



Derin Öğrenme Yöntemleri ile Bitki Yaprakları Üzerindeki Hastalıkların Sınıflandırılması

Furkan Alp Esen¹, Aytuğ Onan²

¹ İzmir Katip Çelebi Üniversitesi, Fen Bilimleri Enstitüsü, Yazılım Mühendisliği Bölümü, İzmir, Türkiye, (ORCID: 0000-0002-2157-3057), furkanalpesen@gmail.com

² İzmir Katip Çelebi Üniversitesi, Fen Bilimleri Enstitüsü, Yazılım Mühendisliği Bölümü, İzmir, Türkiye (ORCID: 0000-0002-9434-5880), aytugonan@gmail.com

(1st International Conference on Innovative Academic Studies ICIAS 2022, September 10-13, 2022)

(DOI: 10.31590/ejosat.1181081)

ATIF/REFERENCE: Esen, F. A. & Onan, A. (2022). Derin Öğrenme Yöntemleri ile Bitki Yaprakları Üzerindeki Hastalıkların Sınıflandırılması, (40), 151-155.

Öz

Teknolojik olarak ileriye gittiğimiz günümüz dünyasında tarımsal faaliyetlerin verimli hale getirilmesi her geçen gün daha da çok zaman harcıyoruz. Elimizdeki kaynakları teknolojik yöntemler ile destekleyerek bu harcadığımız zamanı kısaltabiliriz. Bilgisayarlı görü ve derin öğrenme yöntemlerinin etkin olarak işletilmesi ile eğitilen modelleri kullanarak yapacağımız her bir tahmin ile bitkinin hastalığını teşhis edebiliriz. Görüntü tabanlı sınıflandırma algoritmaları olan daha önceden farklı amaçlar için eğitilmiş modellerin bizim problemimiz için kullanıldığında ne gibi sonuçlar almışız onu inceliyor olacağız. Adına aktarımlı (transfer) öğrenme dediğimiz bu yöntem ve topladığımız veri setinin verdiği sonuçları, bize şimdiki çalışma ve gelecekteki çalışmalar için nasıl daha etkili yöntemlere ihtiyaç var sorusunun cevabını verecektir.

Anahtar Kelimeler: Derin Öğrenme, Bilgisayarlı Görü, Aktarımlı Öğrenme, Veri Seti, Optimizasyon, Model Testi.

Deep Learning Based Plant Diseases Classification

Abstract

In today's world, where we move forward technologically, we spend more and more time to make agricultural activities efficient. We can shorten the time we spend by supporting the resources we have with technological methods. We can diagnose the disease of the plant with each prediction we make using models trained by the effective operation of computer vision and deep learning methods. We will be examining what results we have obtained when the models, which are image-based classification algorithms, were used for our problem, which were previously trained for different purposes. This method, which we call transfer learning, and the results of the dataset we collect, will give us the answer to the question of how more effective methods are needed for current and future studies.

Keywords: Deep Learning, Computer Vision, Transfer Learning, Dataset, Optimization, Model Testing

¹ Sorumlu Yazar: furkanalpesen@gmail.com

1. Giriş

Tarımsal faaliyetler; üzerinde yaşadığımız topraklar olan Anadolu coğrafyası için oldukça büyük bir öneme sahiptir. En eski keşiflerin olduğu 8000 bin öncesinde bile yerleşik hayata geçişin başlangıcı olarak tarımın başlangıcı denebilir. Her gelen yeni nesil kendi yaşadığı topluma ve döneme bağlı olarak farklı şekillerde tahıl, bitki, meyve yetiştiriciliği yapmıştır. Bizler günümüzde son nesil olarak halen dahi aynı teknikleri kullansak bile çok daha fazla teknolojik ve bilgi birikimine sahibiz. Fakat elimizdeki imkanları değerlendirmek yine bize bağlıdır.

Bilgisayar dünyasındaki gelişmeler ile hayatımıza artık entegre olmuş birçok araç ile beraber yaşıyoruz. İnternet ve akıllı telefonlar bu alanda oldukça büyük bir paya sahip. Peki bu araçları bitkilerin olduğu bir dünyada nasıl entegre edebiliriz? Sorusu aslında çözümün ilk adımı olabilir. Akıllı tarım faaliyetlerinin artması ile beraber yavaş yavaş benimsemiş durumdayız. Bunların en çok kullanılan örnekleri; akıllı sulama, akıllı gübreleme, güneş ve nem durumlarına göre ortamın sıcaklığının ayarlanması gibi pek çok parametrenin olduğu farklı senaryoları düşünebiliriz.

Bu makalede doğal olarak oldukça geniş bir yelpazeden bahsetmemiz imkansız. Asıl odaklandığımız konu toprak üzerinde yetiştirebilen veya yetişmesi planlanan tüm bitkiler için olabilecek her türlü hastalığın teşhisini yapmaktır. Bitki üzerinde hastalığın tespitini yapraklarına bakarak anlayabiliy isek yaprakların görüntülerini toplayıp işleyebiliriz. Bilgisayarlı görü ile derin öğrenmeyi birlikte kullanarak daha önceden farklı görüntü problemleri için eğitilmiş modelleri bitki yaprakları üzerindeki hastalıkların tespiti için de kullanabiliriz. Aktarımlı öğrenme yöntemi olarak da geçen bu yöntem ile toplanan veri setinin AlexNet, GoogleNet gibi bazı modellerinin eğitiminin ardından veri seti içerisindeki bitki ve hastalık kategorisi kadar tahminlemeler yapılabilir. Alınan tahmin sonuçları; modellerin eğitim süreleri, verinin kalitesi gibi farklı değişkenlere bağlı olarak makale içerisindeki tablolar üzerinde kıyaslamalı olarak gösterilmektedir.

2. Materyal ve Metot

2.1. Konvolüsyonel Sinir Ağı Modelleri

Derin öğrenme yöntemi; yapay zekanın alt alanlarından biridir. Yapay sinir ağları geliştirilerek matematiksel ve istatistiksel hesaplamaların yapılması ile probleme ait verilerin işlenmesidir. İşlenen veriler; yapay sinir ağının en son katmanında birer sonuca yani tahmine dönüşür. Farklı metrikler ile alınan sonuçlar değerlendirilerek tahminleme işinin başarısı ölçülmektedir.

Yapay sinir ağlarının eğitimi model eğitmek olarak da kullanılır. Model eğitme işlemi problemin türüne göre değişkenlik gösterir. Bilgisayarlı görü olarak adlandırdığımız alan ile birlikte bu makalede odaklanılan kısım görüntü içerikli problemler olacaktır. Görüntü tabanlı problemlerin çözümünde kullanılan yapay sinir ağlarından oluşan algoritmalar ve mimariler “Konvolüsyonel Sinir Ağı (Convolutional Neural Network)” ismi ile literatürde geçmektedir. Konvolüsyonel sinir ağları giriş değeri olarak(input) bir görüntü bekler. Sinir ağına verilen görüntü o sinir ağının mimarisine göre katmanlardan geçerek hesaplamaları yapılır. Bizim beklediğimiz sinir ağının çıktısı bir hastalık grubu olduğu için doğal olarak farklı hastalıklar için sınıflandırmanın

yapıldığını bu problemin de sınıflandırma problemi olduğunu söyleyebiliriz.

Topladığımız veri seti içerisinde; 4 elma,1 arkaplan, 1 yabanmersini, 2 kiraz, 4 mısır, 1 portakal, 2 şeftali, 2 biber, 3 patates, 1 böğürtlen, 1 soya fasulyesi, 1 kabak, 2 çilek ve 10 adet domates olmak üzere toplamda 39 farklı bitki yaprağı sınıfı bulunmaktadır. Doğal olarak eğitimini yaptığımız yapay sinir ağı olan konvolüsyonel sinir ağlarından elde edilen çıktı, 39 adet sınıftan birisi olacaktır. Sınıflandırma işleminin ardından elde edilen sonuç belirli bir yüzdelik orana sahip olmak zorundadır. Bu yüzdelik oran bize tahmin işleminin ne kadar başarılı ya da başarısız olduğunu kıyaslamasında kritik bir öneme sahiptir. Başarım oranları farklı metrik ölçüm yöntemleri barındırabilir fakat bizim üzerinde çalıştığımız modeller “Accuracy (doğruluk)” metriği ile kıyaslanmıştır.

2.2. Aktarımlı Öğrenme (Transfer Learning) Yaklaşımı

Aktarımlı öğrenme; yapay sinir ağlarının tekrar kullanılabilmesi, daha başarılı sonuçlar elde etmek için geliştirilmiş bir yöntemdir.

Yapay sinir ağları farklı problemler için farklı şekillerde tasarlanır ve amacı doğrultusunda kullanılıp geliştirilmeye devam eder. Örneğin metinsel bir problem üzerinde çalışılıyor ise geliştirilen model metinsel problemler için kullanılıp geliştirilmeye devam edilmelidir. Aynı şekilde bizim makalemizde ele aldığımız problem, görsel tabanlı bir problem olduğu için geliştirilen mimariler yani yapay sinir ağları görüntü verileri ile eğitilerek sonuçlar üzerinde analizler yapılmalıdır. Daha önceden farklı görüntü sınıflandırma problemleri için Google, Nvidia, Microsoft gibi firmaların derin öğrenme çalışmalarında kaynak olması veya geliştirme yapılan programlama dilinde içerisindeki kütüphaneler ile eğitilmiş modeller üzerinde çalışmalar yapabiliyoruz. Makalemizde işlenen bitki yapraklarından elde edilen görüntülerin hangi hastalık grubuna ait olduğunu tahmin edebilmek için eğitilen bazı modelleri kendi kaynaklarımız ve verisetimiz ile tekrar eğiterek sonuçlar aldık. Aktarımlı öğrenme ile elde ettiğimiz sonuçlar ilerleyen bölümlerde incelenebilir.

Aktarımlı öğrenme için kullanılan konvolüsyonel sinir ağlarından bazıları:

Alexnet: AlexNet, Alex Krizhevsky tarafından Ilya Sutskever ve Krizhevsky'nin danışmanı olan Geoffrey Hinton ile işbirliği içinde tasarlanan bir evrişimsel sinir ağı mimarisinin adıdır.

DenseNet161: DenseNet, tüm katmanları (eşleşen özellik haritası boyutlarıyla) doğrudan birbirine bağladığımız Yoğun Bloklar aracılığıyla katmanlar arasındaki yoğun bağlantıları kullanan bir tür evrişimsel sinir ağıdır. İleri beslemeli doğayı korumak için, her katman önceki tüm katmanlardan ek girdiler alır ve kendi özellik haritalarını sonraki tüm katmanlara iletir.

ResNet: ResNet, 2015 yılında Kaiming He, Xiangyu Zhang, Shaoqing Ren ve Jian Sun tarafından önemli ölçüde daha derin olan ağların eğitimini kolaylaştırmak için “Deep Residual Learning for Image Recognition” makalesinde tanıtılan belirli bir sinir ağı türüdür. ResNet’in başarılarından bahsedecek olursak:

ImageNet veri setinde, VGG ağlarından daha derin, ancak yine de daha düşük karmaşıklığa sahip 152 katmana kadar derinliğe sahip artık ağların değerlendirilmesi sonucunda %3,57 hata oranı ile ILSVRC 2015 sınıflandırma görevinde 1. oldu.

Faster R-CNN'de VGG-16 katmanlarının ResNet-101 ile değiştirilmesiyle COCO nesne algılama veri kümesinde %28 iyileşmeler gözlemlendi.

ILSVRC ve COCO 2015 yarışmasında ImageNet Algılama, ImageNet yerelleştirme, COCO algılama ve COCO segmentasyonunda 1. oldu.

VGG-16: VGG-16, basit bir ağ modeli olup öncesindeki modellerden en önemli farkı evrişim katmanlarının 2'li ya da 3'li kullanılmasıdır. Tam bağlantı (FC) katmanında $7 \times 7 \times 512 = 4096$ nöronlu bir öznitelik vektörüne dönüştürülür. İki FC katmanı çıkışında 1000 sınıflı softmax başarımı hesaplanır. Yaklaşık 138 milyon parametre hesabı yapılmaktadır. Diğer modellerde olduğu gibi girişten çıkışa doğru matrislerin yükseklik ve genişlik boyutları azalırken derinlik değeri (kanal sayısı) artmaktadır.

EfficientNet B0 – Efficient B7: EfficientNet, bir grup evrişimli sinir ağı modeli olarak düşünülebilir. Ama tabii ki

incelikleri sayesinde adından da anlaşılacağı gibi kendisinden önceki modellerin çoğundan efektif/verimli (efficient)dir. EfficientNet grubu B0-B7 arasında 8 tane modelden oluşur ve sayı büyüdükçe hesaplanan parametre sayısı ve doğruluk artar. Üç temel adımda neden daha verimli olduğunu anlamak mümkün.

Depthwise Evrişim + Pointwise Evrişim: Hesaplama maliyetini asgari doğruluk kaybıyla önemli ölçüde azaltmak için orijinal evrişimi iki aşamaya böler.

Ters çevrilmiş Res: Orijinal ResNet blokları, kanalları sıkıştıran (squeeze) bir katmandan sonra kanalları genişleten (expand) bir katmandan oluşur. Böylece atlama bağlantıları (skip connections) ile zengin kanal katmanlarını bağlar. Ancak MBConv'da, bloklar önce kanalları genişleten, sonra bunları sıkıştıran bir katmandan oluşur, böylece daha az kanala sahip katmanlar atlanarak bağlanır.

Lineer darboğaz: ReLU'dan bilgi kaybını önlemek için her bloktaki son katmandaki lineer aktivasyonu kullanır.

Şekil 1. Farklı Konvolüsyonel Sinir Ağı Mimarileri Katman Sayıları ve Parametre Boyutları

Model	No. of Layer	Parameters (Million)	Size
AlexNet	8	60	-
VGGNet-16	23	138	528 MB
VGGNet-19	26	143	549 MB
Inception-V1	27	7	-
Inception-V3	42	27	93 MB
ResNet-152	152	50	132 MB
ResNet-101	101	44	171 MB
InceptionResNetV2	572	55	215 MB
MobileNet-V1	28	4.2	16 MB
MobileNet-V2	28	3.37	14 MB
EfficientNet B0	-	5	-

Şekil 2. Bitki Hastalığı Tespiti İle İlgili Benzer Çalışmalar

Author	Methods	Results
Mohanty et al. [24] (2016)	AlexNet and GoogleNet	99.27% in AlexNet 99.34% in GoogleNet
Sladojevic et al. [26] (2016)	Finetuned CNN architecture	96.3% accuracy
Ramcharan et al. [4] (2017)	Inception V3 based on GoogleNet	93% accuracy
Fuentes et al. [23] (2017)	Faster R-CNN	83% accuracy
Ferentinos et al. [25] (2018)	AlexNetOWTBn and VGG	99.49% in AlexNetOWTBn 99.53% in VGG
Ramacharan et al. [44] (2019)	Single-shot multibox (SSD) model with MobileNet detector and classifier	80.6% accuracy on images 70.4% accuracy on video
Geetharamani et al. [35] (2019)	Nine-layer deep CNN	96.46% accuracy
Chen et al. [2] (2020)	INC VGGN	92% accuracy
Li et al. [41] (2020)	Shallow CNN with SVM and RF	94% accuracy
Oyewola et al. [43] (2021)	Deep residual neural network (DRNN)	96.75% accuracy

2.2. Veri Seti

Çalışma içerisinde modellerin eğitimi ve sonuçlar üzerinde büyük bir etkiye sahip olan materyalimiz veri setidir. Kullanılan veri seti elbetteki alınan çıktılarını yani tahminleme işleminin ne derece başarılı olacağını belirler. Bu çalışma içerisinde kullanılan veri seti: "Data for: Identification of Plant Leaf Diseases Using a 9-layer Deep Convolutional Neural Network" ismi ile data.mendeley.com dan erişilebilir. Herkese açık şekilde kullanıma açıktır. Veri Setinin içerdiği sınıflardan önceki bölümde bahsetmiştik fakat içerdiği görüntü sayısı ve dağılımları konuşmamıştık. Veri Seti 2 farklı şekilde sunulmaktadır. İlk senaryo veri seti "veri artırma(data augmentation)" yöntemini içermeyen yani görüntü sayısının ve çeşitliliğin az olduğu durum. Bu senaryoyu yapmadık çünkü modelimizin başarısı veri sayısına bağlı olduğu için diğer senaryoyu yani veri artırma yöntemi uygulanmış olanı seçtik. Seçilen veri setine ait durum:

Şekil 3. Verisetinin İçeriğinden Bir Kesit

Class	Plant Name	Diseases Name	Causes Name	Virus	Type of Diseases	No. Of Images
C27	Apple	Apple Black Rot			Rot	1000
C28	Apple	Apple Scab				1000
C29	Corn	Corn Common Rust			Rust	1000
C30	Corn	Corn Gray Leaf Spot			Spot	1000
C31	Grape	Grape Black Rot				1000
C32	Tomato	Tomato Bacterial Spot	Spot		Bacteria - Spot	1000
C33	Tomato	Tomato Late Blight			Pest	100
C34	Tomato	Tomato Leaf Mold				1000
C35	Tomato	Tomato Mosaic Virus	Tomato Mosaic	Viral		1000

3. Araştırma Sonuçları ve Tartışma

3.1. Bulgular

Önceki bölümlerde açıklanan CNN mimarileri üzerinde yapılan geliştirme sonucunda, accuracy değerleri ile karşılaştırmasını yaparsak en başarılı modelin VGG16 olduğunu görürüz. Modellerin başarıları; veri setinin eğitim, test ve doğrulama olacak şekilde 3 parçaya ayrılması ve hangi oranlarda içerisinde veriye sahip olacağı tamamen bize bağlıdır. Biz bu çalışmada; eğitim için %60, test için %30 ve doğrulama için ise %10 olarak ayırdık ve modelleri ona göre eğittik. Farklı veri seti bölme yöntemleri de denenerek karşılaştırılmalı sonuçların arasına eklenebilir.


Araştırma sonucunda, uzunca bir eğitim süresini geride bıraktık. Her bir modelin baştan eğitilmesi işlemi elbetteki modelin büyüklüğüne bağlı olarak 100'er epoch ile Nvidia GTX 1650 ekran kartı üzerinde ortalama 16 saatten fazla sürmüştür. Modellerin tablo halinde karşılaştırılmalı olarak gösterimi aşağıda mevcuttur.

Tablo 1. Modellerin Başarım Karşılaştırması

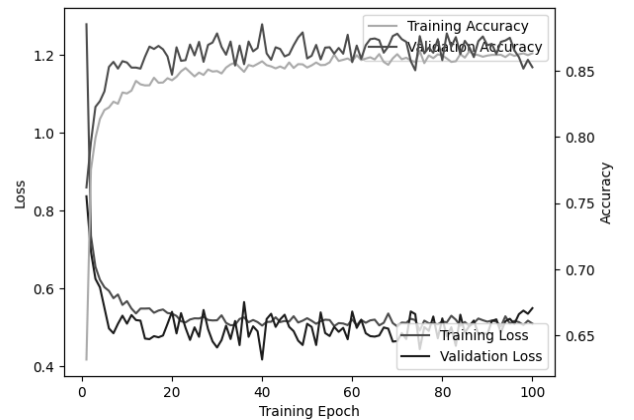
Model Name	Training Time	Total Epoch	Best Epoch	Accuracy
AlexNet	163m 24s	100	82	0.8535
DenseNet	925m 17s	100	71	0.8765
VGG16	367m 21s	100	100	0.9488
ResNet18	139m 1s	100	56	0.9289
Efficient Net B7	602m 50s	75	97	0.9248
Efficient Net B0	190m 20s	100	40	0.8852

Bazı Modellerin eğitimden sonraki Accuracy – Loss grafiklerini görebiliriz.


Şekil 4. AlexNet Eğitim Grafiği



Şekil 5. Efficient Net B0 Eğitim Grafiği



Eğitilen modellerin hastalıklı bitki yaprağı görüntüsü üzerindeki başarılarını incelemek istersek alt kısma bakabiliriz:

Şekil 6. Efficient Net B7 ve AlexNet Tahmin Görüntüleri
Corn_healthy Corn_healthy

Tablo 2. Modellerin Tahmin Değerleri

Model Name	Top Predicted	Score
AlexNet	Corn_healthy	0.9959
DenseNet	Corn_healthy	0.5468
VGG16	Corn_healthy	1.000
ResNet18	Corn_healthy	0.9999
EfficientNet B7	Corn_healthy	0.9540
EfficientNet B0	Corn_healthy	0.9598

4. Sonuç

Bitki yapraklarının hastalıklarını tespit etmek ve sınıflandırmak amacıyla yapılmış çalışmalar bulunabilir. Fakat henüz ticari amaçlı kullanılabilir kadar etkili değildir. Üzerinde geliştirmelere devam edilmesi gerekmektedir. Gelişimi doğrudan etkileyecek olan ise veri setinin çeşitliliği ve sayısının artması olacaktır. Biz bu çalışmada Mendeley Plant Diseases Dataset'i kullandık. Literatürdeki ismi ile "Data for: Identification of Plant Leaf Diseases Using a 9-layer Deep Convolutional Neural Network" bulunabilir. Bu veri seti içerisinde 39 farklı kategori, 61.486 adet görüntü bulunmaktadır. Görüntü sayısını artırmak için uygulanan artırma teknikleri flipping, gamma correction, noise injection, PCA color augmentation, rotation, and scaling uygulanmıştır. Bitki yapraklarındaki hastalıkların tespiti için farklı derin öğrenme teknikleri eğitilmiştir. Eğitimden sonra alınan sonuçlar arasında en iyi başarıyı veren %94.88 ile VGG16 mimarisi olmuştur. Süre olarak da DenseNet'e ve EfficientNetB0'a göre oldukça düşüktür. ResNet18 eğitim süresi olarak oldukça düşük ve başarımlı olarak ortalamanın biraz üstünde bir değer çıkarmıştır. Üzerinde çalışılan bu modeller optimizasyon olarak gelişmiş donanımlı sistemlerde etkili olabilir ancak düşük donanımlı daha çok ihtiyaç olabilecek yerlerde etkili

olmayabilir. Düşük donanım gereksinimleri için diğer mimariler tercih edilebilir. İlk tercih sırasında MobileNetV2 gelebilir.

5. Teşekkür

Tüm araştırma ve geliştirme aşamalarında zamanını ve enerjisini esirgemeyen Aytuğ Onan'a teşekkür ediyorum. Umarız ki akıllı tarım üzerine daha çok çalışırız, projeler geliştiririz. Konu ile alakalı diğer çalışmalarını yapan kaynakçada belirtilenlere de ayrıca teşekkür ediyoruz.

Kaynakça

- Mohanty, S. P. (2016). Plant Science. *Using Deep Learning for Image Based Plant Disease Detection*.
- Sk. Mahmudul Hassan, A. K. (2021). Electronics. *Identification of Plant Leaf Diseases Using CNN and Transfer Learning Approach*.
- Ünal, Z. (2017). A Bibliographical Analysis. *Smart Farming Becomes Even Smarter with Learning*.
- Vu, K. (2021, 27 September). Computer Vision in Agriculture [Blog yazısı]. Erişim adresi: <https://www.kdnuggets.com/2021/09/computer-vision-agriculture.html>
- Lexi, A. (2020, 28 January). Image Classification with Pytorch Transfer Learning [Github]. Erişim adresi: <https://github.com/LexiAM/image-classification-with-pytorch-transfer-learning>
- Kızrak, A. (2019, 20 December). Ölçeklendirme ile CNN Modelinin Doğruluk ve Verimliliği Artırma: EfficientNet [Blog yazısı]. Erişim adresi: <https://ayyucekizrak.medium.com/%C3%B6l%C3%A7lendirme-ile-cnn-modelinin-do%C4%9Fruluk-ve-verimlili%C4%9Fini-art%C4%B1rma-efficientnet-cb6f2b6512de>
- Kızrak, A. (2018, 28 May). Derine Daha Derine: Evrişimli Sinir Ağları [Blog yazısı]. Erişim adresi: <https://ayyucekizrak.medium.com/deri%CC%87ne-daha-deri%CC%87ne-evri%59Fimli-sinir-a%C4%9Flar%C4%B1-2813a2c8b2a9#:~:text=VGG%2D16,1000%20s%C4%B1n%C4%B1fl%C4%B1%20softmax%20ba%C5%9Far%C4%B1m%C4%B1%20hesaplan%C4%B1r>
- Çilek, Ş. (2021, 9 August). ResNet(Residual Network) Nedir? [Blog yazısı]. Erişim adresi: <https://suhedacilek.medium.com/resnet-residual-network-nedir-49105e642566>
- Papers with Code. (2021, 12 February). DenseNet. Erişim adresi: <https://paperswithcode.com/model/densenet?variant=densenet-161>
- Wikipedia. (2022, 8 September). AlexNet. Erişim adresi: <https://en.wikipedia.org/wiki/AlexNet>