

Derin Öğrenme Modellerinde Komşuluk Bileşen Analizi Yöntemi Kullanarak Çiçek Görüntülerinin Sınıflandırılması

Harun BİNGÖL^{1*}

^{*1} Yazılım Mühendisliği, Mühendislik ve Doğa Bilimleri Fakültesi, Malatya Turgut Özal Üniversitesi, Malatya, Türkiye
^{*1} harun.bingol@ozal.edu.tr

(Geliş/Received: 04/01/2022;

Kabul/Accepted: 03/02/2022)

Öz: Çiçekler tıpkı insanlar ve hayvanlar gibi doğanın yeri doldurulamaz canlılarıdır. Çiçekler birçok hastalığın tedavisinde tıp uzmanları tarafından kullanılmaktadır. İlaç şirketleri büyük araştırma laboratuvarlarında ilaç üretmek için devasa bütçeler ayırarak bu çiçek türleri üzerine araştırma yapmaktadırlar. Bazı çiçekleri gördüğümüz zaman hemen tanırız fakat doğada bizim bildiğimizden çok daha fazla çiçek türü mevcuttur. Hatta günümüzde hiç tanınmamış çiçek türleri bile vardır. Bu çalışmada çiçek türleri üzerine çalışan araştırmacıların, çiçek türlerini tespit etme işlerini kolaylaştırmak amacıyla çiçek görüntüleri derin öğrenme metotları kullanarak sınıflandırılmıştır. Derin öğrenme yöntemleri son zamanlarda özellikle görüntü işlemede yaygın bir şekilde kullanılmakta ve oldukça etkili sonuçlar vermektedir. Bu çalışmada altı farklı derin öğrenme yöntemi kullanılmıştır. İlk aşamada çiçek görüntüleri, önceden eğitilmiş olan Alexnet, Googlenet, Shufflenet, Efficientnetb0, Resnet50 ve Inceptionv3 mimarileri kullanarak sınıflandırılmıştır. İkinci aşamada ise bu altı mimariden elde edilen özellik haritaları KBA (Komşuluk Bileşen Analizi) yöntemi ile optimize edildikten sonra ayrı ayrı makine öğrenmesi sınıflandırıcılarında sınıflandırılmıştır. Üçüncü aşamada, önceden eğitilmiş bu altı derin öğrenme modelini kullanarak veri setindeki çiçek görüntülerinin özellik haritaları çıkarılmıştır. Bu altı derin öğrenme mimarisinden üç tanesi kullanılarak elde edilen özellik haritaları birleştirilmiştir. Daha sonra bu özelliklere algoritmanın çalışma zamanını kısaltmak için KBA metodu uygulanarak gereksiz özellikler çıkarılmış ve optimize edilmiştir. Optimize edilmiş olan özellik haritası klasik makine öğrenmesi sınıflandırıcılarında sınıflandırılmıştır. Deneysel çalışmalarımız sonucunda önermiş olduğumuz modelin doğruluk oranı yüzde 93.49'dur.

Anahtar kelimeler: Derin Öğrenme, ESA, Çiçek Görüntüleri, Sınıflandırıcılar, KBA

Classification of Flower Images using Neighborhood Component Analysis Method in Deep Learning Models

Abstract: Flowers are irreplaceable creatures of nature, just like humans and animals. Flowers are used by medical professionals in the treatment of many diseases. Pharmaceutical companies devote huge budgets to producing drugs in large research laboratories and research these flower types. When we see some flowers, we immediately recognize them, but there are many more flower types in nature than we know. There are even species of flowers that have never been recognized today. In this study, flower images were classified using deep learning methods in order to make it easier for researchers working on flower species to identify flower species. Deep learning methods have recently been widely used especially in image processing and give very effective results. In this study, 6 different deep learning methods were used. In the first stage, flower images were classified using pre-trained Alexnet, Googlenet, Shufflenet, Efficientnetb0, Resnet50 and Inceptionv3 architectures. In the second stage, the feature maps obtained from these six architectures were optimized with the NCA (Neighborhood Component Analysis) method and classified in separate machine learning classifiers. In the third step, feature maps of flower images in the dataset were extracted using these six pre-trained deep learning models. The feature maps obtained using three of these six deep learning architectures were combined. Then, unnecessary features were removed and optimized by applying the NCA method to these features in order to shorten the running time of the algorithm. The optimized feature map is classified in classical machine learning classifiers. As a result of our experimental studies, the accuracy rate of the model we proposed is 93.49 percent.

Key words: Deep Learning, CNN, Flower Images, Classifiers, NCA

1. Giriş

Çiçekler yüzyıllardır doğada var olan bir canlı türüdür. Antik çağlardan beri pek çok medeniyette sosyal ve dini açıdan çiçeğin her zaman önemli bir yeri olmuştur [1]. Bu canlıları insanlar farklı amaçları doğrultusunda kullanmaktadır. Renkli görüntüleri ve hoş kokularından ötürü insanların hep ilgisini çekmiştir. Bu canlıları insanlar özel günlerde birbirlerine hediye etmek için kullanabileceği gibi bir mekânın peyzaj süslemesinde de kullanmaktadır. Dahası insan ve hayvan hastalıklarını tedavi etmek için ilaç sanayisinde de kullanılmakta ve bu

* Sorumlu yazar: harun.bingol@ozal.edu.tr. Yazarın ORCID Numarası: ¹ 0000-0001-5071-4616

konu üzerine bilim dünyası sürekli çalışmaktadır. Çiçeklerin renklerinden ve sahip oldukları şekillerinden ötürü bir birlerinden ayırt etmek uzmanlık gerektiren oldukça zor bir iştir. Yeterince uzman bulunmadığı durumlarda ya da yeterince uzman olsa bile mevcut uzmanların çiçekleri bir birinden ayırt edip sınıflandırma işlemi için fazladan vakit harcamaması ve iş gücü kaybı yaşanmaması için derin öğrenme teknolojileri kullanılmaktadır. Derin öğrenme teknolojileri ile geliştirilmiş olan birçok model vardır. Görüntü işleme alanında en çok kullanılan model ise Evrimsel Sinir Ağı (ESA) modelidir. ESA modeli yapısı gereği vektörlerle çalışmaz bunun yerine ham görüntülerle yani matrislerle çalışmaktadır. Bu sayede uzman bilgisine ihtiyaç duyulmadan sınıflandırılması düşünülen görüntüleri ait özellikler otomatik olarak ortaya çıkarılmaktadır. Sınıflandırma, hangi sınıfa ait olduğu bilinmeyen görüntülerin önceden tanımlanmış olan sınıflardan birine dahil edilmesi olayıdır [2]. Bu olay sınıflandırılacak olan görüntüden elde edilen özellikler baz alınarak gerçekleşmektedir. Derin öğrenme yöntemleri ile sınıflandırma uygulamaları literatürde oldukça yaygın kullanılmaktadır. Çiçek türlerinin sınıflandırılması ile ilgili literatürdeki bazı çalışmalar şu şekildedir:

Saha ve arkadaşları yapmış oldukları çalışmada etiketli eğitim verilerinin olmadığı durumlarda kullanılacak, çiçek görüntülerinin segmentasyon işleminde derin öğrenme teknolojilerini kullanan yeni bir yöntem önermişlerdir. Önermiş oldukları yöntemin başarımı için denetimli yöntemlere benzer sonuçlar elde ettiklerini belirtmişlerdir [3].

Wang ve arkadaşları yapmış oldukları çalışmada elma çiçeğinin fenolojik aşamalarını tahmin etmek için derin öğrenmeye dayalı otomatik bir yöntem önermişlerdir. Kullanmış oldukları veri seti hem gece hem de gündüz görüntülerinden oluşmaktadır. Önermiş oldukları algoritmanın 0,235'lik bir Kullback-Leibler (KL) değeriyle çok daha iyi doğruluk elde ettiği belirtilmiş, YOLOv5l için KL değeri 0,511'de bunun neredeyse iki katı olduğunu ifade etmişlerdir [4].

Shi ve arkadaşlarının yapmış oldukları bu makalede, derin öğrenmeye dayalı bir çiçek görüntüsü otomatik tanıma sistemini önermişlerdir. Önermiş oldukları sistemde kullanıcı mobil akıllı telefon ile çiçek görüntülerini çekmekte ve bu çekilen görüntüsünü InceptionV3'e dayalı transfer öğrenimi ile yeniden eğitilen CNN ağına gönderdiklerini belirtmişlerdir. Deneyler esnasında veri seti olarak Oxford-17[5] ve Oxford-102[6] 'ye dayalı 32 çiçek kategorisi kullandıklarını belirtmişlerdir. Sınıflandırma doğruluğu diğer yöntemlerden daha yüksek olan yaklaşık olarak %95 oranlarına ulaştıklarını belirtmişlerdir. [7].

Jyothi ve arkadaşları yapmış oldukları çalışmada kendilerine ait nispeten büyük bir çiçek video veri setimiz üzerinde kapsamlı bir deney yapıldı. Kullanmış oldukları veri setinde 30 farklı çiçek sınıfına ait çiçek 2600'den fazla video olduğunu belirtmişlerdir. Deneysel çalışmalarda küme analizi kullanılarak seçilen ana karelere dayalı olarak çalıştığı vurgulanmıştır. Tüm ana kare, bir ana karenin parçalı çiçek bölgesi ve çiçek bölgesinin gradyanı ESA tarafından özellik çıkarımı için dikkate alındığını vurgulamışlardır. Sunulan model geleneksel öznitelik çıkarım yöntemleriyle karşılaştırılmış ve önerilen modelin erişim sonuçları açısından mevcut modellerden daha üstün olduğunu belirtmişlerdir [8].

Patel ve arkadaşı yaptıkları çalışmada çiçek nesne tespiti, lokalizasyonu ve sınıflandırması için NAS-FPN ve Faster R-CNN tabanlı derin bir ESA önermişlerdir. Deneyler esnasında ResNet 50, ResNet 101, Inception ResNet V2, Inception V2, NAS ve MobileNet V2 transfer öğrenme metodları ile 19679 çiçek görüntüsünü içeren çiçek 30 veri kümesi ve çiçek 102 veri kümesi üzerinde eğitildiği ve değerlendirildiği belirtilmektedir. Önerilen modelin, çiçekleri çok sınıflı sınıflandırma ve çoklu etiketleme teknikleri kullanarak çiçek adı, bölümü, sınıfı, alt sınıfı, sırası, ailesi ve bitki çiçeğini içeren diğer önemli ayrıntılarla birlikte tespit edebilir, konumlandırabileceği ve sınıflandırabileceği belirtilmiştir. Önerilen modelin 102 çiçek sınıfı veri setinde %87,6 ve 30 çiçek sınıfı veri setinde %96,2 mAP ile optimum sonuç verdiği belirtilmiştir [9].

Yapılan bu çalışmada çiçek görüntülerini derin öğrenme mimarileri kullanarak sınıflandırmak amacıyla hibrit bir model geliştirilmiştir. Geliştirmiş olduğumuz bu modelde üç farklı derin modelin özellik haritaları birleştirildikten sonra optimize edilmiştir. Optimize edilen özellik haritası Destek Vektör Makinesi (DVM) sınıflandırıcısı kullanılarak sınıflandırılmıştır.

Bu makalenin organizasyonu şu şekilde yapılmaktadır. Bölüm 2' de çiçek görüntülerinin sınıflandırılmasında kullanılan derin öğrenme mimarileri ve KBA boyut indirgeme yöntemi açıklanmaktadır. Ayrıca önermiş olduğumuz hibrit model bu bölümde detaylı bir şekilde verilmektedir. Bölüm 3'te çiçek görüntülerini sınıflandırmak için gerçekleştirilen deneysel sonuçlar verilmektedir. Bölüm 4'te algoritmaların başarımları üzerine yorumlar gerçekleştirilmekte ve son olarak Bölüm 5'de sonuçlar yorumlanmakta ve gelecekte yapılabilecek uygulamalar hakkında bilgiler verilmektedir.

2. Materyal ve Metot

Bu bölümde çalışmada kullanılan veri seti, ESA mimarileri, KBA boyut indirgeme yöntemi ve önermiş olduğumuz hibrit model açıklanmıştır.

2.1. Veri seti

Yapılan çalışmada kullanılan veri seti halka açık olan kaggle [10] web sitesinden alınmıştır. Bu veri setinde 4317 adet çiçek görüntüsü içeren papatya, karahindiba, gül, ayçiçeği ve lale olmak üzere 5 farklı çiçek türü mevcuttur. Veri setinden alınan örnek çiçekler Şekil 1’de gösterilmektedir. Veri setinde bulunan çiçek türlerine ait olan görüntü sayıları Tablo 1’de verilmektedir.



Şekil 1. Çiçek veri setinden örnek görüntüler

Tablo 1. Veri setindeki çiçek türlerine ait görüntü sayıları

Çiçek Adı	Karahindiba	Papatya	Ayçiçeği	Lale	Gül	Toplam
Görüntü Sayısı	1052	764	733	784	784	4317

2.2. ESA mimarileri ve KBA

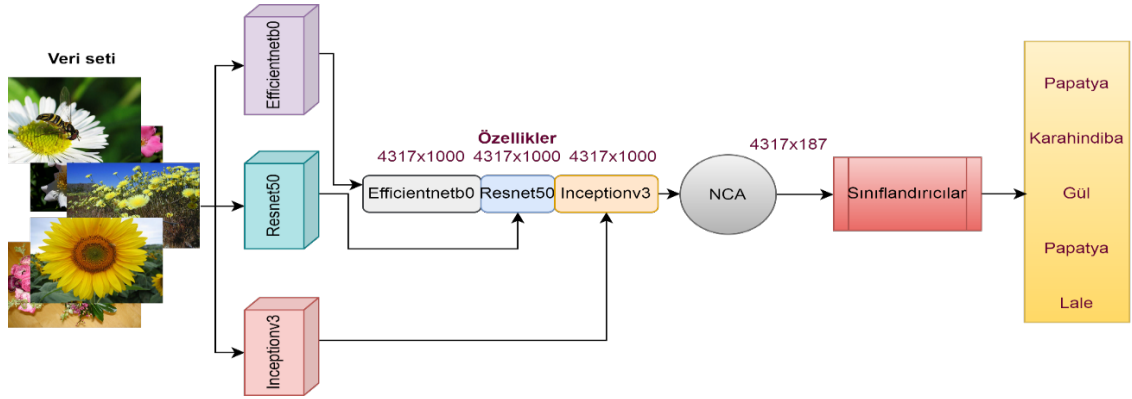
Çalışmamızın bu bölümünde deneyler esnasında kullanılan 6 adet ESA mimarisi olan Alexnet, Googlenet, Shufflenet, Efficientnetb0, Resnet50 ve Inceptionv3 hakkında bilgi verilmektedir. Alexnet mimarisi, Krizhevsky ve arkadaşları [11] tarafından önerilen ve ilk olarak ImageNet LSVRC-2012 yarışmasında ortaya çıkan ve rekabetçi sonuçlar elde eden derin bir ESA mimarisidir [12]. Googlenet mimarisi aslında Inception mimarisini temel alan yalnız daha derin ve daha geniş bir modeldir. Bu mimari hesaplama verimliliği ve pratikliği göz önünde bulundurularak tasarlanmıştır, böylece özellikle düşük bellek ve sınırlı hesaplama kaynaklarına sahip olan bireysel cihazlarda kullanılabilir [13]. Shufflenet çok kısıtlı hesaplama gücüne sahip olan mobil aygıtlar için geliştirilmiş oldukça başarılı sonuçlar üreten bir ESA mimarisidir [14]. EfficientNet mimarisi, sabit bir bileşik katsayı kullanarak ağırlık derinlik, genişlik ve görüntü çözünürlüğü gibi farklı boyutlarını aynı anda eşit bir şekilde ölçeklendirme ilkesine dayanmaktadır. Bu aile 8 farklı ESA mimarisini bünyesinde barındırır. Efficientb0’dan Efficientb7’ye kadar isimlendirilmektedir. Efficientb0, 224×224 giriş boyutuna sahip temel sürümü temsil eder ve ters çevrilmiş darboğaz kalıntısı, sıkıştırma ve uyarma bloklarını temel alır [15]. Resnet50 modeli 2015 yılında He ve arkadaşları [16] tarafından geliştirilen bir ESA modelidir. Bu model aynı zamanda 2015 yılında yapılan ILSVRC ImageNet yarışmasının kazananıdır. Bu yarışmada Resnet50 mimarisi %3,6 hata oranıyla birinci olmuştur. Resnet50, derin ESA’nın eğitim sürecindeki zorlukları aşmaya çalışmakla beraber, algılama doğruluğunu artırmaya çalışır. Toplu normalleştirmeyi kullanan ilk mimarilerden biridir [17,18]. Inceptionv3 mimarisi Szegedy ve arkadaşları [19] tarafından inceptionv1 ve inceptionv2 modelleri geliştirilerek elde edilmiştir. Inceptionv3 modelini evrişim bloğu, başlangıç bloğu ve sınıflandırıcı bloğu olmak üzere üç bölümden oluşan bir model olarak tanımlamışlardır [20]. Bu model girdi verilerini 299×299 boyutunda alır. Inceptionv3 modeli toplam 315 katmandan oluşmaktadır. Ayrıca aktivasyon katmanı olarak Relu katmanını kullanmaktadır. Normalleştirme için toplu normalleştirme ve ortaklama için maksimum ortaklama ve ortalama ortaklamayı birlikte kullanmaktadır [21].

KBA, hesaplama maliyetini düşürmek ve küçük boyuta sahip daha kullanışlı özellik haritaları elde etmek için kullanılmaktadır. Bu yöntem sayesinde değerli olan bilgi kaybolmadan matris üzerinde optimizasyon işlemi yapılarak daha düşük boyutlu özellik haritaları elde edilir. KBA yöntemi, daha az değerli özellikleri bertaraf

etmekte ve zaman tüketim maliyetini azaltmada etkili olarak kullanılan yöntemlerdendir. Bu aynı zamanda sınıflandırma maliyetlerine de olumlu olarak yansımaktadır.

2.3. Önerilen hibrit model

Yapılan bu çalışmada son yıllarda oldukça popüler olan Efficientnetb0, Resnet50 ve Inceptionv3 mimarileri taban olarak kullanılmıştır. Bu mimariler sayesinde çiçek veri setindeki görüntülerin farklı özellikleri elde edilmiştir. Her bir mimaride elde edilen özellik haritasının boyutu 4317 x 1000'dir. Daha sonra elde edilen özellik haritaları birleştirilerek 4317 x 3000 boyutunda bir özellik haritası elde edilmiştir. Elde edilen özellik haritasının boyutunu indirmek için KBA boyut indirgeme yöntemi kullanılmıştır. KBA boyut indirgeme yöntemi uygulandıktan sonra elde edilen özellik haritasının boyutu 4317 x 187 olmuştur. Son olarak optimize edilen özellik haritası klasik makine öğrenmesi sınıflandırıcılarında sınıflandırılmıştır. Önermiş olduğumuz yöntem a blok diyagram Şekil 2'de gösterilmektedir.



Şekil 2. Önerilen yöntemin blok diyagramı

3. Deneysel Sonuçlar

Bu çalışmamız Matlab 2021b ortamında i5 işlemcili, 8 GB ram ve Geforce GTX1650 4GB ekran kartına sahip olan bilgisayarda gerçekleştirilmiştir. Yapılan çalışmada modellerin performans metriklerini değerlendirmek için karışıklık matrisi kullanılmıştır. DP (Doğru Pozitif), YP (Yanlış Pozitif), YN (Yanlış Negatif) ve DN (Doğru Negatif)'tir. Tablo 2'de karmaşıklık matrisine örnek verilmiştir.

Tablo 2. Karmaşıklık matrisi

Doğru Sınıf	1	DP	YP
	2	YN	DN
		1	2
		Tahmin Sınıf	

Çalışmada kullanılan başarımlar ölçüm matrisleri karışıklık matris kullanılarak hesaplanmaktadır. Yapılan çalışmada modellerin başarımlarını değerlendirmek için doğruluk, duyarlılık, özgünlük ve f_ölçütü değerlendirme ölçütleri kullanılmıştır [22].

$$Doğruluk = \frac{DP+DN}{DP+DN+YP+YN} \quad (1)$$

$$Duyarlılık = \frac{DP}{DP+YN} \quad (2)$$

$$Özgünlük = \frac{DN}{DN+YP} \quad (3)$$

$$F_ölçütü = \frac{2*DP}{(2*DP+YP+YN)} \quad (4)$$

Çalışmamızda öncelikle önermiş olduğumuz modelin performansını karşılaştırmak için önceden eğitilmiş altı farklı ESA mimarisinde sonuçlar alınmıştır. Bu mimarilerde alınan doğruluk değerleri Tablo 3'te verilmektedir.

Tablo 3. ESA mimarilerinden alınan doğruluk değerleri

Alexnet	Googlenet	Shufflenet	Efficientb0	Resnet50	Inceptionv3
87,96	90,39	87,85	90,28	91,55	92,82

Tablo 3 incelendiğinde 6 farklı ESA mimarisi içinde en yüksek doğruluk değerinin %92,82 değeri ile Inceptionv3, en düşük doğruluk değerini %87,85 değeri ile Shufflenet mimarisi vermiştir. Tablo 4'te 6 ESA mimarisinin doğruluk değerlerini gösteren karmaşıklık matrisleri gösterilmektedir.

Tablo 4. ESA mimarilerine ait karmaşıklık matrisleri

Alexnet						Googlenet							
Doğru Sınıf	1	141	6	2	1	3	Doğru Sınıf	1	145	3	2	3	
	2	7	191	1	7	4		2	6	192	1	8	3
	3	3	1	143	1	9		3		2	143		12
	4	2	12	2	130			4	1	8	5	130	3
	5	4	8	25	5	155		5		4	19	3	171
Tahmini Sınıf						Tahmini Sınıf							
Shufflenet						Efficientnetb0							
Doğru Sınıf	1	135	10	2	2	4	Doğru Sınıf	1	142	5	2	4	
	2	11	185	2	6	6		2	3	197		7	3
	3	1	1	141	2	12		3	3	2	138	4	10
	4	3	11	2	128	3		4	3	6	4	131	3
	5	1	1	23	2	170		5	1	5	14	5	172
Tahmini Sınıf						Tahmini Sınıf							
Resnet50						Inceptionv3							
Doğru Sınıf	1	141	8	1	2	1	Doğru Sınıf	1	146	4	1	2	
	2	9	198		2	1		2	3	205			2
	3	2		143		12		3		1	141		15
	4	3	5	2	135	2		4	2	5	1	137	2
	5	2	4	15	2	174		5		4	18	2	173
Tahmini Sınıf						Tahmini Sınıf							

Çalışmada kullanılan 6 farklı ESA mimarisinde en yüksek doğruluk değeri Inceptionv3 mimarisinde elde edilmiştir. Bu mimaride toplam 864 tane çiçek görüntüsünden 802 tanesi doğru tahmin edilirken, 62 tanesi ise model tarafından yanlış tahmin edilmiştir.

Çalışmamızın ikinci adımda çalışmada kullanılan 6 ESA mimarisinden ayrı ayrı elde edilen özellik haritaları KBA boyut indirgeme yöntemi ile optimize edildikten sonra DVM sınıflandırıcısında sınıflandırılmıştır. KBA yönteminde 0,0005'den küçük değerler elemine edilmiştir. 6 ESA mimarisinden elde edilen özellik katmanı ve özellik sayıları Tablo 5'de verilmiştir.

Tablo 5. Mimariler, özellik haritalarının elde edildiği katman ve özellik sayıları

	Alexnet	Googlenet	Shufflenet	Efficientnetb0	Resnet50	Inceptionv3
Katman	Fc8	loss3-classifier	node_202	efficientnet-b0 model head dense MatMul	Fc1000	predictions
Özellik Sayısı	1000	1000	1000	1000	1000	1000
KBA'lı özellik sayısı	355	155	271	652	293	379
Doğruluk değerleri	87	87.7	89.2	92.1	90.9	89.6

Çalışmada kullanılan 6 farklı ESA mimarisinden elde edilen özellik haritaları KBA yöntemi ile optimize edildikten sonra en yüksek doğruluk değeri %92.1 ile Efficientnetb0 mimarisinde elde edilirken, en düşük doğruluk değeri ise %87 ile Alexnet mimarisinde elde edilmiştir. Elde edilen karmaşıklık matrisleri Tablo 6'da verilmiştir.

Tablo 6. ESA mimarilerinin sınıflandırıcılara verildikten sonraki karmaşık matrisleri

Alexnet + SVM						Googlenet + SVM							
Doğru Sınıf	1	665	42	21	21	25	Doğru Sınıf	1	651	53	13	25	22
	2	32	957	7	42	14		2	34	965	7	30	16
	3	15	6	654	10	99		3	13	1	662	10	98
	4	16	33	10	652	22		4	20	22	8	666	17
	5	16	13	95	21	839		5	14	18	90	18	844
			1	2	3	4		5			1	2	3
Tahmini Sınıf						Tahmini Sınıf							
Shufflenet + SVM						Efficientnetb0 + SVM							
Doğru Sınıf	1	664	46	15	15	24	Doğru Sınıf	1	686	33	12	16	17
	2	36	976	8	17	15		2	28	994	5	16	9
	3	9	6	685	10	74		3	8	8	706	6	58
	4	11	27	16	661	18		4	7	22	8	683	13
	5	12	15	78	14	865		5	8	13	46	10	907
			1	2	3	4		5			1	2	3
Tahmini Sınıf						Tahmini Sınıf							
Resnet50 + SVM						Inceptionv3 + SVM							
Doğru Sınıf	1	676	40	11	16	21	Doğru Sınıf	1	677	34	12	25	16
	2	28	985	6	17	16		2	17	980	4	27	24
	3	7	5	705	10	57		3	7	6	671	23	77
	4	7	24	13	679	10		4	12	21	20	658	22
	5	10	15	64	18	877		5	7	12	66	15	884
			1	2	3	4		5			1	2	3
Tahmini Sınıf						Tahmini Sınıf							

Çalışmada kullanılan 6 farklı ESA mimarisinden elde edilen özellik haritaları optimize edildikten sonra DVM sınıflandırıcısında sınıflandırılmıştır. En yüksek doğruluk değeri Inceptionv3 mimarisinde elde edilmiştir. Bu mimaride toplam 4317 tane çiçek görüntüsünden 3870 tanesi doğru tahmin edilirken, 447 tanesi ise model tarafından yanlış tahmin edilmiştir. Son olarak Tablo 6'da en yüksek doğruluk değerine ulaşan ve koyu olarak gösterilen 3 mimariden elde edilen özellik haritaları birleştirilmiştir. Her bir mimaride elde edilen özellik haritasının boyutu 4317 x 1000 iken, birleştirme işleminden sonra elde edilen özellik haritasının boyutu 4317 x 3000'dir. Daha sonra elde edilen özellik haritasının boyutu KBA yöntemi ile optimize edildikten sonra elde edilen yeni boyut 4317 x 187 olmuştur. Önerilen modelin doğruluk değeri %93,49 elde edilmiştir. Önerilen modelde elde edilen karmaşıklık matrisi Tablo 7'de gösterilmektedir.

Tablo 7. Önerilen modelin karmaşıklık matrisi

Doğru Sınıf	1	699	34	9	10	12
	2	8	1015	2	11	16
	3	7	1	718	6	52
	4	6	17	8	692	10
	5	5	11	43	13	912
		1	2	3	4	5
		Tahmini Sınıf				

Önermiş olduğumuz model 4317 çiçek görüntüsünden 4036 tanesini doğru sınıflandırırken 281 tanesini yanlış sınıflandırmıştır. Önermiş olduğumuz modelde elde edilen ortalama doğruluk değeri %93,49 olmuştur. Elde edilen bu ortalama doğruluk değeri önerilen modelin, deneyler esnasında kullanılan standart ESA mimarilerinin üretmiş olduğu doğruluk değerlerinden yüksektir. Modelimizde elde edilen performans değerlendirme ölçütleri Tablo 8'de gösterilmektedir.

Tablo 8. Önerilen modelin performans değerlendirilmesi

	Doğruluk	Duyarlılık	Özgünlük	F Ölçütü
Papatya	91,49	96,41	98,19	93,28
Karahindiba	96,48	94,16	98,85	95,30
Gül	91,58	92,05	98,13	91,81
Ayçiçeği	94,41	94,54	98,85	94,47
Lale	92,68	91,02	97,82	91,84

4. Tartışma

Çiçek sınıflandırma işlemleri, geleneksel olarak insanlar tarafından göz yardımıyla sınıflandırılması işlemleri gerçekleştirilirken çiçek sayısının çok fazla olması, görüntünün yeterince net olmaması, işlemlerin çok zaman alması ve yeterince uzmanın bulunmaması gibi birçok sorunla karşılaşmaktadır. Bir diğer sorun ise çiçeğe ait yaprak, diken, dal gibi elemanların sınıflandırma başarımını olumsuz etkilemesidir.

Günümüzde teknolojinin gelişmesi ile birlikte çiçek görüntülerinin sınıflandırma işlemleri, bilinmeyen çiçek türlerinin ortaya çıkarılmasında ya da bilinen bir çok çiçek türüne ait bir çok çiçek görüntüsü içinden bir birine çok benzeyen çiçeklerin göz yanılması gibi durumlardan etkilenmeyerek geleneksel yöntemlere kıyasla çok daha kısa sürede ve daha yüksek başarımla yapay zeka yöntemleri kullanılarak gerçekleştirilmektedir. Deneyler esnasında kullanılan veri setini kullanan diğer çalışmalar Tablo 9'da gösterilmektedir.

Tablo 9. Deneysel çalışmalarda aynı veri kümesini kullanan bilimsel çalışmalar

Akademik çalışma	Kullanılan Metot	Doğruluk (%)
Guo ve ark. [23]	ESA, Genetik algoritma	74,34
Luus ve ark. [24]	ESA, Boyut indirgeme, Yarı denetimli öğrenme	79,33
Toğaçar ve ark. [25]	ESA, Özellik seçim yöntemi	91,10
Önerilen yöntem	ESA, KBA	93,49

Önermiş olduğumuz yöntemi, bizim bildiğimiz kadarıyla, aynı veri kümesini kullanan diğer çalışmalar ile karşılaştırmasını Tablo 9’da gösterilmektedir. Tablo 9 incelendiğinde önermiş olduğumuz metodun, en yüksek başarımla elde eden çalışmadan yaklaşık olarak %2,39 daha yüksek başarımla çiçek görüntülerini sınıflandırdığı görülmektedir.

5. Sonuçlar

Derin öğrenme yöntemleri günümüzde görüntü işleme ve sınıflandırma uygulamalarında yoğun bir şekilde kullanılmaktadır. Çiçek görüntülerinin derin öğrenme yöntemleri kullanılarak sınıflandırılmasına olan gereksinim son yıllarda giderek artmış durumdadır. Yapılan bu çalışmada 4317 adet çiçek görüntüsünden oluşan 5 adet çiçek sınıfını bünyesinde ihtiva eden halka açık veri kümesi kullanılarak derin öğrenme yöntemleri ve özellik seçim metotları birlikte kullanılarak sınıflandırma uygulaması gerçekleştirilmiştir. Önerilen modelin doğruluğu %93,49’dur.

Gerçekleştirilen bu çalışmada kullanılan ESA mimarileri, KBA boyut indirgeme yöntemi ve DVM sınıflandırıcısı çiçek görüntüleri üzerinde oldukça etkili sonuçlar göstermiştir. Kullanılan bu mimariler ve yöntemler insan hastalıklarının tespit ve teşhisinde de etkili bir şekilde kullanılabilir.

Yapılan bu çalışma göstermiştir ki, bir görüntüye ait tüm özellikler kullanılarak gerçekleştirilen sınıflandırma işlemi yapmak yerine çok daha az sayıda nitelikli özellik seçilerek daha iyi başarımla gösteren sınıflandırma işlemi gerçekleştirilebilmektedir. İleriki çalışmalarda daha başarılı sonuçları elde etmemize olanak sağlayacak olan hem derin öğrenme yöntemleri hem de özellik seçim metotları araştırılacak ve çiçek görüntülerinin sınıflandırılması uygulamalarında kullanılmaya çalışılacaktır.

Kaynaklar

- [1] Bulut, Y., Akpınar, E., Yılmaz, H. (2007). Erzurum kentinin kesme çiçek tüketim potansiyelinin belirlenmesi ve çözüm önerileri.
- [2] Sonka, M., Hlavac, V., Boyle, R. (2014). Image processing, analysis, and machine vision. Cengage Learning.
- [3] Saha, S., Sheikh, N., Banerjee, B., Pendurkar, S. (2020). Self-supervised Deep Learning for Flower Image Segmentation. In 2020 14th International Conference on Innovations in Information Technology (IIT) (pp. 126-130). IEEE.
- [4] Wang, X. A., Tang, J., Whitty, M. (2021). DeepPhenology: Estimation of apple flower phenology distributions based on deep learning. Computers and Electronics in Agriculture, 185, 106123.
- [5] Anisi, D. A. (2003). Optimal motion control of a ground vehicle (Doctoral dissertation, Master’s thesis. Royal Institute of Technology (KTH), Stockholm, Sweden).
- [6] Jacques Cohen (Ed.). 1996. Special Issue: Digital Libraries. Commun. ACM 39, 11 (Nov. 1996).
- [7] Shi, L., Li, Z., Song, D. (2019). A flower auto-recognition system based on deep learning. In IOP Conference Series: Earth and Environmental Science (Vol. 234, No. 1, p. 012088). IOP Publishing.
- [8] Jyothi, V. K., Guru, D. S., YH, S. K. (2018). Deep learning for retrieval of natural flower videos. Procedia computer science, 132, 1533-1542.
- [9] Patel, I., Patel, S. (2020). An Optimized Deep Learning Model for Flower Classification Using NAS-FPN and Faster R-CNN. International Journal of Scientific & Technology Research, 9(03), 5308-5318.
- [10] Alexander Mamaev. Flowers Recognition | Kaggle, 2 Ocak 2022, URL-7, <https://www.kaggle.com/alxmamaev/flowers-recognition>
- [11] Krizhevsky, A., Sutskever, I., Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. Advances in neural information processing systems, 25, 1097-1105.
- [12] Lu, S., Lu, Z., Zhang, Y. D. (2019). Pathological brain detection based on AlexNet and transfer learning. Journal of computational science, 30, 41-47.
- [13] Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., ... & Rabinovich, A. (2015). Going deeper with convolutions. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 1-9).

- [14] Zhang, X., Zhou, X., Lin, M., Sun, J. (2018). Shufflenet: An extremely efficient convolutional neural network for mobile devices. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 6848-6856).
- [15] Samia, B., Boudjelal, M., Lézoray, O. (2021). Skin lesion classification using convolutional neural networks based on Multi-Features Extraction. In 19th International Conference on Computer Analysis of Images and Patterns (CAIP 2021).
- [16] He, K., Zhang, X., Ren, S., Sun, J. (2016). Deep residual learning for image recognition. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 770-778).
- [17] Çinar, A., Yildirim, M. (2020). Detection of tumors on brain MRI images using the hybrid convolutional neural network architecture. Medical hypotheses, 139, 109684.
- [18] Bingol, H., Alatas, B. (2021). Classification of Brain Tumor Images using Deep Learning Methods. Turkish Journal of Science and Technology, 16(1), 137-143.
- [19] Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2016). Rethinking the inception architecture for computer vision. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 2818-2826).
- [20] Lin, C., Li, L., Luo, W., Wang, K. C., Guo, J. (2019). Transfer learning based traffic sign recognition using inception-v3 model. Periodica Polytechnica Transportation Engineering, 47(3), 242-250.
- [21] Eroglu, Y., Yildirim, M., Cinar, A. (2021). mRMR-based hybrid convolutional neural network model for classification of Alzheimer's disease on brain magnetic resonance images. International Journal of Imaging Systems and Technology.
- [22] Eroglu, Y., Yildirim, K., Çinar, A., Yildirim, M. (2021). Diagnosis and grading of vesicoureteral reflux on voiding cystourethrography images in children using a deep hybrid model. Computer Methods and Programs in Biomedicine, 210, 106369.
- [23] Guo, Hu, Wu, Peng, Wu. The Tabu_Genetic Algorithm: A Novel Method for Hyper-Parameter Optimization of Learning Algorithms, Electronics. 2019;8(5):579. URL-16, <https://www.mdpi.com/2079-9292/8/5/579>
- [24] Luus F, Khan N, Akhalwaya I. Active Learning with TensorBoard Projector. 2019;1-7. URL-17, <http://arxiv.org/abs/1901.00675>
- [25] Toğaçar, M., Ergen, B., Özyurt, F. (2020). Evrışimsel Sinir Ağı Modellerinde Özellik Seçim Yöntemlerini Kullanarak Çiçek Görüntülerinin Sınıflandırılması. Fırat Üniversitesi Mühendislik Bilimleri Dergisi, 32(1), 47-56.