

İMobileNet CNN Yaklaşımları ve Özellik Seçme Yöntemleri Kullanarak Araç Türlerini Sınıflandırma

Gürkan DOĞAN¹, Burhan ERGEN²

¹Munzur Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 62000, Tunceli, Türkiye

²Fırat Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 23000, Elazığ, Türkiye

(Alınış / Received: 02.03.2021, Kabul / Accepted: 30.09.2021, Online Yayınlanma / Published Online: 25.12.2021)

Anahtar Kelimeler

Derin öğrenme,
Özellik çıkarma,
Özellik seçme,
Sınıflandırma,
Araç Türleri

Özet: Günümüzde, trafik hayatında seyreden araç yoğunluğu ciddi boyutlara ulaşmıştır. Bu nedenle, mevcut ulaşım ağlarının kullanım kapasitesi maksimum seviyelere çıkmakta ve trafik sıkışıklığına yol açmaktadır. Akıllı Ulaşım Sistemlerinin bir çözümü olan Görsel Trafik Gözetleme Sistemleri trafik sıkışıklığını azaltmak için kullanılan alternatif yöntemlerden biridir. Görsel Trafik Gözetleme Sisteminin temel görevlerinden biri; video veya görüntülerden algılanan araç türlerini doğru bir şekilde sınıflandırmaktır. Bu çalışma, Görsel Trafik Gözetleme Sisteminin araç türlerini sınıflandırma doğruluğunu arttıracak yeni yöntemler sunmayı amaçlamaktadır. Çoğu görüntü sınıflandırma doğruluğunu arttıran çalışmalarda geleneksel yöntemler kullanılırken bu çalışmada günümüzde trend olan mobil evrişimli sinir ağları (MCNN) iki farklı yaklaşımla ele alınmaktadır. İlk olarak, MobileNetv1 ve MobileNetv2 modelleri optimize edilerek İMobileNetv1 ve İMobileNetv2 yaklaşımları önerildi. İkinci olarak, bu önerilen MCNN yaklaşımları sadece özellik çıkarıcı olarak kullanıldığı ve elde edilen özelliklerin birleştirilmesi, seçilmesi ve sınıflandırılması gibi yöntemlerin birlikte kullanıldığı bir yaklaşım önerildi. Önerilen yaklaşımlarla yapılan sınıflandırma sonucunda, %85,05 oranında çok yüksek bir sınıflandırma başarısı elde edilmiştir.

Classification of Vehicle Types Using İMobileNet CNN Approaches and Feature Selection Methods

Keywords

Deep learning,
Feature extraction,
Feature selection,
Classification,
Vehicle Types

Abstract: Nowadays, the density of vehicles in traffic life has reached serious levels. Therefore, the utilization capacity of existing transportation networks increases to maximum levels and leads to traffic congestion. Visual Traffic Surveillance Systems, a solution of Intelligent Transportation Systems, is one of the alternative method used to reduce traffic congestion. One of the main tasks of the Visual Traffic Surveillance System is to correctly classify the types of vehicles detected from video or images. This study aims to present new methods that will improve the accuracy of the visual Traffic Surveillance System in classifying vehicle types. While traditional methods are used in most studies that increase image classification accuracy, today's trend mobile convolutional neural networks (MCNN) are considered with two different approaches in this study. Firstly, the MobileNetv1 and MobileNetv2 models were optimized and the İMobileNetv1 and İMobileNetv2 approaches were proposed. Second, the proposed MCNN approaches were used only as feature extractors. An approach that uses methods such as combining, selecting, and classifying the features obtained from these approaches was proposed. As a result of the classification made with the proposed approaches, a very high classification success rate of 85.05% has been achieved.

1. Giriş

Son yıllarda, toplumların sosyal ve ekonomik refahlarının artması ve otomotiv endüstrisinin devasa

boyutlara ulaşması ile birlikte ulaşım sistemleri ciddi manada etkilenmiştir. Otomotiv endüstrisindeki bu ivmelenme ile birlikte Uluslararası Motorlu Araç Üreticileri Örgütü 'nün yeni araç tescili veya satışı

*İlgili yazar : gurkandogan@munzur.edu.tr

raporlarına göre 2005 ve 2019 arasında trafiğe yeni kayıt yapılan motorlu araç sayısı yaklaşık olarak 1.2 milyar adettir [1]. Araç sayısının bu boyutlara ulaşması; mevcut ulaşım ağlarının kullanım kapasitesini maksimum seviyeye çıkarmakta ve birçok ülkede trafik sıkışıklığına neden olmaktadır [2]. Bununla birlikte, yeni karayolları veya şeritler inşa etmek, sınırlı alan ve yüksek maliyet nedeniyle çoğu zaman uygun bir seçenek değildir. Örneğin, Los Angeles şehrinde yüksek kapasiteli araç şeridi inşa etmenin maliyeti şerit ve mil başına 750 bin \$ 'a kadar çıkmaktadır [3].

Görsel Trafik Gözetleme Sistemlerini kullanmak trafik sıkışıklıklarını azaltmak için etkili bir alternatif yöntemdir. Bu sistemler araç sayısı, türleri ve araç hızı gibi trafik verilerini toplamak için kullanılan Akıllı Ulaşım Sistemlerinin (ITS) ayrılmaz bir bileşenidir. Trafik gözetleme sistemleri ile toplanan verilere dayanarak, karayolu sistemlerini daha verimli kullanmak, gelecekteki ulaşım ihtiyaçlarını tahmin etmek ve ulaşım güvenliğini iyileştirmek için trafik analizi gerçekleştirilebilir [4]. Birçok ülkedeki ulaştırmadan sorumlu yetkililer tarafından trafik gözetleme sistemlerini geliştirmek, yerleştirmek ve sürdürmek için büyük miktarda para harcamaktadır [5].

Bir trafik gözetleme sisteminin temel görevlerinden biri araç sınıflandırmaktır. Farklı araç türlerinin doğru sınıflandırılması, etkili trafik operasyonu ve ulaşım planlaması için çok önemlidir. Örneğin, karayolu üzerindeki büyük kamyonların sayısı ile ilgili bilgiler, karayolunun kapasitesini tahmin etmek ve karayolu bakım çalışmalarını planlamak için kullanılabilir. Karayolu şeritlerinin geometrik tasarımı da ilgili şeridi sıklıkla kullanan araç türlerine göre yapılmaktadır [6].

Araç türlerinin sınıflandırılması bahsedildiği gibi büyük bir önem arz ettiği için bu çalışmanın ilham kaynağını oluşturmaktadır. Bu çalışmada, trafik gözetleme sisteminin temel özelliklerinden biri olan araç türlerini sınıflandırma işlevi ele alınmış olup mevcut sınıflandırma yöntemlerinin başarısından daha yüksek bir sınıflandırma başarısı elde edilmesine odaklanmıştır.

Bu doğrultuda, araç türlerini sınıflandırmak için geleneksel makine öğrenmesi teknikleriyle, derin öğrenmeye dayalı teknikler kıyaslandığında derin öğrenmeye dayalı teknikler büyük ilerlemeler sağlamıştır. Özellikle araç takibini tanımlama, öznitelik çıkarma ve tespit etme görevlerinde çok iyi bir performansa sahiptir [7]-[9].

Diğer taraftan, mobil cihazların günlük yaşamda artan kullanımını ve çeşitli alanlardaki derin öğrenme tekniklerinin başarıyla uygulanması ve düşük kaynak tüketimi gerektirmesi araştırmacıları, mobil cihazlarda derin öğrenme yöntemlerini kullanmaya

teşvik etmektedir [10]. MobileNet[11] (diğer adıyla MobileNetv1) ve MobileNetv2[12] temel olarak akıllı telefon veya düşük kaynak tüketimi gerektiren cihazlarda kullanılmaktadır [13].

Bunun yanı sıra, bir evrişimsel ağı sıfırdan eğitmek için kapsamlı hesaplama gücüne, bellek miktarına ve büyük veri kümelerine ihtiyaç vardır. Küçük bir veri kümesine sahip bir ağı eğitilmesi genellikle aşırı öğrenme problemlerine yol açar. Transfer öğrenme, bu problem için en iyi çözümlerden birisidir.

Araç türlerini sınıflandırma problemi birçok araştırmacının ilgi odağında yer almıştır. Bu problemi ele alan çalışmaların büyük bir kısmında geleneksel yöntemler kullanılmıştır. Bu yöntemlerde, farklı algoritmalar kullanılarak araç görüntüsünden arka plan ve diğer özelliklerin çıkarılmasıyla sadece belirli görevler için çözümler önerilmiştir. Lee ve ark. [14], HOG ve SVM teknikleriyle, Manzoor ve Morgan [15], Ölçekle Değişmeyen Öznitelik Dönüşümü (SIFT) tekniğini öznitelik çıkarmak için kullanmıştır ve SVM tabanlı bir sınıflandırma modeli önermiştir. Bu sınıflandırma tekniği, [16], [17] 'de kenar öznitelikleri ile, [18] 'da ise, Haar ve Gabor öznitelikleri kullanılarak araçların tespiti yapılmıştır. Zhang [19], PHOG ve Gabor Transform öznitelik tanımlama yöntemlerini birleştirmiştir ve araç tipini tanımak için kademeli (cascade) sınıflandırıcı şemasını önermiştir. Psyllos [20], araç üreticisi ve modeli tanımak (VMR) için bir model önerilmiştir. Öznitelik çıkarmak için SIFT kullanılırken sınıflandırma için Olasılıksal Sinir Ağı (PNN) kullanılmıştır.

Manuel öznitelik çıkarmayı kullanan geleneksel yöntemlerin aksine, Evrişimli Sinir Ağı (CNN), sadece belirli bir görevin çözümü için değil, birden çok görevler için genelleştirilen çözümler sunar ve öznitelik çıkarmayı otomatik olarak yapar [21]. Araçları türlerine göre sınıflandıran çalışmalardan [22]'de CNN temelli derin sinir ağı, SIFT ve SVM teknikleri birlikte kullanılmıştır. Kafai [23], araçların arka görüntülerinden öznitelikler çıkararak Bayes ağları ile sınıflandırma yaparken Zhang ve ark. [24], vektör nicemeleme temsiline yeniden yapılandırma hatasının araç türü sınıflandırması için kullanıldığı bir çerçeve önermektedir. Liu [25], araç türünü doğru bir şekilde sınıflandırmak için topluluk derin öğrenmeye dayalı bir görüntü sınıflandırma yöntemi önerilmiştir.

Öte taraftan, düşük güçlü cihazlarda çalışan MobileNetv1 ve MobileNetv2 CNN modellerini kullanarak yapılan araç türü sınıflandırma çalışması bilinmemekle birlikte bu CNN modelleri farklı çalışmalarda kullanılmıştır. Rabano ve ark. [26], atıkların sınıflandırılması için MobileNetv1 yöntemi kullanmıştır. Bi ve ark. [27], elma yaprağı hastalıklarını tanımlamak için MobileNetv1 tabanlı bir yöntem önermiştir. Taufiqurrahman ve ark. [28], diyabetik retinopatiyi sınıflandırmak için

MobileNetv2 ve SVM tabanlı hibrit bir model önerilmiştir. [29] ve [30]'de, Covid-19 hastalığını sınıflandırmak için Mobilnetv2 ve diğer derin öğrenme yöntemleri kullanılmıştır. Baydilli [31] 'de polen taşıyan arıların sınıflandırma başarısını arttırmak için ince ayar (fine-tuning) ve transfer öğrenme teknikleriyle birlikte MobileNetv2 'yi kullanmıştır.

Mobil evrişimli sinir ağı modellerini öznetelik çıkarma için kullanan ve bu öznetelikler ile araç türlerini sınıflandırmayı gerçekleştiren yöntem benzer olarak literatürde bilinen bir çalışma yoktur. Bu çalışmadaki amaç, farklı mobil evrişimli sinir ağı modellerinde bazı iyileştirmeler yaparak belirli katmanlarda elde edilen öznetelikleri birleştirip (concatenate) seçmek ve bu özneteliklerden doğruluk oranı daha yüksek araç türü sınıflandırması yapmaktır. Bu çalışmanın literatüre katkıları şunlardır;

- Düşük kaynak tüketimi gerektiren ve mobil evrişimli sinir ağı modeli olan MobileNetv1 ve MobileNetv2 en iyileştirilerek ve iteratif olarak belirlenen hiper parametrelerle (Bölüm 3.1 'e bkz.) araç türlerini sınıflandırma başarısı yüksek olan bir yaklaşım sunar,
- En iyileştirilen ve hiper parametreleri belirlenen MobileNetv1 ve MobileNetv2 modelleri yalnızca bir öznetelik çıkarıcı olarak kullanıldığı ve elde edilen özneteliklerin birleştirildiği, seçildiği ve sınıflandırıldığı başka bir yaklaşım sunarak araç türlerini sınıflandırma başarısını daha da yükseltir.

2. Materyal ve Metot

2.1. Araç Veri Seti



Şekil 1. Araç veri setinden bir örnek

Araç veri seti [32], farklı zamanlarda ve farklı açılarda gerçek ortamdan elde edilen yaklaşık 28 bin araç görüntüsünden ve 17 farklı kategoriden oluşmaktadır. Bu veri setinin boyutu, kategorisi ve çerçeve boyutu azaltılarak 3884 adet araç görüntüsü, 6 farklı kategori ve 224x224 çerçeve boyutu ile asıl veri seti elde edildi. Veri setinin boyutu ve kategorisinin azaltılmasının nedeni kısıtlı donanım kaynaklarına sahip bilgisayar (13.6 GB RAM) üzerinde koşturulmasıdır. Ayrıca, araç görüntülerinin seçimi rastgele olarak yapılmıştır. Şekil 1'de birkaç görüntüsü verilen araç veri seti, 646 bisiklet, 682 otobüs, 690 otomobil, 527 taksi, 624 kamyon, 715 minibüs görüntüsünü içermektedir. Daha sonra, veri setinin %80'i eğitim, %10'u

doğrulama ve %10 'u test için kullanılmak üzere ayrıldı.

2.2. Mobil CNN Modelleri

MobileNetv1, derinlemesine ayrılabilir evrişim katmanlarından oluşan verimli bir sinir ağıdır. Daha küçük modellerin ezberleme probleminin daha az olduğu teorisine dayanarak, MobileNetv1, çoğunlukla daha küçük karmaşıklığa sahip olduğu için derinlemesine kullanır [11], [12]. Öte yandan, MobileNetv1'in bir üst sürümü olan MobileNetV2, adımlara göre farklılık gösteren iki tür Darboğaz Katmanı (Bottleneck Layer) olan yeni katman bloğu uygulamaktadır. MobileNetv2'de sadece evrişimli katmandan oluşan Darboğaz Katmanı yerine, bu parametreyi daha da düşürmeyi amaçladıkları, derinlemesine bir evrişim katmanı kullanılmaktadır [12].



Şekil 2. Önerilen yaklaşımın şematik ifadesi. a) iMobileNetv1, b) iMobileNetv2

Bu çalışmada, mobile CNN modelleri kompakt yapısı, kaynak tüketimi, yüksek doğruluk ve hızlı olması açısından tercih edildi. Ek olarak, farklı yapıya sahip ağ mimarileri, bir görüntünün farklı öznetelikleri ayırt edici yönünün güçlü olduğu düşünüldüğünden bu modeller tercih edildi [33]-[35].

Bizim önerdiğimiz ilk yaklaşımda, orijinal MobileNetv1 [11] ve MobileNetv2 [12] modellerinin mimarisini temel alan bazı iyileştirmeler yapıldı. İyileştirilen MobileNetv1 ve MobileNetv2 sırasıyla

iMobileNetv1 ve iMobileNetv2 olarak adlandırıldı. Şekil 2 önerilen yaklaşımların şematik temsilini ifade etmektedir. İki model de, ilk adımda girdi olarak araç veri setini alırken ikinci adımda önceden eğitilmiş ImageNet veri setini transfer öğrenme yöntemi ile kullanır. Üçüncü adımda, İMobileNetv1 ve İMobileNetv2 yaklaşımlarında sırasıyla orijinal MobileNetv1 ve MobileNetv2 mimarilerinde yer alan tüm evrişim katmanları kullanılmaktadır. Dördüncü adımda, İMobileNetv1 ve İMobileNetv2 yaklaşımlarında sırasıyla orijinal MobileNetv1 ve MobileNetv2 mimarilerinde önceden eğitilmiş olan tüm katmanların ağırlıkları dondurulur. Eğer bu noktada tüm katmanlar eğitilirse, gradyanın büyüklüğündeki güncellemeler, sınıflandırıcıdan gelen rastgele ağırlıklar nedeniyle çok büyük olacaktır ve önceden eğitilen model öğrendiklerini unutacaktır. Bu nedenle, eğitim esnasında önceden eğitilen modelin ağırlıklarının güncellenmesi önlenir [36]. Beşinci adımda, her iki yaklaşım için Küresel Ortalama Havuzlama (Global Average Pooling)(KOH) katmanı, yedinci adımda Parça Normalizasyon (Batch Normalization) katmanı, sekizinci adımda Relu Aktivasyon Katmanı eklenirken dokuzuncu adımda, İMobileNetv1 ve İMobileNetv2 yaklaşımlarına Unutma Katmanı (Dropout Layer) eklendi. Son katmanda ise İMobileNetv1 ve İMobileNetv2 yaklaşımları için Tam Bağlantı (Full Connected)(TB) katmanı eklendi. Tüm bu eklenen katmanlar, modelin eğitim esnasında daha stabil olmasını sağlamak ve ezberlemeyi önlemek için yapılmıştır.

Son olarak, önerilen iki CNN yaklaşımı için 224x224x3 görüntü boyutları girdi olarak verilmiştir. Araç veri seti, küçük boyutlu olduğundan yeterli öğrenmeyi sağlayabilmek için ImageNet ile birlikte transfer öğrenme kullanılmıştır. Ek olarak, önerilen her iki modelde, orijinal modellerin sadece evrişim katmanları kullanılarak öznetelik çıkarma işlemi gerçekleştirilmiştir. Ayrıca, öğrenmeyi en iyileştirmek için dondurma, KOH, normalizasyon, aktivasyon, unutma katmanı ve/veya işlemleri eklenirken son katmanın çıkışında da aktivasyon fonksiyonu olarak softmax kullanılmıştır. İMobileNetv1 modelinin toplamda 91 katmanı bulunurken İMobileNetv2 modelinin toplamda 159 katmanı bulunmaktadır.

2.3. SVM Sınıflandırıcı

Destek Vektör Makineleri (SVM) temel olarak iki sınıfa ait verileri birbirinden en uygun şekilde ayırmak için kullanılan denetimli öğrenme algoritmasıdır. Genellikle sınıflandırma problemleri için tercih edilmesine rağmen bazen regresyon problemleri için de tercih edilmektedir. SVM, veri türleri arasında bir ayırım yapabilmek için bir doğru (hiper düzlem /çizgi) çizer. Bu doğrunun farklı veri türleri için de maksimum uzaklıkta olması amaçlanır. Öte yandan, iki veya daha fazla sınıflı verileri ayırmak için temel SVM yöntemi genelleştirilmiştir [38]. Bu sayede, SVM doğrusal olmayan sınıflandırma, regresyon ve çok

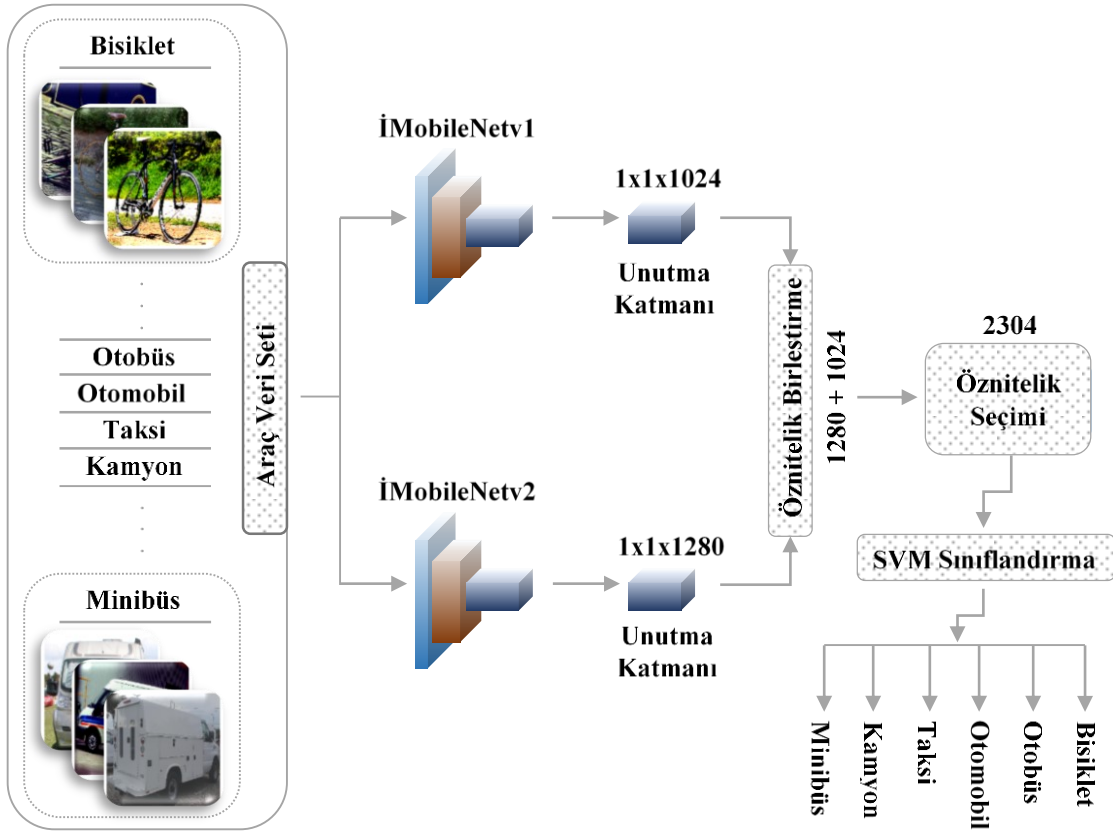
değişkenli fonksiyon tahmini için güçlü bir araç haline gelmiştir. Ek olarak, SVM, bahsedildiği gibi veri türlerini doğrusal olarak sınıflandırmaya çalışır ancak bazı durumlarda bu mümkün olmaz. Bu tür durumlarda, çekirdek hilesi (kernel trick) ile çözüm aranır. Bu çalışmada, araç türlerini sınıflandırma işlemi için SVM Sınıflandırıcısı ve Yarıçapsal Tabanlı Fonksiyon (Radial Basis Function) (RBF) çekirdek hilesi kombinasyonu kullanılmaktadır.

2.4. Öznetelik Seçme Yöntemleri

Öznetelik seçme, veri setinde var olan özneteliklerden yeni bir alt öznetelik kümesi çıkarma işlemidir. Bu işlem ile gereksiz ve birbiriyle ilgisiz olan öznetelikler kaldırılır. Bu sayede, hem verinin boyutu azaltılır hem de performans artışı gerçekleştirilir [42]. Öznetelik seçme işlemi ise öznetelik seçme yöntemleri kullanılarak başarılıdır. Öznetelik seçme yöntemleri, bir veri setindeki nesnelere tanımlayan en iyi özneteliklerin seçilerek sınıflandırma başarısını arttırmayı hedeflemektedir. Bu çalışmada, Karşılıklı Bilgi (Mutual Information) (KB) [43], Stokastik Gradyan İnişi Sınıflandırıcısı (Stochastic Gradient Descent Classifier) (SGIS) [44] ve Doğrusal Destek Vektör Sınıflandırıcısı (Linear Support Vector Classifier) (DDVS) [45] gibi gömülü öznetelik seçme yöntemleri kullanılarak öznetelik seçimi yapıldı. Bu yöntemlerle doğrudan öznetelik seçimi yapılamamaktadır. Ancak, modelden öznetelik seçimi tekniği kullanılarak öznetelikler seçilebilmektedir. Bu teknik, her özneteliğin önemini belirlemek için eğitimden sonra bir tahmin ediciyle birlikte kullanılabilen bir meta-dönüştürücüdür [46]. Öznetelik değerlerine karşılık gelen önem, sağlanan eşik parametresinin altındaysa, öznetelikler önemsiz kabul edilir ve kaldırılır. Eşiği sayısal olarak belirtmenin yanı sıra, bir dizi parametre kullanarak bir eşik bulmanın sezgisel yöntemleri de bulunmaktadır. Mevcut sezgisel yöntemler; ortalama, ortanca (medyan) ve ortalamanın ondalıklı sabit sayılarla çarpımından elde edilen katları vb. gibidir.

2.5. Önerilen Yaklaşım

Bu çalışmada, gerçek ortamdan elde edilen araç görüntüleri için kapsamlı bir çalışma yapılarak iki farklı yöntem önerildi. İlk olarak, MobileNetv1, MobileNetv2 modelleri optimize edilerek İMobileNetv1 ve İMobileNetv2 yaklaşımları (Şekil 2'ye bkz.) önerildi. İkinci olarak, bu önerilen CNN yaklaşımları sadece bir öznetelik çıkarıcı olarak kullanıldığı ve elde edilen özneteliklerin birleştirilmesi, seçilmesi ve sınıflandırılması gibi yöntemlerin birlikte kullanıldığı bir yaklaşım önerildi. İkinci önerilen yaklaşım, temelde dört farklı adım üzerine inşa edilmiştir. Bu temel adımlar, Şekil 3'te önerilen yaklaşımın diyagramında sunulmaktadır. İlk adımda, araç veri seti, İMobileNetv1 ve İMobileNetv2 yöntemleri kullanılarak eğitim gerçekleştirilir ve ardından unutma katmanından öznetelikler çıkarılır. İkinci adımda, bu öznetelikler birleştirilerek toplamda



Şekil 3. Önerilen yaklaşımın diyagramı

2304 özellikten oluşan bir öznitelik kümesi oluşturulur. Üçüncü adımda, bu öznitelik kümesinden Karşılıklı Bilgi (KB), Stokastik Gradyan İnişi Sınıflandırıcısı (SGİS) ve Doğrusal Destek Vektör Sınıflandırıcısı (DDVS) gibi öznitelik seçme yöntemleri kullanılarak üç yeni alt öznitelik kümesi oluşturulur. Son adımda ise bu üç öznitelik kümesi ayrı ayrı SVM sınıflandırıcı ile sınıflandırma işlemine tabi tutulur. Bu çalışma ile gerçek görüntülerden oluşan araç veri setinin sınıflandırma başarısının artırılması hedeflenmiştir.

3. Bulgular

3.1. Deneysel Strateji

Bu çalışmada, İMobileNetv1 ve İMobileNetv2 yöntemleri için eğitimdeki etkisi göz önünde bulundurularak parça boyutu (batch size) sırasıyla 16 ve 8 olarak ayarlandı. İMobileNetv1 ve İMobileNetv2 yöntemleri için unutma (dropout) oranı sırasıyla 0.07 ve 0.4 olarak ayarlanmıştır. Her iki modelde en iyi sonuçları veren Adam [47] optimizasyon algoritması kullanıldı. Her iki model için farklı öğrenme oranları iteratif olarak denendi ve en uygun öğrenme oranı 1×10^{-5} olarak belirlendi. Bu modellerin çıkış katmanının aktivasyon fonksiyonu olarak softmax fonksiyonu kullanılırken bu modellerde kayıp (loss) fonksiyonu olarak kategorik çapraz entropi kullanıldı. Öte yandan, öznitelik seçiminde kullanılan yöntemlerden Karşılıklı Bilgi (KB) için en yüksek skora sahip öznitelik sayısı parametresi (k), Stokastik

Gradyan İnişi ve Doğrusal Destek Vektör Sınıflandırıcısından elde edilen öznitelik sayısının aritmetik ortalaması olarak ayarlandı. Böylece KB ile SGİS ve DDVS yöntemlerinin seçtiği öznitelikler yaklaşık olarak eşit sayıda olması sağlanmıştır ve bu yöntemlerin kendi aralarında değerlendirilmesine imkan verilmiştir. Diğer yöntemlerden Stokastik Gradyan İnişi Sınıflandırıcısı (SGİS) için durdurma kriteri parametresi 1×10^{-4} ve Doğrusal Destek Vektör Sınıflandırıcısı (DDVS) için düzenleme (regularization) parametresi 1×10^{-2} , cezalandırmada kullanılan norm parametresi $l1$ (Lasso), veri setindeki örnek sayısı öznitelik sayısından büyük olduğu için dual parametresi *false* ve durdurma kriteri parametresi 1×10^{-5} olarak seçildi. Son olarak, elde edilen özelliklerden sınıflandırma yapmak için SVM kullanılır ve bu sınıflandırıcının çekirdek (kernel) türü *RBF* olarak seçilir.

3.2. Deneysel Sonuçlar

Bu çalışmada, ilk olarak önerilen İMobileNetv1 ve İMobileNetv2 gibi CNN yaklaşımlarıyla iki ayrı sınıflandırma yapılır. Daha sonra, bu modellerin ilgili katmanlarından elde edilen öznitelikler birleştirilir ve birleştirilen öznitelikler belirtilen öznitelik seçme yöntemleri ile üç farklı alt öznitelik kümesi seçilir. Son olarak, bu alt öznitelik kümeleri ayrı ayrı SVM ile sınıflandırılır. Sonuçların değerlendirilmesi için karmaşıklık matrisinden elde edilen ölçütler incelenir; duyarlılık (Duy.), anımsama (Anı.), f-skor (FSk.) ve doğruluk (Doğ.). Bu metriklerin değerleri aşağıdaki

denklemler ile bulunur. Bu denklemlerde geçen DP, doğru-pozitif, DN, doğru-negatif, YP, yanlış-pozitif, YN, yanlış-negatif 'i ifade etmektedir [48], [49].

$$\text{Duyarlılık} = DP / (DP + YP) \quad (1)$$

$$\text{Anımsama} = DP / (DP + YN) \quad (2)$$

$$F\text{-Skor} = 2DP / (2DP + YP + YN) \quad (3)$$


$$\text{Doğruluk} = \frac{(DP + DN)}{(DP + DN + YN + YP)} \quad (4)$$

Deneysel çalışma, genel olarak iki farklı aşamada gerçekleştirilir. İlk aşamada, önerilen iki farklı CNN modeli ile transfer öğrenme gerçekleştirilerek ayrı ayrı sınıflandırma yapılır ve sonuçları değerlendirilir. İkinci aşamada, bu iki CNN modelinden elde edilen iki ayrı öznelik grubunun ikili kombinasyonu seçilerek birleştirilir. Daha sonra, öznelik seçme yöntemleri kullanılarak bu birleştirilen özneliklerden alt özellik kümeleri oluşturulur. Bu alt özellik kümeleri ayrı ayrı SVM ile sınıflandırılır ve sonuçları değerlendirilir.

Önerilen mobil CNN yaklaşımlarıyla araç veri seti eğitime tabi tutulduğunda, Şekil 4'deki gibi eğitim ve doğrulama kümelerinin doğruluk ve kayıp grafikleri oluşmaktadır. Bu grafiklerde en iyi eğitim ve

doğrulama uyumu İMobileNetv1 modelinde gerçekleşmiştir. Öte yandan, sınıflandırmadaki en yüksek doğruluk oranı %82,47 ile yine bu modelde yakalanmıştır. Şekil 5 ve Tablo 1'de görüldüğü gibi bu modeller arasında en düşük doğruluk oranı ise %81,7 ile İMobileNetv2'de gerçekleşmiştir. İMobileNetv1 ve İMobileNetv2 CNN yaklaşımlarından çıkarılan özneliklerin birleştirilmesiyle oluşturulan öznelik kümesinden en iyi öznelik seçimi de Doğrusal Destek Vektör Sınıflandırıcısı yöntemi ile yapılmıştır. DDVS yöntemi kullanılarak seçilen öznelikler ile %85,05 oranında en yüksek sınıflandırma başarısı elde edilmiştir. Birleştirilen özneliklerden en kötü öznelik seçimi ise Karşılıklı Bilgi (KB) yönteminin kullanılmasıyla elde edilmiştir.

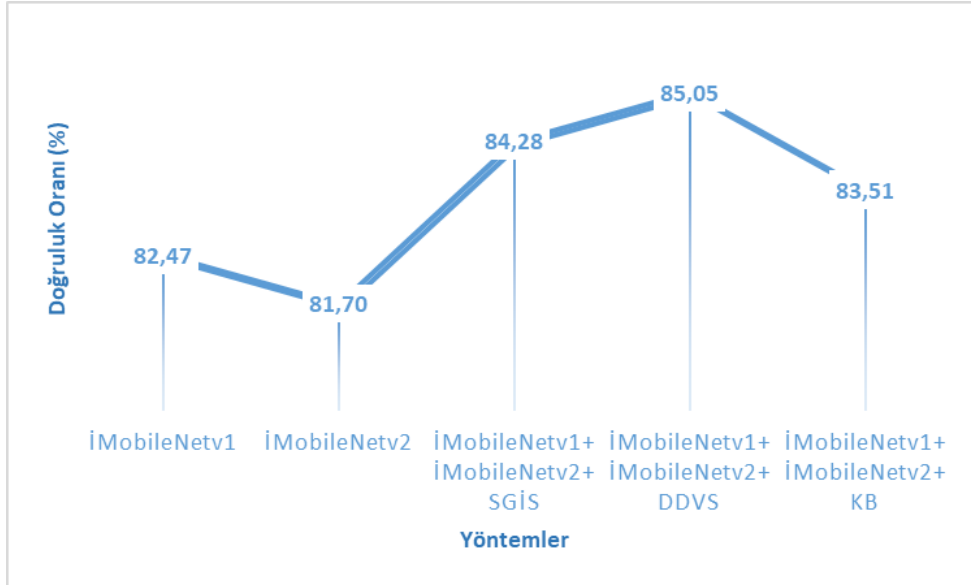
Sonuç olarak, önerilen CNN yaklaşımları ve gerçek görüntülerden elde edilen araç veri setinin birlikte kullanımı ile araç türlerinin sınıflandırılması sonucunda gayet başarılı bir doğruluk oranı elde edilmiştir. Kullanılan araç veri setinin çok küçük boyutta olduğu dikkate alındığında %82,47 doğruluk oranı çok iyi bir orandır. Bu doğruluk oranını daha da yükseltmek için önerilen CNN modelleri sadece öznelik çıkarıcı olarak kullanıldığı ve bu modellerden elde edilen özneliklerin birleştirildiği ve seçildiği ikinci bir yaklaşım önerisi ile sınıflandırma sonucunda yaklaşık %3 oranında bir artış elde edilerek %85,05 oranında bir başarıya ulaşılmıştır.



Şekil 4. Önerilen yöntemler için doğrulama ve kayıp grafikleri; İMobileNetv1 yaklaşımı için doğruluk ve kayıp grafiği sırasıyla a) ve b), İMobileNetv2 yaklaşımı için doğruluk ve kayıp grafiği sırasıyla c) ve d)

Tablo 1. Önerilen yaklaşımların SVM ile sınıflandırma sonuçları

Yöntemler	Metrikler	Bisiklet	Otobüs	Otomobil	Taksi	Kamyon	Minibüs	Doğruluk Oranı (%)
İMobileNetv1	Duy.	0,99	0,88	0,73	0,80	0,78	0,76	82,47423
	Ani.	0,93	0,91	0,72	0,77	0,72	0,86	
	Fsk.	0,96	0,90	0,72	0,78	0,75	0,81	
İMobileNetv2	Duy.	0,92	0,87	0,78	0,71	0,80	0,78	81,70103
	Ani.	0,93	0,88	0,72	0,72	0,76	0,84	
	Fsk.	0,93	0,87	0,75	0,72	0,78	0,81	
İMobileNetv1+ İMobileNetv2+ SGİS	Duy.	0,93	0,96	0,68	0,84	0,90	0,74	84,27835
	Ani.	0,99	0,89	0,81	0,76	0,77	0,77	
	Fsk.	0,96	0,92	0,74	0,79	0,83	0,75	
İMobileNetv1+ İMobileNetv2+ DDVS	Duy.	0,98	0,94	0,71	0,79	0,86	0,77	85,05155
	Ani.	0,99	0,89	0,81	0,73	0,81	0,79	
	Fsk.	0,98	0,91	0,76	0,76	0,84	0,78	
İMobileNetv1+ İMobileNetv2+ KB	Duy.	0,96	0,94	0,69	0,71	0,88	0,77	83,50515
	Ani.	0,99	0,88	0,82	0,71	0,75	0,77	
	Fsk.	0,98	0,91	0,75	0,71	0,81	0,77	

**Şekil 5.** Önerilen yaklaşımda kullanılan yöntemlere göre doğruluk oranları

4. Tartışma ve Sonuç

Bu çalışmada, gerçek görüntülerden oluşan bir araç veri setinden daha yüksek bir sınıflandırma başarısı elde etmek için iki farklı yaklaşım önerdik. Bunlardan ilki, transfer öğrenme ile birlikte MobileNetv1, MobileNetv2 CNN modellerinin mimarilerini temel alan sırasıyla İMobileNetv1, İMobileNetv2 yaklaşımıdır. Bu önerilen CNN yaklaşımları ile çok küçük bir veri seti olan araç veri setindeki görüntülerin eğitilmesi ve sınıflandırılması çok başarılı bir şekilde gerçekleştirildi. İkincisi ise,

önerilen CNN modellerinden elde edilen yüksek sınıflandırma başarısını, öznelik seçme yöntemlerini kullanarak daha da arttırmayı hedeflemektir. Bu amaçla, önerilen CNN modelleri sadece öznelik çıkarıcı olarak kullanılmıştır. Bu modellerin farklı katmanlarından çıkarılan bu iki ayrı öznelik kümesi ikili kombinasyonla birleştirilerek KB, SGİS ve DDVS gibi farklı öznelik seçme yöntemleri ile üç yeni alt öznelik kümesi seçildi. Bu aşamada, en değerli özneliklerden oluşan bir öznelik kümesinin seçilmesi amaçlandı. Daha sonra, bu üç yeni alt öznelik kümesi ayrı ayrı SVM ile sınıflandırma

işlemine tabi tutuldu. Yapılan deneysel testlerde, en yüksek sınıflandırma başarısı önerilen İMobileNetv1 ve İMobileNetv2 CNN modellerinden çıkarılan özneliklerin birleştirilmesi ve bu birleştirilen özelliklerden en önemli özelliklerin seçimi DDVS öznelik seçme yöntemi ile sağlanmıştır. Sınıflandırma işleminin sonucunda ise %85,05 oranında bir doğruluk oranı ile çok iyi bir başarı sağlanmıştır. Bu sonuç, önerilen ilk CNN modelinin en yüksek sınıflandırma başarısından yaklaşık olarak %3 daha fazladır. Bu çalışma ile düşük kaynaklı cihazlarda çalışabilen Mobilenetv1 ve MobileNetv2 CNN modellerinin gerçek ortamdan elde edilen veri setindeki görüntüleri sınıflandırma başarısı çok iyi bir şekilde artırılmıştır. Gelecek çalışmalarımızda ise, farklı iyileştirmeler ve özellik seçme yöntemleri ile bu önerilen yaklaşımımızı daha yüksek bir sınıflandırma başarısı sağlaması için geliştirmeyi hedeflemekteyiz.

Etik Beyanı

Bu çalışmada, "Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesi" kapsamında uyulması gerekli tüm kurallara uyulduğunu, bahsi geçen yönergenin "Bilimsel Araştırma ve Yayın Etiğine Aykırı Eylemler" başlığı altında belirtilen eylemlerden hiçbirinin gerçekleştirilmediğini taahhüt ederiz.

Kaynakça

- [1] "Registrations Or Sales Of New Vehicles - All Types," 2019, p. 6.
- [2] M. Won, T. Park, and S. H. Son, "Toward Mitigating Phantom Jam Using Vehicle-to-Vehicle Communication," *IEEE Trans. Intell. Transp. Syst.*, vol. 18, no. 5, pp. 1313–1324, May 2017, doi: 10.1109/TITS.2016.2605925.
- [3] Federal Highway Administration, *The 2016 Traffic Monitoring Guide*, no. October. .
- [4] M. Won, S. Sahu, and K. J. Park, "DeepWiTraffic: Low cost WiFi-based traffic monitoring system using deep learning," *Proc. - 2019 IEEE 16th Int. Conf. Mob. Ad Hoc Smart Syst. MASS 2019*, pp. 476–484, 2019, doi: 10.1109/MASS.2019.00062.
- [5] H. Lee and B. Coifman, "Using LIDAR to Validate the Performance of Vehicle Classification Stations," *J. Intell. Transp. Syst. Technol. Planning, Oper.*, vol. 19, no. 4, pp. 355–369, 2015, doi: 10.1080/15472450.2014.941750.
- [6] M. Won, "Intelligent Traffic Monitoring Systems for Vehicle Classification: A Survey," *IEEE Access*, vol. 8, pp. 73340–73358, 2020, doi: 10.1109/ACCESS.2020.2987634.
- [7] W. Chu, Y. Liu, C. Shen, D. Cai, and X. Hua, "Multi-Task Vehicle Detection With Region-of-Interest Voting," vol. 27, no. 1, pp. 432–441, 2018.
- [8] X. Hu *et al.*, "SINet: A scale-insensitive convolutional neural network for fast vehicle detection," *arXiv*, vol. 20, no. 3, pp. 1010–1019, 2018, doi: 10.22214/ijraset.2019.6296.
- [9] H. Tehrani Niknejad, A. Takeuchi, S. Mita, and D. McAllester, "On-road multivehicle tracking using deformable object model and particle filter with improved likelihood estimation," *IEEE Trans. Intell. Transp. Syst.*, vol. 13, no. 2, pp. 748–758, 2012, doi: 10.1109/TITS.2012.2187894.
- [10] J. Wang, B. Cao, P. Yu, L. Sun, W. Bao, and X. Zhu, "Deep learning towards mobile applications," *Proc. - Int. Conf. Distrib. Comput. Syst.*, vol. 2018-July, pp. 1385–1393, 2018, doi: 10.1109/ICDCS.2018.00139.
- [11] A. G. Howard *et al.*, "MobileNets: Efficient convolutional neural networks for mobile vision applications," *arXiv*, 2017.
- [12] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L. C. Chen, "MobileNetV2: Inverted Residuals and Linear Bottlenecks," *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, pp. 4510–4520, 2018, doi: 10.1109/CVPR.2018.00474.
- [13] A. S. Winoto, M. Kristianus, and C. Premachandra, "Small and Slim Deep Convolutional Neural Network for Mobile Device," *IEEE Access*, vol. 8, pp. 125210–125222, 2020, doi: 10.1109/ACCESS.2020.3005161.
- [14] S. H. Lee, M. Bang, K. H. Jung, and K. Yi, "An efficient selection of HOG feature for SVM classification of vehicle," *Proc. Int. Symp. Consum. Electron. ISCE*, vol. 2015-Augus, pp. 14–15, 2015, doi: 10.1109/ISCE.2015.7177766.
- [15] M. A. Manzoor and Y. Morgan, "Vehicle Make and Model classification system using bag of SIFT features," *2017 IEEE 7th Annu. Comput. Commun. Work. Conf. CCWC 2017*, 2017, doi: 10.1109/CCWC.2017.7868475.
- [16] M. Cheon, W. Lee, C. Yoon, and M. Park, "Vision-Based Vehicle Detection System With Consideration of the Detecting Location," *IEEE Trans. Intell. Transp. Syst.*, vol. 13, no. 3, pp. 1243–1252, 2012, doi: 10.1109/tits.2012.2188630.
- [17] Z. Kim, "Realtime obstacle detection and tracking based on constrained delaunay triangulation," *IEEE Conf. Intell. Transp. Syst. Proceedings, ITSC*, pp. 548–553, 2006, doi: 10.1109/itsc.2006.1706798.
- [18] Y. Zhang, S. J. Kiselewich, and W. A. Bauson, "Legendre and gabor moments for vehicle recognition in forward collision warning,"

- IEEE Conf. Intell. Transp. Syst. Proceedings, ITSC*, pp. 1185–1190, 2006, doi: 10.1109/itsc.2006.1707383.
- [19] B. Zhang, “Reliable classification of vehicle types based on cascade classifier ensembles,” *IEEE Trans. Intell. Transp. Syst.*, vol. 14, no. 1, pp. 322–332, 2013, doi: 10.1109/TITS.2012.2213814.
- [20] A. Psyllos, C. N. Anagnostopoulos, and E. Kayafas, “Vehicle model recognition from frontal view image measurements,” *Comput. Stand. Interfaces*, vol. 33, no. 2, pp. 142–151, 2011, doi: 10.1016/j.csi.2010.06.005.
- [21] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner, “Gradient-based learning applied to document recognition,” *Proc. IEEE*, vol. 86, no. 11, pp. 2278–2323, 1998, doi: 10.1109/5.726791.
- [22] H. Huttunen, F. S. Yancheshmeh, and C. Ke, “Car type recognition with Deep Neural Networks,” *IEEE Intell. Veh. Symp. Proc.*, vol. 2016-August, no. Iv, pp. 1115–1120, 2016, doi: 10.1109/IVS.2016.7535529.
- [23] M. Kafai and B. Bhanu, “Dynamic bayesian networks for vehicle classification in video,” *IEEE Trans. Ind. Informatics*, vol. 8, no. 1, pp. 100–109, 2012, doi: 10.1109/TII.2011.2173203.
- [24] B. Zhang, Y. Zhou, and H. Pan, “Vehicle classification with confidence by classified vector quantization,” *IEEE Intell. Transp. Syst. Mag.*, vol. 5, no. 3, pp. 8–20, 2013, doi: 10.1109/MITS.2013.2245725.
- [25] W. Liu, M. Zhang, Z. Luo, and Y. Cai, “An Ensemble Deep Learning Method for Vehicle Type Classification on Visual Traffic Surveillance Sensors,” *IEEE Access*, vol. 5, pp. 24417–24425, 2017, doi: 10.1109/ACCESS.2017.2766203.
- [26] S. L. Rabano, M. K. Cabatuan, E. Sybingco, E. P. Dadios, and E. J. Calilung, “Common garbage classification using mobilenet,” *2018 IEEE 10th Int. Conf. Humanoid, Nanotechnology, Inf. Technol. Commun. Control. Environ. Manag. HNICEM 2018*, pp. 18–21, 2018, doi: 10.1109/HNICEM.2018.8666300.
- [27] C. Bi, J. Wang, Y. Duan, B. Fu, J. R. Kang, and Y. Shi, “MobileNet Based Apple Leaf Diseases Identification,” *Mob. Networks Appl.*, 2020, doi: 10.1007/s11036-020-01640-1.
- [28] S. Taufiqurrahman, “Diabetic Retinopathy Classification Using A Hybrid and Efficient MobileNetV2-SVM Model,” 2020.
- [29] M. M. Ahsan, K. D. Gupta, M. M. Islam, S. Sen, M. L. Rahman, and M. S. Hossain, “Study of different deep learning approach with explainable AI for screening patients with covid-19 symptoms: Using CT scan and chest X-ray image dataset,” *arXiv*, 2020, doi: 10.3390/make2040027.
- [30] M. S. Boudrioua, “COVID-19 Detection from Chest X-Ray Images Using CNNs Models: Further Evidence from Deep Transfer Learning,” *SSRN Electron. J.*, 2020, doi: 10.2139/ssrn.3630150.
- [31] Y. Y. BAYDİLLİ, “Polen Taşıyan Bal Arılarının MobileNetV2 Mimarisi ile Sınıflandırılması,” *Eur. J. Sci. Technol.*, no. 21, pp. 527–533, 2021, doi: 10.31590/ejosat.836856.
- [32] Sandeep, “Vehicle Dataset,” 2020, url: <https://www.kaggle.com/iamsandeepprasad/vehicle-data-set>.
- [33] M. Toğaçar, B. Ergen, and Z. Cömert, “Classification of flower species by using features extracted from the intersection of feature selection methods in convolutional neural network models,” *Meas. J. Int. Meas. Confed.*, vol. 158, 2020, doi: 10.1016/j.measurement.2020.107703.
- [34] Y. Wang, L. Sun, Y. Zhang, D. Lv, Z. Li, and W. Qi, “An adaptive enhancement based hybrid cnn model for digital dental x-ray positions classification,” *arXiv*, pp. 1–9, 2020.
- [35] A. Huo, W. Zhang, and Y. Li, “Traffic Sign Recognition Based on Improved SSD Model,” pp. 54–58, 2020, doi: 10.1109/iccnea50255.2020.00021.
- [36] R. Patel and A. Chaware, “Transfer learning with fine-tuned MobileNetV2 for diabetic retinopathy,” *2020 Int. Conf. Emerg. Technol. INCET 2020*, pp. 7–10, 2020, doi: 10.1109/INCET49848.2020.9154014.
- [37] B. E. Boser, I. M. Guyon, and V. N. Vapnik, “Training algorithm for optimal margin classifiers,” *Proc. Fifth Annu. ACM Work. Comput. Learn. Theory*, no. October 2015, pp. 144–152, 1992, doi: 10.1145/130385.130401.
- [38] G. Anthony, H. Gregg, and M. Tshildizi, “Image classification using SVMs: One-Against-One Vs One-against-All,” *28th Asian Conf. Remote Sens. 2007, ACRS 2007*, vol. 2, pp. 801–806, 2007.
- [39] Y. I. A. Rejani and S. T. Selvi, “Early Detection of Breast Cancer using SVM Classifier Technique,” vol. 1, no. 3, pp. 127–130, 2009.
- [40] S. Dhakshina Kumar, S. Esakkirajan, S. Bama, and B. Keerthiveena, “A microcontroller based machine vision approach for tomato grading and sorting using SVM classifier,” *Microprocess. Microsyst.*, vol. 76, p. 103090, 2020, doi: 10.1016/j.micpro.2020.103090.
- [41] S. Han, Q. Cao, and M. Han, “Parameter selection in SVM with RBF kernel function,” *World Autom. Congr. Proc.*, 2012.

- [42] V. Bolón-Canedo and B. Remeseiro, "Feature selection in image analysis: a survey," *Artif. Intell. Rev.*, vol. 53, no. 4, pp. 2905–2931, 2020, doi: 10.1007/s10462-019-09750-3.
- [43] A. Kraskov, H. Stögbauer, and P. Grassberger, "Estimating mutual information," *Phys. Rev. E - Stat. Physics, Plasmas, Fluids, Relat. Interdiscip. Top.*, vol. 69, no. 6, p. 16, 2004, doi: 10.1103/PhysRevE.69.066138.
- [44] T. Zhang, "Solving large scale linear prediction problems using stochastic gradient descent algorithms," in *Twenty-first international conference on Machine learning - ICML '04*, 2004, vol. 6, p. 116, doi: 10.1145/1015330.1015332.
- [45] K. Crammer, "On the algorithmic implementation of multiclass kernel-based vector machines," *J. Mach. Learn. Res. - JMLR*, vol. 2, no. 2, pp. 265–292, 2002.
- [46] Sklearn, "Feature selection using Select From Model," 2021.
- [47] D. P. Kingma and J. L. Ba, "Adam: A method for stochastic optimization," *3rd Int. Conf. Learn. Represent. ICLR 2015 - Conf. Track Proc.*, pp. 1–15, 2015.
- [48] D. M. W. Powers, "Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation," no. January 2008, 2020.
- [49] T. Fawcett, "An introduction to ROC analysis," *Pattern Recognit. Lett.*, vol. 27, no. 8, pp. 861–874, 2006, doi: 10.1016/j.patrec.2005.10.010.

Ekler**Ek A.** Bu çalışmada kullanılan kısaltmalar

Kısaltma	Anlam
MCNN	Mobile Convolutional Neural Network
CNN	Convolutional Neural Network
ITS	Intelligent Transportation Systems
HOG	Histogram of Oriented Gradient
PHOG	Pyramid Histogram of Oriented Gradient
SVM	Support Vector Machine
VMMR	Vehicle Make and Model Recognition
SIFT	Scale Invariant Feature Transform
PNN	Probabilistic Neural Network
KOH / GAP	Küresel Ortalama Havuzlama / Global Average Pooling
RBF	Radial Basis Function
ReLU	Rectified Linear Activation Function
KB / MI	Karşılıklı Bilgi / Mutual Information
SGİS / SDGC	Stokastik Gradyan İniş Sınıflandırıcısı / Stochastic Gradient Descent Classifier
DDVS / LSVC	Doğrusal Destek Vektör Sınıflandırıcısı / Linear Support Vector Classifier