

(Geliş Tarihi / Received Date: 17.05.2019, Kabul Tarihi/ Accepted Date: 11.11.2019)

## Derin Öğrenme Yöntemlerini Kullanarak Görüntülerin Analizi

Nina Aalami\*<sup>1</sup>

<sup>1</sup>Eskişehir Osmangazi Üniversitesi, Fen Bilimler Fakültesi, Bilgisayar Bölümü, 26400, Eskişehir

### Anahtar Kelimeler:

Derin Öğrenme,  
Makina Öğrenmesi,  
Görüntü İşleme,  
Konvolüsyonel Sinir Ağları,  
Yapay Sinir Ağı

**Özet:** Görüntü işleme, görüntüyü dijital forma dönüştürmenin ve üzerinde bazı işlemler gerçekleştirmenin bir yoludur. Bu durumda, giriş bir görüntüdür ve çıkış görüntü ile ilişkilendirilmiş bir görüntü veya özellikleri olabilir. Gün geçtikçe daha fazla kullanılan bu yöntem, mühendislik bilimlerinde ve bilgisayar bilimlerinde yaygın olarak kullanılmaktadır. Günümüzde ki bilgisayarlar, gelişmiş teknikleri ve algoritmaları kullanarak, sayısal veri işlemenin yanı sıra görüntüleri otomatik olarak işleyebilir ve kategorize edebilirler. Fotoğraflarda da doğal olarak oluşan desenleri öğrenen Derin Öğrenme ağı (CNN) tarafından yapılmaktadır.

Bu makalede, amacımız kullanılan derin öğrenme algoritmalarını diğer yöntemlerle karşılaştırmak ve görüntü işlemede en iyi derin öğrenme algoritması hakkında ayrıntılı bilgi vermektir.

## Analysis of Images Using Deep Learning Methods

### Keywords:

Deep Learning,  
Machine Learning,  
Image Processing,  
Convolutional Neural Network,  
Artificial Neural Network

**Abstract:** Image processing is a way to convert an image to digital form and perform some operations on it. In this case, the input is an image, and the output may be an image or features associated with the image. This method, which is used more and more, is widely used in engineering and computer sciences. today's computers can automatically process and categorize images, as well as digital data processing, using advanced techniques and algorithms. This is done by the Deep Learning network (CNN) which actually learns patterns that naturally occur in photos.

In this paper, our aim is to confront each other of the deep learning algorithms used and discuss in detail about the best deep learning algorithm in image processing.

## 1. GİRİŞ

Bilindiği gibi, görüntü işleme teknikleri askeri ve güvenlik, üretim, makine görüşü, gözetleme vb. birçok sektörde kullanılmaktadır. En çok kullanılan sektörlerden birisi de tıbbi sektördür. Eski zamanlarda, hata seviyesi ve tıbbi tanı riski çok yüksekti, ancak bugün, gelişmiş cihazların ve karmaşık ve akıllı algoritmaların sayesinde, hata ve risk yüzdesi azaltılmıştır. Bilim adamları yapay zekâ kavramını kullanarak risk ve hata oranını azaltmak, insan müdahale miktarını en aza indirmeye çalışmaktadırlar. Yapay zekânın en önemli tekniklerinden biri de derin öğrenmedir. Pratik olarak, derin öğrenme sadece makine öğrenmenin bir alt kümesidir, ama yetenekleri farklıdır. Bir makine öğrenme algoritması yanlış bir tahmin verirse, o zaman bir mühendis müdahale etmek zorunda ve ayarlamalar yapılmalıdır. Ancak derin öğrenme de, bir tahminin doğru olup olmadığını algoritmalar kendi başlarına

belirleyebilir. Bu tekniklerde, bir veri kümesi bilgisayara aktarılır ve bilgisayar bu verileri kullanarak ve genelleştirir.

Yian Seo ve ark.[1] giyim sınıflandırması için yapılan çalışmalarda H-CNN (Hiyerarşik Evrişimli Sinir Ağı) kullanmışlardır. Çeşitli iş alanlarında daha iyi performans için derin öğrenme algoritmalar uygulanabilir, en önemli ve karmaşık iş alanlarından biri de giyim işidir. Bu nedenle, giyim sınıflandırması, çeşitli giyim özellikleri ve sınıflandırma derinliğindeki karmaşıklığı nedeniyle zor olabilir. Bu çalışma da, giysilerin sınıflandırılmasında daha iyi performans için H – CNN kullanılmıştır.


Tıbbi etkileyen gelişmelerden biri de cihazları daha akıllı hale getirmektir. Boukaye Boubacar ve ark. numuneleri analiz zamandan tasarruf etmek için akıllı bir mikroskop önermiştir. Akıllı bir mikroskopu tasarlamak için, beş derin öğrenme ile salgın patojeni sınıflandırmak için

\*İlgili yazar: niinaa.aalami@gmail.com

verimli Konvolüsyon Sinir Ağı (CNN) mimarisine dayanan bir metodoloji önerdiler. Bunlar;

- i. Verilen görüntülerin bir eğitim veri kümesi
- ii. CNN Eğitimi
- iii. Test veri hazırlığı
- iv. CNN veri testinde model üretti ve sonunda
- v. Sınıflandırılan görüntülerin değerlendirilmesidir [2].

Tıp endüstrisinde, görüntüleri analiz etmek için birçok algoritma geliştirilmiştir. Derin öğrenme algoritmaları, özellikle evrişimli ağlar, tıbbi görüntüleri analiz etmek için hızla tercih edilen bir yöntem haline gelmiştir. Geert Litjens ve ark. çalışmalarında, görüntü sınıflandırma, nesne algılama, bölümlendirme, kayıt ve diğer görevler için derin öğrenmenin kullanımını araştırmışlardır [3]. Derin öğrenme algoritmalarının gelişmesiyle birlikte çeşitli tıbbi performanslar gelişmektedir. Dinggang Shen ve ark. , derin öğrenme yöntemlerinin ilkelerini ortaya koyduktan sonra tıp sektöründeki performanslarının başarı oranında önemli artışlar sağladıklarıdır [4].



**Şekil 1.** Görüntünün büyüklüğü derin modelin çoklu girişlerini ve bağlı katmanlarından geçer ve son olarak ağıncı çıkışı ve buradan tekrar ağıncı girişini besler. (<https://iq.opengenus.org/object-detection-using-r-cnn>)

Renoh Johnson Chalakkal ve ark. çalışmalarında, girdi olarak retina görüntülerinin kalitesini değerlendirmek için derin öğrenme temelli bir yaklaşım önerdiler. Yöntem, görüntü kalitesini netlik, aydınlatma ve homojenlik açısından tanımlayan derin öğrenmeye dayalı bir sınıflandırma ile başlar, ardından görüntüdeki alanı tanımlar ve içeriğini değerlendiren denetimsiz bir ikinci aşama izlenir [5].

Sensörlerdeki ve kayıt sistemlerindeki gelişmeler de, görüntü işleme sürecinde yeni bir bakış açısı sunmaktadır. Yuting Lyu ve ark. çalışmalarında, özelliği çıkarmak ve hatayı tanımlamak için, zamanında derin bir Derin Zeka Ağı (DBN) derin öğrenme çerçevesi önerildi. Görüntüleri doğrudan ağıncı giren geleneksel DBN yöntemlerinden farklı olarak, önerilen çerçevede, alt ağlar yerel özellikleri alt görüntülerden çıkarmak için kullanılır [6].

## 2. EVRİŞİMLİ SİNİR AĞI (CNN)

CNN'ler ayırt edici derin mimarinin bir alt tipidir ve görüntüler ve videolar gibi iki boyutlu verilerin grid-like topoloji ile işlenmesinde tatmin edici performans göstermiştir [7]. CNN'lerin mimarisi, hayvan görsel korteks organizasyonundan ilham alınmıştır. Bir CNN'nin öğrenme sürecinde üç faktör kilit rol oynar:

- i. seyrek etkileşim,
- ii. Parametre paylaşımı ve
- iii. Eşdeğer gösterimi'dir.

Bu yüzden CNN'ler, bilinmeyen sınıflar için iyi çalışan genel amaçlı özellikleri çıkarmada güçlü araçlardır (Şekil 1).

## 3. BÖLGESEL-TABANLI EVRİŞİMLİ SİNİR AĞI (R-CNN)


Çok sayıda bölge seçme problemini atlamak için, Ross Girshick ve ark. görüntüden sadece 2000 bölgeyi çıkarmak için seçici bir arama kullandıkları ve bölge önerileri olarak adlandırdıkları bir yöntem önerdiler. Bu nedenle, şimdi çok sayıda bölgeyi sınıflandırmaya çalışmak yerine, yalnızca 2000 bölgeyle çalışabiliriz [8].

R-CNN, aşağıdan yukarı bölge önerilerini bir convolutional neural network tarafından hesaplanan zengin özelliklerle birleştiren son teknoloji ürünü bir görsel nesne algılama sistemidir [9].

R-CNN, PASCAL VOC 2012'deki önceki en iyi algılama performansını% 30 oranında artırmıştır (Tablo 1).

**Tablo 1.** PASCAL VOC algılama sonuçları

Method	VOC2007mAP	VOC2010mAP	VOC 2012 mAP
R-CNN	54.2%	50.2%	49.6%
R-CNN bbox reg	58.5%	53.7%	53.3%




**Şekil 2.** R-CNN model genel(<https://medium.com/coinmonks/review-r-cnn-object-detection-b476aba290d1>)

R-CNN'lerin amacı, nesne algılama problemini çözmektir. Belirli bir görüntü verildiğinde, tüm nesnelerin üzerine sınırlayıcı kutular çizebilir. Süreç iki genel bileşene ayrılabilir; bölge teklif basamağı ve sınıflandırma basamağı. Herhangi bir sınıf agnostik


(bilinmezlik) bölge teklif yöntemine uygun olmalıdır (Şekil 2). Seçmeli arama, özellikle R-CNN için kullanılır.

### 3. HIZLI BÖLGESEL-TABANLI EVRİŞİMLİ SINIR AĞI (Hızlı R-CNN)

R-CNN'lerde bulunan bazı hatalar, hızlı R-CNN olarak adlandırılan başka bir algoritmanın geliştirilmesine yol açmıştır. Hızlı R-CNN yaklaşımı R-CNN algoritmasına benzer. Ancak, bölge önerilerini CNN'ye beslemek yerine, evrişimli bir özellik haritası oluşturmak için girdi görüntüsünü CNN'ye besler. Konvolüsyon özellik haritasından, tekliflerin bölgesini tespit eder ve bunları karelere çarptırırız ve bir ROI havuzlama katmanı kullanarak bunları tam olarak bağlı bir katmana beslenebilmeleri için sabit bir boyutta yeniden şekillendiririz. ROI özellik vektöründen, önerilen bölgenin sınıfını ve sınırlayıcı kutu için ofset değerlerini tahmin etmek için softmax katmanını kullanırız.



**Şekil 3:** Hızlı bölgesel-tabanlı evrişimli sınır ağı (<https://towardsdatascience.com/r-cnn-fast-r-cnn-faster-r-cnn-yolo-object-detection-algorithms-36d53571365e>)



**Şekil 4.** Nesne belirleyici algoritmalarının test zamanı

“Hızlı R-CNN” sebebi yani R-CNN'den daha hızlı olmasının nedeni, her seferinde evrimsel sınır ağına 2000 bölge teklifini beslemesine gerek duymamasıdır. Bunun yerine, evrişim işlemi görüntü başına sadece bir kez yapılır ve ondan bir özellik haritası oluşturulur. Hızlı R-CNN, CNN, sınıflandırıcı ve sınırlayıcı kutu regresörünü tek bir ağda birleştirdi [11].

### 4. YÖNTEM SONUÇLARININ İNCELENMESİ

Bu çalışmada, derin öğrenme yöntemleriyle görüntüleri analiz etmenin farklı yöntemlerini kısaca inceledik. Çoğu modern derin öğrenme modeli yapay sinir ağına dayanmaktadır. Derin öğrenmede her seviye, girdi verilerini biraz daha soyut ve bileşik bir gösterime dönüştürmeyi öğrenir. Derin öğrenmede, convolutional neural network (CNN) görsel imgelemeyi analiz etmek için en sık uygulanan derin sinir ağları sınıfıdır. CNN'ler, minimum ön işleme gerektirecek şekilde tasarlanmış çok katmanlı algılayıcıların bir varyasyonunu kullanır.

CNN'ler ön işlemeyi en aza indirmek için tasarlanmış çeşitli çoklu görevler kullanır.

CNN'de var olan sorunlardan biri, bir görüntüyü analiz etmek için o görüntünün çok sayıda bölgesini seçmek zorunda kalabiliriz. Ve bu iş, hesaplama işlemlerini artıracak. Bu nedenle, R-CNN algoritmalar bu oluşumları bulmak ve hızlı bir şekilde bulmak için geliştirilmiştir. R-CNN yöntemi, çok sayıda görüntü alanı seçmek yerine, seçici algoritmalar kullanarak, görüntünün sınırlı bir alanını seçip ve kullanabiliriz.

R-CNN metodu, bir kaç problem ile karşı karşıya kalmıştır, bunlar;

- Ağı eğitmek için çok fazla zaman alması
- Gerçek zamanlı olarak uygulanamaz olması,
- Seçmeli arama algoritmasının sabit bir algoritma olmasıdır

Yani bu aşamada öğrenme olmaz bu yüzden, en hızlı RCNN yöntemi geliştirilmiştir. R-CNN ve Hızlı R-CNN her ikisi bölge önerilerini bulmak için selective search kullanmaktadır. Seçmeli arama, yavaş ve zaman alıcı bir işlem olduğundan dolayı seçmeli arama yerine nesne belirleyici kullanılabilir (Şekil 4)(Tablo 2).

**Tablo 2.** Hızlı R-CNN ve R-CNN sonuç performansı

	R-CNN	Hızlı R-NN
Resim başına test süresi	50 saniye	2 saniye
Hızlandırma	1×	25×
MAP (VOC 2007)		66.0

### 4. TARTIŞMA VE SONUÇ

Bu makalenin amacı, derin öğrenme kullanarak görüntüleri analiz etmenin çeşitli yöntemlerini incelemektir. Çeşitli kaynaklardan yapılan araştırmalara göre, görüntüleri analiz etmek için birçok teknikler vardır. Hızlı R-CNN metodu, R-CNN mimarisinin en hızlı ve doğru yollarından biridir. Bu yöntem, görüntü analiz sürecini iyileştirir ve önceki yöntemler hız açısından karşılaştığı sorunların çözümüne önemli katkılar sağlamaktadır.

### KAYNAKÇA

- [1] Seo, Y., Shin, K. 2019. Hierarchical convolutional neural networks for fashion image classification. Expert Systems with Applications, 116: 328 – 339, doi: <https://doi.org/10.1016/j.eswa.2018.09.022>.
- [2] Traore, B.B., Kamsu- Fogue, B., Tangara, F. 2018. Deep convolution neural network for image

- recognition. *Ecological Informatics*, 48, 257-268.  
doi: <https://doi.org/10.1016/j.ecoinf.2018.10.002>.
- [3] Litjens, G., Kooi, T., Bejnordi, B.E., Setio, A.A.A., Ciompi, F., Ghafoorian, M., van der Laak, J. A.W.M., Ginneken, B.V., Sánchez, C.I. 2017. A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42, 60-88. doi: <https://doi.org/10.1016/j.media.2017.07.005>
- [4] Shen, D., Wu, G., Zhang, D., Suzuki, K., Wang, F., Yan, P. 2015. Deep Learning in Medical Image Analysis. *Computerized Medical Imaging and Graphics*, 41, 1-2. doi: <https://doi.org/10.1016/j.compmedimag.2015.02.001>
- [5] Chalakkal, R.J., Abdulla, W.H., Thulaseedharan, S.S. 2019. Quality and content analysis of fundus images using deep learning. *Computers in Biology and Medicine*, 108, 317-331. doi: <https://doi.org/10.1016/j.combiomed.2019.03.019>
- [6] Lyu, Y., Chen, J., Song, Z. 2019. Image-based process monitoring using deep learning framework. *Chemometrics and Intelligent Laboratory Systems*, 189, 8-17. doi: <https://doi.org/10.1016/j.chemolab.2019.03.008>
- [7] Liu, W., Wang, Z., Liu, X., Zeng, N., Liu, Y., Alsaadid, F.E. 2017. A survey of deep neural network architectures and their applications. *Neurocomputing*, 234, 11-26. doi: <https://doi.org/10.1016/j.neucom.2016.12.038>
- [8] R-CNN <https://towardsdatascience.com/r-cnn-fast-r-cnn-faster-r-cnn-yolo-object-detection-algorithms-36d53571365e>
- [9] R-CNN <https://github.com/rbgirshick/rcnn>
- [10] Girshick, R. 2015. Fast R-CNN. *ICCV '15 Proceedings of the 2015 IEEE International Conference on Computer Vision (ICCV)*, 1440-1448. doi: 10.1109/ICCV.2015.169
- [11] <https://www.slideshare.net/simplyinsimple/detection-52781995>.