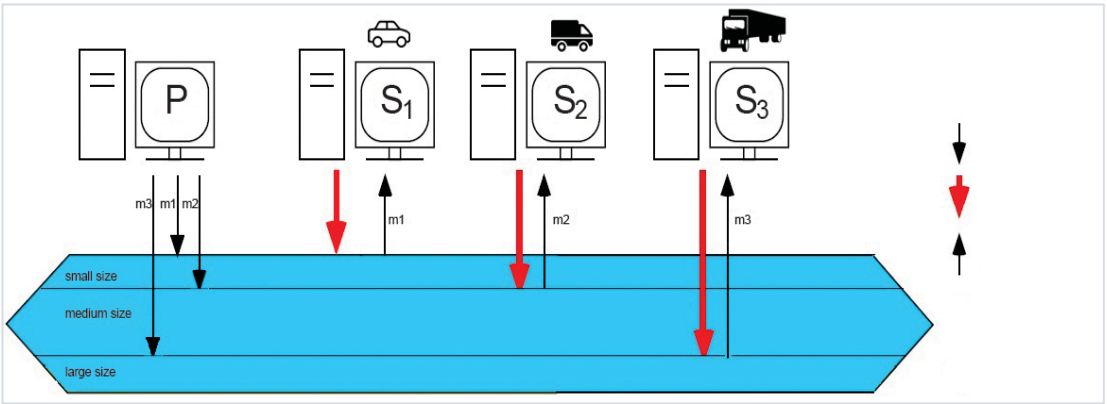
Algoritma 3. JNI Mimarisi

```
1. Extern C++
2.         JNIEXPORT jint JNICALL IMG\_BackgroundSubtraction(JNIEnv*
3.         env, jobject obj, jlong matPtr
4.         IMG\_input =  (Mat*)matPtr;While
5. end
```

Şekil 1.16. JNI Mimarisinin sözde kod gösterimi

1.6. Konu Tabanlı Yayınla/Kaydol Sistemi

Yazılım mimarisinde yayınla/kaydol mesajlaşma modeli, mesajlar sanal bir kanala (konuya) yayınlanır. Mesaj göndericileri (publisher) alcılardan (subscribers) habersiz olarak mesajları yayınlarken alıcılar da göndericilerden habersiz olarak bir veya daha fazla konuya abone olabilmektedir. Şekil 1.17'de yer alan mimaride gösterildiği üzere, mesajlar belirli abonelere gönderilmiyor; bunun yerine mesajlar, kime veya ne zaman gönderildiği bilinmeden belirli bir konuda yayınlanıyor ve aboneler, konuya göre beyanda bulunurlar. Her konu, mümkün olan her yayıncıyı ilgilenen tüm abonelere ideal bir şekilde bağlayan mantıksal bir kanala karşılık gelir.



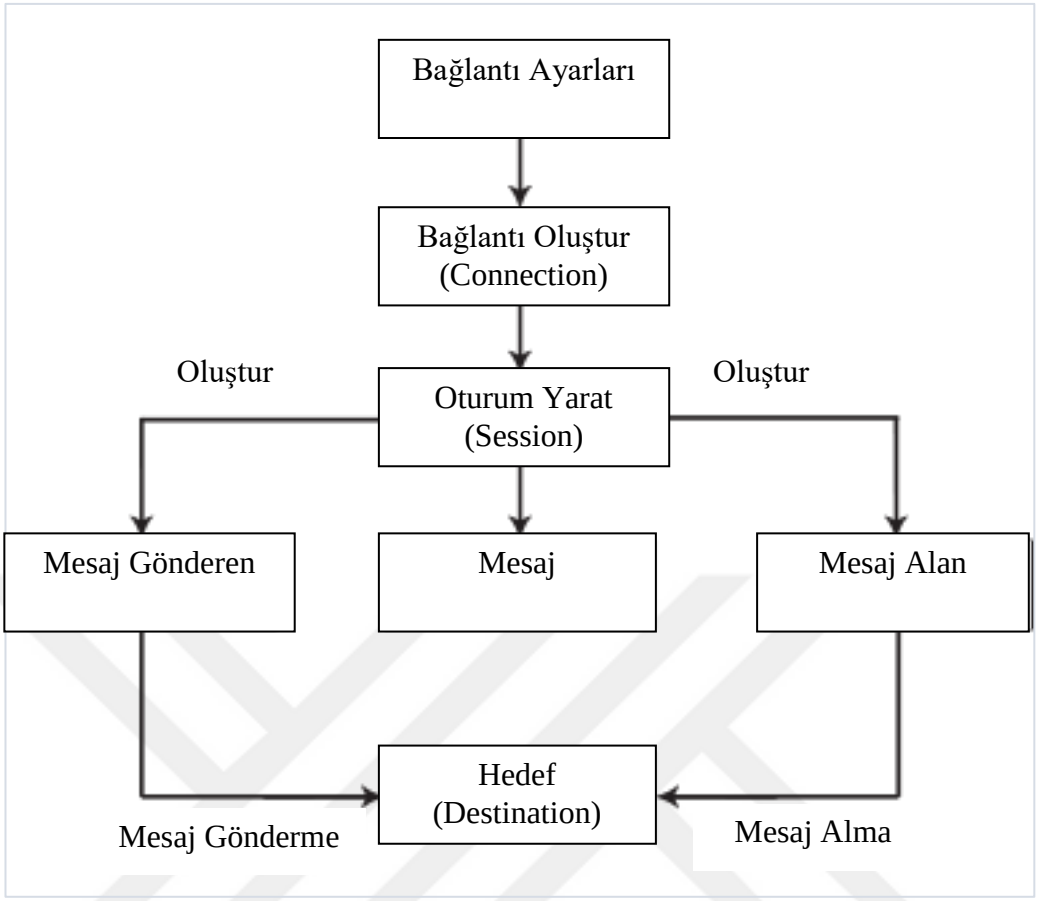
Şekil 1.17. Önerilen yayınla/kaydol modeli

Çalışmamızda, Şekil 1.18'de gösterilen örnekte oldu gibi, üç sınıf bulunmasından dolayı yayınla/kaydol sisteminde de üç konu bulunmaktadır.



Şekil 1.18. Önerilen yayınla/kaydol model diyagramı

Önerilen yöntemde, konu tabanlı yayınla/kaydol mesajlaşma, JAVA Mesaj Servisi (JMS) spesifikasyonları kullanılarak gerçekleştirilir.Java Message Service (JMS), Java 2 Platform Enterprise Edition'a (J2EE) dayalı uygulama, Şekil 1.19'da gösterildiği üzere bileşenlerinin mesajlar oluşturmasına, göndermesine, almasına ve bunları okumasına olanak tanıyan Message-oriented Middleware (MoM) standardıdır. Bir MoM standardı olduğu için dağılan iletişimi gevşek bağlı (loosely coupled), güvenilir ve asenkronize biçimde desteklemektedir [65].



Şekil 1.19. JMS API Genel Mimari [65]

Uygulama sunucusu olarak Glassfish 4.0 versiyonu kullanılmıştır. GlassFish, Java EE platformu için Sun Microsystems tarafından başlatılan ve şimdi Oracle Corporation'ın sponsorluğunu yaptığı açık kaynaklı bir uygulama sunucusu projesidir. Glassfish NetBeans ve Eclipse gibi editörler tarafından kolayca kullanılabilir ve farklı ihtiyaçlara karşılık olarak farklı domainler oluşturulmasına izin verir.

Konular ve bağlantı ayarları tanımlandıktan sonra sunucu başlatılarak kullanıma hazır hale getirilir. Tüm bu işlemler yerel (local) olarak yapılandırıldığında hiçbir ayarlamaya gerek kalmadan kullanılabilir fakat GlassFish 3.1.2 ve üzeri versiyonları varsayılan olarak uzaktan yönetime izin vermemektedir. "Secure Admin must be enabled to access the DAS remotely" hatası sunucuya uzak bir bilgisayardan ulaşmaya çalışıldığında verilen hatadır. Varsaysılan olarak güvenli yönetici, DAS ve kendi içinde işlemlerini yetkilendirmek için GlassFish Server'ın kendi imzasını taşıyan sertifikaları, bu sertifikalara karşılık gelen takma adlar aracılığıyla kullanır. Bu sertifika tabanlı kimlik doğrulama ve yetkilendirmeye alternatif olarak, etki

alanındaki tüm sunucuların birbirlerine kimlik doğrulaması yapmalarını ve gönderilen yönetici işlemlerini yetkilendirmek için enable-secure-admin-internal-user (1) alt komutu ile beraber SSL sertifikaları yerine var olan bir yönetici kullanıcı adı ve şifresi kullanılabilir.

asadmin change admin password domain_name [Domain_Name]

asadmin enable secure admin port [Port_Name]

Enable-secure-admin komutu, domainde bulunan yapıların mesajların SSL sertifikasını kullanarak şifrelenerek gönderilmesini sağlar. Aynı zamanda Domain Administration Server (DAS) bu komut ile uzaktan yönetime izin vermektedir.

Uygulamalar, iletileri güvenilir bir şekilde ve asenkron biçimde oluşturmak, göndermek ve almak için olanak tanır [66]. Şekil 1.20, kullanılan yöntemin sözde kodunu göstermektedir. Yayıncı, ilgili konuya sınıflandırılmış araç görüntülerini gönderir ve bu konudaki tüm aktif aboneler sınıflandırılmış araç imgelerini alırlar.

Pub/Sub mesajlaşma mimarisi aşağıdaki özelliklere sahiptir:

- Bir konuya birden çok alıcı abone olabilir, böylece bir ileti birden çok kullanıcıya aynı anda iletilir.
- Yayımcılar ile aboneler arasında zamanlama bağımlılığı vardır. Bir konuya abone olan bir kullanıcı, yalnızca abonelik oluştuktan sonra mesajları alabilir ve mesajları almaya devam etmesi için aboneliğinin aktif olması gerekmektedir.

Algoritma 4. Yayınla/Kaydol Mimarisi

```
1.  Yayınlayıcı
2.          connect_server()
3.          If (topic==NULL)
4.                  then Sınıflandırma sonucundan gelen veriler için konu
5.          end If
6.          while(frames!=NULL)
7.                  arac=arac_sınıflandırma(frame)
8.                  Sınıflandırma sonucuna göre araçları ilgili konularda yayımla
9.                  topicPublisher.send(arac)
10.         end
11. Aboneler
12.         connect_server() Bağlantıyı başlat
13.         while(topic) Konuyu dinlemeye başla
14.                 mesaj= subscriber.receive()
15.                         If(mesaj != NULL)
16.                                 mesaj_al()
17.                         end if
18.         end while
```

Şekil 1.20. Yayınla/Kaydol Mimarisi sözde kod gösterimi

Çalışmamızda kullandığımız gönderici (publisher) mimarisi algoritma Şekil 1.21'de ayrıntılı olarak verilmiştir.

- Context nesnesi varsayılan sunucuda bulunan JMS tarafından yönetilen nesneleri aramak için kullanılır.
- Oluşturulan context nesnesi ile konu nesnesi aranır.
- Yeniden oluşturduğumuz context nesnesi ile oluşturulan konuya bağlantı kurulur.
- Bağlantı kurulduktan sonra oluşturulan konular için oturum açılır.
- Daha sonra gönderici sınıflandırma sonucuna göre görüntüleri konu nesnelerine gönderir.

Algoritma 5. Yayımcı (Publisher) Mimarisi

```
1.  Yayınlayıcı
2.      InitialContext()
3.      Context.lookup("connection name")
4.      createTopicConnection()
5.
6.      Context.lookup("TopicS")
7.      createPublisher(topicS) //Küçük Sınıf Araç
8.
9.      Context.lookup("TopicM")
10.     createPublisher(topicM) //Orta Sınıf Araç
11.
12.     Context.lookup("TopicL")
13.     createPublisher(topicL) //Büyük Sınıf Araç
14.
15.     Sınıflandırılan Nesnelerin İletimi
16.     If (Küçük Sınıf Araç)
17.         publisherS.send(message);
18.     If (Orta Sınıf Araç)
19.         publisherM.send(message);
20.     If (Büyük Sınıf Araç)
21.         publisherL.send(message);
```

Şekil 1.21. Yayımcı (Publisher) Mimarisi sözde kod gösterimi

Çalışmamızda kullandığımız abone (subscriber) mimarisi Şekil 1.22'de ayrıntılı olarak verilmiştir.

- Context nesnesi varsayılan sunucuda bulunan JMS tarafından yönetilen nesneleri aramak için kullanılır.
- Oluşturulan context nesnesi ile konu nesnesi aranır.
- Context nesnesi ile oluşturulan konuya bağlantı kurulur.
- Bağlantı kurulduktan sonra, alıcı konuları dinlenmeye başlar.

Algoritma 5. Abone (Subscriber) Mimarisi

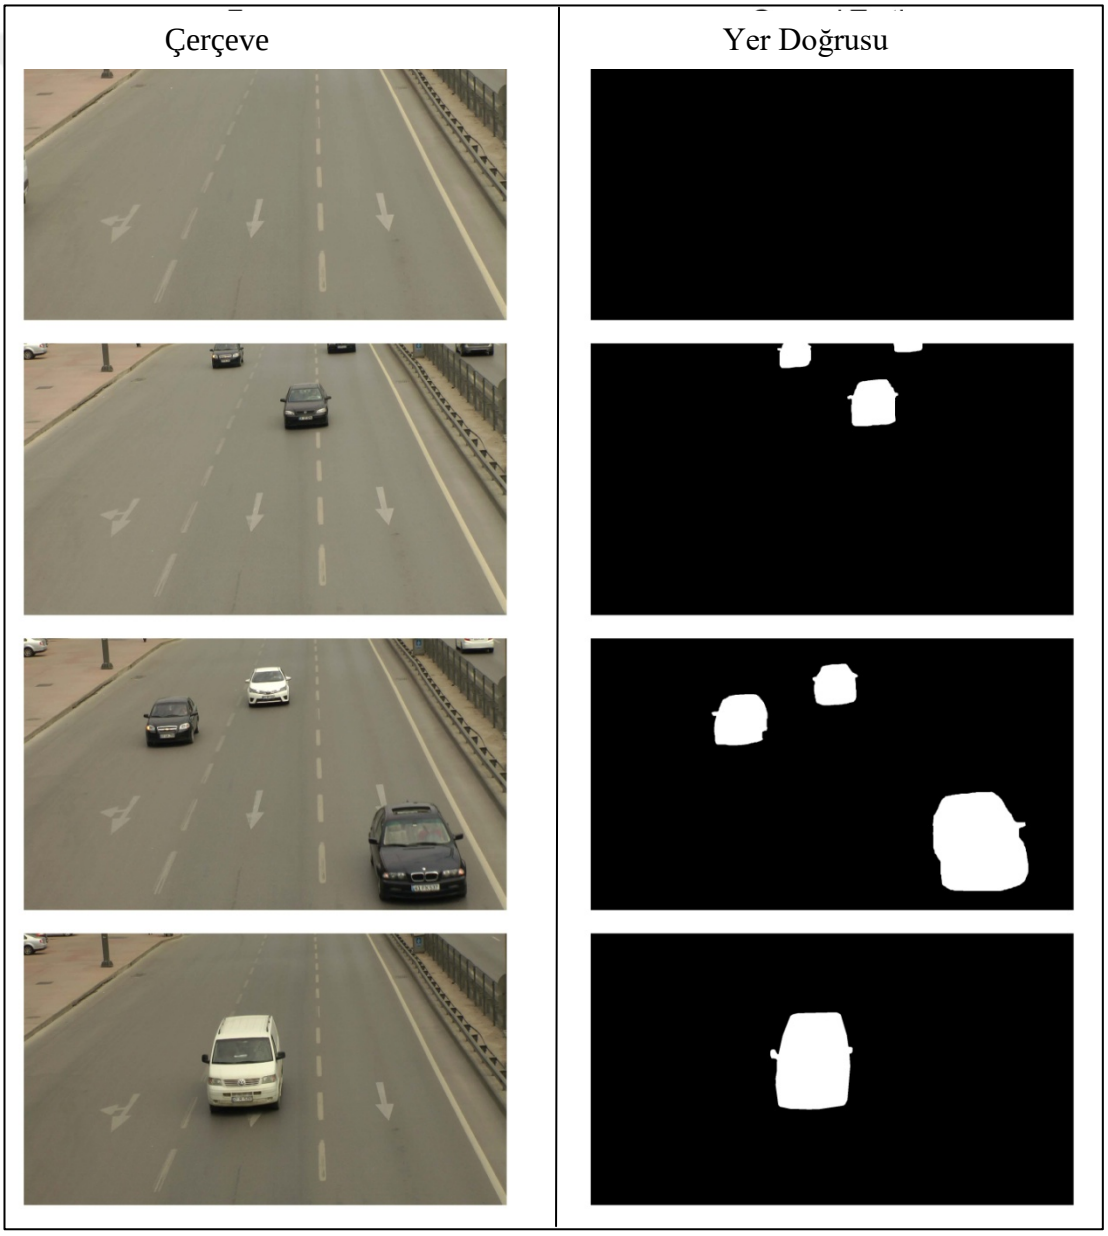
```
1.  Abone
2.          setProperty("org.omg.CORBA.ORBInitialHost","X.X.X.X")
3.          // X.X.X.X Göndericinin IP adresi
4.          InitialContext()
5.          createTopicConnection()
6.
7.          Context.lookup("TopicS")
8.          createDurableSubscriber(topic, "VehicleS")
9.         //Küçük Sınıf Araç İçin Dinlemeye Başla
10.
11.        Context.lookup("TopicM")
12.        createDurableSubscriber(topic, "VehicleM")
13.        //Orta Sınıf Araç İçin Dinlemeye Başla
14.
15.        Context.lookup("TopicL")
16.        createDurableSubscriber(topic, "VehicleL")
17.        //Büyük Sınıf Araç İçin Dinlemeye Başla
```

Şekil 1.22. Abone (Subscriber) Mimarisi sözde kod gösterimi

Yayımla/kaydol modelinin dezavantajı mesajı almak için alıcının o anda çalışıyor olması gerekmektedir aksi halde mesajlar alamayacaktır. JMS API DurableSubscriber yapısı ile mesajlar tüm aboneler tarafından alınması durumuna kadar mesajları saklar. Durable subscriber ile kayıt olan abone bir süre offline olsa dahi tekrar bağlanması durumunda mesajları alacaktır.

2. SONUÇLAR VE ÖNERİLER

Proje kapsamında, kendi veri setimizi (TPSdataset) ve ground truth görüntülerimizi oluşturmak adına çekim gerçekleştirildi. Çekim sonunda 1920 x 1080 boyutunda 3071 çerçeve elde edildi, çerçevelerin yer doğrusu (ground truth) görüntüleri oluşturuldu. Şekil 2.1'de elde edilen veri seti ve bunlara ait yer doğrusu (ground truth) görüntüler verilmiştir.



Şekil 2.1. Örnek veri seti görüntüleri

Çıkarılan özellik kümesi, performans ölçüleri olarak doğruluk (accuracy), hassaslık (recall) ve kesinlik (precision) parametreleri kullanılarak değerlendirildi. Formüller aşağıda açıklanmıştır:

$$\text{Kesinlik Precision} = \frac{TP}{TP+FP} \tag{2.1}$$

$$\text{Hassaslık Recall} = \frac{TP}{TN + FN} \tag{2.2}$$

$$\text{Doğruluk Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \tag{2.3}$$

Tablo 2.1. Çok Sayıda Sınıf İçin Karışıklık Matrisi

		Tahmin Edilen Sınıf				
		C_1	**C_2**	**C_3**	**...**	**C_N**
Doğru Sınıf	**C_1**	T_1	F_{12}	F_{13}	...	F_{1N}
	C_2	F_{21}	T_2	F_{23}	...	F_{2N}
	C_3	F_{31}	F_{32}	T_3	...	F_{3N}
	...	...	...	...	...	...
	C_N	F_{N1}	F_{N2}	F_{N3}	...	T_N

$$\text{Kesinlik Precision } C_i = \frac{T_i}{T_i + \sum_{j=1}^{N} F_{ji}} \tag{2.4}$$

$$\text{Hassaslık Recall } C_i = \frac{T_i}{T_i + \sum_{j=1}^{N} F_{ij}} \tag{2.5}$$

$$\text{Doğruluk Accuracy} = \frac{\sum_{i=1}^{N} Ti}{\text{Testte Kullanılan Tüm Değerler}} \tag{2.6}$$

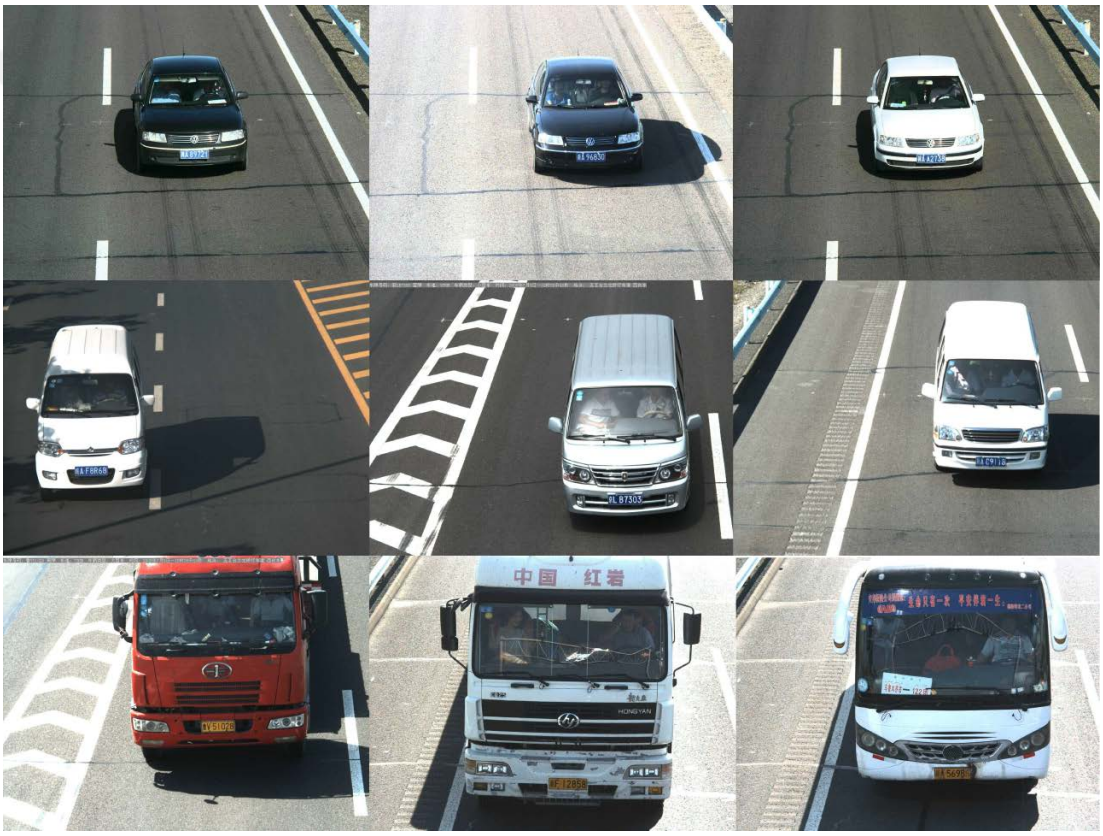
(2.1) - (2.3) denklemlerinde TP gerçek pozitiftir, TN gerçek negatiftir, FP yanlış pozitiftir ve FN yanlış negatiftir. TP aracın doğru bir şekilde sınıflandırılmış olduğu durumlar, TN aracın doğru bir şekilde negatif olarak sınıflandırılmış olduğu durumlardır. Araçların yanlış sınıflandırılması durumları FP ve FN durumlarıdır.Kesin ölçüm, (rastgele seçilmiş) sınıflandırılmış aracın doğru olma ihtimalini gösterirken, hassaslık (recall), doğru tahmin edilen pozitif olayların oranını ölçer. Tablo 2.2 üç sınıflandırıcı için performans sonuçlarını göstermektedir.Kalın değerler en iyi sonucu göstermektedir. Her iki veri kümesi için de her sınıflandırıcının işlem sürelerini özetlemektedir. Tablo 2.2'de TPSdataset1 yedi özellikli veri kümesini, TPSdataset2 ise beş özellikli veri kümesini belirtir.

Tablo 2.2. Farklı sınıflandırma algoritmaları ve TPSdataset'nin farklı özellikleri ile araç sınıflandırma sonuçları

Sınıflandırma Algoritması	İşlem Süresi(ms)	Kesinlik (Precision)		Hassaslık (Recall)		Doğruluk (Accuracy)
YSA TPSdataset 1 (200 x 7)	1,833	Küçük Sınıf	96,8%	Küçük Sınıf	85,7%	87%
		Orta Sınıf	54,3%	Orta Sınıf	83,3%	
		Büyük Sınıf	96,7%	Büyük Sınıf	96,7%	
YSA TPSdataset 2 (200 x 5)	1,588715	Küçük Sınıf	97,6%	Küçük Sınıf	96%	**95%**
		Orta Sınıf	84,8%	Orta Sınıf	92,9%	
		Büyük Sınıf	100%	Büyük Sınıf	93,8%	
Adaboost TPSdataset 1 (200 x 7)	0,069416	Küçük Sınıf	95,2%	Küçük Sınıf	94,4%	92%
		Orta Sınıf	82,6%	Orta Sınıf	82,6%	
		Büyük Sınıf	93,3%	Büyük Sınıf	96,5%	
Adaboost TPSdataset 2 (200 x 5)	0,058551	Küçük Sınıf	94,3%	Küçük Sınıf	96%	92%
		Orta Sınıf	84,9%	Orta Sınıf	84,7%	
		Büyük Sınıf	93,3%	Büyük Sınıf	93,3%	
DVM TPSdataset 1 (200 x 7)	0,016955	Küçük Sınıf	95,97%	Küçük Sınıf	92,97%	92%
		Orta Sınıf	80,4%	Orta Sınıf	84,1%	
		Büyük Sınıf	93,3%	Büyük Sınıf	100%	
DVM TPSdataset 2 (200 x 5)	**0,003630**	Küçük Sınıf	95,2%	Küçük Sınıf	95,9%	93%
		Orta Sınıf	86,9%	Orta Sınıf	83,3%	
		Büyük Sınıf	93,3%	Büyük Sınıf	96,5%	

Çalışmamızda ayrıca, Beijing Institute of Technology Üniversitesi Media Computing and Intelligent Systems (Medya Hesaplama ve Akıllı Sistemler) Laboratuvarı çalışanları tarafından oluşturulan ve akademik çalışmalar için paylaşılan "BIT-Vehicle Dataset" veri seti de kullanılmıştır. "BIT-Vehicle Dataset" veri seti farklı zaman ve yerlerden farklı çözünürlüklerde (1600x1200 ve 1920x1080) 9,850 adet araç görüntüsü içermektedir. Araç görüntüleri; farklı aydınlanma koşullarında

(yaklaşık %10'nu gece), farklı çözünürlüklerde, farklı yüzey renklerinde ve farklı bakış açılarında elde edilmiştir. Tüm araç görüntüleri altı kategoride sunulmuştur: otobüs (558 adet), minibüs (883 adet), kamyon (822 adet), kamyonet (476 adet), sedan (5,922 adet) ve SUV (1,392 adet). BIT-Vehicle veri setinden 300 örnek kullanılmıştır. Numuneler üç kategoriye ayrılmıştır: büyük, orta ve küçük sınıf araçlar. Geniş araç sınıfı, 36 otobüs ve 64 kamyon olmak üzere iki tür araç, orta araç sınıfı, 96 minibüs ve 4 minivan olmak üzere iki tür araç ve küçük araç sınıf araç 100 sedan içermektedir. Şekil 2.2 BIT Vehicle veri setine ait örnek görüntüler içermektedir.



Şekil 2.2. BIT veri seti üzerinden örnekler

Tablo 2.3, üç sınıflandırıcı için performans sonuçlarını göstermektedir. Kalın değerler en iyi sonucu verir. Her iki veri kümesi için de sınıflandırıcıların işlem sürelerini özetlemektedir (yedi özellik ve beş özellik).

Tablo 2.3. Farklı sınıflandırma algoritmaları ve BIT-Vehicle veri seti üzerinde farklı özellikler ile araç sınıflandırma sonuçları

Sınıflandırma Algoritması	İşlem Süresi(ms)	Kesinlik (Precision)		Hassaslık (Recall)		Doğruluk (Accuracy)
YSA BIT-Vehicle Dataset1(300x7)	1,978870	Küçük Sınıf	99%	Küçük Sınıf	86,8%	94,3%
		Orta Sınıf	85%	Orta Sınıf	97,3%	
		Büyük Sınıf	99%	Büyük Sınıf	100%	
YSA BIT-Vehicle Dataset2(300x5)	1,338385	Küçük Sınıf	99%	Küçük Sınıf	93,4%	97%
		Orta Sınıf	94%	Orta Sınıf	97,9%	
		Büyük Sınıf	98%	Büyük Sınıf	100%	
Adaboost BIT-Vehicle Dataset1(300x7)	0,016991	Küçük Sınıf	99%	Küçük Sınıf	93,4%	97%
		Orta Sınıf	93%	Orta Sınıf	97,9%	
		Büyük Sınıf	99%	Büyük Sınıf	100%	
Adaboost BIT-Vehicle Dataset2(300x5)	0,013396	Küçük Sınıf	99%	Küçük Sınıf	92%	96,3%
		Orta Sınıf	92%	Orta Sınıf	96,8%	
		Büyük Sınıf	98%	Büyük Sınıf	100%	
DVM BIT-Vehicle Dataset1(300x7)	0,017596	Küçük Sınıf	99%	Küçük Sınıf	92,5%	96,3%
		Orta Sınıf	92%	Orta Sınıf	96,8%	
		Büyük Sınıf	98%	Büyük Sınıf	100%	
DVM BIT-Vehicle Dataset2(300x5)	**0,012535**	Küçük Sınıf	99%	Küçük Sınıf	95,2%	**97,3%**
		Orta Sınıf	95%	Orta Sınıf	96,9%	
		Büyük Sınıf	98%	Büyük Sınıf	97,3%	

Bilindiği üzere, görüntü işleme yöntemleri; askeri endüstriden güvenliğe [67], tıptan robotiğe, astronomiden havacılığa, biyomedikalden uzaktan algılamaya [68-70] kadar birçok alanda kullanılmaktadır. Trafik ve yönetimi de bu alanlar içinde en önemlilerindendir. Bu çalışmamızın en önemli özgün değeri; yazılımsal ve donanımsal yatırım yapmadan sabit bir kamera ile elde edilen araç görüntülerinin sınıflandırması ve sınıflandırılan araçların görüntülerini içeren video parçacıklarının

ya da görüntüsünün bir mesajlaşma protokolü ile konu tabanlı olarak istemcilere/tüketicilere iletilmesi mimarisinin gerçeklenmesidir.

Görüntü işleme uygulamaları genelde çok kaynak (CPU, bellek vs.) ve zaman gerektirirken, bu görüntüler kamera-video (streaming) olunca durum daha da içinden çıkılmaz bir durum almaktadır. Bu anlamda geliştirilen ürün hard-realtime uygulamalarını soft-real time a dönüştürerek konu-tabanlı mesajlaşma protokolü ile gerçek zamanlı olarak video görüntüleri üzerinden bir uyarı sistemi sağlayabilmektedir. Bu şekilde, gerçek zamanlı kamera görüntüleri üzerindeki çalışmalarda ölçekleme ve performans problemlerine çözüm sunulmuş olmaktadır.

Uyarı ve güvenlik sistemlerinin geliştirilmesine, geçmişteki veri karakteristiklerini inceleyerek geleceğe dönük tahminler yapmaya imkân verecek ve bu da çeşitli alanlardaki farklı uzmanlık seviyelerinde karar vericilerin kritik ve stratejik kararları zamanında ve doğru almasını sağlayacaktır. Geleceğe yönelik analiz ve tahminler için geçmişteki verilerin incelenmesi kaçınılmazdır.

Gelecek tek bir konudan ziyade hiyerarşik konu yapısında yayınla/kaydol modeline dayalı bir sistemin gerçeklenmesi düşünülmüştür. Ayrıca birçok üreticinin (producers/publishers) araç görüntüsü için katkı sağladığı durumlarda büyük miktarda veriler elde edilecektir. Bu da büyük veri analizi ve analitiği gibi diğer çalışmalar için bir girdi sağlayacaktır.

KAYNAKLAR

[1] Draghici S., A neural network based artificial vision system for license plate recognition, *Int. J. Neural Systems*, 1997, **8**, 113-126.

[2] Ghazal M., Hajjdiab H., License Plate Automatic Detection And Recognition Using Level Sets And Neural Networks , *1st International Conference on Communications, Signal Processing, and their Applications IEEE*, Sharjah, United Arab Emirates, 12-14 February 2013.

[3] Kasaei S. H. M., Kasaei S. M. M., Extraction And Recognitionof The Vehicle License Plate For Passing Under Outside Environment , *European Intelligence and Security Informatics Conference IEEE*, Athens, Greece, 12-14 September 2011.

[4] Ying-Nong C., Chin-Chuan H., Gang-Feng H., et al. Facial/License plate detection using a two-level cascade classifier and a single convolutional feature map., *Int J Adv Robotic Syst*, 2015, **12**(12), 1–16.

[5] Bas E, Tekalp A. M., Salman S. Automatic Vehicle Counting From Video For Traffic Flow Analysis, *In: Proceedings of IEEE intelligent vehicles symposium*, Istanbul, Turkey, 13–15 June 2007.

[6] Al-Sobkya A.A., Mousa R.M., Traffic density determination and its applications using smartphone, *Alex Eng J*, 2016, **55**(1), 513–523.

[7] Pelegri J., Alberola J., Llario V., Vehicle Detection And Car Speed Monitoring System Usinggmrmagnetic Sensors, *In: Proceedings of IEEE annual conference in the industrial electronics society*, Sevilla, Spain, 5–8 November 2002.

[8] Ryusuke K., Shigeyuki K., Tomoyuki N., et al., A Punctilious Detection Method For Measuring Vehicles' Speeds., *In: Proceedings of the international symposium on intelligent signal processing and communication system*, Tottori, Japan, 12–15 December 2006.

[9] Harry H.C., Benjamin D.S., Joe P., et al., Development And Field Test Of A Laser-Based Nonintrusive Detection System For Identification Of Vehicles On The Highway, *IEEE Trans Intell Trans Syst*, 2005, **6**(2), 147–155.

[10] Marikhu R., Moonrinta J., Ekpanyapong M., et al. Police Eyes: Real World Automated Detection Of Traffic Violations, *In: Proceedings of ECTI-CON, Krabi, Thailand*, 15–17 May 2013.

[11] Peng Y., Jin J.S., Luo S., et al. Vehicle Type Classification Using PCA With Self-Clustering, *In: Proceedings of IEEE international conference on multimedia expo workshops*, Melburne, Australia, 9–13 July 2012.

[12] Messelodi S., Modena C.M., Zanin M. A., Computer Vision System For The Detection And Classification Of Vehicles At Urban Road Intersections, *Pattern Anal Appl*, 2005, **8**(1-2), 17–31.

[13] Buch N., Orwell J., Velastin S.A., Detection And Classification Of Vehicles For Urban Traffic Scenes., *In: Proceedings of 5th international conference on visual information engineering*, Xian, China, 29 July–1 August 2008.

[14] Morris B., Trivedi M., Robust Classification And Tracking Of Vehicles In Traffic Video Streams. *In: Proceedings of IEEE Intelligent Transportation Systems Conference,* Toronto, Canada, 17–20 September 2006.

[15] Fang J., Meng H., Zhang H., Wang X., A Low-Cost Vehicle Detection And Classification System Based On Unmodulated Continuous-Wave Radar, *Intelligent Transportation Systems Conference*, Seattle, WA, USA, 30 September-3 October 2007.

[16] Wu K., Zhang H., Xu T., Song J., Overview of Video-Based Vehicle Detection Technologies, *The 6th International Conference on Computer Science & Education (ICCSE 2011),* Singapore, Singapore, 3-5 August 2011.

[17] Avery R.P., Wang Y., Rutherford G.S., Length-Based Vehicle Classification Using Images From Uncalibrated Video Cameras, *The 7th International IEEE Conference on Intelligent Transportation System*s, Washington, WA, USA, USA, 3-6 October 2004.

[18] Zhang G., Avery R. P., Wang Y., A Video-based Vehicle Detection and Classification System for Real-time TrafficData Collection, *Transportation Research Record: Journal of the Transportation Research Board*, 2007, **1993**, 198-147.

[19] Qin Z., Method of Vehicle Classification Based on Video, *Proceedings of the 2008 IEEE/ASME International Conference on Advanced Intelligent Mechatronics*, Xian, China, 2-5 July 2008.

[20] Lai J.C., Huang S.S., Tseng C.C., Image-Based Vehicle Tracking and Classification on the Highway, *Green Circuits and Systems (ICGCS), International Conference,* Shanghai, China, 21-23 June 2010.

[21] Kul S., Eken S., Sayar A., Evaluation of Real-time Performance for BGSLibrary Algorithms A Case Study on Traffic Surveillance Video, *IEEE 6th International Conference on IT Convergence and Security*, Prague, Czech Republic, 26-26 September 2016.

[22] Sobral A., Vacavant A., A Comprehensive Review Of Background Subtraction Algorithms Evaluated With Synthetic And Real Videos, *Comput. Vis. Image Underst.*, **122**, 4–21.

[23] Kul S., Eken S., Sayar A., Distributed And Collaborative Real-Time Vehicle Detection And Classification Over The Video Streams, *Int. J. Adv. Robot. Syst.*, **14**(4), 1729-8814.

[24] Messelodi S., Modena C.M., Zanin M., A Computer Vision System For The Detection And Classification Of Vehicles At Urban Road Intersections, *Pattern Analysis & Applications*, **8**(1-2), 17-31.

[25] Buch N., J. Orwell, S.A. Velastin, Detection And Classification Of Vehicles For Urban Traffic Scenes, *5th International Conference on Visual Information Engineering*, Xian China, China, 29 July-1 August 2008.

[26] Morris B. and Trivedi M., Robust Classification And Tracking Of Vehicles In Traffic Video Streams, *In Intelligent Transportation Systems Conference*, Toronto, Ont., Canada, 17-20 September 2006.

[27] Morris B., Trivedi M, Improved Vehicle Classification In Long Traffic Video By Cooperating Tracker And Classifier Modules, *In AVSS '06: Proceedings of the IEEE International Conference on Video and Signal Based Surveillance*, Sydney, Australia, 22-24 November 2006.

[28] Chen X., Zhang C.C., Vehicle Classification From Traffic Surveillance Videos At A Finer Granularity, *In Advances In Multimedia Modeling, Lecture Notes in Computer Science*, **4351**, 772-781, 2007.

[29] Zhang C., Chen X., Chen W., A PCA-based Vehicle Classification Framework, *IEEE International Workshop on Multimedia Databases and Data Management, in conjunction with IEEE International Conference on Data Engineering (ICDE2006)*, Atlanta, Georgia, USA, 3-7 April 2006.

[30] Gandhi T., Trivedi M.M., Video Based Surround Vehicle Detection, Classification And Logging From Moving Platforms: Issues And Approaches, *In Intelligent Vehicles Symposium*, Istanbul, Turkey, 13-15 June 2007.

[31] Zhang G., Avery R.P., Wang Y., Video-Based Vehicle Detection And Classification System For Real-Time Traffic Data Collection Using Uncalibrated Video Cameras, *Transportation Research Record*, **1993**, 138-147.

[32] Duman D., Akar G.B., Hareket Halindeki Araçların Sınıflandırılması, *21st Signal Processing and Communications Applications Conference (SIU)*, Girne, KKTC, 24-26 April 2013.

[33] Ghada S.M., Vehicle Type Classification with Geometric and Appearance Attributes, *World Academy of Science, Engineering and Technology International Journal of Civil, Structural, Construction and Architectural Engineering*, **8**(3), 273-278.

[34] Dong Z., Wu Y., Pei M., Jia Y., Vehicle Type Classification Using a Semisupervised Convolutional Neural Network, *IEEE Trans. Intell. Transp. Syst.*, **16**(4), 2247–2256.

[35] Bouwmans T. Background Subtraction For Visual Surveillance: A Fuzzy Approach, Pal S., Petrosino A. and Maddalena L., Taylor and Francis Group., *Handbook On Soft Computing For Video Surveillance*, 5, Taylor and Fransic Group , San Diego, United States, 103–138, 2012.

[36] https://en.wikipedia.org/wiki/Publish\%E2\%80\%93subscribe_pattern.com (Ziyaret Tarihi: 20 Temmuz 2015)

[37] Lee H., Tseng C., A software framework for Java message service based Internet messaging system, Parallel and Distributed Computing, Applications and Technologies, 2003. PDCAT'2003. Proceedings of the Fourth International Conference, Chengdu, China,29-29 August 2003.

[38] Fabret F., Jacobsen A., Llirbat F., Pereira J., Ross K., Shasha D., Filtering Algorithms And Implementation For Very Fast Publish/Subscribe, *Proceedings of the 20th Intl. Conference on Management of Data (SIGMOD),* **30,** 115–126.

[39] P. Th. Eugster, Type-Based Publish/Subscribe, *ACM Transactions On Programming Languages And Systems (TOPLAS)*, **29**, 6-31.

[40] Banno R., Takeuchi S., Takemoto M., , Kawano T., Kambayashi T., Matsuo M., A Distributed Topic-Based Pub/Sub Method for Exhaust Data Streams towards Scalable Event-Driven Systems, *IEEE 38th Annual Computer Software and Applications Conference (COMPSAC)*, Vasteras, Sweden, 21-25 July 2014.

[41] Gascon-Samson J., Garcia F.P., Kemme B., Kienzle J., Dynamoth: A Scalable Pub/Sub Middleware for Latency-Constrained Applications in the Cloud, *IEEE 35th International Conference on Distributed Computing Systems (ICDCS)*, Columbus, OH, USA, 29 June-2 July 2015.

[42] Tuysuz G., Avenoglu B., Eren P.E., A Workflow-Based Mobile Guidance Framework for Managing Personal Activities, *Seventh International Conference on Next Generation Mobile Apps, Services and Technologies (NGMAST)*, Prague, Czech Republic, 25-27 September 2013.

[43] Roess R.R., Prassas E.S., McShane W.R., *Traffic Engineering*, 4th ed., Prentice Hall, Michigan, 2010.

[44] Akbaş A., Avcı C., Delibaşoğlu İ., Karakullukçu B., Ulusal AUS Sistem Mimarisinin Tasarımı Üzerine, *1. Karayolu Akıllı Ulaşım Sistemleri Kongre ve Sergisi (KAUS 2014)*, İstanbul, Türkiye, 26-28 Mayıs 2014.

[45] http://vision-traffic.ptvgroup.com/en-us/products/ptv-vissim/ (Ziyaret Tarihi: 22 Temmuz 2015)

[46] Sobral A., BGSLibrary: An Opencv C++ Background Subtraction Library, *IX Workshop de Viso Computacional*, Rio de Janeiro, Brazil, 3–5 January 2013.

[47] El B.F., Bouwmans T., Vachon B., Fuzzy Integral for Moving Object Detection, *IEEE International Conference on Fuzzy Systems*, Hong Kong, China, 1-6 June 2008.

[48] Wren C., Azarbayejani A., T. Darrell, A. Pentland, Pfinder: RealTime Tracking of the Human Body, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **19**(7), 780-785.

[49] Kaewtrakulpong P., Bowden R., An Improved Adaptive Background Mixture Model for Realtime Tracking with Shadow Detection, P. Remagnino, G. Jones, N. Paragios and C. Regazzoni, Eds., *Video-Based Surveillance Systems*, Springer, Berlin, 135-144, 2002.

[50] Baf F., Bouwmans T., Vachon B., Type-2 Fuzzy Mixture of Gaussians Model: Application to Background Modeling, *Journal of Basic and Applied Sciences*, **1**(2), 265- 276.

[51] Yao J., Odobez J., Multi-Layer Background Subtraction Based On Color And Texture, *IEEE Computer Vision and Pattern Recognition Conference*, Minneapolis, MN, USA, 17-22 June 2007.

[52] Hofmann M., Tiefenbacher P., Rigoll G., Background Segmentation With Feedback: The Pixel-Based Adaptive Segmenter, *IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops*, Providence, RI, USA, 16-21 June 2012.

[53] Oliver N. M., Rosario B., Pentland A. P., A Bayesian Computer Vision System For Modeling Human Interactions, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **22**(8), 831-843.

[54] Goyette N., Jodoin P.-M., Porikli F., Konrad J., Ishwar P., Changedetection.Net: A New Change Detection Benchmark Dataset, *Workshop on Change Detection at the IEEE International Conference on Computer Vision and Pattern Recognition*, Providence, RI, USA, 16-21 June 2012.

[55] Vacavant A., Chateau T., Wilhelm A., Lequièvre L., A Benchmark Dataset For Foreground/Background Extraction, *Background Models Challenge (BMC) at Asian Conference on Computer Vision (ACCV)*, vol. 7728, Springer, Berlin, 291-300, 2012.

[56] https://www.cs.auckland.ac.nz/courses/compsci773s1c/lectures/Image Processing-html/topic4.htm. (Ziyaret Tarihi: 16 Ekim 2016)

[57] Shapiro L.G., Stockman G.C., *Computer Vision*, 1st Edition, Prentice Hall, Upper Saddle River, New Jersey, 2001.

[58] Avery R.P., Wang Y., Rutherford G.S. Length-based vehicle classification using images from uncalibrated video cameras. In: *Proceedings of the 7th international IEEE conference on intelligent transportation system*, Washington, USA, 3–6 October 2004.

[59] Samet H., *Foundations Of Multidimensional And Metric Data Structures*, 1st ed., Morgan Kaufmann Publishers, Inc. San Francisco, CA, USA, 2005.

[60] Ding C., He X., Zha H., et al. Adaptive dimension reduction for clustering high dimensional data. In: *Proceedings of the international conference on data mining*, Washington DC, USA, 9–12 December 2002.

[61] Han J., Kamber M., *Data Mining Concepts And Techniques*, 3rd ed., Morgan Kauffmann Publishers, San Francisco, CA, USA, 2000.

[62] Hall M., Holmes G. Benchmarking Attribute Selection Techniques For Discrete Class Mining, *IEEE Trans. Knowl. Data Eng.*, **15**(16), 1437–1447.

[63] Soman, K.P., Loganathan, R., Ajay, V., *Machine Learning With SVM And Other Kernel Methods*, PHI Learning Pvt. Ltd., New Jersey, USA, 2011.

[64] http://download.oracle.com/javase/1.3/docs/guide/jni/index.html (Ziyaret tarihi: 10 Ekim 2015).

[65] http://oracle.com/technetwork/middleware/glassfish/overview/index.html (Ziyaret tarihi: 12 Ekim 2015).

[66] Berkhin P., *Survey Of Clustering Data Mining Techniques*, San Jose: Accrue Software Inc., Berlin, 2002.

[67] Kul S., Eken S., Sayar A., Video Gözetleme Sistemlerinde Terk Edilmiş Nesne Saptamak için Servis Odaklı Uyarı Sistemi, *IEEE 23. Sinyal İşleme ve İletişim Uygulamaları Kurultayı*, Malatya, 16–19 May 2015.

[68] Sayar A., Eken S., Mert Ü., Tiling of Satellite Images to Capture an Island Object, *Communications in Computer and Information Science Springer*, **459**, 195–204.

[69] Eken S., Dağıtık Sistemler İçin Ada Uydu Görüntülerinin Vektörel Modellenmesi Ve Zaman-Mekânsal Analizi, Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, Kocaeli, 2012, 315734.

[70] Sayar A. Eken S., Mert Ü., Registering LandSat-8 Mosaic Images: A Case Study on the Marmara Sea, *IEEE 10th International Conference on Electronics Computer and Computation*, Ankara, Turkey, 7-9 November 2013.

KİŞİSEL YAYIN VE ESERLER

[1] **Kul S.**, Eken S., Sayar A., Konvolüsyonel Sinir Ağı Kullanarak Gerçek Zamanlı Araç Tipi Sınıflandırması, *1.Ulusal Bulut Bilişim ve Büyük Veri Sempozyumu B3S'17*, Antalya, Türkiye, 19-20 Ekim 2017.

[2] **Kul S.**, Eken S., Sayar A., A Concise Review on Vehicle Detection and Classification, *The Third International Workshop on Data Analytics and Emerging Services (DAES) with the International Conference on Engineering and Technology*, Antalya, Turkey, 21-23 August 2017.

[3] **Kul S.**, Eken S., Sayar A., Distributed and collaborative real-time vehicle detection and classification over the video streams, *Int. J. Adv. Robot. Syst.*, **14**(4), 1729-8814.

[4] **Kul S.**, Eken S., Sayar A., Evaluation of Real-time Performancefor BGS-Library Algorithms A Case Study on Traffic Surveillance Video, IEEE *6th International Conferenceon IT Convergence and Security*, Prague, Czech Republic, 26 September 2016.

[5] **Kul S.**, Eken S., Sayar A., Measuring the Efficiencies of Vehicle Classification Algorithms on Traffic Surveillance Video, International Conference on Artificial Intelligence and Data Processing (IDAP16), Malatya, Turkey, 17-18 September 2016.

ÖZGEÇMİŞ

Seda KUL 1993'te Trabzon'da doğdu. Lise öğrenimini Yahya Kaptan Lisesi'nde tamamladı. 2011 yılında girdiği Kocaeli Üniversitesi Bilgisayar Mühendisliği Bölümü'nden 2015 yılında ikincilik ile mezun oldu. Aynı yıl içinde Kocaeli Üniversitesi Bilgisayar Mühendisliği Anabilim Dalı'nda yüksek lisans eğitimine başladı. Yüksek lisans eğitiminde dağıtık sistem, görüntü işleme ve yapay zeka konusunda çalışmaları bulunmaktadır.