

GÖRÜNTÜ İŞLEME VE GÖZETİMLİ MAKİNE ÖĞRENME TEKNİKLERİYLE TİCARİ HAVA ARACI SINIFLANDIRMA

Kübra Karacan*
İstanbul Teknik Üniversitesi
İstanbul

Tevfik Uyar†
İstanbul Kültür Üniversitesi
İstanbul

M. Kaan Öztürk‡
Boğaziçi Üniversitesi
İstanbul

ÖZET

Bu çalışmada Boeing 737-800, Airbus A319, Airbus A320 ve Boeing 777 tipi ticari yolcu uçaklarının görüntüleri sayısal olarak işlenmiş ve elde edilen özneliklere sınıflandırma amacıyla gözetimli yapay öğrenme algoritmaları uygulanmıştır. İniş konfigürasyonundaki görüntülerini içeren 300 fotoğraftan hava araçlarının kenarları Sobel operatörüyle elde edilmiş, eşikleme, genleşme ve boşluk doldurma yoluyla arka plandan ikili resim olarak tamamen izole edilmiştir. Yapay öğrenme sınıflama uygulamasında kullanmak üzere silüeti çevreleyen dikdörtgen genişliği ve yüksekliği, çevre, dış merkezlik ve açık/kapalı piksel oranı olmak üzere beş öznelik elde edilmiştir. Toplamda sekiz adet gözetimli makine öğrenme yönteminin önışlemsiz olarak, ölçeklemeyle, doğrusal ayırtaç çözümlemeyle ve hem ölçekleme hem de doğrusal ayırtaç çözümlemeyle olmak üzere doğruluk skorlarına bakılmıştır. Yöntemlerden ikisi hariç %90 civarında sınıflama başarısına ulaşılmış, önışleme ve dönüşüm sonrasında yaygın kullanılan yöntemlerle de yapay sinir ağlarıyla denk bir başarı elde edilebildiği anlaşılmıştır.

GİRİŞ

Elektronik görüntüleme ve sayısal görüntü işleme uygulamalarının kullanımı gün geçtikçe artmakta ve önem kazanmaktadır. Bilim ve mühendislik sahasında görüntü kullanımı açısından fotoğrafçılığın icadından sonraki ikinci devrim olarak nitelendirilen sayısal görüntü işleme, mühendislik ve doğa bilimleri arasındaki birleştirici rolüyle de ön plandadır [Jähne, 2004]. Öte yandan yapay öğrenme de, veri temelli araştırmaların sayısında muazzam bir artışa ve bilgi teknolojilerinin ilerlemesine yol açmaktadır. Yapay zekâya dayalı karar algoritmaları ticari uygulamalarla her geçen gün hayatımıza daha çok dahil olarak gündelik kararlarımız üzerinde etkili olmaya başlamıştır [Müller & Guido, 2016]. Bu iki gelişen sahanın birleştirilerek birlikte kullanımından pek çok alanda faydalanılabilir.

Günümüzde gerek sivil gerekse askeri havacılıkta hava araçlarının tanımlanması radyo iletişim araçlarıyla ve/veya radar taraması yoluyla yapılmakta, görsel işaretlere bakarak tanımlama işi

* Yüksek Lisans Öğrencisi, İTÜ Fen Bil. Enstitüsü, E-posta: karacank16@itu.edu.tr

† Doktora Öğrencisi, İKÜ Sosyal Bil. Enstitüsü, E-posta: tuyar@entropol.com

‡ E-posta: kaan.ozturk@boun.edu.tr

insanlar tarafından gerçekleştirilmektedir. Basit bir görüntü üzerinden hava aracı tanımlamanın mevcuttaki yöntemlere ilave olarak kullanılabilmesinin askerî açıdan güvenliği artırabilecek bir uygulama olacağı öne sürülmüştür [Karacor, Torun, & Abay, 2011]. Benzer şekilde ticari hava araçlarının görüntü yoluyla tanımlanmasından hem emniyeti artırmak hem de giderek artan ve karmaşıklaşan hava trafiği ve havaalanı operasyonlarının otomasyonunda yararlanılabilir. Dünya Bankası 2017 verilerine göre ticari havayoluyla seyahat eden yolcuların sayısı 1970'den bu yana neredeyse kesintisiz olarak artmaktadır [The World Bank, y.y.]. Bu nedenle gelecekte ticari hava araçlarının görüntü işleme ve yapay öğrenme yöntemleriyle sınıflandırılmasının kullanışlı olabileceği düşünülmektedir.

Literatürde görüntüler aracılığıyla hava aracı tanımlamayı amaçlayan bazı çalışmalar bulunmaktadır. Bu maksatla yapılan bilinen en eski çalışmalardan birinde 6 askeri uçak tipine ait 132 hava aracının ikili görüntülerini tanımada moment invariant yönteminin insan gözlemcilerden daha başarılı olduğu tespit edilmiştir [Dudani, Breeding, & McGhee, 1977]. Bir başka çalışmada 61 askeri hava aracında moment invariant yönteminin tanıma başarısı %50.82 olarak ölçülürken, faz korelasyon yönteminin başarı oranı %88.52 olarak ölçülmüştür [Roopa & Murthy, 2013].

Yapay sinir ağlarının bir makine öğrenme yöntemi olarak öne çıkmasıyla birlikte, askeri hava aracı tanımlama ile ilgili çalışmalar da gerçekleştirilmiştir. Karacor vd. [2011], F-4, F-16, C-130 ve Mirage tipi askeri uçaklara ait 432 adet görüntü kullanılmış ve yapay sinir ağı (YSA) yöntemiyle %97 sınıflandırma başarısına ulaşılmıştır. Başka bir çalışmada ise dört adet çok katmanlı ileri geri yayımlı sinir ağı, normalleştirilmiş özellik kümeleriyle en uygun şekilde tasarlanıp ve eğitilmiştir. Bu çalışmada kullanılan yöntem 4 tip avcı uçağını sınıflandırmada %91 başarı göstermiştir [Roopa, Rama Murthy, & Prasanna Raj, 2018].

Adı geçen çalışmaların tamamı askeri hava araçları için gerçekleştirilmiştir. Bizse bu çalışmamızda ticari hava araçlarının gözetimli makine öğrenme teknikleriyle sınıflandırılabilme olanaklarını inceledik. Karacor ve arkadaşlarının [2011] çalışmasını temel alarak, 4 adet ticari hava aracının yapay sinir ağlarından daha yaygın ve tutumlu algoritmalarla sınıflandırılıp sınıflandırılmayacağını araştırdık. Bu amaçla araçların fotoğraflarını sayısal görüntü işlemeyle ikili görüntülere dönüştürdük ve bu ikili görüntülerden, uçak tipini öğrenme için kullanılacak beş öznitelik elde ettik. Bu öznitelikleri ölçekleme veya LDA (doğrusal ayırtaç çözümlemesi) dönüşümünden geçirdiğimizde yaygın algoritmaların da yapay sinir ağına denk (0.9 +/- 0.03) başarıyla sınıflandırma yapabildiğini gördük.


YÖNTEM

Çalışmamızda hava aracı fotoğrafçıların kendi çektikleri yüksek kaliteli resimleri yükledikleri bir web sitesinden indirdiğimiz ["Airliners.net", y.y.], Boeing 737-800, Airbus A319, Airbus A320 ve Boeing 777 tipi uçakların aşağıdaki şartlara uyan toplamda 300 fotoğrafını kullandık:

- Fotoğraf uçak havadayken çekilmiş olmalı
- Fotoğraf yandan çekilmiş olmalı
- Fotoğrafta sadece uçak bulunmalı
- Uçak iniş konfigürasyonunda olmalı [iniş takımları açık ve iniş hücum açısında].

Bu şartlar biri hariç Karacor ve arkadaşlarının [2011] çalışmasındakilerle aynıdır. O çalışmadaki "hava aracı fotoğrafının yandan / yana yakın bir pozisyondan çekilmesi" şartını iniş

konfigürasyonunda olma ve iniş takımlarının açık olması şartıyla değiştirdik. Uçak fotoğrafçıları sık sık hava alanlarına yakın noktalarda konuşlanarak iniş yapan uçakları çektiklerinden aynı uçak tipine ait yeterli sayıda fotoğraf bulabildik.



Şekil 1: Sayısal görüntü işlemeyle ikili görüntünün eldesi: Resimler MATLAB yazılımı araçları kullanılarak a) Önce gri tonlamalı görüntüye dönüştürülmüş, b) Sobel yöntemiyle ikili görüntü maskelemesi uygulanmış, c) genişletme ve d) boşluk doldurma işlemleri yapılmıştır. Bu sayede üzerinde işlem yapmaya hazır ikili görüntüler elde edilmiştir.

Görüntü İşleme

Yolcu uçaklarını sınıflandırmada kullanacağımız öznelikler elde etmek için öncelikle fotoğraflardaki uçakları arka plandan izole etmemiz gerekti. Bir fotoğraftaki nesneyi izole etmenin temel yollarından biri kenar belirlemektir. Kenar belirlemede çoğu zaman görüntünün gri seviye değerlerine bakılırken; reflektans, renk veya doku ayrıca ayırt edici parametrelerdir [Bovik, 2009].

Temelde kenar belirleme operatörleri Gradyan ve Laplasyan bazlı olarak iki grupta incelenir. Gradyan bazlı kenar belirlemede görüntünün ilk türevindeki maksimum ve minimum değerler, yani yerel ekstremler; Laplasyan bazlı kenar belirlemede ise ikinci türevin 0 olduğu yerler, yani büküm noktaları baz alınır. Gradyan bazlı olanlar arasında en çok bilinen ve uygulananlar Prewitt, Canny, Sobel ve Roberts operatörleridir ve bu operatörler performans ve işlemci üzerinde yarattıkları işlem yükleri, dolayısıyla da hız açısından birbirlerinden farklılık gösterirler [Maini & Aggarwal, 2009].

Gradyan bazlı fonksiyonlarda 2-boyutlu bir fonksiyon olan gri seviyeli görüntüde kenar belirlemek için fonksiyonun gradyanını hesaplamamız gerekir. İki boyutlu fonksiyonunun gradyanı, 2-boyutlu bir vektör fonksiyondur ve iki ortogonal doğrultu yönündeki kısmi türevlerden oluşur. Bu kısmi türevler, örneğin Sobel filtresi gibi filtreler kullanılarak, iki ortogonal yön boyunca hesaplanan kısmi farklılıklar karşılık gelir. Kenar, gradyan vektörünün büyüklüğünün,

gradyan vektörünün yönü boyunca lokal bir maksimum olduğu yerdir [Petrou & Petrou, 2010]. Sobel filtresi gri seviye değerleri esas alındığında oldukça başarılıdır ve kullanımı yaygındır. Biz de bu nedenle kenar belirlemek için Sobel operatörünü tercih ettik [Heath, Sarkar, Sanocki, & Bowyer, 1998].

Sobel-Feldman operatörü veya kısaca Sobel operatörü olarak da adlandırılan Sobel filtresi, görüntü işleme ve bilgisayarlı görüde özellikle kenar algılama algoritmalarında kullanılan ve kenarları belirgin hale getiren bir operatördür. Stanford Yapay Zeka Laboratuvarı'nda (SAIL) araştırma görevlisi olarak çalışan iki meslektaşın, Irwin Sobel ve Gary Feldman'ın isimleriyle anılır. Sobel ve Feldman, 1968 yılında SAIL'de bir konuşmada "İzotropik 3x3 Görüntü Gradyan Operatörü" fikrini ortaya koymuşlardır [Sobel & Feldman, 1968].

Görüntüdeki her noktada, Sobel-Feldman operatörünün sonucu ya gradyan vektör ya da bu vektörün normuna karşılık gelir. Bu operatör, görüntüyü yatay ve dikey yönde küçük, ayrılabilir ve tam sayı değerli bir filtre ile birleştirmeye dayanır ve bu nedenle hesaplama açısından nispeten tutumludur [Heath, Sarkar, Sanocki & Bowyer, 1998]. Eşitlik 1'deki gibi 3x3'lük 2 adet çekirdek [konvolüsyon] matris; yatay ve dikey yön boyunca oluşan farkları tespit eder ve bu sayede kenarlar belirlenir.

$$\begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix} \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} \quad (1)$$

Kenarlar, sırasıyla eşitlik 2 ve 3'teki gibi tanımlanmış kuvvet [strength] ve yön [orientation] parametreleriyle karakterize edilir [Petrou & Petrou, 2010]:

$$E(i,j) \equiv \sqrt{[\Delta f_y(i,j)]^2 + [\Delta f_x(i,j)]^2} \quad (2)$$

$$a(i,j) \equiv \tan^{-1} \frac{\Delta f_x(i,j)}{\Delta f_y(i,j)} \quad (3)$$

Gradyent operatörü uyguladığımız gri seviyeli görüntüler, bir eşik değeri belirlendikten sonra o değer baz alınarak ikili görüntülere çevrilir. Bu sayede Gradyent operatörüyle ve Sobel filtresiyle, belirlediğimiz eşik değerinde ve yumuşaklıkta kenarlar elde edilir.

Bu işlem sonrasında resimdeki uçak nesnesinin kenarları ince ve yer yer boşluklu bir yapıya dönüşür. Bu yüzden kenarlara morfolojik operatörlerden biri olan genleşme işlemi uygulanır. Bu işlem, ikili görüntünün her pikseline, yapısal elemanın merkezini konumlandırarak tüm görüntü taranır. Yapısal elemanın merkeziyle görüntünün piksel değeri üstüste konur ve yapısal elemanın büyüklüğü kadar piksel Şekil 2'deki gibi genişletilir. Genleşme işlemi süresince ayrıca nesnelerin sınırları düzelir, çok küçük delikler dolar veya boşluklar giderilir [Bovik, 2009].

Bu işlemten sonra artık karşılaştırma için kullanacağımız görüntüler elde edilmiştir.

0	0	0	0	0	0	1	1	1	1	0	0	Yapısal Eleman
0	1	1	0	0	0	1	1	1	1	0	0	
0	1	0	0	0	0	1	1	1	1	0	0	
0	0	1	0	0	0	1	1	1	1	0	0	
0	0	0	0	0	0	0	1	1	1	0	0	
0	0	0	0	0	0							
1	1	1				1	1	1				

Şekil 2: Genleştirme işlemi: Yapısal eleman genleştirilmemiş resim üzerindeki pikselle eş merkezli hale getirildiğinde yapısal elemanın kapladığı kadar alandaki pikseller doldurulur.

Öznitelikler

Görüntüler elde edildikten sonra yapay öğrenme algoritmasında kullanılacak veri setini oluşturmak gerekti. Gözetimli öğrenme yöntemleri için kullanmak üzere aşağıdaki beş öznitelik elde edilmiştir:

- *Çevreleyen Dikdörtgen Genişliği*: Silüeti içeren en küçük dikdörtgenin uzun kenarı
- *Çevreleyen Dikdörtgen Yüksekliği*: Silüeti içeren en küçük dikdörtgenin kısa kenarı
- *Çevre*: Silüetin piksel cinsinden çevre uzunluğu
- *Dış merkezlik*: Silüeti tarayan elipsin odakları arasındaki uzaklığın asal eksen uzunluğuna oranı
- *Açık Kapalı Piksel Oranı*: Silüeti içeren en küçük dikdörtgendeki 1 değerli piksellerin 0 değerli pikseller oranı.

Genişlik ve yükseklik değerleri için çerçeveleyen dikdörtgenin seçilmesinin nedeni uçakların farklı uzaklıklardan fotoğraflanmış olmalarından kaynaklanan ölçü farklarını gidermektir. Bu öznitelikler Karacor ve arkadaşları [2011] tarafından da kullanılmıştır ancak sözkonusu araştırmadan farklı olarak öznitelik sayısı minimize edilmeye çalışılmış ve *dolu alan* (ikili resimdeki 1 değerli piksel sayısı), *uçak alanı* (2x2'lik komşuluklardaki piksel doluluk oranına dayanan alan) ve *arkaplan alanı* (2x2'lik komşuluklardaki piksel boşluk oranına dayanan alan) öznitelikleri çalışmamıza dahil edilmemiştir.

Elde ettiğimiz beş öz niteliğin bir uçağın ölçüleriyle ilgili en önemli unsurların yeterince hesaba katılmasını sağladığı düşünülmüştür. MATLAB'la elde edilen bu değerler, Python programında işlenmek üzere 300 x 6'lık bir veri tablosu olarak dışa aktarılmıştır.

Yapay Öğrenme

Yapay öğrenmede gözetimli sınıflandırma, belli verileri ve bu verilerin ait oldukları sınıfları vererek, bu sınıflandırmayı otomatik olarak üretecek bir modelin parametrelerinin belirlenmesini tabir eder [Alpaydın, 2012]. Veriler genellikle çok boyutludur. Sınıflandırma yöntemleri genellikle altta yatan belli bir parametrik model varsayarlar ve elde edilen verileri kullanarak bu modele en uygun parametrelerin ne olduğu belirlenmeye çalışılır.

Veri kümemizdeki 300 görüntünün işlenmesiyle, öğrenilecek öznitelikleri elde ettikten sonra bu özniteliklerle verilmiş yeni bir uçağın tipinin tahmin edilmesi için çeşitli gözetimli öğrenme yöntemlerini karşılaştırdık. Kullandığımız sınıflandırma yöntemlerini şöyle listeleyebiliriz:

- Lojistik bağlanım (Logistic regression - LogReg)
- En yakın komşular (k-NN)
- Rastgele orman (Random Forest - RF)
- Gradient boost (GrB)
- AdaBoost (AdaB)
- Gaussian Naive Bayes (GNB)
- Destek vektörü makinesi (Support Vector Machine - SVM)
- Sinir ağı (Neural Network - NN) (8 düğümlü bir tek gizli katman)

Bu sınıflandırma yöntemleri için Python'la yapay öğrenme için hazırlanmış olan *scikit-learn* ["scikit-learn", y.y.] kütüphanesini kullandık. Bu yöntemlerin matematiksel ayrıntıları için Alpaydın'ın [2012] kapsamlı derlemesine bakılabilir.

Sınıflandırma yöntemlerinin veriye doğrudan uygulanması yerine, verinin önceden çeşitli yöntemlerle transformasyonu daha fazla başarı sağlandığı bilinmektedir. Örneğin, öznitelikler arasında büyük ölçek farkları varsa, hepsinin aynı ölçeğe getirilmesi hem öğrenmeyi hızlandırır hem de öğrenme başarısını artırır. Bu yüzden, sınıflandırma algoritmalarından önce ölçeklendirme uyguladık ve başarıyı nasıl etkilediğini inceledik.

Ölçekleme için *scikit-learn* kütüphanesindeki *StandardScaler* ölçekleyicisini kullandık. Bu ölçekleyiciyle verileri, ortalamaları 0 ve standart sapmaları 1 olacak şekilde ölçekledik.

Veriyi dönüştürmek için ayrıca Doğrusal Ayırtaç Çözümleme (*Linear Discriminant Analysis – LDA*) yöntemini kullandık. LDA gözetimli sınıflandırma ile kullanılan bir boyut azaltma yöntemidir. İlk olarak R. Fisher tarafından ortaya atılmıştır. Yöntemin özünde, özniteliklerin lineer bileşimlerini kullanarak, farklı sınıflardaki veri noktaları arasında kolay bir ayırıştırma yapmayı sağlayacak bir alt uzay belirlemek bulunur. LDA analizi, sınıfların ortalamaları arasındaki mesafenin azamileştirildiği, her sınıfın kendi içindeki varyasyonunun ise asgarileştirildiği bir alt uzay verir [Xanthopoulos, Pardalos, & Trafalis, 2013]. LDA kendi başına bir öğrenme yöntemi değildir, ancak LDA ile elde edilen yeni koordinatlarda öğrenme algoritmalarının başarısı artabilir. LDA'dan sonra, lojistik bağlanım, destek vektör makineleri vb. sınıflandırma algoritmaları kullanılır. Bu çalışmada *scikit-learn* Python kütüphanesi içindeki LDA implementasyonunu kullandık.

Başarı karşılaştırması için her bir öğrenme algoritması hem kendi başına hem de öncesinde ölçekleme ve/veya LDA ile dönüştürülerek çalıştırıldı. Bu veri hatlarının [pipeline] her biri k-katlı çapraz doğrulama yöntemiyle değerlendirildi: 300 veri noktası rastgele olarak 30 dilime ayrıldı; sırayla her bir dilim sınama kümesi, geri kalanlar ise öğrenme kümesi olarak kullanılarak tahmin doğruluğu (*accuracy*) skorları hesaplandı. Bu hesaplamanın sonucunda, çeşitli öğrenme algoritmaları ve/veya ön işleme dönüşümleriyle elde ettiğimiz skorlar Tablo 1'de görülebilir. Skor değerleri dilimlerin ortalamaları, hata payı ise standart sapmalarıdır.

Bu sonuçları elde ettiğimiz Python kodu ve kullandığımız öğrenme verileri, bu çalışma için hazırladığımız GitHub deposunda incelemeye açıktır ["Github: Aircraft-recog", 2018]. Tablo 1'deki sonuçlara baktığımızda çoğu yöntemle %90'a yakın bir doğruluk elde edebildiğimizi

görüyoruz. Özellikle Gaussian Naive Bayes, Destek Vektör Makinesi, Yapay Sinir Ağı ve k-En Yakın Komşu algoritmalarında ölçekleme, beklendiği gibi büyük bir başarı artışı getiriyor. Ancak LDA, kendi içindeki lineer dönüşüm içinde zaten bir ölçekleme yaptığı için, çoğunlukla ölçeklemeden daha büyük bir avantaj sağlıyor. Bunun tek istisnası AdaBoost algoritması: Ölçekleme başarıyı artırmazken, LDA ile başarı çok düşüyor.

Tablo 1: Veri kümesine çeşitli sınıflandırma algoritmalarının ölçekleme ve LDA ile uygulanması ile elde edilen doğruluk skorları.

Yöntem	Doğruluk skoru			
	Önişlemsiz	Ölçek + Yöntem	LDA + Yöntem	Ölçek + LDA + Yöntem
RF	0.79 ± 0.11	0.82 ± 0.13	0.89 ± 0.08	0.88 ± 0.12
GrB	0.82 ± 0.11	0.83 ± 0.11	0.88 ± 0.09	0.88 ± 0.12
AdaB	0.77 ± 0.15	0.78 ± 0.13	0.54 ± 0.19	0.51 ± 0.16
GNB	0.55 ± 0.17	0.70 ± 0.15	0.90 ± 0.08	0.90 ± 0.11
LogReg	0.66 ± 0.15	0.71 ± 0.13	0.71 ± 0.13	0.71 ± 0.17
SVM	0.32 ± 0.18	0.92 ± 0.08	0.91 ± 0.09	0.91 ± 0.09
ANN	0.32 ± 0.17	0.91 ± 0.09	0.88 ± 0.09	0.89 ± 0.08
k-NN	0.53 ± 0.18	0.84 ± 0.14	0.93 ± 0.10	0.93 ± 0.08

Bu karşılaştırmadan görüyoruz ki, görüntü sayısal olarak işlendikten sonra ortaya çıkan az sayıda özniteliklerle çalıştırılan Gaussian Naive Bayes, Destek Vektör Makinesi, hatta k-En Yakın Komşu gibi basit yapay öğrenme algoritmaları bile, ölçeklendirme veya LDA gibi bir ön işleme aşamasıyla birleştirildiğinde Yapay Sinir Ağı kadar başarı sağlayabiliyor.

Tablo 1’de gösterilen Yapay Sinir Ağı başarısını elde etmek için sekiz düğümü bulunan tek bir gizli katmana sahip bir sinir ağı kullandık. Daha karmaşık bir sinir ağı ile daha başarılı sonuçlar elde edilebileceği düşünülebilir. Bu ihtimali test etmek için veri kümesinin %80’ini LDA dönüşümü yaptıktan sonra farklı büyüklüklerde sinir ağlarıyla eğittik. Sırasıyla 1, 2, ve 3 gizli katman için, her bir katmanda 8, 12, ve 16 düğüm olacak şekilde 39 ayrı sinir ağı oluşturduk, ve her birini eğitim kümesi içinde çapraz doğrulama yaparak eğittik. Bunların çoğunun doğruluk başarısı 0.88-0.93 arasında gerçekleşti. En yüksek doğruluk puanı, tek gizli katmanda 12 düğümlü ağda, ve üç gizli katmanda 16, 16, ve 8 düğümlü ağda gözlemlendi. Ancak, bu ağların başarısını deneme kümesiyle ölçtüğümüzde sırasıyla 0.83 ve 0.87 elde ettik. Deneme kümesindeki başarının öğrenme kümesinin altında kalması aşırı öğrenme olduğuna işaret etmektedir. Dolayısıyla bu veri kümesinde daha karmaşık bir sinir ağı kullanarak daha yüksek bir sonuç elde edilmesini beklemiyoruz.

SONUÇ

Bu çalışmamızda ticari hava araçlarının sınıflandırmasını ölçekleme veya LDA [doğrusal ayırtaç çözümlemesi] dönüşümünün ardından Destek Vektör Makinesi, k-En Yakın Komşu, Rastgele Orman, Gradient Boosting, Gaussian Naive Bayes ve yapay sinir ağları kullanarak yüksek bir doğrulukla otomatik bir şekilde gerçekleştirdik. Daha basit algoritmaların da verinin önceden işlenerek hazırlanması sayesinde, yapay sinir ağları kadar başarılı sonuç verebildiğini gördük. Dolayısıyla, sinir ağları kadar fazla hesaplama yükü taşımayan bir algoritma ile çok daha hızlı tepki veren bir sistem oluşturmak mümkün olabilir. Seçilen ticari hava araçları arasındaki varyasyon askeri hava araçlarına nispetle daha düşük olmasına rağmen oldukça yüksek bir doğruluk oranına erişilmiştir. Üstelik kullanılan öznitelik sayısının sadece 5 olması da dikkate değerdir.

Bu uygulamanın gelecekte hava trafik kontrolü ya da havaalanı ve apron park alanı yönetim otomasyonlarında kullanılmasının mümkün olduğunu düşünüyoruz.

Kaynaklar

- Airliners.net. (y.y.). Tarihinde 19 Mart 2018, adresinden erişildi <http://www.airliners.net/>
- Alpaydın, E. (2012). Yapay öğrenme. Boğaziçi Üniversitesi Yayınevi.
- Bovik, A. C. (Alan C. (2009). The essential guide to image processing. Academic Press.
- Dudani, S. A., Breeding, K. J., & McGhee, R. B. (1977). Aircraft Identification by Moment Invariants. IEEE Transactions on Computers, C-26(1), 39–46.
- Github: Aircraft-recog. (2018). Tarihinde 31 Temmuz 2018, adresinden erişildi <https://github.com/mkozturk/aircraft-recog>
- Heath, M., Sarkar, S., Sanocki, T., & Bowyer, K. (1998). Comparison of Edge Detectors A Methodology and Initial Study *. Computer Vision And Image Understanding (C. 69).
- Jähne, B. (2004). Practical handbook on image processing for scientific and technical applications. Florida: CRC Press.
- Karacor, A. G., Torun, E., & Abay, R. (2011). Aircraft Classification Using Image Processing Techniques And Artificial Neural Networks. International Journal of Pattern Recognition and Artificial Intelligence, 25(08), 1321–1335.
- Maini, R., & Aggarwal, H. (2009). Study and comparison of various image edge detection techniques. International Journal of Image Processing, 3(1), 1–11.
- Müller, A. C., & Guido, S. (2016). Introduction to machine learning with Python : a guide for data scientists. Sebastopol: O'Reilly.
- Petrou, M., & Petrou, C. (2010). Image processing : the fundamentals. Wiley.
- Roopa, K., & Murthy, T. V. R. (2013). Aircraft Image Recognition System Using Phase Correlation Method. Journal of Intelligent Systems, 22(3), 283–297.

Roopa, K., Rama Murthy, T. V., & Prasanna Raj, P. C. (2018). Neural Network Classifier for Fighter Aircraft Model Recognition. *Journal of Intelligent Systems*, 27(3), 447–463.

scikit-learn. (y.y.). Tarihinde 19 Mart 2018, adresinden erişildi <http://scikit-learn.org/stable/>

Sobel, & Feldman, G. (1968). A 3x3 Isotropic Gradient Operator for Image Processing.

The World Bank. (y.y.). Air transport, passengers carried | Data. Tarihinde 20 Temmuz 2018, adresinden erişildi
<https://data.worldbank.org/indicator/IS.AIR.PSGR?end=2017&start=1970&view=chart>

Xanthopoulos, P., Pardalos, P. M., & Trafalis, T. B. (2013). Robust Data Mining. *Robust Data Mining*.