

Desenleştirilmiş Karma Verilerin Transfer Öğrenme Yöntemi Kullanılarak Evrişimli Sinir Ağlarıyla Sınıflandırılması

Bahadır ELMAS¹, Elif Özge ÖZDAMAR²

^{1,2} Mimar Sinan Güzel Sanatlar Üniversitesi, Fen Edebiyat Fakültesi, İstatistik Bölümü, 34380, İstanbul, Türkiye

(Alınış / Received: 06.05.2023, Kabul / Accepted: 14.03.2024, Online Yayınlanma / Published Online: 27.04.2024)

Anahtar Kelimeler

Kategorik Değişken Kodlama,
Veri Görselleştirme,
Önceden Eğitilmiş Ağlar,
Transfer Öğrenme

Öz: Teknolojik ve bilimsel gelişmeler, farklı yapı ve boyuttaki veri setlerini görselleştirmeyi ve analiz etmeyi zorunlu hale getirmiştir. Veri görselleştirmede kullanılan grafikler hem tanımsal hem de analizleri destekleyici olarak keşifsel amaçlarla uygulanmaktadır. Grafikler, veri setlerindeki zaman, mekân, akış, ilişki, belirsizlik ve hiyerarşi gibi yapı ve olguları ortaya çıkarmak için de kullanılmaktadır. Günümüz araştırmalarında kullanılan veri setleri sadece nominal, ordinal ve / veya nümerik değişkenlerden (karma veri seti) oluşan yapısal veri setlerini içermemekte, yarı yapısal ya da yapısal olmayan veri setlerini de barındırmaktadır. Söz konusu veri setlerinde evrişimli sinir ağlarının başarısı literatürdeki birçok araştırmayla kanıtlanmıştır. Bu çalışma, yapısal veri setleri üzerinde evrişimli sinir ağlarını transfer öğrenme yöntemi ile eğiterek uygulayabilmek için bir yöntem önermektedir. Bu amaç doğrultusunda, literatürde çeşitli araştırmalarda kullanılan dokuz adet yapısal veri seti üzerinde önerilen yaklaşım uygulanarak, ağların ölçülen başarısı aynı veri setleriyle çalışılan literatürdeki diğer çalışmalarla karşılaştırılmış ve daha iyi sonuçlar elde edilmiştir.

Classification of Visualized Mixed Data with Convolutional Neural Networks Using Transfer Learning Method.

Keywords

Categorical Variable
Encoding,
Data Visualization,
Pre-Trained Networks,
Transfer Learning

Abstract: Technological and scientific advances have made it compulsory to visualize and analyze datasets of different structures and sizes. The graphics used in data visualization are applied for exploratory purposes, both in terms of definition and analysis. Graphs are also used to reveal structures and phenomena in datasets such as time, space, flow, relationships, uncertainty, and hierarchy. The datasets used in today's research not only contain structural datasets consisting of nominal, ordinary, and/or numerical variables (mixed datasets), but also contain semi-structural or non-structured data sets. Numerous studies in the literature have demonstrated the effectiveness of evolutionary neural networks in these datasets. This study suggests a method to train evolutionary neural networks to apply the transfer learning method to structural datasets. To this end, the proposed approach was applied to nine structural datasets used in various literature studies, comparing the measured success of the networks with other studies in the literature that studied the same data sets and achieving better results.

1. Giriş

Araştırmacılar için veri görselleştirme, veriyi tanımlama, analiz etme, analiz sonuçlarını ortaya koyma ve sonuçları paylaşma süreçlerinin vazgeçilmez bir unsurudur. Söz konusu süreçler boyunca grafikler; veri setindeki değişken/değişkenlerin dağılım, frekans, oran gibi

tanımsal istatistikleri ya da zaman, mekân, akış, ilişki, belirsizlik, hiyerarşi gibi olguları belirginleştirmek amacıyla kullanılmaktadır.

Günümüzdeki teknolojik ve bilimsel gelişmelerin, farklı yapı ve boyuttaki veri setlerini görselleştirmeyi ve analiz etmeyi zorunlu hale getirdiği söylenebilir. Bu gelişmeler nedeniyle veri görselleştirmeye olan ilgi

*İlgili yazar: bahadir.elmas@msgsu.edu.tr

gün geçtikçe artmaktadır. Bu ilgi; araştırmacıların, grafiklerin bahsi geçen alanlar dışında da kullanılabilmesine dair fikirler ortaya atmalarına da ışık tutmuştur. Bu bağlamda, çalışmamız karma veri setleri üzerinde görüntü sınıflandırmada dikkate değer sonuçlar üreten bir derin öğrenme yöntemi olan evrişimli sinir ağlarının uygulanması için yeni bir yaklaşım önermektedir. Araştırmamız adımları şu şekildedir: Literatürde farklı makine öğrenme algoritmaları kullanılarak sınıflandırılması yapılmış dokuz adet karma veri seti belirlenmiş ve bu veri setleri önerilen yaklaşım ile grafikler kullanılarak desenleştirilmiştir. Daha sonra elde edilen yeni görsel veri setleri kullanılarak evrişimli sinir ağları transfer öğrenme yöntemiyle eğitilmiş ve elde edilen sonuçlar, aynı karma veri setlerini kullanan literatürdeki diğer araştırmaların sonuçlarıyla karşılaştırılmıştır.

Derin öğrenme, çok büyük verilerde özelliklerin çıkarılması için kullanılan, yapay sinir ağlarından türetilmiş, çok katmanlı ve çoğu durumda klasik makine öğrenme yöntemlerinin aksine veri ön işleme gerektirmeyen bir makine öğrenmesi metodudur [1, 2]. ImageNet yarışması ile popüler hale gelen derin öğrenme; ses, görüntü, doğal dil işleme, metin ve karakter tanıma veya otonom sistemler gibi birçok alanda kullanılmaktadır [1].


Bir problemin çözümünde evrişimli sinir ağ modeli sıfırdan oluşturulabileceği gibi, transfer öğrenme yöntemi ile önceden eğitilmiş ağlar da kullanılabilir. Bir evrişimli sinir ağını tasarlamak ve eğitmek, spesifik görevler için daha iyi sonuçlar verebilir, ancak bu yöntemin dezavantajı hedeflenen sonuçlara ulaşmak için her şeyden önce büyük miktarda veri setine ve donanımsal alt yapıya ihtiyaç duyulmasıdır. Bunlara ek olarak milyonlarca eğitilmesi gereken parametreye sahip yeni bir ağ modelinin eğitimi, veri setinin büyüklüğü veya tasarlanan ağın karmaşıklığı nedeniyle oldukça uzun zaman almakta ve birçok deneysel çalışma yapılmasını gerektirmektedir. Söz konusu sorunların çözümü için literatürde transfer öğrenme olarak adlandırılan yöntem sıklıkla başvurulmaktadır. Transfer öğrenme; hızlı ilerleme ve gelişmiş performans sağlamak amacıyla, önceden eğitilmiş bir ağın benzer ikinci bir görevde yeniden tasarlandığı makine öğrenmesi tekniğidir. Geleneksel makine öğrenme teknikleri, her görevi yeniden öğrenmeye çalışırken, transfer öğrenme, önceki görevlerden öğrendikleri bilgileri yeni görevi öğrenme sürecinde kullanır [3].

Bu çalışma kapsamında; literatürde üzerinde çeşitli makine öğrenmesi yöntemleri kullanılarak çalışılan dokuz adet veri setindeki her gözlem, veri görselleştirmede en sık kullanılan sütun ve pasta grafikleri ile desenleştirilmiştir. Oluşturulan yeni görsel veri setleri ile transfer öğrenme yöntemi kullanılarak önceden eğitilmiş AlexNet [4, 5], DenseNet201 [6], ResNet50 [7, 8] ve VGG19 [8, 9] ağ mimarileri ile sınıflandırma başarısı ölçülmüştür.

Çalışmanın ilerleyen bölümleri şu şekilde düzenlenmiştir: Deneysel Metot başlıklı ikinci kısımda, evrişimli sinir ağlarının mimari yapısı, transfer öğrenme ve önerilen yöntem detaylandırılmıştır. Ayrıca kullanılan veri setleri ve literatürdeki bu veri setleri ile yapılan sınıflandırma çalışma sonuçları hakkında bilgi verilmiştir. Sonuçlar ve Tartışmalar başlıklı üçüncü bölümde araştırma sonuçları paylaşılmıştır. Dördüncü bölümde ise sonuçların değerlendirilmesi yapılmıştır.

2. Materyal ve Metot

Evrişimli sinir ağları; özellik çıkarma ve sınıflandırma olmak üzere iki ana bölümden oluşmaktadır. Özellik çıkarma bölümünün ilk katmanlardaki konvolüsyon sonuçlarında girdiye ait temel özellikler elde edilirken, sonraki katmanlarda ise belirleyici özellikler elde edilir. Bu bölümün derinliği, katman türleri ve sayısı, uygulamaya veya verilere bağlı olarak değişebilir. Sınıflandırma katmanı ise genellikle tam bağlı bir yapay sinir ağı mimarisine sahiptir [3, 10]. Evrişimli sinir ağları çoğunlukla Şekil 1'deki gibi Evrişim [11, 12], ReLU, Havuzlama ve Tam Bağlantılı katmanlardan oluşur [2, 13]. Evrişimli sinir ağları farklı mimarilere sahip olup, tasarıma göre bu katmanların sayısı ve sırası değişiklik gösterir.



Şekil 1. Evrişimli Sinir Ağ

Evrişim katmanındaki yapılan işlem; girdinin özellik çıkarımını amaçlayan maskeler ile filtrelenmesidir [14]. Evrişim sonucunda yatay, dikey, açısız, yumuşatılmış ya da keskinleştirilmiş kenarlar bulunarak, orijinali ile aynı boyuttaki örüntü türevleri elde edilir. Tasarlanan ağlarda genellikle transfer fonksiyonu olarak ReLU tercih edilmektedir. Bu fonksiyonun özelliği, örüntüdeki negatif değerleri sıfıra çekmesidir. Havuzlama katmanında ise, boyut düşürme fonksiyonları kullanılarak öğrenilen özelliklerin özet bilgisi sonraki katmanlara aktarılır. Bu amaçla maksimum, minimum veya ortalama gibi lokal matrislerle görüntü yeniden örneklenir. Böylelikle girdinin boyutu azaltılır ve hesaplama maliyeti düşürülür [10, 15]. Söz konusu katmanlarda yapılan işlemler sonucunda elde edilen özellikler tek boyutlu vektör haline getirilerek tam bağlantılı katmanlarda sınıflandırma işlemi gerçekleştirilir. Ağın sınıflandırma performansı, bir kayıp fonksiyonu ile hesaplanarak, filtreler ve ağırlıklar geri yayılımla kayıp değerine göre güncellenir.

Bu çalışmada kullanılan AlexNet, DenseNet201, ResNet50 ve VGG19 ağları olup, söz konusu ağlara ait katman, derinlik, parametre sayısı, görüntü giriş

boyutu ve ağ mimarileri bilgileri Tablo 1'de verilmiştir.

Tablo 1. Ağ mimarileri

	AlexNet	DenseNet201	ResNet-50	VGG19
Derinlik	8	201	50	19
Katman	25	709	177	47
Parametre(Milyon)	61	20	25,6	144
Gör.Giriş Boyutu	227x227	224x224	224x224	224x224
Mimari	11x11conv, 96 max-pooling 5x5 conv, 256 max-pooling 3x3 conv, 384 3x3 conv, 384 3x3 conv, 256 max-pooling fc4096 fc4096 fc1000 softmax	7x7 conv max-pooling 1x1 conv x6 3x3 conv 1x1 conv avg-pooling 1x1 conv x12 3x3 conv 1x1, conv avg-pooling 1x1 conv x48 3x3 conv 1x1 conv avg-pooling 1x1 conv x32 3x3 conv avg-pooling fc1000,softmax	7x7 conv, 64 max-pooling 1x1 conv, 64 3x3 conv, 64 1x1 conv, 256 1x1 conv, 128 3x3 conv, 128 1x1 conv, 512 1x1 conv, 256 3x3 conv, 256 1x1 conv, 1x1 conv, 512 3x3 conv, 512 1x1 conv, avg-pooling fc1000 softmax	[3x3 conv,64] x2 max-pooling [3x3 conv, 128] x2 max-pooling [3x3 conv, 256] x4 max-pooling [3x3 conv, 512] x4 max-pooling [3x3 conv, 512] x4 max-pooling fc4096 fc4096 fc1000 softmax

Çalışmamızda sıfırdan bir evrişimli ağ modeli geliştirmek ve eğitmek yerine transfer öğrenme yöntemi tercih edilmiştir. Araştırmalar, büyük görüntü verilerinden öğrenilen özelliklerin, çeşitli görüntü tanıma görevlerine yüksek oranda aktarılabilir olduğunu göstermiştir. Daha önceki görevlerinde yüksek performans gösteren bir modelin, benzer görevler için de iyi performans göstermesi beklenir. Ancak bu durum, düşük performans gösteren bir modelin başka bir görevde yüksek performans göstermeyeceği anlamına gelmez. Literatürde transfer öğrenme uygulamalarında farklı durumlar için çeşitli stratejiler önerilmiştir:

Uygulamada transfer öğrenme için kullanılacak ağın belirlenmesi sürecinde, basit ağların seçilmesi durumunda hızlı yineleme gerçekleşir. Böylelikle farklı veri ön işleme adımları ve eğitim seçenekleri denenebilir. Basit bir ağda en uygun ayarlar belirlendikten sonra sonuçları daha da iyileştirmek amacıyla daha büyük ağlara geçmek doğru bir yaklaşım olacaktır [3].

Mevcut veri setinin kaynak veri setinden çok küçük ve benzer olması durumunda evrişimli sinir ağı üzerinde ince ayar yapılması ağın aşırı öğrenmesine neden olabilir. Bu nedenle ağın yüksek seviyeli özelliklerini korumak için giriş ve ara katmanlar değiştirilmemelidir [3]. Tam bağlantılı katman ise probleme uygun şekilde tasarlanarak ağ ağırlıkları

rastgele seçilmez. Daha sonra ise mevcut veri setiyle eğitim gerçekleştirilmelidir [16]. Ağ eğitimi sırasında, korunmuş katmanlara ait parametreler güncellenmeyeceği için eğitim önemli ölçüde hızlanır.

Mevcut veri setinin kaynak veri setinden çok küçük ve farklı olması durumunda ise, ağın giriş ve ara katman parametreleri önemlerini yitireceği için söz konusu katmanlar yeniden düzenlenmelidir. Benzer şekilde tam bağlantılı katmanlar da düzenlenerek ağ ağırlıkları rastgele verilmelidir. Yapılan düzenlemelerden sonra, aşırı öğrenme probleminin önüne geçebilmek için sadece ağa yeni eklenen ve düzenlenen katmanların ağırlıklar eğitilmelidir [3].

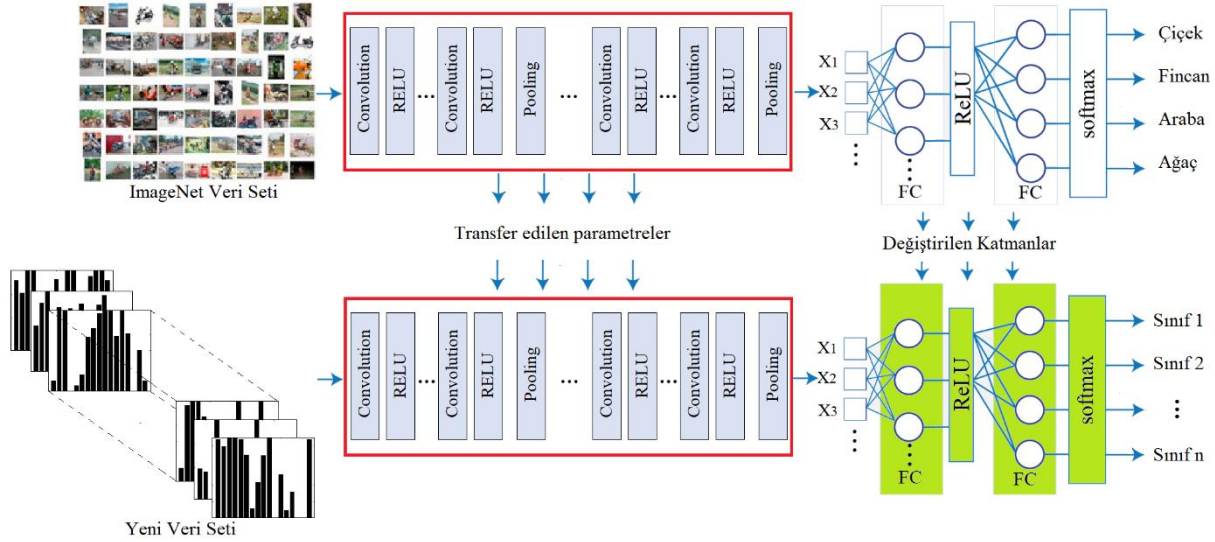
Bir modeli sıfırdan eğitmek için yeterli verinin olması durumunda, görevler farklı olsa bile, yeni bir ağ tasarlayarak parametreleri rasgele başlatmaktansa, önceden eğitilmiş bir ağı kullanmak daha iyi sonuçlar verebilir. Böyle bir durumda ağın son tam bağlantılı katmanı çıkarılır ve yerine probleme ilişkin sınıf sayısına uygun yeni bir tam bağlantılı katman eklenir [3].

Sıfırdan tasarlanmış bir ağın veri seti yetersiz ve problemlidir ise, ağ mevcut veri ile eğitilmeden önce genel bir görev için hazırlanmış büyük bir veri setiyle eğitilebilir. Böylece parametrelerin başlangıç değerleri aktarılmış olur. Bu yaklaşım ağın öğrenmede iyi bir başlangıç yapmasını ve daha yüksek performans elde etmesini sağlar.

Bir başka durum ise; transfer işleminin gerçekleştirileceği modellerin mimari uyumsuzluğudur. Söz konusu durumlar için bilgi aktarımının sağlanacağı yöntem ise damıtmadır. Damıtma; yeni modelin, önceden eğitilmiş modelin çıktılarını taklit edecek şekilde eğitilmesidir. Bu

yaklaşımında dikkat edilmesi gereken, yeni modelin kaynak modelden daha küçük olmasıdır.

Çalışmamızda Şekil 2’de verilen ve en yaygın transfer öğrenme yöntemi olan tam bağlı katman dışındaki tüm katmanların aktarıldığı yöntem tercih edilmiştir.



Şekil 2. Transfer Öğrenme.

Evrişimli sinir ağlarının desen sınıflandırmadaki performansı, literatürde birçok kez farklı veri setleri üzerinde sınanmış ve başarısı kabul görmüştür. Bu çalışma, evrişimli sinir ağlarının bu alandaki bilinen başarısını, desen içermeyen veri setleri üzerinde de araştırmayı amaçlamaktadır. Bu amaç doğrultusunda, öncelikle veri setlerinin desene dönüştürme işleminin gerçekleştirilmesi gerekmektedir. Bu işlem, veri setleri farklı sayılarda nominal, ordinal ve veya nümerik değişken barındırabileceğinden, bir tür standartlaştırma yani kodlanarak nümerik hale dönüştürülmesinden sonra gerçekleştirilmesi gerekir. Bu kodlama yöntemi, Tablo 2’de verilen temsili bir veri seti üzerinde aşamalarıyla açıklanmıştır.

Tablo 2. Örnek veri seti

A	B	C	D	E	Sınıf
Aşağı	Kadın	[40-50]	Normal	150	3
Sabit	Kadın	[50-60]	Yok	50	1
Yukarı	Erkek	[20-30]	Normal	100	1
Sabit	Kadın	[20-30]	< 25	180	1
Sabit	Kadın	[0-10]	Yok	90	2
Yok	Kadın	[10-20]	> 75	230	2
Yok	Erkek	[0-10]	> 75	150	3

Örnek veri setini kodlayarak nümerik hale getirebilmek için öncelikle Tablo 3’teki gibi nominal ve ordinal değişkenlere atanacak kod değerleri belirlenir. Bu değerler önem ve sıra gözetmeksizin 1’den başlayarak oluşturulur.

Tablo 3. Veri seti referans tablosu

A		B		C		D	
Yok	1	Erkek	1	[0-10]	1	Yok	1
Sabit	2	Kadın	2	[10-20]	2	Normal	2
Aşağı	3			[20-30]	3	< 25	3
Yukarı	4			[30-40]	4	> 75	4
				[40-50]	5		
				[50-60]	6		

Bir sonraki aşamada, kodlama tablosundan hareketle, veri setindeki tüm nominal ve ordinal değişkenler belirlenen kod değerleri ile değiştirilir. Veri setinin nümerik değerlerinden oluşan sütunlarına ise (E sütunu gibi) müdahale edilmez. Bu sürecin sonunda Tablo 3’teki temsili veri seti Tablo 4’deki gibi nümerik hale dönüştürülmüş olur.

Tablo 4. Nümerik hale dönüştürülmüş veri seti

A	B	C	D	E	Sınıf
3	2	5	2	150	3
2	2	6	1	50	1
4	1	3	2	100	1
2	2	3	3	180	1
2	2	1	1	90	2
1	2	2	4	230	2
1	1	1	4	150	3


Veri setindeki tüm değişkenlerin nümerik olarak kodlanmasından sonra, değerleri birimden bağımsızlaştırmak, yani değeri birbirinden çok uzak olabilecek olan değişkenleri aynı değer aralığına (0-1)

indirmek amacıyla Tablo 5'teki gibi min-max normalizasyon işlemi gerçekleştirilir.

Tablo 5. Normalize edilmiş veri seti

A	B	C	D	E	Sınıf
0,67	1,00	0,80	0,33	0,56	3
0,33	1,00	1,00	0,00	0,00	1
1,00	0,00	0,40	0,33	0,28	1
0,33	1,00	0,40	0,67	0,72	1
0,33	1,00	0,00	0,00	0,22	2
0,00	1,00	0,20	1,00	1,00	2
0,00	0,00	0,00	1,00	0,56	3

Yukarıda bahsedilen aşamalardan sonra bütün veri seti, sınıflama değişkeni hariç 0 – 1 aralığına çekilmiş olur ve desenleştirme işlemine uygun hale gelir. Desenleştirme; veri setindeki her satır için bir grafik çizilerek, gözlem sayısı kadar grafikten oluşan yeni bir veri seti elde edilme işlemidir. Bu çalışma; desenleştirme işleminin sınıflandırmada performansını araştırdığından, birbirinden farklı grafikler kullanılarak desenleştirme işlemi gerçekleştirilmiş ve böylelikle aynı nümerik veri seti için farklı desen veri setleri oluşturularak incelenmiştir. Bahsi geçen veri setlerinde kullanılan grafik türleri, veri görselleştirmede en sık kullanılan çubuk ve pasta grafikleri olarak belirlenmiştir. Kullanılan grafikler sırasıyla, eksen ve etiket bilgilerinden arındırılmış Şekil 3'te gösterildiği gibi siyah dolgulu çubuk grafik, renkli dolgulu çubuk grafik ve renkli pasta grafikleridir.



Şekil 3. Çalışmada kullanılan çubuk ve pasta grafikleri

Tablo 6. Üzerinde çalışılan veri setleri

No	Adı	Satır x Sütun Sayısı	Sınıf Sayısı	Çizilen Toplam Grafik Sayısı	Veri Kaynağı
1	Dry Bean Dataset	13611 x 16	7	13611	[17]
2	Durum Wheat Dataset	9000 x 236	3	9000	[18]
3	Early Stage Diabetes Risk Prediction	520 x 16	2	520	[19]
4	Human Stress Detection	2001 x 3	3	2001	[20]
5	Mushroom Classification	8124 x 22	2	8124	[21]
6	Pistachio Image Dataset	2148 x 28	2	2148	[22]
7	Pumpkin Seeds Dataset	2500 x 12	2	2500	[23]
8	Raisin Dataset	900 x 7	2	900	[24]
9	Rice Dataset Cammeo and Osmancık	3810 x 7	2	3810	[25]

3. Bulgular

Sinir ağlarında, analizi yapılacak veri seti, eğitim ve doğrulama olmak üzere iki gruba ayrılarak, ağı eğitimi ve başarımlar ölçümü bu iki farklı veri seti üzerinde gerçekleştirilir. Ağı başarı oranı; belirlenen

Bu grafikler belirlenirken şu kıstaslar göz önünde bulundurulmuştur:

- Öncelikle veri görselleştirmede en sık kullanılan grafiklerden biri olan çubuk grafik desen veri setini oluşturmak için tercih edilmiştir. Desenlerdeki grafik alanın arka zeminini beyaz, zemin ile kontrast oluşturması için çubuk dolgu rengi ise siyah olarak belirlenmiştir. Grafik alan üzerinde çerçeve, eksen ve etiket bilgileri kullanılmamıştır.
- Evrişimli Sinir Ağlarının desen sınıflandırmadaki başarısı üzerinde, desen üzerindeki şekiller ve şekillerin konumu kadar, şekillerin renklerinin de etkili olduğu bilinmektedir. Bu nedenle desen veri seti oluşturulurken renklendirilmiş dolgulu çubuk grafik kullanılmıştır. Çubukların renklendirmesi, her değişkene farklı bir renk atanarak gerçekleştirilmiştir.
- Veri görselleştirmede en sık kullanılan diğer bir tür olan pasta grafik ile desen veri setini oluşturulmuştur. Pasta grafikte dilimlerin renklendirilmesinde, çubuk grafikteki aynı değişken renk kodları kullanılmıştır.

Söz konusu grafikler kullanılarak, literatürde üzerinde farklı sınıflandırma yöntemleri denenmiş Tablo 6'da nitelikleri sunulan 9 farklı veri seti için desen veri setleri oluşturulmuştur. Bu veri setleri üzerinde, AlexNet, DenseNet201, ResNet50 ve VGG19 ağları kullanılarak transfer öğrenme yöntemi ile sınıflandırma gerçekleştirilmiş ve elde edilen sonuçlar, kullanılan veri setlerine ait çalışmalarındaki sonuçlarla karşılaştırılmıştır.

eğitim ve doğrulama setlerine bağlı olarak değişkenlik göstereceği için; veri setinin bu iki grup tarafından en iyi şekilde temsil edilmesi ve sistematik hatanın mümkün olduğunca önüne geçilmesi amacıyla literatürde yeniden örnekleme adı altında çeşitli yöntemler geliştirilmiştir. Bu çalışmada literatürde


yaygın olarak kullanılan Stratified Shuffle Split ve K-fold Cross Validation yöntemleri kullanılmıştır [26, 27, 28, 29]. Her iki yöntem de 10'ar kere tekrarlanarak ağlar eğitilmiştir. İlk yöntemde, her tekrar için veri setinin rastgele olarak %90'ı eğitim, %10'u ise doğrulama amaçlı kullanılmıştır. İkinci yöntemde ise; ilk önce veri seti 10 parçaya ayrılmış, ağ ilk 9 parça veriyle eğitilerek, kalan veri doğrulama için kullanılmıştır. Daha sonraki tekrarlarında, sırasıyla parçalar kaydırılarak, bütün veri setinin hem eğitim hem de doğrulanma için kullanılması sağlanmıştır. Her iki yöntemde elde edilen sonuçlar karşılaştırıldığında değerlerin çok yakın oldukları saptanmıştır. Bu nedenle çalışma sonuçlarında bu iki yöntem ile elde edilen değerlerin ortalamaları sunulmuştur.

Bu çalışmada önerilen yöntem; Tablo 6'da verilen 9 farklı veri seti üzerinde test edilmiştir. Veri setleri kodlandıktan sonra desenleştirilerek oluşturulan grafiklerin yukarıda anlatılan iki yöntemle AlexNet, DenseNet201, ResNet50 ve VGG19 evrişimli sinir ağları transfer öğrenme yöntemi kullanılarak eğitilmiş, ardından ağların başarısı ölçülmüştür. Şekil 3'te gösterildiği gibi, desenleştirmede siyah dolgulu çubuk grafik, renkli çubuk grafik ve renkli pasta grafikler kullanılmıştır. Veri setlerinin analizinde her iki yeniden örnekleme yöntemi kullanılarak eğitilen ağların, grafik çeşitlerine göre başarı oranları Tablo 7'de gösterilmiştir. Tablodaki her bir veri seti için çalışma kapsamındaki sonuçlar, her iki yöntemle ağların 10'ar kez eğitilmesi sonucu elde edilen test sonuçlarının ortalama değerleridir.

Tablo 7. Çalışma kapsamındaki sonuçlar

Veri Setleri	Siyah Dolgulu Çubuk Grafiği				Renkli Dolgulu Çubuk Grafiği				Renkli Dolgulu Pasta Grafiği			
	AlexNet	DenseNet201	ResNet-50	VGG19	AlexNet	DenseNet201	ResNet-50	VGG19	AlexNet	DenseNet201	ResNet-50	VGG19
1 Dry Bean Dataset	92,36	92,64	91,92	92,8	91,7	94,34	92,42	92,36	88,52	91,48	88,85	87,97
2 Durum Wheat Dataset	92,76	94,89	92,56	92,36	93,33	95,89	94,4	92,02	89,56	93,18	90,31	88,86
3 Early Stage Diab. Risk Pre.	89	91,5	93,6	91,5	92,5	98,5	93,7	92,8	88	90	89,1	88,6
4 Human Stress Detection	99,73	100	99,47	100	100	100	100	100	55,6	61,33	58,27	56,27
5 Mushroom Classification	97,02	99,52	98,64	98,44	98,16	99,85	99,27	98,14	91,79	96,25	90,48	90,2
6 Pistachio Image Dataset	84,89	89,02	87,5	87,39	89,53	93,11	92,19	89,28	81,96	86,85	80	80,11
7 Pumpkin Seeds Dataset	87,17	86,75	88	87,25	87,33	89,33	88,08	89,5	86,25	86,83	86,33	82,92
8 Raisin Dataset	86,89	85,33	84,44	82,89	87,78	90,22	88,22	87,1	89,33	89,11	88	87,11
9 Rice Dat. Camm. and Osm.	92,09	92,15	91,84	91,04	91,26	92,64	93,25	92,78	92,09	92,21	93,37	91,1

Tablo 7'de bulunan her veri seti için, kullanılan grafik türüne göre en başarılı ağ sonucu Şekil 4'te görselleştirilmiştir.



Şekil 4 Veri Setleri-Ağ Başarı Oranı

Şekil 4'te verilen grafikte ifade edildiği gibi renkli dolgulu çubuk grafikte desenleştirmenin başarısı, siyah dolgulu çubuk ve renkli pasta grafiğe göre daha yüksektir. Bunun nedeni hem çubuk yüksekliğinin hem de çubuk renklerinin görsel kodlama açısından bilgi içermesidir. Siyah dolgulu çubuk grafik tek renkten oluşup, renklere dayalı bir farklılık bilgisi içermemekte, sadece yüksekliğe dayalı görsel kodlama bilgisi barındırmaktadır. Renkli pasta grafik ise hem renk hem de alan bilgisi ile kodlanmış fakat renkli dolgu çubuk grafik kadar başarılı sonuçlar vermemiştir. Bunun nedenini şu şekilde açıklayabiliriz: Veri setinde değişken sayısı arttıkça,

renk skalasında birbirine daha yakın renklerin kullanılması zorunlu hale gelmektedir. Çubuk grafikte kartezyen koordinat sistemi kullanıldığından ve çubuklar arasındaki boş alanın değişkenler açısından ayırt edici bir özellik sağlaması nedeniyle, değişken sayısının artması pasta grafiğe kıyasla başarıyı etkilememektedir.

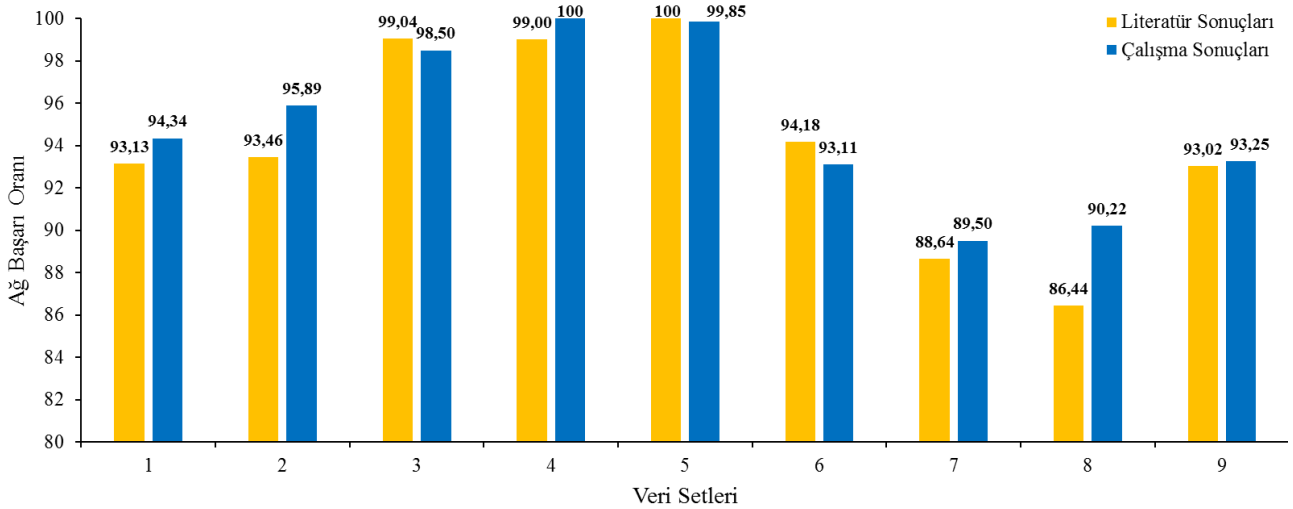
En başarılı sınıflandırma sonuçlarını veren renkli çubuk grafik değerleri ile üzerinde çalıştığımız kaynak veri setleri için literatürdeki diğer çalışmalarda elde edilen sonuçların karşılaştırılması Tablo 8'de verilmiştir.

Tablo 8 Çalışma-Literatür karşılaştırılması

Veri Setleri	Renkli Çubuk Grafik Çalışma Sonuçları				Literatürdeki Diğer Çalışma Sonuçları										Literatür Kaynak
	AlexNet	DenseNet201	ResNet-50	VGG19	Logistic Reg.	MLP	SVM	Decision Tree	Rand. Forest	Naive Bayes	K Near. Neigh.	ANN	XGBoost	CNN	
1 Dry Bean	91,7	94,34	92,42	92,36	-	91,73	93,13	92,52	-	-	87,92	-	-	-	[30]
2 Durum Wheat	93,33	95,89	94,4	92,02	-	-	-	-	-	-	-	93,46	-	-	[31]
3 Early Stage Diab.	92,5	98,5	93,7	92,8	-	-	94,62	95,58	97,69	88,85	89,42	92,31	97,89	99,04	[32]
4 Human Str. Det.	100	100	100	100	-	-	-	-	-	-	-	99	-	-	[33]
5 Mushroom Class.	98,16	99,85	99,27	98,14	-	-	100	-	-	95,88	-	-	-	-	[34]
6 Pistachio Image	89,53	93,11	92,19	89,28	-	-	-	-	-	-	94,18	-	-	-	[35]
7 Pumpkin Seeds	87,33	89,33	88,08	89,5	87,92	88,52	88,64	-	87,56	-	87,64	-	-	-	[36]
8 Raisin	87,78	90,22	88,22	87,1	85,22	86,33	86,44	-	-	-	-	-	-	-	[37]
9 Rice Cam. Osm.	91,26	92,64	93,25	92,78	93,02	92,86	92,83	92,49	92,39	91,71	88,58	-	-	-	[38]

Tablo 8'deki veri setine göre en başarılı sınıflandırma sonuçlarını veren evrişimli sinir ağlarının sonuçları ile literatürdeki çalışmalarda kullanılan en başarılı

yöntemlerin sonuçlarının karşılaştırılması Şekil 5'te verilen grafik ile görselleştirilmiştir.



Şekil 5. Çalışma-Literatür karşılaştırılması

Elde edilen bulgulara dayanarak, bu çalışmada önerilen karma veri setlerinin desenleştirilmesiyle

oluşturulan yeni görsel veri setlerinin transfer öğrenme yöntemiyle evrişimli sinir ağlarıyla

sınıflandırılması, literatürde kullanılan diğer yöntemlere bir alternatif olarak değerlendirilebilir.

4. Tartışma ve Sonuç

Bu çalışmada, evrişimli sinir ağlarının görüntü tanımlamadaki yüksek başarısından hareketle, karma veri setlerinin önerilen yaklaşımla desenleştirilmesinden sonra transfer öğrenme kullanılarak evrişimli sinir ağları yardımıyla yapılan sınıflandırma başarısı incelenmiştir.

Araştırmada uygulanan desenleştirme yöntemi; literatürde yaygın olarak kullanılan çubuk ve pasta grafikler ile gerçekleştirilmiştir, söz konusu grafikler açısından, görsel kodlamanın sınıflandırma başarısındaki etkisi araştırılmıştır. Kullanılan grafiğin türüne göre görsel kodlama; yükseklik, alan ve renk olmak üzere farklılaşmaktadır. Çalışma bulgularında, renkli çubuk grafik ile desenleştirmenin, diğer desenleştirmelere göre sınıflandırmada daha başarılı olduğu tespit edilmiştir. Karma veri setlerinin desenleştirilerek, transfer öğrenme yöntemi ile evrişimli sinir ağları kullanılarak sınıflandırılmasının, literatürde kullanılan diğer sınıflandırma yöntemlerine bir alternatif olabileceği ve oldukça iyi performans gösterdiği gözlemlenmiştir. Gelecekteki çalışmalarda, desenleştirmeyi daha fazla görsel kodlama içerebilecek şekilde genişletilmesi amaçlanmaktadır.

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] Dandıl, E., Polattimur, R. 2020. Dog behavior recognition and tracking based on faster R-CNN. Journal of the Faculty of Engineering and Architecture of Gazi University, 35(2), 819-834.
- [2] Yıldız, O. 2019. Melanoma detection from dermoscopy images with deep learning methods: A comprehensive study. Journal of the Faculty of Engineering and Architecture of Gazi University, 34(4), 2241-2260.
- [3] Pan, S. J., Yang, Q. 2010. A survey on transfer learning. IEEE Transactions on Knowledge and Data Engineering, 22(10), 1345-1359.
- [4] Zhou, Y., Nejati, H., Do, T. T., Cheung, N. M., Cheah, L. 2016. Image-based vehicle analysis using deep neural network: A systematic study. IEEE International Conference on Digital Signal Processing, 16-18 October, Beijing, 276-280.

- [5] Krizhevsky, A., Sutskever, I., Hinton, G. E. 2012. ImageNet classification with deep convolutional neural networks. NIPS'12: Proceedings of the 25th International Conference on Neural Information Processing Systems, 3-6 December, Nevada, 1097-1105.
- [6] Huang, G., Liu, Z., Maaten, L. V. D., Weinberger, K. Q. 2018. Densely connected convolutional networks. IEEE Conference on Computer Vision and Pattern Recognition, 21-26 July, Honolulu, 4700-4708.
- [7] He, K., Zhang, X., Ren, S., Sun, J. 2016. Deep Residual Learning for Image Recognition. IEEE Conference on Computer Vision and Pattern Recognition, 27-30 June, Las Vegas, 770-778.
- [8] Theckedath, D., Sedamkar, R. R. 2020. Detecting affect states using VGG16, ResNet50 and SE-ResNet50 networks. Springer Nature Computer Science, 79, 1-7.
- [9] Ye, H., Han, H., Zhu, L., Duan, Q. 2019. Vegetable pest image recognition method based on improved VGG convolution neural network. Journal of Physics: Conference Series, 1237(3).
- [10] Fırıldak, K., Talu, M. F. 2019. Evrişimsel sinir ağlarında kullanılan transfer öğrenme yaklaşımlarının incelenmesi. Anatolian Journal of Computer Science, 4(2), 88-95.
- [11] Lawrence, S., Giles, C. L., Tsoi, A. C., Back, A. D. 1997. Face recognition: A convolutional neural-network approach. IEEE Transactions on Neural Networks, 8(1), 98-113.
- [12] MathWorks. 2019. Learn About Convolutional Neural Networks. <https://www.mathworks.com/help/deeplearni ng/ug/introduction-to-convolutional-neural-networks.html> (Erişim Tarihi: 06.05.2023).
- [13] Baykal, E., Doğan, H., Ercin, M. E., Ersoz, S., Ekinci, M. 2019. Transfer learning with pre-trained deep convolutional neural networks for serous cell classification. Multimedia Tools and Applications, 79, 15593-15611.
- [14] Karabulut, E. M. 2016. Investigation of deep learning approaches for biomedical data classification. Çukurova Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, 108s, Adana.
- [15] Goodfellow, I., Bengio, Y. 2016. Courville A., Deep Learning. Massachusetts Institute of Technology Press, Londra, 800s.
- [16] Machine Learning Mastery. 2017. A Gentle Introduction to Transfer Learning for Deep Learning. <https://machinelearningmastery.com/transfer-learning-for-deep-learning/> (Erişim Tarihi: 06.05.2023).

- [17] Kaggle. 2020. Dry Bean Dataset. <https://www.kaggle.com/c/dry-beans-classification-iti-ai-pro-intake01>. (Erişim Tarihi: 22.06.2022).
- [18] Koklu, M. 2020. Durum Wheat Dataset. <https://www.kaggle.com/datasets/muratkoklu/dataset/durum-wheat-dataset>. (Erişim Tarihi: 22.06.2022).
- [19] UC Irvine Machine Learning Repository. 2020. Early Stage Diabetes Risk Prediction. <https://archive-beta.ics.uci.edu/ml/datasets/early+stage+diabetes+risk+prediction+dataset>. (Erişim Tarihi: 22.06.2022).
- [20] Rachakonda, L. 2020. Human Stress Detection. <https://www.kaggle.com/datasets/laavanya/stress-level-detection>. (Erişim Tarihi: 22.06.2022).
- [21] UCI Machine Learning. 2020. Mushroom Classification, <https://www.kaggle.com/datasets/uciml/mushroom-classification>. (Erişim Tarihi: 22.06.2022).
- [22] Koklu, M. 2020. Pistachio Image Dataset. <https://www.kaggle.com/datasets/muratkoklu/dataset/pistachio-image-dataset>. (Erişim Tarihi: 22.06.2022).
- [23] Koklu, M. 2020. Pumpkin Seeds Dataset. <https://www.kaggle.com/datasets/muratkoklu/dataset/pumpkin-seeds-dataset>. (Erişim Tarihi: 22.06.2022).
- [24] Koklu, M. 2020. Raisin Dataset. <https://www.kaggle.com/datasets/muratkoklu/dataset/raisin-dataset>. (Erişim Tarihi: 22.06.2022).
- [25] Koklu, M. 2020. Rice Dataset Cammeo and Osmancik. <https://www.kaggle.com/datasets/muratkoklu/dataset/rice-dataset-commeo-and-osmancik>. (Erişim Tarihi: 22.06.2022).
- [26] Chollet, F. 2017. Deep Learning with Python. Manning Publications, New York, 384s.
- [27] Kaggle. 2019. Stratified Shuffle Split working with less data. <https://www.kaggle.com/viswanathanc/stratifiedshufflesplit-working-with-less-data>. (Erişim Tarihi: 22.06.2022).
- [28] Medium. 2020. StratifiedKFold v.s KFold v.s. <https://xzz201920.medium.com/stratifiedkfold-v-s-kfold-v-s-stratifiedshufflesplit-ffcae5bdfd>. (Erişim Tarihi: 12.10.2020).
- [29] Github. 2019. Cross-Validation: Why and how to do it. <https://srikarvaka.github.io/model-evaluation/Cross-validation/>. (Erişim Tarihi: 22.06.2022).
- [30] Koklu, M., Ozkan, I. A. 2020. Multiclass classification of dry beans using computer vision and machine learning techniques. *Computers and Electronics in Agriculture*, 174, 105507.
- [31] Kaya, E., Saritas, İ. 2019. Towards a real-time sorting system: Identification of vitreous durum wheat kernels using ANN based on their morphological, colour, wavelet and gaborlet features. *Computers and Electronics in Agriculture*. 166, 105016.
- [32] Ergün, Ö. N., İlhan, H. O. 2021. Early stage diabetes prediction using machine learning methods. *European Journal of Science and Technology Special*, 29, 52-57.
- [33] Rachakonda, L., Mohanty, S. P., Kougianos, E., Sundaravadivel, P. 2019. Stress-Lysis: A DNN-Integrated edge device for stress level detection in the IoMT. *IEEE Transactions on Consumer Electronics*, 65(4), 474-483.
- [34] Wibowo, A., Rahayu, Y., Riyanto, A., Hidayatulloh, T. 2018. Classification algorithm for edible mushroom identification. *International Conference on Information and Communications Technology (ICOIACT)*, 06-07 March, Yogyakarta, 250-253.
- [35] Ozkan, I. A., Koklu, M., Saraçoğlu, R. 2021. Classification of Pistachio Species Using Improved k-NN Classifier. *Progress in Nutrition*, 23(2), e2021044.
- [36] Koklu, M., Sarigil, S., Ozbek, O. 2021. The use of machine learning methods in classification of pumpkin seeds (*Cucurbita pepo* L.). *Genetic Resources and Crop Evolution*, 68(1), 2713-2726.
- [37] Cinar, I., Koklu, M., Tasdemir, S. 2020. Classification of raisin grains using machine vision and artificial intelligence methods. *Gazi Mühendislik Bilimleri Dergisi*, 6(3), 200-209.
- [38] Cinar, I., Koklu, M. 2019. Classification of rice varieties using artificial intelligence methods. *International Journal of Intelligent Systems and Applications in Engineering*, 7(3), 188-194.