



# **Derin Öğrenme Modelleri**

**Doç. Dr. Mehmet Metin ÖZGÜVEN**

**Ankara Üniversitesi Ziraat Fakültesi  
Tarım Makinaları ve Teknolojileri Mühendisliği Bölümü**

**ZTM364 Tarımda Yapay Zeka Kullanımı**

# Derin Öğrenme Modelleri

## LeNet

**LeCun tarafından hazırlanan ve ilk konvolüsyonel yapay sinir ağı olarak tanımlanan mimaridir. Banka çeklerindeki sayıları tanımlamak amacıyla geliştirilen bu ağa LeCun tarafından LeNet adı verilmiştir. Sıfır ile dokuz arasındaki sayıların sınıflandırmasını yapmasından dolayı on sınıflı bir yumuşatma katmanı kullanılmaktadır. Ağ içinde ortalama havuzlama (Average pooling) kullanılmaktadır. LeNet mimari yapısı, tam bağlantılı katman, aktivasyon (relu) katmanı, havuzlama (pooling) ve yumuşak bağlı katmanlardan meydana gelmektedir. LeNet mimari yapısı MNIST veri tabanını kullanarak rakamların tanınmasını sağlamaktadır (Doğan ve Türkoğlu, 2019).**

# Derin Öğrenme Modelleri

## AlexNet

**AlexNet mimarisi 2012'de yapılan ILSVRC ImageNet Büyük ölçekli görsel tanıma yarışmasında birinci olmuştur. Örüntü tanıma oranı %26'dan %15'lere indirilmesi, AlexNet mimarisini bu başarımından dolayı en çok bilinen mimarilerden biri haline getirmiştir. Mimari yapıda doğrusal olmayan fonksiyonlar için klasik fonksiyonlardan daha hızlı olduğu ve eğitim süresini kısalttığından dolayı ReLu (aktivasyon) fonksiyonu kullanılmaktadır. Dropout (bırakma) katmanı eğitimde aşırı öğrenmenin önüne geçilmek için kullanılmaktadır. Momentum değerleri ve ağırlık gecikmeleri için ise gradyan inişli model kullanılmaktadır. Yirmi beş katmandan oluşan mimari yapının içinde beş ana konvolüsyonel katman bulunmaktadır. Relu katmanı genellikle bütün konvolüsyonel katmanlardan sonra kullanılmaktadır. Giriş, normalizasyon, havuzlama, dropout, tam bağlı, yumuşak bağlı ve çıkış katmanlarından oluşmaktadır (You ve ark., 2017).**

# Derin Öğrenme Modelleri

## ZF Net

**Matthew Zeiler ve Rob Fergus tarafından, AlexNet mimari yapısının üzerinde değişiklikler yapılarak ortaya çıkarılan ZFNet mimari yapısı, 2013 yılında ILSVRC ImageNet yarışmasında %11.2 hata oranı ile birinci olmuştur. Giriş katmanında konvoşüsyon işlemi için filtre 7x7 matristen oluşmaktadır. Relu katmanı aktivasyon fonksiyonunda, gradyan iniş eğitimde, çapraz entropi hata kaybında kullanılmaktadır. Deconvolutional Neural Network adında bir görselleştirme tekniği ile ZFNet mimarisine farklı bir yapı kazandırılarak derin öğrenme mimarisini daha başarılı bir noktaya taşımıştır (Zeiler ve Fergus, 2013).**

# Derin Öğrenme Modelleri

## VGGNet

**Simonyan ve Zisserman tarafından Oxford Üniversitesinde 2014 yılında geliştirilen ve altı farklı mimariden oluşan VggNet, 2014 ImageNet yarışmasında %7.3 hata oranıyla oldukça başarılı performans gösteren bir mimari yapıdır. Diğer derin öğrenme mimarilerinden farkı 2x2 ve 3x3'lük filtrelere sahip olmasıdır. Yine VggNet mimarisinde peş peşe üç tam bağlı katman yer almaktadır. Sonuncu tam bağlı katmanda bin nöron bulunmakta olup, çıkış için üretilecek olan sınıflandırma katmanında ise softMax (Yumuşak bağlı) katmanı bulunmaktadır (Simonyan ve Zisserman, 2014; Doğan ve Türkoğlu, 2019).**

# Derin Öğrenme Modelleri

## VGG16

**VGG16 (OxfordNet olarak da bilinir), Oxford Üniversitesi'nden Simonyan ve Zisserman tarafından sunulan, adını onu geliştiren Oxford'dan Visual Geometry Group'tan alan evrişimli bir sinir ağı mimarisidir (Simonyan ve Zisserman, 2015). 2014 yılında ILSVRC2014 (Large Scale Visual Recognition Challenge 2014) yarışmasını kazanmak için kullanılmıştır. Hala mükemmel bir görme modeli olarak kabul edilmektedir. Model, 1000 sınıfa ait 14 milyondan fazla görüntüden oluşan bir veri seti olan ImageNet'te %92,7'lik ilk 5 test doğruluğuna ulaşmaktadır. Büyük çekirdek boyutlu filtreleri (sırasıyla birinci ve ikinci evrişim katmanında 11 ve 5) birden fazla 3×3 çekirdek boyutunda filtreyle değiştirerek AlexNet üzerinde iyileştirme yapmaktadır. VGG16 haftalarca eğitilmiş ve NVIDIA Titan Black GPU'ları kullanılmıştır.**

# Derin Öğrenme Modelleri

## GoogleNet

**Kompleks bir mimari yapıya sahip olan GoogleNet 2014 yılında yapılan ILSVRC yarışmasında %5.7 hata oranı ile birinci olmuştur. Yüz kırk dört katmandan oluşan GoogleNet yirmi iki katman derinliğe sahip olup Inception modülüyle değişik boyutlarda filtreleme işlemi yaparak diğer derin öğrenme mimarilerinden farklı bir yaklaşım ortaya çıkarmaktadır (Szegedy ve ark., 2014).**

# Derin Öğrenme Modelleri

## ResNet

**ResNet 2015 yılında yapılan ILSVRC ImageNet yarışmasında %3.6 hata oranı ile birinci olan bir mimari yapıdır. Bu hata oranı, insanların ortalama %5-%10 hata oranı ile görüntüyü sınıflandırma işleminde insandan daha iyi görsel tanıma yaptığını ortaya koymuştur. Otuz dört katmandan oluşan ResNet katman sayısı diğer derin öğrenme mimarilerin katman sayısından daha fazladır. İki RELU ile doğrusal katman arasında kalıntı değeri (Residual value) ve kalıntı bloklardan (Residual block) oluşmaktadır (Russakovsky ve ark., 2015).**



# Derin Öğrenme Modelleri

## Faster R-CNN

Faster R-CNN, nesne tespiti için kullanılan bir derin öğrenme mimarisidir. Bu mimari üç bölümden oluşmaktadır. Evrişim katmanındaki filtreler ile görüntünün öznelikleri çıkarılmış ve böylece iki boyutlu matris yapısında bir öznelik haritası oluşturulmuştur. İkinci bölümde, sinir ağı olarak kullanılan Bölge Önerme Ağı (RPN), özellik haritalarında ilgili nesneye benzerlik olasılığını tahmin etmektedir. Tahmin katmanı aşaması olan üçüncü bölümde, Fast R-CNN ağı kullanılarak bölgelerin sınıflandırma değeri ile tahmin doğruluk oranı birleştirilerek iki çıktı katmanı oluşturulmuştur. İlk çıktı katmanı softmax sınıflandırmasını gerçekleştirirken, diğer çıktı katmanı tahmin doğruluğunu veren regresyon katmanıdır. Bu bölümde sınırlayıcı kutuların sınıfları belirlenerek puan tahminleri yapılmaktadır. Faster R-CNN modelinin getirdiği yenilik, RPN ağının doğrudan özellik haritasının bulunduğu katmana bağlanabilmesidir. Bu sayede tüm görüntülerde nesne tespiti için bir ortam sağlanmaktadır (Jiang ve Learned-Miller, 2017)

# Derin Öğrenme Modelleri

## Single Shot Multibox Detector (SSD)

**SSD modeli, görüntülerdeki nesnelere algılamak için tek bir CNN kullandığı için bu alandaki en hızlı çalışan algoritmalarından biridir (Liu ve ark., 2016; Ning ve ark., 2017). Yüksek çözünürlüklü görüntülerde nesne algılama ve sınıflandırma için yaygın olarak kullanılmaktadır (Liu ve ark., 2019). Nesne tespiti için belirlediği alanlarda sabit boyutlu sınırlayıcı kutular oluşturmakta ve belirlenen her kutu için tahmin puanı hesaplanmaktadır. Eğitim aşamasında, modeldeki tüm parametreler, geriye yayılım algoritması ve kayıp değerleri ile güncellenmektedir (Li ve Zhou, 2017). Bu sayede optimum filtre parametreleri belirlenmekte ve kayıp değeri en aza indirilmektedir. Bu aşamadaki tüm hesaplamaları tek bir ağda yaparak örnekleme aşamasını ortadan kaldırdığı için diğer nesne algılama yapan modellere göre uygulaması çok kolay ve basittir (Ghoury ve ark., 2019).**

# Derin Öğrenme Modelleri

## Yolo

**Yolo, son teknoloji ürünü, gerçek zamanlı bir nesne algılama sistemidir. Joseph Redmon tarafından geliştirilmiştir. Tek bir çerçevede birden fazla nesneyi tanıyabilen gerçek zamanlı bir nesne tanıma sistemidir. Yolo zamanla daha yeni sürümlere dönüşmüştür, yani Yolov2, Yolov3 ve Yolov4.**

# Derin Öğrenme Modelleri

## Yolov4

**Yolov4, Yolov3 modelinin bir evrimi olan bir nesne algılama algoritmasıdır. Yolov4 yöntemi Alexey Bochkovskiy, Chien-Yao Wang ve Hong-Yuan Mark Liao tarafından oluşturuldu (Bochkovskiy ve ark., 2020). Karşılaştırılabilir performansla EfficientDet'ten iki kat daha hızlıdır. Ayrıca Yolov4'teki AP (Ortalama Hassasiyet) ve FPS (Saniyedeki Kare Sayısı), Yolov3'e kıyasla sırasıyla %10 ve %12 arttı. Yolov4'ün mimarisi, omurga olarak CSPDarkNet53, mekansal piramit havuzlama ek modülü, PANet yolu toplama boynu ve Yolov3 kafasından oluşur.**

# Derin Öğrenme Modelleri

## Yolov8-Yolov8x

**YOLOv8 (Jocher ve ark, 2023) modeli, çeşitli nesne tespiti görevlerinde kullanılan bir modeldir. YOLOv8, anchor-free bir model kullanarak nesnellik, sınıflandırma ve regresyon görevlerini bağımsız bir şekilde işlemektedir (Terven ve Cordova-Esparza, 2023). Beş farklı modele ayrılan YOLOv8 serisi, ölçekleme parametreleri YOLOv8n, YOLOv8s, YOLOv8m, YOLOv8l ve YOLOv8x versiyonlarına sahiptir. YOLOv8x ağı mimarisi, omurga, boyun ve kafa bölümlerini içermektedir. YOLOv8x, giriş görüntüsünden özellik haritaları oluşturmak için CSPDarknet53 (Redmon ve Farhadi, 2018) isimli bir omurga ağı kullanmaktadır**



Doç. Dr. Mehmet Metin ÖZGÜVEN

[mmozguven@ankara.edu.tr](mailto:mmozguven@ankara.edu.tr)

ZTM364 Tarımda Yapay Zeka Kullanımı