



Moda Görseli Sınıflandırma: Düzenleyici Teknikler ile Evrişimsel Sinir Ağları Uygulaması

Fashion Image Classification: Convolutional Neural Networks with Regularization Techniques

Şule ÖZTÜRK BİRİM

Manisa Celal Bayar Üniversitesi

İşletme Bölümü

Manisa, Türkiye

sule.ozturk@cbu.edu.tr

ORCID: 0000-0001-7544-8588

Öz

Çevrimiçi moda sektörü son yıllarda hızlı bir şekilde büyümektedir. Bu sektörde yer alan moda ürünü görselleri miktarı da sürekli artış göstermektedir. Ürünleri tanımlama ve sınıflandırma yeteneğine sahip bir sistem, görsellere otomatik etiket eklenmesini sağlayarak hızlı erişime olanak verdiği gibi çalışanların iş yükünü de hafifletebilir. Ayrıca moda sınıflandırma sistemi müşterilerin beğenisine dayalı ürünler sunmak için de kullanılabilir. Büyük miktarlardaki görseli işleyebilmek için ise yüksek performanslı algoritmalarla ihtiyaç duyulmaktadır. Son yıllarda derin öğrenme uygulamalarından Evrişimsel Sinir Ağları (CNN) görüntü analizindeki başarısı ile ön plana çıkmaktadır. Literatürde bir çok CNN mimarisi yer almaktır. Birlikte, sınıflandırma doğruluğunu artıracak yeni CNN mimarilerine olan ihtiyaç artan görsel verisi ile birlikte devam etmektedir. Bu çalışmanın amacı, moda görselinin başarıyla sınıflandırılmasıdır. Bu amaç doğrultusunda, 10 sınıfı ayrılmış moda ürünü görselleri içeren Fashion-MNIST veri setini kullanarak farklı CNN mimarileri önerilmektedir. Önerilen mimarilerle L2 ve Dropout düzenleyici yöntemlerin tahmin başarısına olan etkisi incelenmiştir. Bu sayede, verileri daha iyi sınıflandıran CNN modeli araştırılmıştır. Çalışmada önerilen mimariler; temel CNN, L2 düzenleyici ile CNN, Dropout düzenleyici ile CNN ve son olarak her iki düzenleyiciyi içeren CNN modelleridir. Her iki düzenleyici yöntem de ağ ezberlemeyi azaltmıştır. Elde edilen sonuçlara göre Dropout içeren CNN mimarisi %94,3 doğruluk) değeri ile en iyi performansı sunan model olmuştur.

Anahtar Sözcükler: Sınıflandırma Sistemleri, Derin Öğrenme, Evrişimsel Sinir Ağları, Düzenleyici Yöntemler, Dropout, L2, Fashion-MNIST Veri Seti, Konvolüsyon

Gönderme, düzeltme ve kabul tarihi: 22.02.2022 - 06.05.2022 - 26.05.2022

Makale türü: Araştırma

Abstract

In the rapidly growing online fashion market, the amount of fashion product images are also constantly increasing. A system with the ability to identify and classify images can provide quick access to products by automatically adding labels, as well as easing the workload of employees. Additionally, the fashion classification system can be used to offer products based on customers' taste. In order to process large amounts of images, Convolutional Neural Networks (CNN), which is one of the deep learning applications, has proven its success in recent years. Although there are many CNN architectures in the literature, the new ones that will increase the classification accuracy continues to be a need as visual data increases in the internet. This study proposes different CNN architectures using the Fashion-MNIST dataset, which includes fashion product images divided into 10 classes. With the proposed architectures, the aim is to investigate the effect of L2 and Dropout regularization methods on classification success. Suggested architectures are; base CNN, CNN with L2 regularization, CNN with Dropout regularization, and finally CNN with both regularization methods. According to the results, the CNN architecture with Dropout was the best model that offered the highest accuracy with 94,3%.

Keywords: Classification Systems, Deep Learning, Convolutional Neural Networks, Regularization Methods, Dropout, L2, Fashion-MNIST Dataset, Convolution

1. Giriş

Görsel sınıflandırma, bilgisayarlı görüntü işleme konusunun en önemli problemlerinden birisidir. Literatürde birçok araştırmacı görsel sınıflandırma problemini çeşitli konular ve kategoriler açısından ele almıştır [1-2]. İnsanlar için belirli

özelliklere göre ayırt etmesi ve sınıflandırması oldukça kolay olan görsellerin, bilgisayarlar tarafından başarıyla sınıflandırılabilmesi için oldukça karmaşık uygulamalar gereklidir [3]. Web siteleri, sosyal medya, arama motorları içerikleri maruz kalınan görsel sayısını her geçen gün artırmaktadır. Görseli piksel bilgisini kullanarak, analiz edebilmek adına yapılandırılmamış veriye dönüştürebilmek mümkündür. Çok fazla sayıda görselden elde edilen yapılandırılmamış veri, internette yer alan Büyük Veri çeşitlerinden bir tanesidir. Son yıllarda MİB'lerde yer alan çoklu çekirdek sayısı ile hesaplama gücünün artması ve GiŞ'nın hesaplama işlemlerinde kullanılması yüksek miktarlardaki görsel veriyi işlemeye olanak sağlamaktadır [4].

Son dönemlerde derin öğrenme, doğal dil işleme, tahmin, sınıflandırma, görsel işleme, nesne tanıma gibi alanlarda başarısı ile tanınmaktadır [5]. Görsel işleme özelinde düşünülürse derin öğrenme yöntemlerinden Evrişimsel Sinir Ağları (Convolutional Neural Networks – CNN) sınıflandırma ve nesne tanıma konularında oldukça başarılı sonuçlar ortaya çıkarmıştır [6]. CNN, geri yayılım algoritması ile eğitilerek girdi verilerinden özellikler ortaya çıkan çok katmanlı bir sinir ağıdır. Çok sayıda görüntü verisinden karmaşık, yüksek boyutlu, doğrusal olmayan eşlemeleri öğrenerek oldukça başarılı bir sınıflandırma tahmini veren bir algoritmadır [2]. CNN modelleri çok sayıda görüntü girdisi ile bir dizi katman kullanarak (konvolüsyonel ve maksimum havuz katmanları gibi) görüntülerden uzamsal özellikleri otomatik olarak çıkarmayı ve parametreleri optimize etmeyi öğrenir ve bu sayede çıktı katmanında görüntü sınıfını tahmin edebilir [7], [8]. CNN'nin temel avantajları, girdilerdeki değişmeyecek belirgin özellikleri çıkarması ve verilerdeki ölçeklenme ve bozulma problemlerine karşı dayanıklı olmasıdır [9].

E-ticaret pazarı her geçen gün büyümektedir. Covid-19 pandemisi ile bu büyümeyen hızı oldukça artmıştır. Pazarın büyülüğu arttıkça kullanıcılar sunulan ürün görselleri de hızla artmaktadır. Kullanıcıların internet üzerinden alışveriş yapmakta hoşlandıkları önemli bir kategori moda ürünleridir. E-ticaret pazarının önemli bir kısmını moda sektörü oluşturmaktadır. 2021 sonu itibarıyle global online ticaret pazarında online moda endüstrisinin %46.6'lık penetrasyonu olduğu görülmektedir [10]. Moda sektöründeki bu büyük pay, ürünlerin görsel analizine ihtiyacı da artırmaktadır. Oldukça fazla mikardaki moda görselindeki renk, özellik, kategori gibi sınıfları algoritmalar ile doğru bir şekilde ortaya çıkarabilecek sistemler, zaman işgücü ve sermaye unsurlarında tasarrufa sebep olacaktır [11].

Moda endüstrisinde çok fazla sayıda görsel kullanılmaktadır. Katalog resimleri ya da online mağazada kullanmak için manken üzerindeki resimler çeşitlerden bazilarıdır. E-ticaret hacmi ile birlikte artan moda görselleri, CNN gibi derin öğrenme uygulamalarına sektörde fazlasıyla ihtiyaç duyulmasına sebep olmaktadır. Bu ihtiyacın birincil sebebi kullanıcılarla ürün araştırmasında ve ürün tavsiyesinde yardımcı olacak sistemlerin gelişmesinde öncelikle ürün sınıflandırma uygulamalarına ihtiyaç duyulmasıdır [4, 12-13]. Moda sektörünün bireyler açısından önemi düşünüldüğünde, sınıflandırmanın pek çok uygulaması olduğu söylenilabilir. Örneğin kullanıcılar aradıkları bir giysinin görselini arama

motoruna girdiklerinde, arama motoru sınıflandırma sistemi kullanarak benzer ürünleri getirebileceği gibi, ilgili ürünü içeren alternatif görseller de sunabilir. Ayrıca sınıflandırma ile görselin detayları tahmin edilerek kullanıcıya benzer ürünler sunan bir tavsiye sistemi geliştirilebilir [13-14]. Moda sınıflandırma sisteminin bir başka yaygın kullanımı da ürünleri etiketlemek içindir [15]. Sınıflandırma sistemi online mağazalarda veya sosyal medyada ürün görselini gördüğü anda görselin üzerine etiket ve isteğe bağlı ürün tanımlaması getirebilir [4]. Ayrıca, giysilere etiketler veya otomatik açıklama ekleyerek, sosyal ağlardan bir kullanıcının fotoğrafını almak gibi, daha etkin bilgi alınmasına olanak tanıyalabilir [12]. Kataloglara sürekli eklenen yeni ürün akışı göz önüne alındığında, görüntü etiketlerinin otomatik olarak oluşturulması, çalışanların iş yükünü hafifletebilir, ilgili ürünlerde hızlı erişimi kolaylaştırabilir ve metin içeren ürün açıklamalarının oluşturulmasına yardımcı olabilir [3].

Bu çalışmada CNN tabanlı sınıflandırma sistemlerinin Fashion-MNIST moda veri setinde, ürün çeşidi sınıflandırması amacıyla uygulanması gerçekleştirilmiştir. Derin öğrenme yöntemlerinden CNN, önemi yadsınamayacak moda sınıflandırma probleminin ele alınmasında etkin bir yöntem olarak kullanılmaktadır. CNN mimarisini oluştururken öncelikle gerekli katmanlar, sayıları ve katmanlar içindeki parametreler belirlenerek temel bir model geliştirilmiştir. Sonrasında bu temel model baz alınarak, L2 ve Dropout düzenleyici yöntemlerini ayrı ayrı ve birlikte içeren CNN modelleri oluşturulmuştur. Oluşturulan dört CNN modeli doğruluk değeri kullanılarak karşılaştırılmıştır. Edinilen bulgulara göre Dropout içeren CNN modelinin en iyi sınıflandırma performansı sergilediği görülmüştür. Bu çalışmanın literatüre katkıları şu şekilde özetlenebilir:

- Yeni katman mimarilerine sahip CNN temelli sınıflandırıcılar önerilmiştir.
- Yeni sınıflandırıcılar L2 ve Dropout düzenleyici yöntemleri kullanarak ağ ezberleme probleminin azaldığı gözlenmiştir.
- Dropout içeren CNN modelinin en üstün tahmin doğruluğu sağladığı bulunarak, aynı veri setini kullanan diğer çalışmalarla kıyaslandığında çalışmaların coğundan üstün performans sağladığı görülmüştür.

Çalışmanın ilerleyen kısımları moda sınıflandırması ile ilgili literatürde yapılan çalışmalar ve yöntemin detaylı anlatılması ile devam edecektir. Sonrasında bulgular anlatılacak ve bulguların önemi ile gelecek çalışmalarla dair fikirler tartışma ve sonuç bölümünde detaylandırılacaktır.

2. Literatür Taraması

Derin öğrenmenin görüntü analizinde literatürde yaygın olarak kullanılmasının ana nedeni belirlenen problemin çözümünü yüksek bir doğruluk orANIyla gerçekleştirmesidir [1]. Bu durum görsel sınıflandırmasında da geçerlidir. Bu bölümde görsel ve özellikle moda sınıflandırmasında CNN kullanan çalışmalardan söz edilecektir.

Özbilgin ve Tepe [16], robotik uygulamalarda kullanılabilecek bir görsel tespiti ve sınıflandırma uygulaması gerçekleştirmiştir. Alexnet CNN mimarisini ve bölgesel CNN

uygulaması ile ev ve ofiste yer alan nesnelerin tespiti ve sınıflandırılması gerçekleştirilmiştir. Önerilen sistemin %93,81 doğruluk oranıyla çalıştığı bulunmuştur. Bilgin vd. [17], kuş türlerini bir kuş görsel veri seti kullanarak CNN mimarilerinden VGG16, ResNet50, ResNet152V2, InceptionV3, MobileNet ve DenseNet121 yapılarından yararlanarak sınıflandırmıştır. Elde edilen bulgular, DenseNet121 modelinin en iyi performansı sağladığını göstermiştir. Ay [18], video karelerinde yüzlerin korkutucu veya normal olarak sınıflandırılabilmesi için literatürde yer alan ResNet, VGGNet, MobileNet, InceptionNet ve DenseNet CNN mimarilerini uygulamıştır. HorrorFace veri seti kullanılarak yapılan çalışmada, ResNet modelinin en yüksek doğruluk değeri sunduğu bulunmuştur. Eshwar vd. [12], CNN kullanarak hem giysi türü sınıflandırması hem de benzer görseli getiren bir sistem oluşturmuştur. Moda verisi bir web sitesinden toplanmıştır. Veri seti 5 kıyafet türü içeren 5093 görselden oluşmaktadır. Yazarlar GoogLeNet CNN mimarisini, veri setine uygun olacak şekilde düzenleyip uygulamışlardır. Elde edilen bulgulara göre %98 oranında test verisi doğruluğu elde etmişlerdir. Ayrıca görseller arasındaki benzerlik değerleri kullanılarak kullanıcılarla benzer ürünler getiren bir sistem de oluşturulmuştur. Baheti vd. [19], dikkati dağılmış sürücü tespiti için VGG-16 CNN mimarısını kullanmıştır. Ayrıca L2, Dropout ve batch normalizasyon tekniklerinin sistemin performansı üzerindeki etkileri incelenmiştir. Düzenleyiciler kullanarak VGG-16 mimarısı %95,54 sınıflandırma doğruluğu ortaya çıkarmıştır. Cho vd. [11] moda sınıflandırmasında CNN tabanlı hiyerarşik bir sınıflandırma yöntemi önermiştir. Kullandıkları veri oldukça büyük boyutlu olan DeepFashion veri setidir. Hiyerarşik yapının sınıflandırma performansını artırdığı görülmüştür. Kolisnik vd. [7], koşul-CNN (condition-CNN) ismini verdikleri hiyerarşik bir yapıyı CNN'de görsel sınıflandırma için kullanmışlardır. Koşul-CNN, sınıf tahminlerini yapmak için farklı sınıf seviyeleri arasındaki ilişkiye koşullu olasılıklar olarak öğrenir. Kaggle Moda Ürün Resimleri veri setini kullanarak yapılan uygulamada Koşul-CNN modelinin, temel CNN modellerine kıyasla daha az eğitilebilir parametre gerektirdiği ve üstün bir tahmin doğruluğu sağladığı görülmüştür. Sun vd. [20], görsel sınıflandırma için CNN'de kullanılan ağırlık değerlerinin atanmasında genetik algoritmaları kullanmıştır. Yazarlar önerilen modelin sınıflandırma hatasını önemli ölçüde azalttığını bulmuşlardır.

Bhatnagar vd. [6], Fashion-MNIST veri setini kullanarak farklı CNN mimarileri ile ürün sınıflandırması yapmıştır. Yazarlar, üç farklı CNN modeli önermişlerdir. Bu modeller temel CNN modeli, CNN ile batch normalizasyon modeli ve CNN ile hem batch normalizasyon yöntemi hem de residual skip connections (skip) yöntemlerinin birlikte kullanıldığı modeldir. Bulgulara göre en iyi performansı %92,54 doğruluk değeri ile CNN ile batch normalizasyon ve skip yöntemlerinin birlikte kullanıldığı modelin sağladığı görülmüştür. CNN'de giysi sınıflandırması için hiyerarşik yapıyı kullanan bir başka çalışma Seo ve Shin [4] tarafından gerçekleştirilmiştir. Yazarlar VGGNet CNN mimarısını Fashion-MNIST veri setinde hiyerarşik olarak uygulamışlardır. Bulgular hiyerarşik olmayan mimariye göre sonuçlarda doğruluğun arttığını ve kaybın (loss) azaldığını göstermiştir. Önerilen modelin test veri

setindeki doğruluk değeri %93,52 olarak hesaplanmıştır. Greeshma ve Sreekumar [21], hiper parametre optimizasyonun ve Dropout düzenleyici yöntemlerin CNN sınıflandırma performansındaki rolünü araştırmışlardır. Çalışmada moda sınıflandırması için Fashion-MNIST veri seti kullanılmıştır. Yazarlar veri büyütme (Data Augmentation) uygulaması da gerçekleştirmiştir. Bulgular hiper parametre optimizasyonu ile Dropout içeren CNN modelinin %93.99 doğruluk değeri ortaya çıkardığını göstermiştir. Meshkini vd.[3], Fashion-MNIST veri setini kullanarak literatürde yer alan CNN mimarilerinden AlexNet, GoogleNet, VGG, ResNet, DenseNet ve SqueezeNet yapılarının sınıflandırma performansını karşılaştırmıştır. Batch normalizasyon ile SqueezeNet yapısının %93.43 ile en yüksek doğruluk değerini ortaya çıkardığı bulunmuştur. Kayed vd. [9], literatürde yer alan CNN tabanlı LeNet-5 mimarisini Fashion-MNIST veri seti sınıflandırmasında kullanmıştır. Eğitim aşamasından sonra test verisi tahmin değerlerine göre LeNet-5 modelinin %98 doğruluk ile sınıflandırma yaptığı bulunmuştur.

Yakın zamanda yapılmış bir çalışmada MNIST ve Fashion-MNIST veri setleri kullanılarak Kuantum CNN adı verilen modeller oluşturulup uygulanmıştır [22]. Kuantum CNN Fashion-MNIST için %93,6 doğruluk değeri ortaya çıkmıştır. Henrique vd. [23] çalışmalarında farklı CNN mimarilerini kullanılan Dropout değeri açısından karşılaştırmıştır. Düşük Dropout değeri içeren CNN-Dropout-3 modeli %99,1 validasyon doğruluk değeri ile en iyi model seçilmiştir. Khanday vd. [24] ise filtre boyutu açısından CNN modellerini CIFAR10 ve FashionMNIST veri setini kullanarak karşılaştırmıştır. Model performansının filtre boyutu ile ters orantılı olduğu görülmüştür. 3x3 filtrenin her iki veri setinde de en iyi performansı sağladığı bulunmuş ve Fashion-MNIST için en iyi doğruluk değeri %93,68 olarak bulunmuştur.

Literatürde yapılan çalışmalarla bakıldığından moda sınıflandırması için çok sayıda farklı CNN mimarisinin kullanıldığı görülmektedir. Ayrıca farklı düzenleyici yöntemlerin CNN performansına etkileri de araştırılmıştır. Ancak, L2 düzenleyici yönteminin hem ağızberlemeye hem de tahmin doğruluğuna olan etkisini araştıran bir çalışmaya rastlanmamıştır. Bu çalışma CNN mimarisi ile sınıflandırma tahmininde Dropout ve L2 düzenleyici yöntemlerin etkisinin birlikte araştırılmasıyla literatüre katkı sağlamaktadır. Bununla birlikte verimli bir şekilde hesaplama yapan ve sınıflandırma performansı yüksek olan CNN mimarileri de önerilmektedir.

3. Materyal ve Yöntem

Bu çalışmada Zolando Research tarafından oluşturulmuş moda ürünleri veri seti Fashion-MNIST kullanılmıştır [25]. Bu veri, 28 x 28 piksel boyutlu, siyah-beyaz, 70 000 moda ürünü görseli içermektedir. Ürünler 10 ayrı kategoriden oluşmakta olup her bir kategoride 7000 ürün resmi bulunmaktadır. Eğitim veri seti 60000, test veri seti de 10000 görselden oluşmaktadır. Bu çalışmada test veri setinin %80'i doğrulama verisi olarak kullanılmıştır. Bir diğer deyişle test verisinde 8000 görsel doğrulama setini, 2000 görsel de test setini oluşturmaktadır. Önerilen modeller eğitim setinde eğitilmiş,

doğrulama seti ile performansı gözlenmiş ve test veri setini kullanarak sınıflandırma tahmini doğruluğu analiz edilmiştir. Fashion-MNIST veri setine Zolando Research GitHub hesabından ulaşılmaktadır [26]. Şekil 1, veride yer alan kategorileri ve her bir kategoriye ait örnek resimleri göstermektedir.



Şekil-1: Fashion-MNIST kategorileri ve örnek resimler [27]

3.1. Evrişimsel Sinir Ağları (CNN) Mimarisi

CNN, görüntü işleme konularında birbirinden farklı çok sayıda mimari ile literatürde yaygın bir şekilde yer almaktadır. Temel olarak, evrişimsel ya da konvolüsyonel ağ, normal bir görüntüyü dikdörtgen bir kutu olarak alır ve kare piksel parçalarını kullanarak kernel olarak da bilinen bir filtreden geçirir [3]. Her konvolüsyon katmanı, girdiye bir evrişim işlemi uygular ve sonucu bir sonraki katmana iletir. CNN'de birden fazla kez tekrar edebilecek şekilde arkaya arkaya konvolüsyon (convolution) ve havuzlama (pooling) katmanları bulunur. Bu aşamalardan sonra tam bağlı katman ile yapay sinir ağları (ANN) yapısına dönüştürülür. Sonrasında çıktı oluşturabilmek için sınıflandırıcı fonksiyonu uygulanır. CNN'de giriş verisi alınarak katman katman işlemleri ile model eğitimi gerçekleştirilir [1]. Sınıflandırıcı fonksiyon sonuç hesaplaması yaptığından hedef sonuç ile farkı bulunarak hata hesaplaması yapılır ve bu hatanın azaltılması amacıyla ağırlıkların tekrar güncellenmesi için geriye yayılım algoritması kullanılır. CNN'de yer alan katmanlar detaylı bir şekilde ilerleyen kısımda anlatılmaktadır.

Konvolüsyon Katmanı (Convolution Layer): Bu katmanda öncelikle çok küçük boyutlu, genellikle 3x3, 4x4 veya 5x5 olan bir filtr (kernel) oluşturulur. Oluşturulan filtr her bir görsel üzerinde kaydırılarak bir özellik haritası ortaya çıkarılır. Filtre değerleri ile görüntünün üzerinde gezinirken karşılaşılan değerler çarpılarak bu çarpımların toplamı hesaplanır. Aynı filtr her bir görselde uygulanır. Bu işlem hesaplayıcı belleğini verimli bir şekilde kullanmaya imkan verir [6]. Hesaplanan çarpım toplamına doğrusal olmayan bir aktivasyon fonksiyonu uygulanır ve böylece konvolüsyon katmanının çıktısı hesaplanır. Bu çalışmada aktivasyon fonksiyonu olarak ReLu kullanılmıştır.

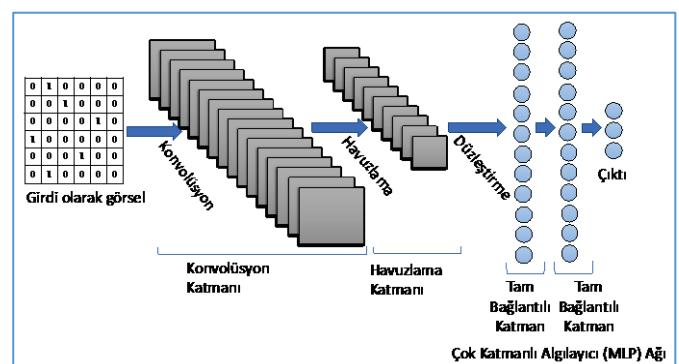
Havuzlama Katmanı (Pooling Layer): Konvolüsyon katmanında oluşan çıktı havuzlama katmanına girer. Burada amaç bir sonraki konvolüsyon katmanı için görüntünün boyutunu küçültmektir. Küçültme işlemi için maksimum havuzlama (Max Pooling) yaygın olarak kullanılmaktadır.

Maksimum havuzlama işlemi, dikdörtgensel komşuluk içindeki maksimum çıktıyı bildirir [28]. 4x4 boyutundaki bir matrise 2x2'lik maksimum havuzlama uygulaması sonucu Şekil 2'de belirtilmiştir.

$A =$	<table border="1" style="display: inline-table; vertical-align: middle;"> <tr><td>2</td><td>5</td><td>3</td><td>9</td></tr> <tr><td>1</td><td>6</td><td>8</td><td>4</td></tr> <tr><td>4</td><td>6</td><td>2</td><td>1</td></tr> <tr><td>5</td><td>7</td><td>3</td><td>8</td></tr> </table>	2	5	3	9	1	6	8	4	4	6	2	1	5	7	3	8	<table border="1" style="display: inline-table; vertical-align: middle;"> <tr><td>2</td><td>5</td><td>3</td><td>9</td></tr> <tr><td>1</td><td>6</td><td>8</td><td>4</td></tr> <tr><td>4</td><td>6</td><td>2</td><td>1</td></tr> <tr><td>5</td><td>7</td><td>3</td><td>8</td></tr> </table>	2	5	3	9	1	6	8	4	4	6	2	1	5	7	3	8	$\text{MaxP}(A) =$	<table border="1" style="display: inline-table; vertical-align: middle;"> <tr><td>6</td><td>9</td></tr> <tr><td>7</td><td>8</td></tr> </table>	6	9	7	8
2	5	3	9																																					
1	6	8	4																																					
4	6	2	1																																					
5	7	3	8																																					
2	5	3	9																																					
1	6	8	4																																					
4	6	2	1																																					
5	7	3	8																																					
6	9																																							
7	8																																							

Şekil-2: 4x4 boyutunda bir matrise 2x2'lik filtr ile Maksimum Havuzlama uygulanması

Düzleştirme İşlemi (Flattening): Konvolüsyon ve havuzlama işlemi gerçekleştikten sonra ağı derinleştirmek adına elde edilen çıktı tekrar konvolüsyon ve havuzlama işlemlerine tabi tutulabilir. Böylece bir seri katman ortaya çıkar. Bu seri katmanlardan ortaya çıkan çok boyutlu görüntüleri tek boyutlu bir vektöre indirmek gereklidir ki çok katmanlı algılayıcı (Multi Layer Perceptron – MLP) ağı yapısına sınıflandırma işlemi için giriş yapabilse [6]. Bu işlemeye düzleştirme (flattening) işlemi denir. Şekil 3, üç sınıf tahmini yapan bir CNN mimarisini tüm temel katmanları ve aşamalarıyla göstermektedir.



Şekil-3: Evrişimsel Sinir Ağı (CNN) Mimarisi

Tam Bağlantı katmanı (Fully Connected Layer): Düzleştirme işleminden sonra CNN yapısına yeni bir MLP ağı yapısı eklenmektedir. Düzleştirme işleminde ortaya çıkan tek boyutlu vektör CNN'de yer alan önceki tüm aşamalara bağlıdır bu nedenle tam bağlı katman adını alır [1]. Şekil 3'te gösterildiği gibi bu katmanlar MLP ağı yapısı ile ayrı bir sinir ağı olarak çalışarak sınıflandırma çıktılarını ortaya koyar.

Çıktı Katmanı (Output Layer): Tam bağlı katmanın dışında oluşan çıktı hedef değer tahmini yapmak için kullanılmalıdır. CNN probleminde amaç çoklu sınıf tahmini yapmaktadır. Bunu başarmak için, tam bağlı katmanı çıktısı softmax aktivasyon fonksiyonu kullanılarak, alternatif sonuçların olasılık dağılımını içeren bir vektöre dönüştürülür [2]. Çıktı katmanında sınıf sayısı kadar nöron olmalıdır. En yüksek olasılık değerine sahip sonuç tahmin edilen sınıf olur.

3.2. Düzenleyici Teknikler (Regularization Techniques)

CNN mimarisinde eğitim işlemi esnasında ağı ezberleme (overfitting) problemi ortaya çıkabilir. Ağ ezberleme problemini ortadan kaldırabilmek için düzenleyici teknikler kullanılır. Bu çalışmada kullanılacak düzenleyici teknikler Dropout ve L2'dir.

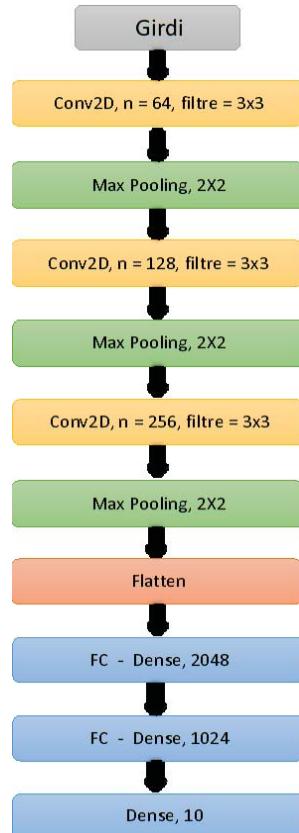
Dropout Katmanı: Dropout terimi, bir sinir ağındaki gizli ve gizli olmayan birimleri devre dışı bırakmayı ifade eder. Bir birimi devre dışı bırakmakla, tüm gelen ve giden bağlantıları ile ağdan geçici olarak çıkarılması kastedilmektedir ve bırakma işlemi rassal olarak gerçekleştirilir. Ağ ezberlemenin önüne geçer ve birçok farklı sinir ağı mimarisini verimli bir şekilde birleştirmenin yolunu sağlayan bir yöntemdir [29]. Dropout katmanı, havuzlama, düzleştirme ve/veya tam bağlantılı katman sonrasında kullanılabilir. Dropout uygulanırken birimlerin ne kadarının atılacağına dair bir yüzdelik değer belirlenir. Bu çalışmada her bir katmandan sonra farklı bir Dropout değeri belirlenmiştir.

L2 düzenleyici: Öğrenme sürecindeki ağ ezberlemeyi azaltmak için kullanılan bir tekniktir. Ağdaki ağırlıkların düzenlenmesi ile ilgilidir. Daha düşük ağırlıklar içeren bir modelin daha yüksek ağırlıklar içeren bir modele göre daha basit çalışacağı varsayımla sahiptir [19]. Parametrelerin ağırlıklarına $\frac{1}{2}\lambda w^2$ işlemi uygulanır. Burada λ düzenleyici gücünü belirleyen bir hiper parametredir [19]. Bu çalışmada $\lambda = 0,0015$ olarak kullanılmıştır.

3.3. Önerilen CNN mimarisi

Bu çalışmada önerilen CNN mimarisi temel mimari ve Dropout içeren mimarı olarak iki şekilde sunulmuştur. Temel CNN ve Dropout CNN sırasıyla Şekil 4 ve 5'te görülebilir. Temel CNN mimarisi 3 adet konvolüsyonel katman ve onları takip eden 3 adet havuzlama katmanından oluşmaktadır. Konvolüsyon katmanlarındaki nöron sayıları sırasıyla 64, 128 ve 256'dır. Kullanılan filtre de 3x3'dür. Havuzlama katmanı filtresi ise 2x2'dir. Konvolüsyon ve havuzlama katmanları bittikten sonra düzleştirme (flatten) katmanı yer alır. Sonrasında 2 tane tam bağlantılı katman bulunur. Tam bağlantılı katmanlardaki nöron sayısı ise sırasıyla 2048 ve 1024'tür. Son olarak, kategori sayısı olan 10 adet nöronundan oluşan çıktı katmanı yer alır. Dropout içeren model mimarisinde ise Şekil 5'te görülebileceği üzere havuzlama, düzleme ve tam bağlantılı katmanlarından sonra Dropout katmanı yer almıştır. Kullanılan Dropout oranları ilgili katmanlar için sırasıyla 0,15, 0,2, 0,3, 0,4, 0,4 ve 0,4'tür.

Önerilen modelin temel amacı, verilen veri setindeki özellikleri öğrenerek, karşılaşacağı yeni görselleri doğru bir şekilde sınıflandırmasıdır. Bunu yapmak için sınıflandırma ile ilgili model kayıpları (model loss) en aza indirilmelidir. En aza indirme işlemi de optimize edici kullanılarak gerçekleştirilir. Optimize ediciler, kayıpları en aza indirmek için ağırlıklar ve öğrenme oranı gibi sinir ağı özelliklerini değiştirmek için kullanılan algoritmalar veya yöntemlerdir [2]. Geri yayılım algoritması ile ağırlıklar ve öğrenme oranı güncellenerek kayıp en aza indirilmeye çalışılır. Bu çalışmada optimize edici olarak Adam yöntemi kullanılmıştır. Hata hesaplaması yapabilmek için ise bir kayıp fonksiyonu (loss function) kullanmak gerekmektedir. Bu çalışmada ele alınan konu bir sınıflandırma problemi olduğu için kayıp fonksiyonu olarak kategorik çapraz entropi (categorical cross entropy) fonksiyonu kullanılmıştır.



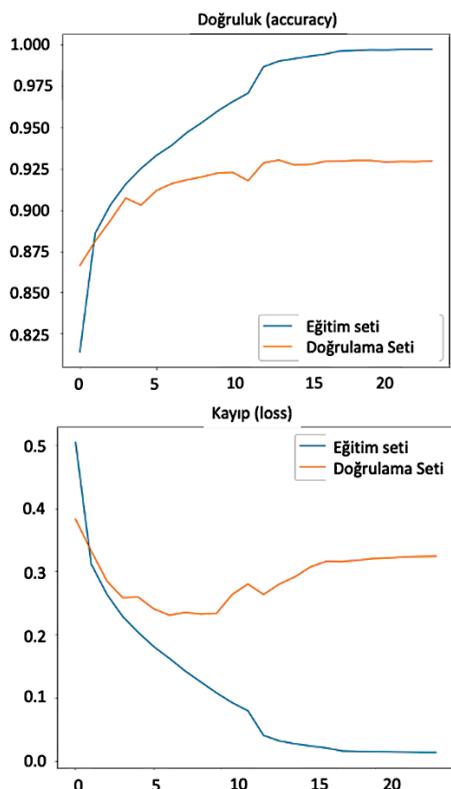
Şekil-4: Temel CNN mimarisi



Şekil-5: Dropout içeren CNN mimarisi

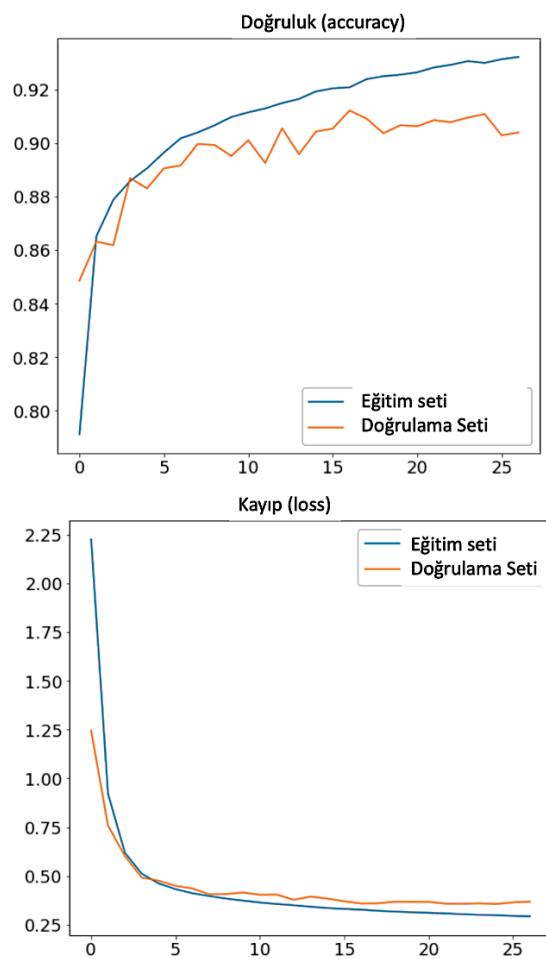
4. Bulgular

Belirtilen CNN mimarileri Python 3 programlama dili ile, Tensorflow 2 ve Keras kütüphaneleri kullanılarak yazılmıştır. Her bir CNN mimarisinin batch boyutu 32 ve epoch miktarı 100 olacak şekilde çalıştırılmıştır. Modellerin çalıştırılması, hesaplama zamanını minimize edebilmek için Google Collab üzerinden kullanıcılarına ücretsiz sunulan bir GPU kullanılarak gerçekleştirilmiştir. Önerilen CNN mimarileri, L2 düzenleyicinin etkisini görebilmek adına, L2 içerecek ve içermeyecek şekilde çalıştırılmıştır. Bu nedenle birbiri ile karşılaştırılan dört model ortaya çıkmıştır. Bu modellerin şekilde adlandırılmıştır; Temel CNN, Temel CNN + L2, Dropout CNN, Dropout CNN + L2. Öncelikle önerilen modeller için artan epoch'lar boyunca eğitim ve doğrulama seti için kayıp (loss) nasıl azaldığı ve doğruluğun nasıl arttığı gözlenmelidir. Önerilen dört model için eğitim ve doğrulama veri setine dair kayıp ve doğruluk değişimi sırasıyla Şekil 6, 7, 8 ve 9'da görülebilir.



Şekil-6: Temel CNN modeli için doğruluk ve kayıp değişimi

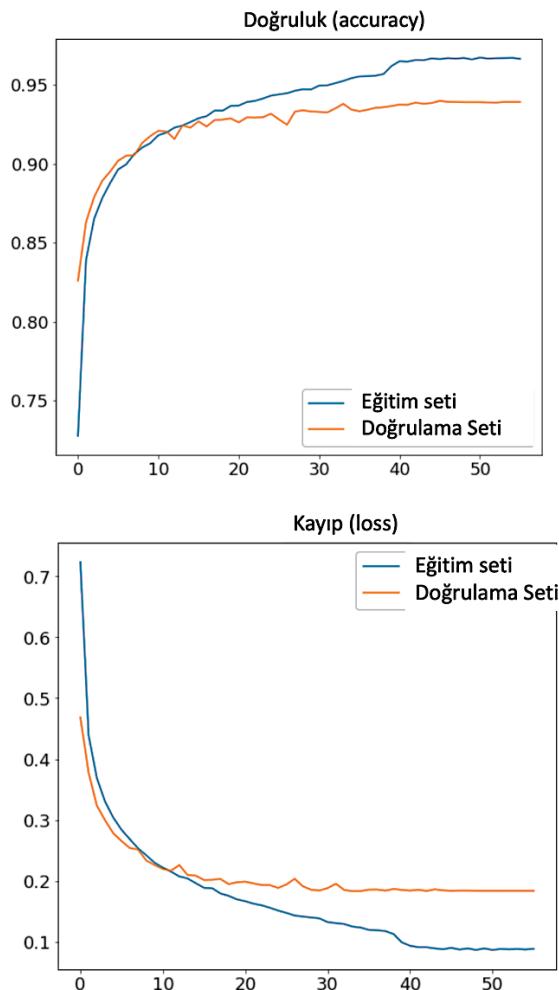
Şekil 6 incelendiğinde eğitim ve doğrulama seti doğruluk değerleri ile kayıp değerleri arasındaki farkın çok fazla olduğu görülmektedir. Eğitim doğruluk değeri neredeyse %100'e çıkarken doğrulama seti doğruluk değeri %92.5 civarındadır. Bu durum bize eğitim setinde ağ ezberlemenin ortaya çıktığını göstermektedir. Gözlenen ağ ezberlemeyi ortadan kaldırmak için öncelikle Temel CNN modeline L2 düzenleyici yöntemi kullanılmıştır. Temel CNN + L2 modeli için eğitim ile doğrulama seti doğruluk ve kayıp değerleri değişimi Şekil 7'de görülebilir.



Şekil-7: CNN + L2 modeli için eğitim ile doğrulama seti doğruluk ve kayıp değişimi

Şekil 7 incelendiğinde eğitim ve doğrulama verileri için doğruluk ve kayıp değerlerinin birbirine yaklaştığını görmekteyiz. Özellikle kayıp değerleri birbirine oldukça yakındır. Ancak, doğrulama seti doğruluk değerinin temel modele göre düşürü, %90 civarında olduğu görülmektedir. Bu durum test veri seti için tahmin performansının da düşebileceğini göstermektedir. Diğer düzenleyici yöntem olan Dropout yönteminin eğitim ve doğrulama veri setleri için kayıp ve doğruluk grafikleri Şekil 8'de yer almaktadır.

Şekil 8 incelendiğinde Dropout CNN modelinde eğitim veri seti için doğruluk değeri %97 civarındayken, doğrulama veri seti için bu değerin neredeyse %94 olduğu görülmektedir. Her iki set için doğruluk farkı temel CNN modeline göre daha azdır. Bu nedenle CNN Dropout modelinin temel modele göre ağ ezberlemeyi azalttığı söylenebilir. Şekil 9'a bakıldığında hem Dropout hem de L2 içeren CNN modelinin eğitim veri seti ve doğrulama veri seti için doğruluk değerlerinin %92 civarında olduğu görülmektedir. Bu yöntemin de temel modele göre ağ ezberlemeyi oldukça azalttığı söylenebilir.

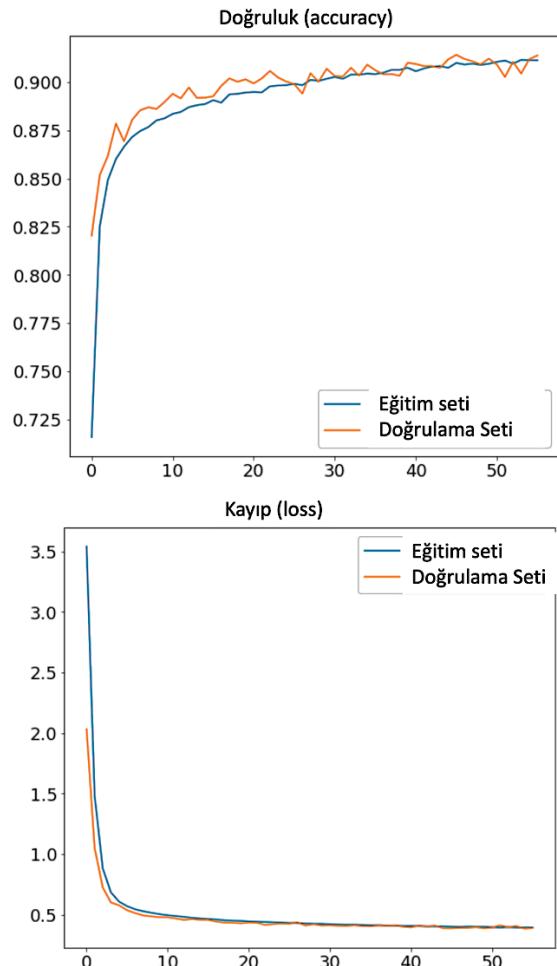


Şekil-8: CNN + Dropout yönteminin eğitim ve doğrulama veri setleri için kayıp ve doğruluk değişimi

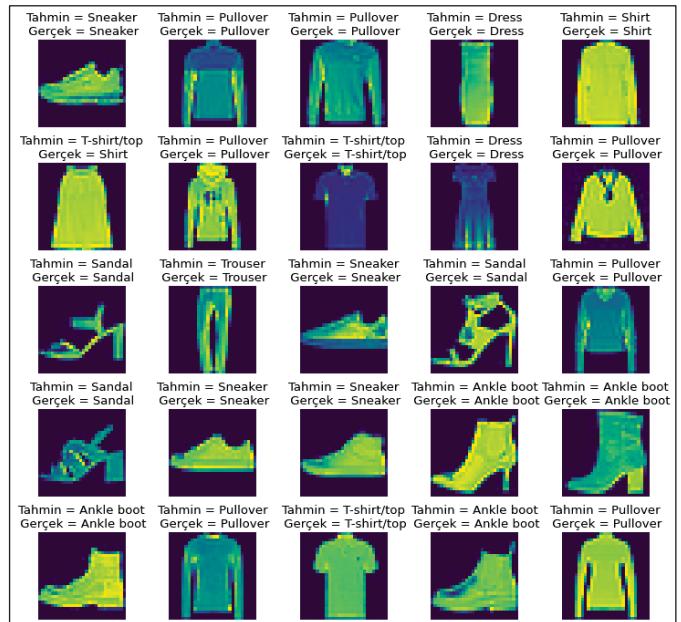
Bütün modeller için eğitim ve doğrulama veri setlerine dair doğruluk ve kayıp değerleri Çizelge 1'de görülmektedir. V 1'e göre en yüksek doğrulama seti doğruluk değeri Dropout CNN modeline aittir. Bu nedenle, Dropout CNN mimarisinin diğer mimarilere göre daha iyi çalıştığı söylenebilir. L2 düzenleyici yönteminin mimarideki ağ ezberleme sorununu azaltlığı ancak tahmin doğruluğunu da olumsuz etkilediği görülmüştür. Tahmin performanslarını görmek için her bir mimariden test veri seti kullanılarak sınıflandırma tahmini yapması istenmiştir. Buna göre test doğruluk değerleri de hesaplanmıştır. Dört mimari için test doğruluk değerleri de Çizelge 1'de gösterilmiştir. Çizelge 1'e göre tahmin performansı açısından en başarılı modelin %94,3 test doğruluk değeri ile Dropout CNN modeli olduğu görülmüştür. Dropout CNN modeliyle gerçekleştirilen tahminleri görmek adına test verisi içinden rassal olarak 25 adet test verisi alınmıştır ve bu test verisinin gerçek sınıfları ile tahmini sınıf değerleri Şekil 10'da gösterilmiştir.

Çizelge-1: Bütün modellerde eğitim, doğrulama ve test seti için doğruluk değerleri

	Temel CNN	CNN + L2	Dropout CNN	Dropout CNN +L2
Eğitim verisi	1,000	0,932	0,988	0,929
Doğrulama verisi	0,930	0,904	0,939	0,914
Test verisi	0,936	0,909	0,943	0,919



Şekil-9: CNN + L2 + Dropout modelinin eğitim ve doğrulama veri setleri için kayıp ve doğruluk değişimi



Şekil-10: Yirmibeş test verisinin CNN + Dropout modeli ile tahmini değerleri ve gerçek değerler ile karşılaştırılması

Şekil 10'da görüldüğü üzere, Dropout CNN modelinin sadece bir hata yaptığı görülmektedir. Shirt olan altıncı ürünü T-shirt/top olarak tahmin etmiştir. Modelin diğer bütün tahminleri ise doğrudur. Dropout CNN modelinin sınıflar

bazında nasıl performans sergilediğini görebilmek adına sınıflandırma raporu (classification report) ve karışıklık matrisi (confusion matrix) oluşturulmuştur. Sınıflandırma raporunda kullanılan performans göstergeleri Precision, Recall ve F1 skorudur. Bu değerler aşağıdaki formüller ile hesaplanır:

$$Precision = \frac{TP}{TP + FP} \quad (1)$$

$$Recall = \frac{TP}{TP + FN} \quad (2)$$

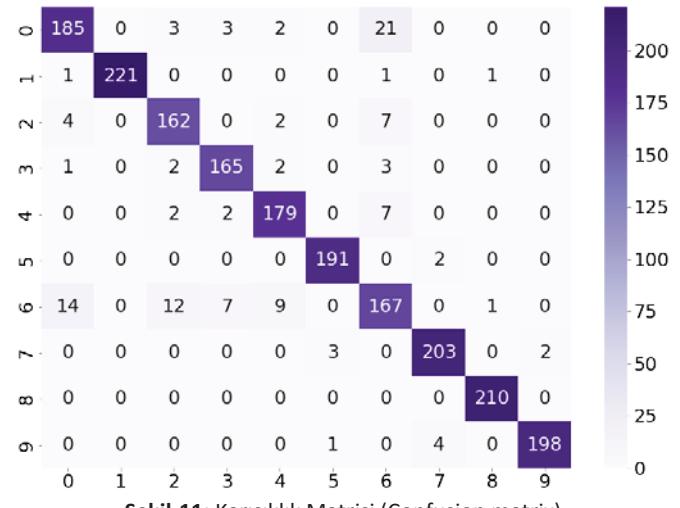
$$F1\ Score = \frac{2 * Precision * Recall}{Precision + Recall} \quad (3)$$

Burada, TP (Gerçek Pozitif), sınıflandırıcı tarafından doğru olarak sınıflandırılan çıktı sayısını, TN (Gerçek Negatif), sınıflandırıcı tarafından doğru olarak sınıfa ait değildir şekilde sınıflandırılan çıktıların sayısını; FP (Yanlış Pozitif), yanlış olarak sınıfa aittir olarak sınıflandırılan çıktı sayısını ve FN (Yanlış Negatif), yanlış olarak sınıfa ait değildir şekilde etiketlenmiş çıktı sayısını ifade eder.

On farklı kategori için Precision, Recall ve F1 skoru değerleri Çizelge 2'de görülmektedir. En düşük Precision, Recall ve F1 değerine ait kategorinin Shirt olduğu görülmektedir. Daha sonra T-shirt/top gelmektedir. Bu iki sınıfın tahmin performanslarının daha düşük çıkışının nedeni birbirine benzer iki kategori olmasıdır. Şekil 10'daki tahmin değerleri içerisinde tek yanlış tahmin Shirt olması gerekirken T-shirt/Top olarak yapılan tahmindir. Bu iki kategorinin yanlış tahmin edilebilme durumu karışıklık matrisinde de görülmektedir. Şekil 11'de yer alan karışıklık matrisine göre, Shirt sınıfı 14 kere T-shirt/Top olarak tahmin edilirken, T-shirt/top sınıfı 21 kere Shirt olarak tahmin edilmiştir. Bu iki sınıfın sona en fazla yanlış tahmin edilen kategori Pullover olmuştur. Shirt sınıfı 12 kere Pullover olarak tahmin edilmiştir, Pullover da 7 kere Shirt olarak tahmin edilmiştir. Tahmin performansı açısından en başarılı kategori 221 doğru tahmin ile Trouser'dır. Onu, 210 doğru tahmin ile Bag sınıfı izlemektedir.

Çizelge-2: Sınıflandırma raporu

	Etiket	Precision	Recall	f1-skoru	Veri sayısı
T-Shirt/Top	0	0,898	0,86	0,878	214
Trouser	1	0,991	0,991	0,991	224
Pullover	2	0,899	0,92	0,91	175
Dress	3	0,927	0,96	0,943	173
Coat	4	0,938	0,953	0,945	190
Sandals	5	0,985	0,99	0,987	193
Shirt	6	0,824	0,805	0,814	210
Sneaker	7	0,971	0,981	0,976	208
Bag	8	0,995	1	0,998	210
Ankle Boots	9	0,99	0,975	0,983	203
Ortalama		0,942	0,943	0,943	2000



Şekil-11: Karışıklık Matrisi (Confusion matrix)

Bu çalışmanın sonuçları son yıllarda Fashion-MNIST veri seti kullanarak sınıflandırma yapmış çalışmalarдан elde edilen bulgularla karşılaştırılmıştır. Önceki çalışmaların sınıflandırma sonucunda elde ettikleri test verisi doğruluk değerleri Çizelge 3'te görülebilir. Çizelge 3'te belirtilen çalışmaların detayları için literatür taraması bölümü incelenebilir. Çizelge 3'teki değerlere göre mevcut çalışma karşılaştırma yapılan sekiz çalışmanın altısından daha yüksek test doğruluğu ortaya çıkmıştır. Bu çalışmada ortaya çıkan 0,9430 doğruluk değeri diğer çalışmalar ile karşılaştırılabilir sonuçlar elde edildiğini göstermektedir. İki çalışma ise mevcut çalışmadan daha yüksek test doğruluk değeri ortaya çıkmıştır. Bu iki çalışmanın ilki Kayed vd. [9]'nin yapmış olduğu CNN LeNet-5 çalışmasıdır. Yazarlar bu çalışmada literatürde yer alan başarısı önceden tespit edilmiş çok katmanlı bir CNN ağı kullanmışlardır. Yazarların başarısı ağıın derinliğinden ve katman sayısının çokluğundan kaynaklanmaktadır. Doğruluk değerinin yüksek olduğu bir diğer çalışma ise Henrique vd. [23] tarafından geliştirilmiştir. Bu çalışmada önerilen CNN mimarileri verilen parametre değerleri ile denenenmiş ancak yazarlarla aynı doğruluk miktarı elde edilememiş, mevcut çalışmadan daha düşük doğruluk değerleri bulunmuştur.

Çizelge-3: Literatürdeki çalışmalar ile karşılaştırma

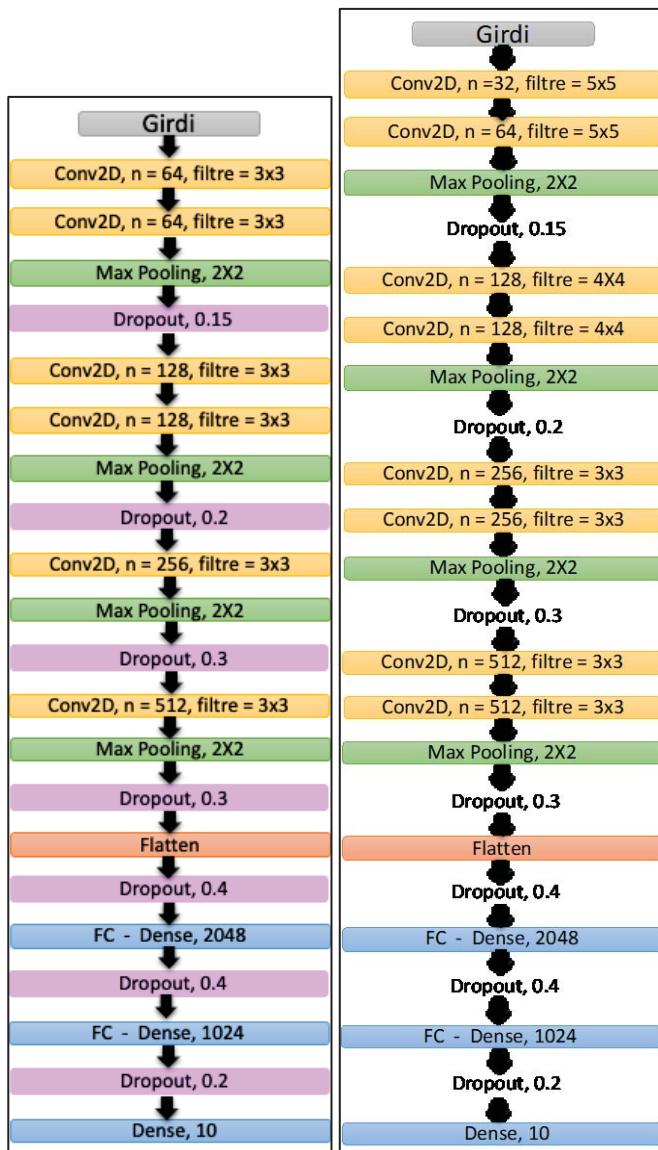
Çalışma	Model	Test Doğruluğu
Bhatnagar et al. [6]	CNN + BN + skip	0,9254
Seo & Shin [4]	CNN VGGNet	0,9352
Greeshma & Sreekumar [21]	CNN + HPO + Dropout	0,9399
Meshkini et al. [3]	CNN SqueezeNet + BN	0,9343
Kayed et al. [9]	CNN LeNet-5	0,9800
Hur et al. [22]	Kuantum CNN	0,9360
Henrique et al. [23]	CNN-Dropout-3	0,9910
Khanday et al. [24]	CNN 3x3 filtre	0,9368
Bu çalışma	CNN + Dropout	0,9430

Hesaplama verimliliği göz önünde bulundurulduğunda mevcut çalışmanın öne sürdüğü modeller herkesin erişimine açık bir sunucuda (Google Colab GPU) makul çalışma sürelerine sahiptir. Bunun yanında son dönemde Fashion-MNIST veri seti kullanarak sınıflandırma yapmış sekiz çalışmanın altısından daha yüksek test doğruluğu ortaya

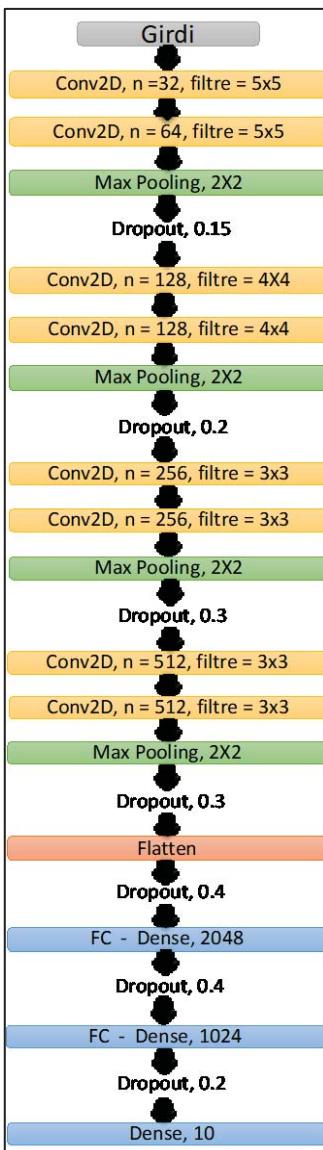
çıkarmıştır. Bu nedenle mevcut çalışmadan öne sürülen CNN + Dropout mimarisinin moda ürünü sınıflandırmada başarılı bir model olduğu söylenilebilir.

Alternatif Mimarilerin ve Hiperparametre Değerlerinin Uygulanması

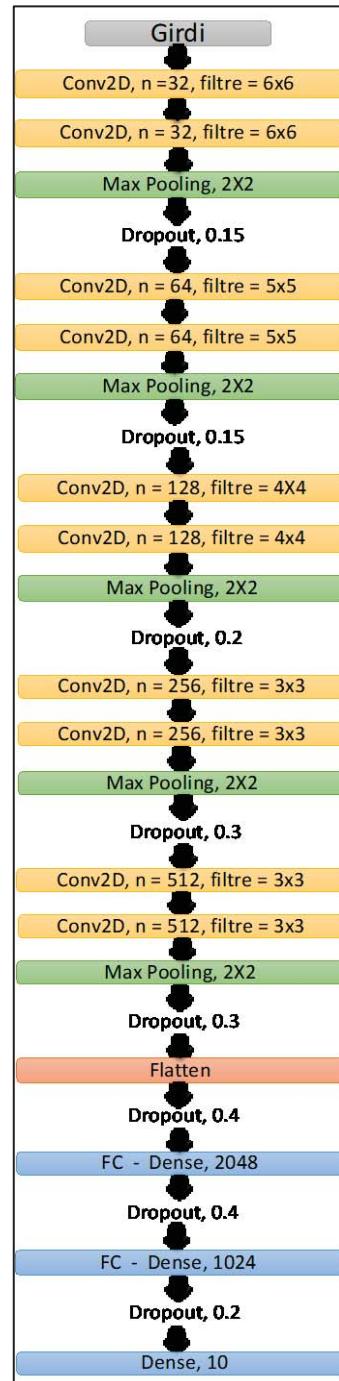
Bu çalışmada önerilen mimariye alternatif olarak daha fazla katman ve hiperparametre içeren üç ayrı CNN mimarisı oluşturulmuştur. Bu mimarilerin oluşturulmasının amacı mevcut mimari ile elde edilen doğruluk değerlerinin iyileştirilip iyileştirilemeyeceğinin gözlenmesidir. Her üç modelde daha fazla katman yer almaktadır. Ayrıca önerilen üç modelde değiştirilen parametreler, katmanlardaki nöron sayıları (n), kernel boyutu, kullanılan dropout kayman sayısı ve oranlarıdır. Buna göre önerilen 3 mimari Dropout düzenleyici teknik içeren yapısı ile bütün hiperparametre değerlerini gösterecek biçimde, Şekil 12, 13 ve 14'te sırasıyla görülmektedir.



Şekil-12: Önerilen birinci model



Şekil-13: Önerilen ikinci model



Şekil-14: Önerilen üçüncü model

Önerilen herbir model, dropout içermeyen temel mimari, L2 içeren mimari, dropout içeren mimari ve L2 ile dropout içeren mimari şeklinde Fashion Mnist verisetinde çalıştırılmış ve kıyafet sınıflandırılması yapılmıştır. Buna göre her bir mimari için elde edilen test verisi doğruluk değerleri Çizelge 4'te görülmektedir.

Çizelge-4: Öneriler için test verisi doğruluk değerleri

	Öneri 1	Öneri 2	Öneri 3
Temel CNN	0,9355	0,9355	0,9355
CNN + L2	0,9205	0,9235	0,9220
CNN + Dropout	0,9380	0,9420	0,9425
CNN + Dropout + L2	0,9185	0,9240	0,9215

Çizelge 4'te gösterilen bulgulara göre, önerilen bütün modeller için Dropout içeren mimari en yüksek doğruluk değerini ortaya çıkarmıştır. Bu sonuç bölüm 3.3'te önerilen mimari ile elde edilen bulgularla paralellilik göstermektedir. Bu bulgulara göre dropout düzenleyici tekniğinin CNN performansını artıracı bir teknik olduğu söylenebilir.

Önerilen mimariler, bölüm 3.3'te açıklanan mimari ile kıyaslandığında test verisi doğruluk değerlerinin benzer düzeyde çıktıgı görülmektedir. Yeni öneriler içinde en yüksek test doğruluk değerini CNN + Dropout mimarisi ile üçüncü model sağlamaktadır. Bu modelin test doğruluk değeri 0,9425'tir. Bu değer bölüm 3.3'te önerilen mimarinin Dropout modelinde ortaya çıkan test verisi doğruluk değeri (0,943) ile oldukça yakındır. Bu bölümde farklı katman sayıları ve hiperparametre değerleri ile denenen 3 model bu çalışmada en iyi performans sağlayan model ile benzer sonuçlar ortaya çıkarmıştır. Bu sayede, bu çalışmada en iyi performans sağlayan modelin güçlü bir mimari olduğu söylenilenbilir.

5. Sonuç ve Öneriler

Bu çalışmada CNN tabanlı moda ürünleri sınıflandırma sistemleri önerilmiştir. Her bir sınıflandırma sisteminde uygulamak için öncelikle temel bir CNN mimarisi belirlenmiştir. Bu temel mimariye ek olarak Dropout düzenleyici yöntemi içeren mimari de önerilmiştir. Ayrıca L2 düzenleyici yönteminin hem ağızlanmaya hem de tahmin performansına olan etkisi de araştırılmıştır. Elde edilen bulgular L2 düzenleyici yönteminin ağızlanmaya azaltıldığı görülmekte birlikte hem doğrulama hem de test doğruluk değerlerini düşürdüğü görülmüştür. Dropout içeren CNN modeli ise temel modele göre hem ağızlanmaya azaltmış hem de önerilen modeller içinde en yüksek test doğruluk değeri ile en iyi sınıflandırma performansı göstermiştir. Bu çalışma yeni katman mimarilerine sahip CNN temelli sınıflandırıcılar önermesi açısından literatüre katkı sağlamaktadır. Ayrıca son dönemlerde yapılmış aynı veri setini kullanan diğer çalışmaların çoğu ile karşılaştırılabilir sonuçlar sağladığı görülmüştür. Hesaplama gücü bu çalışma için sınırlayıcı bir unsurdur. Mevcut hesaplama gücü ile önerilen mimari boyutları ve sayısı belirli limitler içinde kalmaktadır. Daha derin ve daha fazla sayıda mimari test edebilmek için daha yüksek hesaplama gücü gerekmektedir. Önerilen moda sınıflandırma sisteminin gelecek çalışmalarda kullanıcılara ürün önerisi sağlayan bir tavsiye sistemi içinde kullanılması hedeflenmektedir.

Kaynakça

- [1] Ö. İnik and E. Ülker, "Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri," *Gaziosmanpasa Journal of Scientific Research*, vol. 6, no. 3, pp. 85–104, 2017.
- [2] M. Tripathi, "Analysis of Convolutional Neural Network based Image Classification Techniques," *Journal of Innovative Image Processing*, vol. 3, no. 2, pp. 100–117, 2021, doi: 10.36548/jiip.2021.2.003.
- [3] K. Meshkini, J. Platos, and H. Ghassemain, "An Analysis of Convolutional Neural Network for Fashion Images Classification (Fashion-MNIST)," in *International Conference on Intelligent Information Technologies for Industry*, 2020, pp. 85–95.
- [4] Y. Seo and K. shik Shin, "Hierarchical convolutional neural networks for fashion image classification," *Expert Systems with Applications*, vol. 116, pp. 328–339, 2019, doi: 10.1016/j.eswa.2018.09.022.
- [5] Y. Lecun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, no. 7553, pp. 436–444, 2015, doi: 10.1038/nature14539.
- [6] S. Bhatnagar, D. Ghosal, and M. H. Kolekar, "Classification of fashion article images using convolutional neural networks," in *Fourth International Conference on Image Information Processing*, 2017, pp. 357–362, doi: 10.1109/ICIIP.2017.8313740.
- [7] B. Kolisnik, I. Hogan, and F. Zulkernine, "Condition-CNN: A hierarchical multi-label fashion image classification model," *Expert Systems with Applications*, vol. 182, p. 115195, 2021, doi: 10.1016/j.eswa.2021.115195.
- [8] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks," *Handbook of Approximation Algorithms and Metaheuristics*, pp. 1–9, 2012, doi: 10.1201/9781420010749.
- [9] M. Kayed, A. Anter, and H. Mohamed, "Classification of Garments from Fashion MNIST Dataset Using CNN LeNet-5 Architecture," in *International Conference on Innovative Trends in Communication and Computer Engineering*, 2020, pp. 238–243, doi: 10.1109/ITCE48509.2020.9047776.
- [10] A. Orendorff, "10 Trends Styling 2021's Ecommerce Fashion Industry: Growth + Data in Online Apparel & Accessories Market," Common Thread Collective, 2022. [Online]. Available: <https://commonthreadco.com/blogs/coachs-corner/fashion-commerce-industry-trends#fashion-commerce-trend-market>.
- [11] H. Cho, C. Ahn, K. M. Yoo, J. Seol, and S. G. Lee, "Leveraging class hierarchy in fashion classification," in *International Conference on Computer Vision Workshop*, 2019, pp. 3197–3200, doi: 10.1109/ICCVW.2019.00398.
- [12] S. G. Eshwar, J. Gautham Ganesh Prabhu, A. V. Rishikesh, N. A. Charan, and V. Umadevi, "Apparel classification using Convolutional Neural Networks," in *International Conference on ICT in Business, Industry, and Government*, 2016, pp. 1–5, doi: 10.1109/ICTBIG.2016.7892641.
- [13] K. Hara, V. Jagadeesh, and R. Piramuthu, "Fashion apparel detection: The role of deep convolutional neural network and pose-dependent priors," in *IEEE Winter Conference on Applications of Computer Vision*, 2016, doi: 10.1109/WACV.2016.7477611.
- [14] M. Anjan and V. Abhishek, "Fashion recommendation system using CNN," *International Journal of Advance Research, Ideas and Innovations in Technology*, vol. 6, no. 3, pp. 780–783, 2020.
- [15] L. Bossard, M. Dantone, C. Leistner, C. Wengert, T. Quack, and L. Van Gool, "Apparel classification with style," *Lecture Notes in Computer Science*, pp. 321–335, 2013, doi: 10.1007/978-3-642-37447-0_25.
- [16] F. Özbilgin and C. Tepe, "Robotik Uygulamalar İçin Derin Öğrenme Tabanlı Nesne Tespiti ve Sınıflandırması," *Karadeniz Fen Bilimleri Dergisi*, vol. 10, no. 1, pp. 205–213, 2020, doi: 10.31466/kfbd.734393.
- [17] M. Mutlu Bilgin, K. Özdem, and M. A. Akçayol, "Derin Öğrenme ile Kuş Türü Sınıflandırma: Karşılaştırmalı Bir Çalışma," *Journal of Polytechnic*, 2021, doi: 10.2339/politeknik.904933.
- [18] B. Ay, "HorrorFace: Derin Öğrenme Tabanlı Korkutucu Yüzlerin Tespiti ve Sınıflandırılması," *Bilişim Teknolojileri Dergisi*, vol. 14, no. 4, pp. 435–443, 2021, doi: 10.17671/gazibtd.875816.

- [19] B. Baheti, S. Gajre, and S. Talbar, "Detection of Driver Distraction Using Convolutional Neural Network," Proceedings of the IEEE conference on computer vision and pattern recognition workshop, pp. 1032–1038, 2018, doi: 10.1109/CVPRW5428.2018.898116-4149-7_28.
- [20] Y. Sun, B. Xue, M. Zhang, and G. G. Yen, "Evolving Deep Convolutional Neural Networks for Image Classification," IEEE Transactions on Evolutionary Computation, vol. 24, no. 2, pp. 394–407, 2020, doi: 10.1109/TEVC.2019.2916183.
- [21] K. V. Greeshma and K. Sreekumar, "Hyperparameter optimization and regularization on fashion-MNIST classification," International Journal of Recent Technology and Engineering, vol. 8, no. 2, pp. 3713–3719, 2019, doi: 10.35940/ijrte.B3092.078219.
- [22] T. Hur, L. Kim, and D. K. Park, "Quantum convolutional neural network for classical data classification," arxiv preprint:2108.00661, pp. 1–16, 2021.
- [23] A. S. Henrique et al., "Classifying Garments from Fashion-MNIST Dataset Through CNNs," Advances in Science, Technology and Engineering Systems Journal, vol. 6, no. 1, pp. 989–994, 2021, doi: 10.25046/aj0601109.
- [24] O. M. Khanday, S. Dadvandipour, and M. A. Lone, "Effect of filter sizes on image classification in CNN: A case study on CIFAR10 and fashion-MNIST datasets," International Journal of Artificial Intelligence, vol. 10, no. 4, pp. 872–878, 2021, doi: 10.11591/ijai.v10.i4.pp872-878.
- [25] H. Xiao, K. Rasul, and R. Vollgraf, "Fashion-MNIST: a Novel Image Dataset for Benchmarking Machine Learning Algorithms," arxiv preprint: 1708.07747, pp. 1–6, 2017.
- [26] Zalando Research, "Fashion MNIST." <https://github.com/zalandoresearch/fashion-mnist>.
- [27] S. R. Kheradpisheh, M. Mirsadeghi, and T. Masquelier, "BS4NN: Binarized Spiking Neural Networks with Temporal Coding and Learning," Neural Processing Letters, 2021, doi: 10.1007/s11063-021-10680-x.
- [28] I. Goodfellow, Y. Bengio, and A. Courville, Deep Learning. MIT Press, 2016.
- [29] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov, "Dropout: A Simple Way to Prevent Neural Networks from Overfitting," Journal of Machine Learning Research 15, pp. 1929–1958, 2014, doi: 10.1162/0370-2693(93)90272-J.