

Atf İçin: Şener A, Ergen B, 2022. Yoğun Evrişimli Sinir Ağı ile Gökyüzü Görüntülerinden Hava Durumu Tespiti. İğdır Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 12(3): 1238 - 1249.

To Cite: Şener A, Ergen B, 2022. Weather Detection from Sky Images with Dense Convolutional Neural Network. Journal of the Institute of Science and Technology, 12(3): 1238 - 1249.

Yoğun Evrişimli Sinir Ağı ile Gökyüzü Görüntülerinden Hava Durumu Tespiti

Abdullah ŞENER^{*1}, Burhan ERGEN²

ÖZET: Hava durumu koşulları değiştirilemez bir yapı olarak karşımıza çıkmaktadır. Ancak hava koşullarının tespit edilip belirlenmesi bireylerin fiziksel aktivitelerini planlamasında yardımcı olabilmektedir. Yapılan çalışmada farklı gökyüzü görüntüleri ile hava durumu tespiti işlemlerini son yıllarda bilgisayar alanında popüler çalışma konularından biri olan görüntü sınıflandırma yöntemleriyle gerçekleştirilmeye çalışılmıştır. Çalışmada farklı hava koşullarına ve çözünürlüklere sahip görüntüden oluşan veri seti kullanılmıştır. Çeşitli veri artırma yöntemleri kullanılarak veri setindeki görüntü sayıları arttırılmıştır. Görüntüler üzerinde görüntü işleme teknikleri uygulanarak görüntülerin özellik haritaları çıkarılmıştır. Çalışmanın ilerleyen bölümünde görüntüler üzerinde temelde DenseNet görüntü sınıflandırma modeli kullanılarak %96.4 doğruluk oranı ile sınıflandırma işlemi gerçekleştirilmiştir. Gerçekleştirilen sınıflandırma sayesinde doğruluk oranı yüksek hava durumu tespiti gerçekleştirilebilir.

Anahtar Kelimeler: Görüntü sınıflandırma, Görüntü İşleme, Veri Arttırma, DenseNet

Weather Detection from Sky Images with Dense Convolutional Neural Network

ABSTRACT: Weather conditions appear as an unchangeable structure. However, determining and determining weather conditions can help individuals plan their physical activities. In the study, it has been tried to perform different sky images and weather detection processes with image classification methods, which is one of the popular work subjects in the computer field in recent years. In the study, a data set consisting of images with different weather conditions and resolutions was used. The number of images in the data set has been increased by using various data augmentation methods. The feature maps of the images were obtained by applying image processing techniques to the images. In the next part of the study, the classification process was carried out on the images with an accuracy rate of 96.4% using the DenseNet image classification model. Thanks to the classification performed, weather detection with high accuracy can be achieved.

Keywords: Image classification, Image Processing, Data Augmentation, DenseNet

¹ Abdullah ŞENER ([Orcid ID: 0000-0002-8927-5638](https://orcid.org/0000-0002-8927-5638)), Bingöl Üniversitesi, Genç Meslek Yüksekokulu, Bilgisayar Teknolojileri Programı, Bingöl, Türkiye

² Burhan ERHEN ([Orcid ID: 0000-0003-3244-2615](https://orcid.org/0000-0003-3244-2615)), Fırat Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Elazığ, Türkiye

***Sorumlu Yazar/Corresponding Author:** Abdullah ŞENER, e-mail: asener@bingol.edu.tr

GİRİŞ

Fiziksel çevre unsurlarının bireyin hayatına önemli etkileri bulunmaktadır. Bireyler gündelik planlarını genellikle fiziksel çevre unsurlarını göz önünde bulundurarak yaparlar. Fiziksel çevre unsurlarının başında hava durumu koşulları gelmektedir. Hava durumu koşulları çoğu zaman bireylerin gündelik aktivitelerini belirlerken göz önünde bulundurdıkları etkenlerin başında gelmektedir. Bireyin hayatı için önemli olan bu yapının tespiti bireylerin hayatlarını kolaylaştırmada önemli etkisi olacaktır. Bilimsel olarak farklı yollarla hava durumu tespiti yapılmaktadır. Mevcut hava koşulları tespiti sistemleri, hava koşullarını belirlemek için bir dizi pahalı sensörlere ve bu sensörlerden gelen bilgileri insanların tecrübelerine göre yorumlanmasına ihtiyaç duymaktadır. Bu işlemlerin bilgisayarlı görme teknikleri kullanılarak tek bir görüntü üzerinden gerçekleştirilmesi hem maliyet hem de zaman açısından daha faydalı olacaktır. Tek bir görüntü üzerinden hava durumu koşullarının tespiti insanlar için basit ve kolay bir işittir. Bu işlem, otonom bir sistem için daha yüksek bir zorluk seviyesine sahiptir. Tek bir görüntüyü giriş verisi olarak alan iyi bir hava sınıflandırıcı sistem tasarlayarak doğruluk oranı yüksek hava durumu tespiti gerçekleştirilebilir. Yapılan çalışmada farklı hava koşullarına sahip gökyüzü görüntüleri üzerinde görüntü sınıflandırma yöntemleri uygulanarak hava durumu tespiti yapılmaya çalışılmış ve başarılı sonuçlar elde edilmiştir.

Makine öğrenmesinin bir alt alanı olan derin öğrenme, tıbbi görüntü işleme, bilgisayarla görme, konuşma analizi ve doğal dil işleme gibi araştırma alanlarında yaygın olarak kullanılan bir araçtır. Son yıllarda, donanım maliyetlerinin azalmasıyla bilgi işlem gücünün artması ve çok sayıda yeni veri kümesinin oluşturulması nedeniyle derin öğrenme büyük ilgi görmüştür (Pacal ve ark., 2020). Bir tür derin öğrenme algoritması olan evrişimli sinir ağları (CNN'ler), birçok görüntü işleme uygulamalarında elde ettiği başarı ile derin öğrenme alanında merkezi hale gelmiştir (Lecun ve ark., 2015). Çalışmaların farklı alanlarda derin öğrenme ile yaptıkları çalışmalara bakıldığında; Mesut ve Burhan yaptıkları çalışmada biyomedikal görüntülerde derin öğrenme kullanarak mevcut yöntemleri kıyaslamışlardır (Toğaçar ve Ergen, 2019). Funda ve İsmail yaptıkları çalışmada derin öğrenme modeli ile yüz ifadelerinden duygu tespiti üzerine yeni bir model geliştirmişlerdir (Akgül, ve Funda, 2022). Murat ve Ali türkçe metin sınıflandırması için derin sinir ağlarında önceden eğitilmiş kelime yerleştirmeleri kullanarak doğruluğun iyileştirilmesi üzerine bir çalışma yapmışlardır (Aydoğan ve Karcı, 2020). Pacal ve Karaboga gerçek zamanlı derin öğrenme tabanlı otomatik polip algılama sistemi oluşturmuşlardır (Pacal ve Karaboga, 2021) Son zamanlarda donanım gereksinimlerinin kolaylıkla bulunabilmesi nedeniyle derin öğrenme alanı birçok yeni araştırmaya konu olmuş ve birçok yeni araştırmacının yeni araştırmalar yapmasına olanak sağlamıştır. Ayrıca Amazon, NVIDIA ve Google gibi firmalar, modelleri uzaktan eğitmek için derin öğrenme için bulut tabanlı çözümler sundu. Tüm bu iyileştirmeler, derin öğrenme yöntemlerinin kullanıcılara daha hızlı ulaşmasını sağladı.

Görüntü sınıflandırma uygulamaları son zamanlarda elde edilen sonuçlar dikkate alındığında popüler çalışmalar arasında girmiştir (Liu ve ark., 2019). Görüntü sınıflandırma işlemi benzer özelliklere sahip görüntülerin gruplandırılması işlemidir. Görüntü sınıflandırma, görüntü üzerindeki her bir pikselin konumundaki gri değerlerini kullanarak anlamlı bilgilere dönüştürme ve bu bilgileri kullanma işlemidir. Görüntü sınıflandırma, görüntü üzerindeki pikselleri spektral değerlerini alan kuralları kullanarak veya piksellerin oluşturdukları şekil, desen, piksellerin komşulukları vb. gibi özelliklerini kullanarak görüntüleri sınıflara bölme işlemidir (Gao, 2009). Görüntü Sınıflandırma işleminin temel amacı görüntüler üzerinde incelemeler yaparak aynı spektral özelliklere sahip görüntülerin bir araya getirilip gruplandırılması işlemidir (Campbell, 1996). Sınıflandırma işlemi yapılırken genel olarak piksellerin parlaklık değerlerinin birleşimini temel olarak alır. Bir sınıflandırma

işleminde hedeflenen sonuç; hedeflenen bölgenin özellik haritası ve çıkarılan özellik haritasının doğruluğuna ilişkin bilgilerdir (Wilkie, 1996).

Hava görüntüleri üzerinde hava durumlarının belirlenmesinde uzmanların karar verme sürecinin zamanla yerini yapay zekâ destekli cihazlara bırakması bekleniyor. Birçok bilimsel çalışma bu sürecin gelişmesine katkıda bulunmuştur ve etmeye de devam edecektir (Huntingford ve ark., 2019; Mirbabaie ve ark., 2021). Literatür taramasında, derin öğrenme yöntemleri kullanılarak farklı hava koşulları görüntülerinin sınıflandırılmasıyla ilgili birçok çalışma yapılmıştır. Bu çalışmalardan bazıları incelenecek olursa, (Toğaçar, ve Ergen, 2022), derin öğrenme modeli ile süper çözünürlük, semantik segmentasyon yaklaşımları ve ikili yelken balığı optimizasyon yöntemi kullanılarak bulut görüntülerinin sınıflandırılması üzerine bir çalışma yapmışlardır. (Dhananjaya ve ark., 2021) yaptıkları çalışmada otonom sürüş için hava ve ışık seviyelerini sınıflandırma işlemi gerçekleştirmişlerdir. Makine öğrenimi aracılığıyla hava durumunun havalimanı performansı üzerindeki etkisinin tahmine dayalı sınıflandırması ve anlaşılması üzerine (Schultz ve ark.,2021) bir çalışma gerçekleştirmişlerdir. (Triva ve ark.,2022) ön görüş kamerası görüntülerine dayalı araç ortamında hava durumu sınıflandırması adlı çalışmalarını yapmışlardır. (Manzo ve Pellino, 2021) yer tabanlı bulut sınıflandırması için transfer öğrenim sisteminde oylanması üzerine bir çalışma yapmışlardır. (Jehong ve ark.,2018) evrişimsel sinir ağlarını kullanarak hava durumu sınıflandırması üzerinde çalışmışlardır. Yaptıkları çalışmada Alexnet ile çok sınıflı SVM (Alexnet-MCSVM) birlikte kullanılmış sonuç olarak görüntü sınıflandırmada sırası ile %86 ve %75 doğruluk oranları elde edilmiştir. Çok sınıflı SVM (Resnet-MCSVM) ile birlikte Resnet'in doğruluk oranları ise %92 ve %88 olarak elde edilmiştir. (Li ve ark.,2018) derin öğrenmeye dayalı hava durumu görüntü tanıma konusu üzerine çalışmışlardır. Yaptıkları çalışmada %92 doğruluk oranı elde edilmiştir. (Jose ve ark.,2018) Hava Durumu Sınıflandırması: Yeni birçok sınıflı veri seti, veri büyütme yaklaşımı ve Evrişimli Sinir Ağlarının kapsamlı değerlendirmeleri konusu üzerine çalışmışlardır. Yaptıkları sınıflandırma çalışmalarında en yüksek başarı oranına ResNet-50 ile ulaşılmıştır. ResNet-50 ile %80 doğruluk oranı elde edilmiştir.

Yapılan çalışmada farklı sınıflara ve hava koşullarına sahip gökyüzü görüntüleri üzerinde ilk olarak yeniden boyutlandırma ve veri artırma işlemleri uygulanmıştır. Daha sonra evrişimli sinir ağları ile birlikte DenseNet sınıflandırma modeli kullanarak sınıflandırma işlemi gerçekleştirilmiştir. Elde edilen sonuçlar ile hava durumu tespiti yapılmaktadır. Yapılan bu çalışma sayesinde evrişimli sinir ağlarının görüntü sınıflandırmasındaki doğruluk oranının başarısına katkıda bulunulmuştur. Bu sayede maliyeti az ve doğruluk oranı yüksek hava durumu tahminleri yapılabilir.

Çalışmanın ilerleyen bölümlerine bakıldığında; 2. bölümde Materyal ve Metotlardan bahsedilmiştir. Ayrıca yine bu bölümde önerilen yöntem ile ilgili bilgiler yer almaktadır. Deneysel analiz sonuçlarına 3. bölümde yer verilmiştir. Tartışma ve sonuçlar ise 4. ve 5. bölümde yer almaktadır.


MATERYAL VE METOT

Bu bölümde sınıflandırma işlemi gerçekleştirilen veri seti ve sınıflandırma işleminde kullanılan model hakkında bilgiler içermektedir.

Veri Seti

Yapılan çalışmada test edilecek olan modelin performansını değerlendirmek için farklı sınıflara ait 1530 gökyüzü görüntüleri içeren açık kaynaklı bir veri seti kullanılmıştır. Veri setindeki görüntüler Flickr, Unsplash ve Pexels'ten alınan Creative Commons lisansını içeren görüntüler internetten toplanarak kullanılmıştır. Bu veri seti alien_test, Bulutlu, Sisli, Yağmurlu, Açık-Parlak ve Gün doğumu olmak üzere 6 kategoriden oluşmaktadır. Sırası ile bu kategorilere bakıldığında; alien_test,


bulutlu, sisli, yağmurlu, açık-parlak ve gün doğumu etiketlerinden oluşmaktadır. Veri setinde bulunana alien_test, sisli kategorileri ve bazı gerçeği yansıtmayan görüntüler gerçeği yansıtmadığı için bu çalışmada göz ardı edilerek çalışmada geriye kalan 4 kategoride toplamda 1125 görüntü kullanılmıştır. Çalışmada kullanılan görüntülerin kategorilere göre sayılarına bakıldığında; 300 bulutlu, 215 yağmurlu, 253 açık ve 357 gün doğumu görüntülerinden oluşmaktadır. Veri setinde her görüntünün yalnızca bir hava durumu kategorisi vardır. Şekil 1’de veri setine ait bazı görüntüler gösterilmektedir (Veri Seti). Veri setindeki görüntülerin %80 eğitim, %10 test ve %10 geçerleme veri kümesi olmak üzere üçe bölünmüştür. Bu oranlar doğrultusunda 900 görüntü eğitim, 113 görüntü test ve 112 görüntü ise doğrulama için kullanılmıştır. Ayrıca veri setinde modelin eğitiminde göz ardı edilen alien_test kategorisindeki görüntüler modelin doğrulama işleminde kullanılmıştır. Çalışmada kullanılan modelin eğitiminde renkli görüntüler tercih edilmiştir. Modelin veri seti içerisindeki tüm verileri aynı anda sistemde işlenmesi zaman, bellek ve öğrenme açısından maliyetli olacağından veri seti yığınlar bölünmüştür. Bu nedenle modelin mini-batch boyutu 32 olarak belirlenmiştir. Şekil 1’de çalışmada kullanılan veri setine ait bazı görüntüler gösterilmektedir.



Şekil 1. Hava durumu verilerinin sınıflarını temsil eden örnek görüntüler: a) bulutlu b) yağmurlu c) açık-parlak d) gün doğumu (Veri Seti)

Veri Arttırma

Makine öğrenmesi ve derin öğrenme çalışmalarında karşılaşılan en büyük sorunlardan birisi ağ için eğitim verisinin eksikliğidir. Veri eksikliğinden dolayı oluşturulan ağ ezberleme yoluna giderek veri seti dışında verileri tanıma ve bunları sınıflandırmada sorunlarla karşılaşmaktadır. Bu sorunu gidermek için gerekli yollardan birisi; eğitim veri sayısının artırılmasıdır, diğer bir yol ise veri arttırma (Augmentation) yöntemidir. Bu yöntem ile mevcut veri setindeki görüntüler üzerinde bazı işlemler uygulanarak daha fazla yapay görüntü elde edilmektedir. Veri arttırma işleminde genellikle görüntülere yatay çevirme, görüntüyü 90o döndürme, görüntünün rastgele parlaklık kontrastı ile oynama, bulanıklık, optik bozulma, belirli bir ölçekte görüntüyü döndürme, transpoze ve ızgara bozulması veri arttırma yöntemi uygulanarak yapay görüntüler elde edilmektedir. Veri arttırma yöntemlerinden bazıları Şekil 2’de gösterilmektedir.



Şekil 2. Veri artırma yöntemlerinden örnekler

Derin Öğrenme

Bir veya birden fazla gizli katmandan oluşan yapay sinir ağı ve bu sinir ağları ile benzerlik gösteren makine öğrenmesi yöntemlerini içeren metot derin öğrenme olarak ifade edilmektedir (Deng ve Yu, 2014). Derin öğrenmede amaç içerdiği en az bir yapay sinir ağını kullanarak bilgilerden farklı yeni bilgilerin elde edilmesidir. Derin öğrenme yöntemleri gözetimli, yarı gözetimli ve gözetimsiz olarak gerçekleştirilmektedir (Yoshua ve ark., 2015). Biyolojik alanlarda bilginin öğrenilmesi ve bilgilerden yeni çıkarımlar yapılması modellenerek yapay sinir ağları oluşturulmuştur. Bilgisayarların öğrenmesi ve yeni çıkarımlar yapması süreci temelde insan beynin çalışma prensibinden esinlenerek gerçekleştirilmektedir. Temelde aynı işi yapmaya çalışsa da yapay sinir ağları ile insan beyni arasında çeşitli farklılıklar vardır. İki yapı karşılaştırıldığında sinir ağlarının statik ve sembolik olma eğilimi varken, beyin ise dinamik ve analogdur (Marblestone ve ark., 2016; Olshausen, 1996; Yoshua ve ark., 2015).

Derin öğrenme yöntemleri arasında popülerliği en yüksek olan yöntemlerden birisi evrişimli sinir ağları (CNN) mimarisidir (Gu ve ark., 2018). CNN mimarisi görüntüleri sınıflandırırken, benzer özellikleri bir araya getirmek ve nesnelere tanımak için beynin görsel korteksini referans almaktadır (Min ve ark., 2017; Milletari ve ark., 2016). CNN mimarisi görüntüler üzerinde farklı katmanlarda farklı çalışmalar yapmaktadır. CNN mimarisi evrişim katmanı, doğrusal olmayan katman, havuzlama katmanı, düzleştirme katmanı ve tam bağlı katmanlarının birleşimidir (Hanbay, 2020).

CNN mimarisinin yapısına ve katmanların özelliklerine bakılacak olursa; en yoğun matematiksel işlemlerin gerçekleştiği katman evrişim katmanıdır. Evrişim katmanı CNN mimarisinin temelini oluşturmaktadır. Bu katmanda görüntülere bazı filtreler uygulanarak düşük ve yüksek seviyeli özellik saptama işlemi gerçekleştirilir. Doğrusal olmayan katmanda sistemde doğrusal olmayan durumların belirlenmesi gerçekleştirilmektedir. Bu katmanda en iyi sonucu Relu fonksiyonu vermektedir. Relu fonksiyonu Denklem 1’de gösterildiği gibidir.

$$(f * g)(t) = \int_{-\infty}^{+\infty} f(T)g(t - T)dT \quad (1)$$

Fonksiyonun çıktısı Denklem 2’de gösterildiği gibidir.


$$f(x) = \max(0, x) \quad (2)$$

Havuzlama katmanında ise özellik haritalarının boyutu küçültülüp sistem üzerindeki ağırlık sayısı azaltılarak ağ içerisindeki parametrelerin sayısının azaltılması işlemi gerçekleştirilmektedir. Bu işlemleri maximum havuzlama (görüntü nxn matrislere bölünerek bu matrisler içindeki en yüksek değer alınarak) veya ortalama havuzlama (görüntü nxn matrislere bölünerek bu matrisler içindeki

değerlerin ortalaması alınarak) işlemi ile gerçekleştirmektedir. Düzleştirme Katmanının görevi CNN mimarisinin son katmanı olan tam bağlı katmanın girişi için verileri hazırlamaktır. Genellikle bu katman kendisine gelen verileri tek boyutlu bir matrise dönüştürerek bu işlemi gerçekleştirir. Tam bağlı katman giriş katmanı ve çıkış katmanı arasında ilişki kurma işlemi gerçekleştirilmektedir (Niepert ve ark. 2016; Kurt, 2018).

DenseNet

Yoğun bağlantılı evrişim ağında, ağda bulunan her katman bir önceki katmanın bilgilerini giriş olarak alır ve bu bilgiye bulunduğu katmanın bilgilerini de ekleyerek bir sonraki katmana giriş verisi olarak vermektedir. Bu şekilde yoğun bağlantılı evrişim ağlarında katmanlar ileriye doğru birbirlerine bağlanmaktadır (Kumar, 2019). Yoğun bağlantılı evrişim ağının en büyük özelliği yayılım sağlayarak özelliklerin yeniden kullanılmasına olanak sağlamaktadır. Bu şekilde sistemdeki parametre sayısı azalmaktadır (Huang ve ark., 2017). Şekil 3'te yoğun bağlantılı evrişim ağı ve Şekil 4'te 4 genişlemeli 5 katmanlı DenseNet mimarisi gösterilmektedir (Ajayi ve Wang, 2019).




Şekil 3. DenseNet mimarisi (Ajayi ve Wang., 2019)

DenseNet'in Yapısı

Geleneksel ileri beslemeli sinir ağları, $H_l(\cdot)$ işlemlerinin bir bileşimini uyguladıktan sonra l^{th} katmanının çıktısını bir sonraki $(l + 1)^{th}$ katmanına bağlamaktadır. Normalde bu bileşim bir evrişim işlemi veya havuzlama katmanlarında, toplu normalleştirme ve etkinleştirme işlevlerini içermektedir. DenseNet yapısı Denklem 3'te gösterildiği gibidir:

$$x_l = H_l(x_{l-1}) \quad (3)$$



Şekil 4. 4 genişlemeli 5 katmanlı DenseNet mimarisi (Ajayi ve Wang, 2019)

ResNet'in yapısı, yukarıda açıklanan yapıya atlama bağlantısı da dâhil ederek oluşturulmaktadır. ResNet'in denklemi Denklem 4'te gösterildiği gibidir:

$$x_l = H_l(x_{l-1}) + x_{l-1} \quad (4)$$

DenseNet ile ResNet arasındaki fark yukarıda verilen denklemlerde ortaya çıkmaktadır. DenseNet, katmanı çıkış işlemi özellik haritalarını gelen özellik haritalarıyla toplamak yerine onları birleştirerek gerçekleştirmektedir. Bu bilgiler göz önünde bulundurulduğunda DenseNet denkleminin güncellenmiş hali Denklem 5'te gösterildiği gibidir:

$$x_l = H_l([x_0, x_1, x_2, \dots, x_{l-1}]) \quad (5)$$

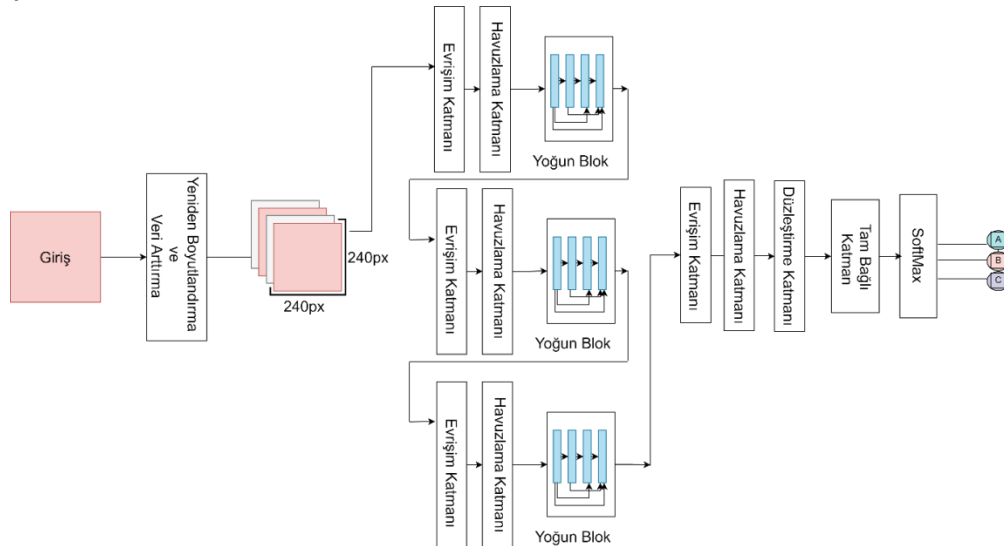
DenseNet'te özellik haritaları birleştirildiği için kanal boyutu her katmanda artmaktadır. Her seferinde k özellik haritaları üretmek için Hl oluşturulduğunda, lth katmanı için genelleme yapılırsa denklem Denklem 6'da gösterildiği gibidir:

$$k_1 = k_0 + k * (l - 1) \quad (6)$$

Yukarıdaki denklemde k parametresi büyüme oranıdır. Büyüme oranı, ağa her katmanda ne kadar bilgi ekleneceğini düzenler. Özellik haritaları, ağın bilgisi olarak görülebilir. Her katmanın önceki özellik haritalarına ve dolayısıyla kolektif bilgiye erişimi vardır. Somut k özellik bilgi haritalarında, her katman daha sonra bu toplu bilgiye yeni bir bilgi ekleyerek ilerler.

Önerilen Yaklaşım

Yapılan çalışmada farklı gökyüzü görüntüleri üzerinde sınıflandırma işlemi için önerilen derin sinir ağına dayalı modelin yapısı Şekil 5'te verilmiştir. Çalışmada görüntüler girdi olarak alındıktan sonra ilk yapılacak işlem hem bilgisayar hafızası için hem de sınıflandırma işleminin daha hızlı yapılabilmesinde önemli olan yeniden boyutlandırma işlemi gerçekleştirilmektedir. Derin sinir ağlarının eğitilmesi için girdi olarak verilen görüntülerin boyutlarının aynı olması gerekmektedir. Girdi olarak verilen görüntüler evrişimli sinir ağı (CNN) mimarisinde işlenmeden önce belirlenen sabit bir boyuta getirilir. Görüntüler sabit boyuta getirilirken çok fazla küçültülmemesi gerekmektedir. Görüntü gereğinden fazla küçültülürse bu sefer görüntünün sınıflandırılması için gerekli olan bilgi çıkarımı zorlaşacaktır (Şahin ve ark.,2020). Bu uyarılar göz önünde bulundurularak farklı çözünürlüğe sahip görüntüler DenseNet sınıflandırma mimarisinin de görüntü boyutu olan 240x240 çözünürlük boyutuna getirilmiştir. Veri setindeki görüntülerin %80 eğitim, %10 test ve %10 geçerleme veri kümesi olmak üzere üçe bölünmüştür. Modelin mini-batch boyutu 32 olarak belirlenmiştir. Geliştirilen modelin eğitim ve test işlemleri 25 adım olarak seçilmiştir. Modelin hiper-parametreleri belirlendikten sonra çözünürlüğü düşürülmüş görüntüler önerilen derin sinir ağına verilerek eğitim ve test işlemleri gerçekleştirilmiştir.



Şekil 5. Önerilen yaklaşımın genel tasarımı ve süreç adımları

BULGULAR VE TARTIŞMA

Oluşturulan modellerin performansı karmaşıklık matrisi yöntemi kullanılarak değerlendirilmiştir. Karmaşıklık Matrisi oluşturulurken kullanılan bazı terimlere bakıldığında; DP: Doğru Pozitif, YP: Yanlış Pozitif, DY: Doğru Negatif ve YN: Yanlış Negatiftir. Sınıfların kesinlik, hassasiyet, doğruluk ve F1-Skor değerleri Denklem 7,8,9 ve 10 ile hesaplanmaktadır.

$$Kesinlik = \frac{DP}{DP + YP} \quad (7)$$

$$Hassasiyet = \frac{DP}{DP + YN} \quad (8)$$


$$Doğruluk = \frac{DP + DN}{DP + DN + YP + YN} \quad (9)$$

$$F1 - Skor = \frac{2x KesinlikxHassasiyet}{Kesinlik + Hassasiyet} \quad (10)$$

Yapılan çalışmada DenseNet modelinin eğitim-test işlemleri ve modelde kullanılan veri seti dosyalarının işlenmesi için Python 3.6 kullanılmıştır. Çalışmada kullanılan bilgisayarın işletim sistemi 64-bit Windows 10'dur. Diğer donanım bilgileri ise NVIDIA GeForce® RTX™ 3060 6 GB ekran kartı, 11. Nesil Intel® Core™ i7 2,3 GHz (24M Önbellek, 4,6 GHz'e kadar, 8 Çekirdek) işlemci ve 16 GB bellek.

Yapılan çalışmanın deneysel sonuçlarına bakıldığında; toplamda 25 adımda gerçekleşen eğitim ve test aşamalarının ilk adımında eğitim ve test kayıp oranları 0.83 ve 0.75 değerlerini gösterirken eğitim ve test doğruluk oranları 70.7 ve 66.9 değerlerini göstermiştir. İlk beş adım sonrasında eğitim ve test kayıp oranları 0.26 ve 0.33 değerlerini gösterirken eğitim ve test doğruluk oranları 91.8 ve 94.6 değerlerini göstermiştir. Değerlerden de anlaşılacağı gibi kayıp verilerinde azalma, doğruluk oranlarında ise yükselme gerçekleşmiştir.


Yirmi adım sonrasında eğitim ve test kayıp oranları 0.17 ve 0.21 değerlerini gösterirken eğitim ve test doğruluk oranları 94.2 ve 95.5 değerlerini göstermiştir. Yirmi adımda ise eğitim ve test kayıp oranları azalmaya devam ederken, eğitim doğruluk oranında ilk on beş adıma göre ufak bir azalma görülmüştür, test doğruluk oranı ise sabit kalmıştır. Yirmi beş adım sonrasında eğitim ve test kayıp oranı 0.13 ve 0.19 değerlerini gösterirken eğitim ve test doğruluk oranları 96 ve 96.4 değerlerini göstermiştir. Geliştirilen modelin eğitim – test doğruluk oranı grafiği ile eğitim- test kayıp oranı grafiği Şekil 6'da gösterilmiştir.



Şekil 6. (a) Eğitim vs. test doğruluk oranı grafiği, (b) Eğitim vs. test kayıp oranı grafiği

Hava durumu bir bölgede belirli bir zamanda meydana gelen meteorolojik olaylardır. Hava durumu tespiti bir bölgede belirli bir zaman içerisinde meydana gelebilecek meteorolojik olayların gözlem ve analizlere dayandırılarak belirlenmesidir. Bireyler gündelik hayatlarında aktivite planlarını hava durumu koşullarına göre şekillendirirler. Yapılan çalışmada yoğun evrişimli sinir ağı modeli kullanılarak gökyüzü görüntülerinden hava durumu tespiti gerçekleştirilmiştir. . Bu çalışmada evrişimli sinir ağı modelinde DenseNet mimarisinin kullanılmasıyla doğruluk oranı yüksek sonuçlar elde edilmiştir. Ancak veri setindeki görüntülerin sayısı ve görüntülerin çözünürlük kalitesi geliştirilen

modelin performansını doğrudan etkilemektedir. Geliştirilen modelde gerçek sınıf ve sınıflandırıcının tahmin ettiği sınıfın gösterildiği karmaşıklık matrisi Şekil 7 'de gösterildiği gibidir.



Şekil 7. Karmaşıklık matrisi

Sınıflandırmada işleminde kullanılan modelin karmaşıklık matrislerinin metrik değerleri çizelge 1'de gösterilmektedir. Çizelge 1'de hesaplanan değerler, Şekil 6'da gösterilen karmaşıklık matrisi ve Denklem 7,8,9,10 kullanılarak hesaplanmıştır. Model en yüksek doğruluk oranını %99,12 ile yağmurlu ve gün doğumu kategorilerinde göstermiştir.

Çizelge 1. Modelin karmaşıklık matrisinin metrik değerleri

Sınıflar	n (gerçek sınıf)	n (sınıflandırılmış)	Doğruluk	Kesinlik	Hassasiyet	F1-Skor
Bulutlu	30	28	%98.23	0.99	0.93	0.97
Yağmurlu	21	20	%99.12	0.99	0.95	0.98
Açık	26	30	%96.46	0.87	0.99	0.93
Gün doğumu	36	35	%99.12	0.99	0.97	0.99

SONUÇ

Yapılan çalışmada bilinen yöntemlerden farklı bir yöntem kullanarak farklı sınıflara ait gökyüzü görüntüleri aracılığıyla hava durumu tespiti yapılmıştır. Bu yöntem bilgisayar ortamında görüntüleri ortak özelliklerine göre sınıflara ayırıp daha sonra gelecek görüntünün sınıfını tahmin etme temeline dayanmaktadır. Farklı çözünürlüklere sahip 4 farklı hava durumu; Bulutlu, Yağmurlu, Açık-Parlak ve Gün doğumu görüntüleri olmak üzere toplamda 1125 adet görüntü bu yöntemi eğitmek ve test etmek için kullanılmıştır. Yapılan çalışmada ilk olarak görüntüler üzerinde yeniden boyutlandırma ve veri artırma işlemleri gerçekleştirilmiştir. Daha sonraki aşamada görüntülerin özellik haritaları çıkarılıp sınıflandırma işlemi gerçekleştirilmiştir. Sınıflandırma işleminde %96.4 doğruluk oranı elde edilmiştir.

DenseNet mimarisi temel alınarak geliştirilen sınıflandırma modelinin sonuçları benzer veri setleri ile yapılan çalışmalarda elde edilen sonuçlarla Çizelge 2'de karşılaştırılmıştır. Çizelge 2 incelendiğinde önerilen yaklaşımın kategorilere göre elde ettiği doğruluk oranları sırası ile Bulutlu %98.23, Yağmurlu %99.12, Açık %96.46 ve Gün doğumu %99.12'dir. Önerilen modelin doğruluk oranları, Ajayi ve Wang'ın önerdikleri modele göre tüm kategorilerde daha yüksek sonuçlar vermiştir. Toğaçar ve ark.'nın önerdikleri model az bir farkla Açık ve Bulutlu kategorilerinde önerilen model göre başarılı sonuçlar vermiştir. Diğer kategorilerde ise önerilen model daha iyi sonuçlar vermiştir. Önerilen yaklaşımın yağmurlu ve gün doğumu hava görüntüleri üzerindeki sınıflandırma başarısı benzer çalışmalar göz önüne alındığında daha iyi sonuç vermiştir.

Çizelge 2. Aynı veri setini kullanan diğer çalışmaların analiz sonuçları ve bu çalışmanın analiz sonuçları

Makale	Yıl	Sınıf	Model/Metot	% Doğruluk
Ajayi ve Wang	2019	Bulutlu	Selection Based on Accuracy Intuition and diversity (SAID)	81.5
		Yağmurlu		95.2
		Açık		88.4
		Gün doğumu		81.7
Toğaçar ve ark.	2021	Bulutlu	Convolutional Neural Network (CNN) and Spiking Neural Network (SNN)	98.48
		Yağmurlu		97.58
		Açık		97
		Gün doğumu		98.48
Önerilen Yaklaşım	2022	Bulutlu	DenseNet	98.23
		Yağmurlu		99,12
		Açık		96.46
		Gün doğumu		99.12

Günümüzde hava koşulları tespitinde, hava koşulları pahalı sensörlere ve bu sensörlerden gelen bilgileri insanların tecrübelerine göre yorumlanmasına ihtiyaç duymaktadır. Gerçekleştirilen sınıflandırma işlemindeki başarı göz önüne alındığında pahalı sensörlere ve bu sensörlerden gelen bilgilerin tecrübeli kişiler tarafından yorumlanmasının kullanılmaması hem az maliyetli hem de daha kısa zamanda hava koşulları tespiti yapılabilmesine olanak sağlamaktadır. İlerleyen çalışmalarda veri setinde kullanılan görüntülerin çözünürlüğü üzerinde iyileştirmeler gerçekleştirilip farklı sınıflandırma modellerinin başarı oranları üzerinde karşılaştırma yapılmaya çalışılacaktır.

Çıkar Çatışması

Makale yazarları, aralarında herhangi bir çıkar çatışması olmadığını beyan ederler.

Yazar Katkısı

Yazarlar makaleye eşit oranda katkı sağlamış olduklarını beyan eder

KAYNAKLAR

- Ajayi GO, Wang Z (2019) Multi-class weather classification from still image using said ensemble method. In: Proceedings of 2019 South African Univ Power Eng Conf Mechatronics/Pattern.
- Akgül, İ., & Funda, Akar. (2022). Derin Öğrenme Modeli ile Yüz İfadelerinden Duygu Tanıma. Journal of the Institute of Science and Technology, 12(1), 69-79.
- Aydoğan, M., & Karci, A. (2020). Improving the accuracy using pre-trained word embeddings on deep neural networks for Turkish text classification. Physica A: Statistical Mechanics and its Applications, 541, 123288.
- Bengio, Yoshua; LeCun, Yann; Hinton, Geoffrey, (2015). "Deep Learning". Nature, doi:10.1038/nature14539.
- Bengio, Yoshua; Lee, Dong-Hyun; Bornschein, Jorg; Mesnard, Thomas; Lin, Zhouhan, (2015). Towards Biologically Plausible Deep Learning. arXiv:1502.04156v3.
- Campbell, J.B, (1996). Introduction to Remote Sensing. Guilford Press, , New York, 621 s.
- Dhananjaya, M. M., Kumar, V. R., & Yogamani, S. (2021). Weather and light level classification for autonomous driving: Dataset, baseline and active learning. In 2021 IEEE International Intelligent Transportation Systems Conference (ITSC) (pp. 2816-2821). IEEE.
- Gao J., (2009). Digital analysis of remotely sensed imagery. The Mc Graw-Hill Companies, USA.
- Gu J, Wang Z, Kuen J, Ma L, Shahroudy A, Shuai B, Chen T, et al., (2018). Recent advances in convolutional neural networks. arXiv:1512.07108.
- Hanbay K., (2020). Hyperspectral image classification using convolutional neural network and two-dimensional complex Gabor transform. Journal of the faculty of engineering and architecture of gazi university, 35(1):443-456.

- Huang G, Liu Z, Van Der Maaten L, Weinberger KQ., (2017). Densely connected convolutional networks. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Honolulu:IEEE p. 4700-4708.
- Huntingford, C., Jeffers, E.S., Bonsall, M.B., Christensen, H.M., Lees, T., Yang, H., (2019). Machine learning and artificial intelligence to aid climate change research and preparedness. *Environ. Res. Lett.* 14 (12), 124007. <https://doi.org/10.1088/1748-9326/ab4e55>.
- Jehong An, Yunfan Chen, Hyunchul Shin, (2018). Weather Classification using Convolutional Neural Networks. 2018 International SoC Design Conference (ISOCC), <https://doi.org/10.1109/ISOCC.2018.8649921>.
- Jose Carlos Villarreal Guerra, Zeba Khanam, Shoaib Ehsan, Rustam Stolkin, Klaus McDonald-Maier, (2018). Weather Classification: A new multi-class dataset, data augmentation approach and comprehensive evaluations of Convolutional Neural Networks. 2018 NASA/ESA Conference on Adaptive Hardware and Systems(AHS), <https://doi.org/10.1109/AHS.2018.8541482>.
- Kumar R., (2019). Adding binary search connections to improve densenet performance. 5th International Conference on Next Generation Computing Technologies, Dehradun: NGCT- 2019;2019. SSRN: <https://ssrn.com/abstract=3545071>.
- Kurt F., (2018). Sinir Ağlarında Hiper Parametrelerin Etkisinin İncelenmesi. Ankara:Hacettepe Üniversitesi.
- L. Deng and D. Yu, , (2014). “Deep Learning: Methods and Applications,” *Found. Trends® Signal Process.*, vol. 7, no. 3–4, pp. 197–387.
- Li X, Shen X, Zhou Y, Wang X, Li TQ., (2020). Classification of breast cancer histopathological images using interleaved DenseNet with SENet (IDSNet). *PloS One.* 2020;15(5):e0232127.
- Li-Wei Kang, Ke-Lin Chou, Ru-Hong Fu, (2018). Deep Learning-Based Weather Image Recognition. 2018 International Symposium on Computer, Consumer and Control(IS3C).<https://doi.org/10.1109/IS3C.2018.00103>.
- Manzo, M., & Pellino, S. (2021). Voting in transfer learning system for ground-based cloud classification. *Machine Learning and Knowledge Extraction*, 3(3), 542-553.
- Marblestone, A. H., Wayne, G., & Kording, K. P. (2016). Toward an integration of deep learning and neuroscience. *Frontiers in computational neuroscience*, 94.
- Milletari F. Navab N. Ahmadi SA., (2016). V-net: Fully convolutional neural networks for volumetric medical image segmentation. Fourth International Conference on 3D Vision, 3DV 2016. ABD: IEEE; 2016. p. 565- 571.
- Min S, Lee B, Yoon S., (2017). Deep learning in bioinformatics. *Briefings in bioinformatics*, 2017;18(5):851-869.
- Mirbabaie, M., Stieglitz, S., Frick, N.R.J., (2021). Artificial intelligence in disease diagnostics: A critical review and classification on the current state of research guiding future direction. *Health Technol. (Berl)* 11 (4), 693–731. <https://doi.org/10.1007/s12553-021-00555-5>.
- Niepert M. Ahmed M. Kutzkov K., (2014). Learning convolutional neural networks for graphs. In International conference on machine learning, . Germany:2016. p. 2014-2023.
- Olshausen, B. A., (1996). Emergence of simple-cell receptive field properties by learning a sparse code for natural images. *Nature*, 381 (6583): 607–609. Bibcode:1996Natur.381..607O.[doi:10.1038/381607a0](https://doi.org/10.1038/381607a0). PMID 8637596. S2CID 4358477.
- Pacal, I., & Karaboga, D. (2021). A robust real-time deep learning based automatic polyp detection system. *Computers in Biology and Medicine*, 134, 104519.
- Pacal, I., Karaboga, D., Basturk, A., Akay, B., & Nalbantoglu, U. (2020). A comprehensive review of deep learning in colon cancer. *Computers in Biology and Medicine*, 126, 104003.
- Schultz, M., Reitmann, S., & Alam, S. (2021). Predictive classification and understanding of weather impact on airport performance through machine learning. *Transportation Research Part C: Emerging Technologies*, 131, 103119.

- Şahin, F., Işık, G., Şahin, G., & Kara, M. K. (2020). Estimation of PM10 levels using feed forward neural networks in Iğdir, Turkey. *Urban Climate*, 34, 100721.
- Toğaçar, M., & Ergen, B. (2019). Biyomedikal Görüntülerde Derin Öğrenme ile Mevcut Yöntemlerin Kıyaslanması. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 31(1), 109-121.
- Toğaçar, M., & Ergen, B. (2022). Classification of cloud images by using super resolution, semantic segmentation approaches and binary sailfish optimization method with deep learning model. *Computers and Electronics in Agriculture*, 193, 106724.
- Toğaçar, Mesut; Ergen, Burhan; Cömert, Zafer. (2021) Detection of weather images by using spiking neural networks of deep learning models. *Neural Computing and Applications*, 33.11: 6147-6159.
- Triva, J., Grbić, R., Vranješ, M., & Teslić, N. (2022). Weather Condition Classification in Vehicle Environment Based on Front-View Camera Images. In 2022 21st International Symposium INFOTEH-JAHORINA (INFOTEH) (pp. 1-4). IEEE.
- Veri Seti: <https://www.kaggle.com/vijaygiitk/multiclass-weather-dataset> (15.11.2021).
- Wilkie, D. S., (1996). Remote sensing imagery for natural resources monitoring: a guide for first-time users. Columbia Univ. Press.
- X. Liu, Z. Deng, Y. Yang., (2019). Recent progress in semantic image segmentation. *Artif. Intell. Rev.* 52 (2019), 1089–1106, <https://doi.org/10.1007/s10462-018-9641-3>.
- Y. Lecun, Y. Bengio, G. Hinton, Deep learning, *Nature* 521 436–444, <https://doi.org/10.1038/nature14539>.