Visão Computacional

Redes Neurais Convolucionais (CNNs)

Prof. Dr. Denis Mayr Lima Martins

Pontifícia Universidade Católica de Campinas

Recap: MLP para o MNIST dataset

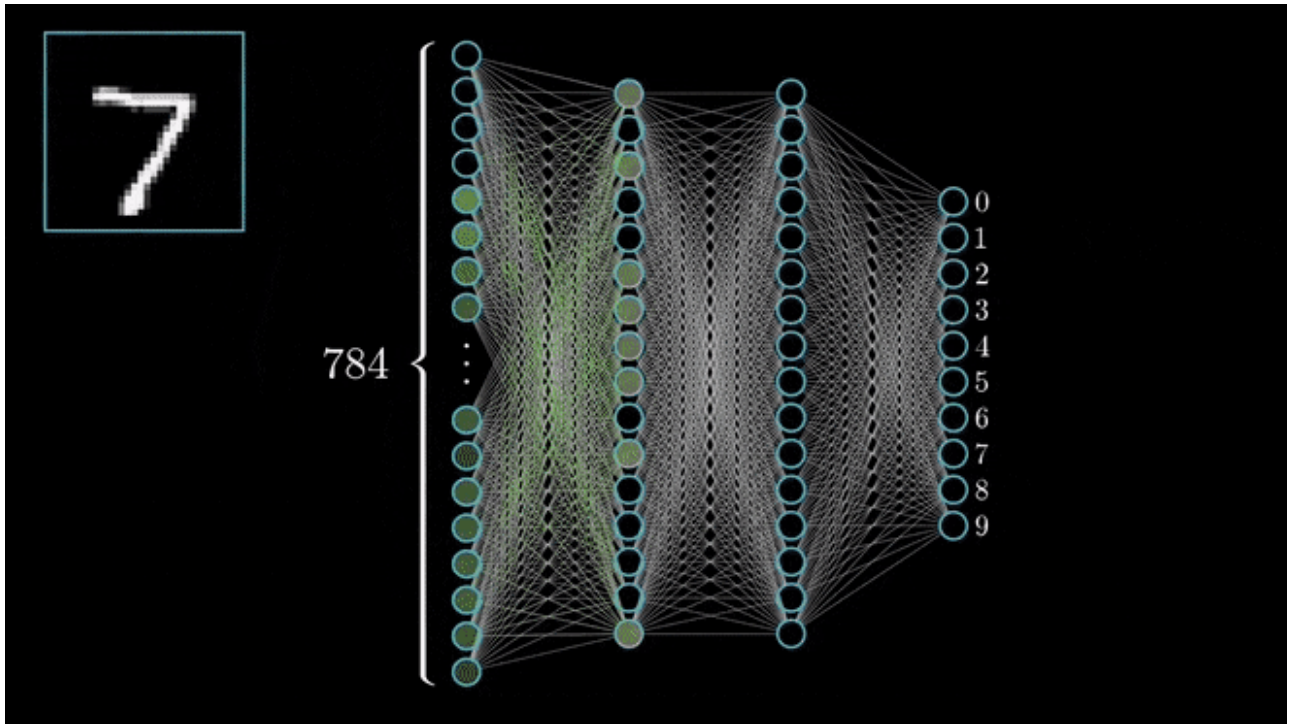

MLP para MNIST dataset. Fonte: Analytics Vidhya.

Neurônio da Camada Escondida

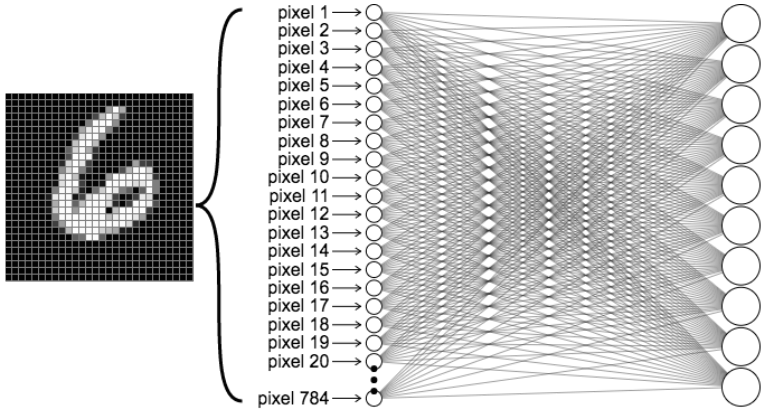

Rede de 1 camada para o MNIST dataset. Fonte: ML4a.

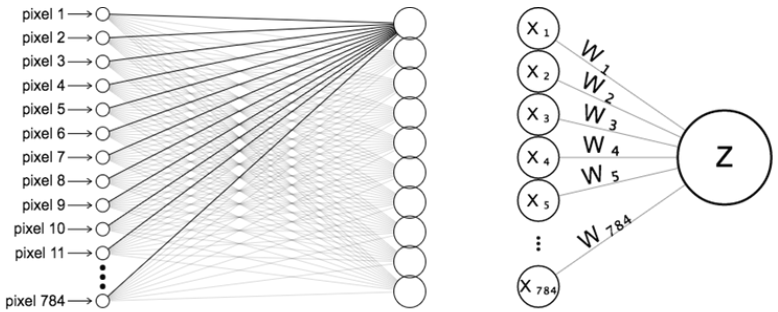

Net input de um neurônio na camada escondida. Fonte: ML4a.

Neurônio da Camada Escondida

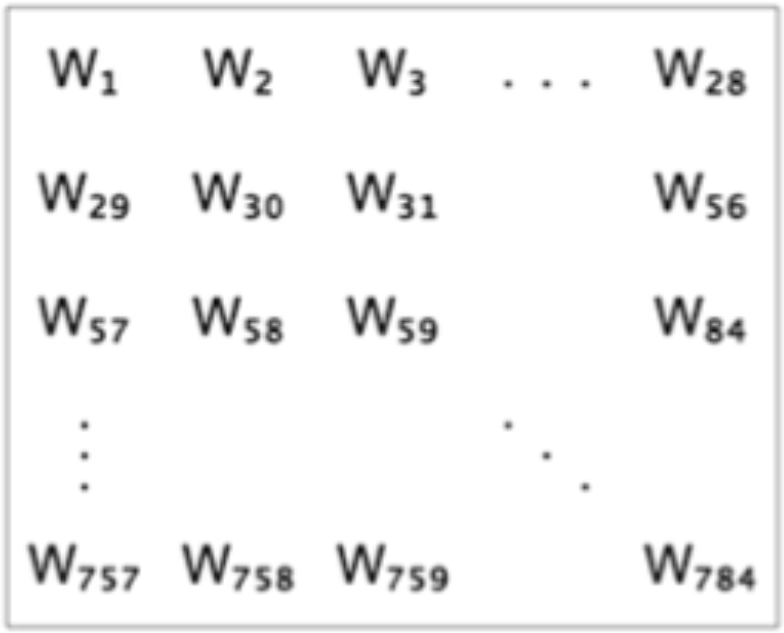

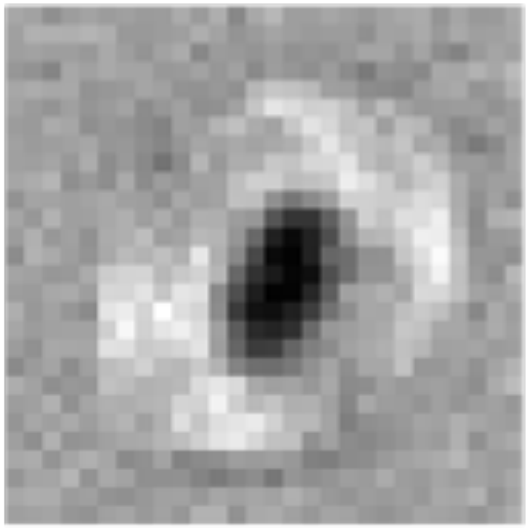

Representação em Imagem de um Neurônio da Camada Escondida de uma MLP para o MNIST dataset. Fonte: ML4a.

Neurônio da Camada Escondida

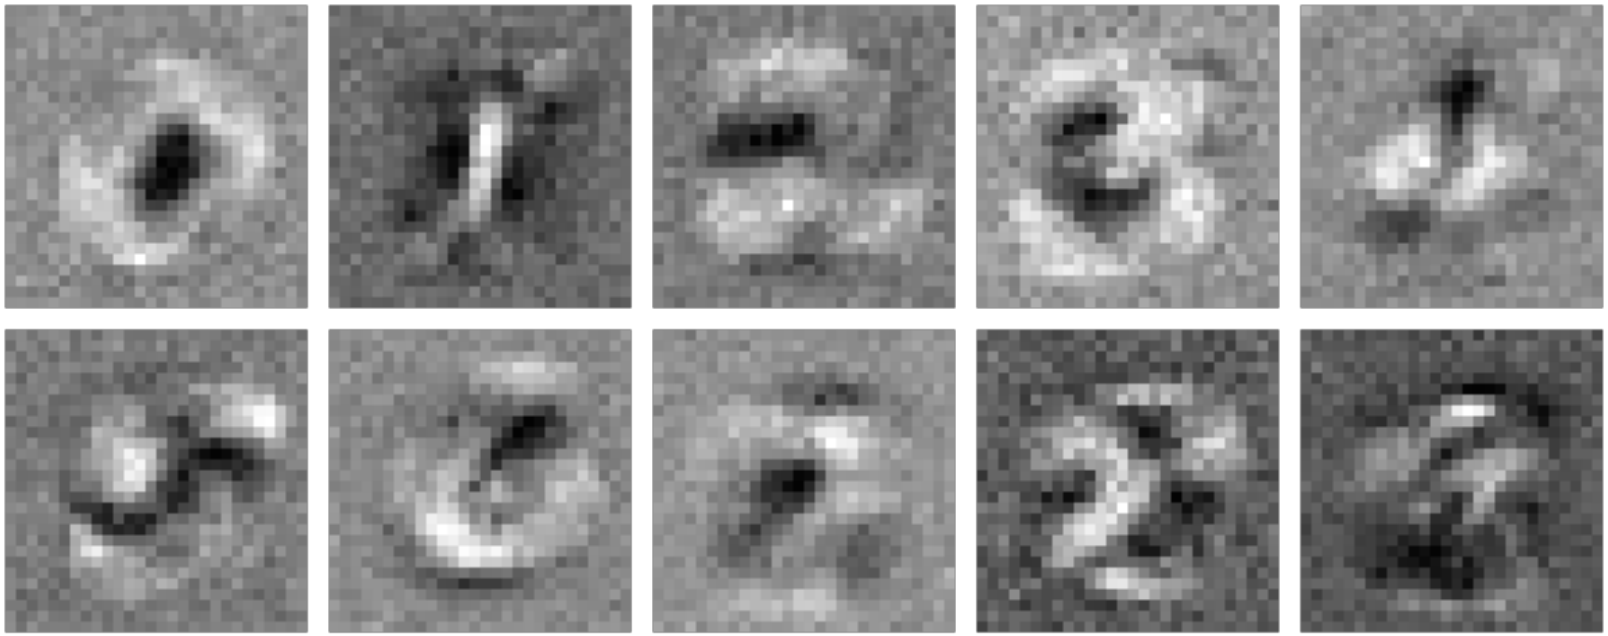

Visualização dos Neurônios da Camada de Saída de uma MLP para o MNIST dataset..

Fonte: ML4a.

Limitações da Rede MLP

- **Dimensionalidade Alta:** Uma imagem 224x244x3 tem 150.528 pixels/entradas. Cada neurônio na primeira camada oculta de um MLP precisaria de 150.528 pesos, levando a bilhões de parâmetros treináveis em uma rede profunda.
- O grande número de parâmetros torna o modelo propenso a **overfitting** (superajuste).

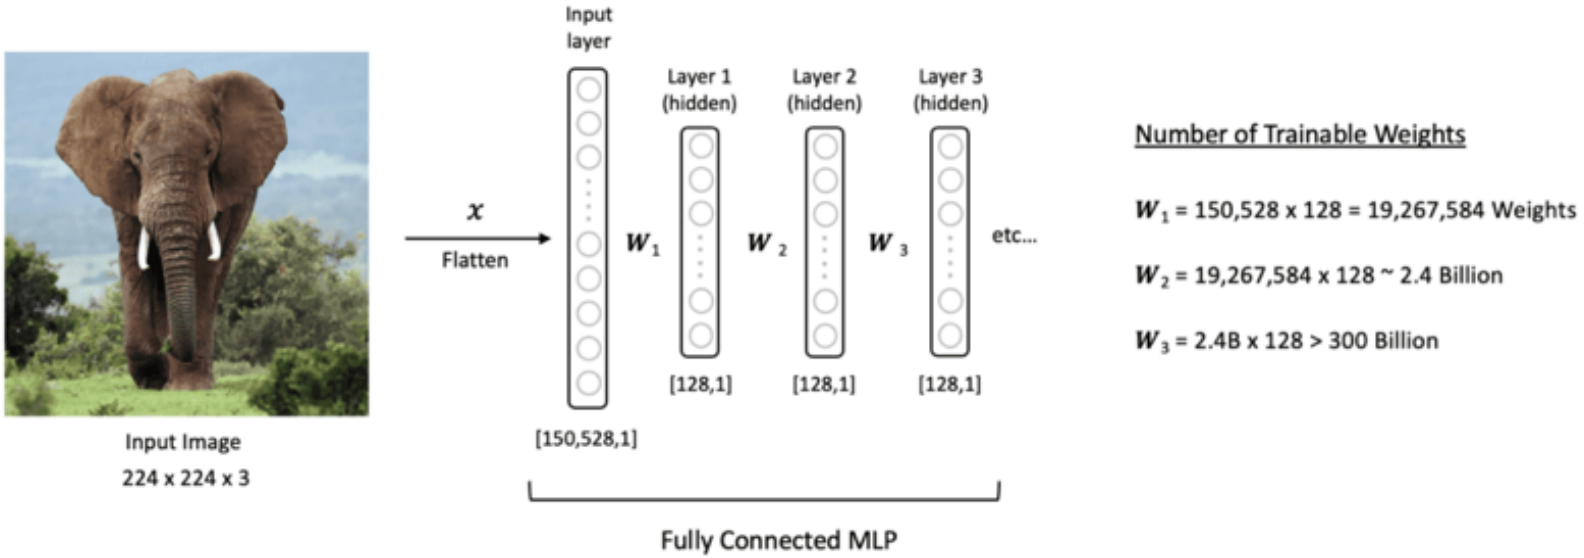

Alta dimensionalidade das MLPs para imagens. Frequentemente levando a overfitting.
Fonte: LearnOpenCV.

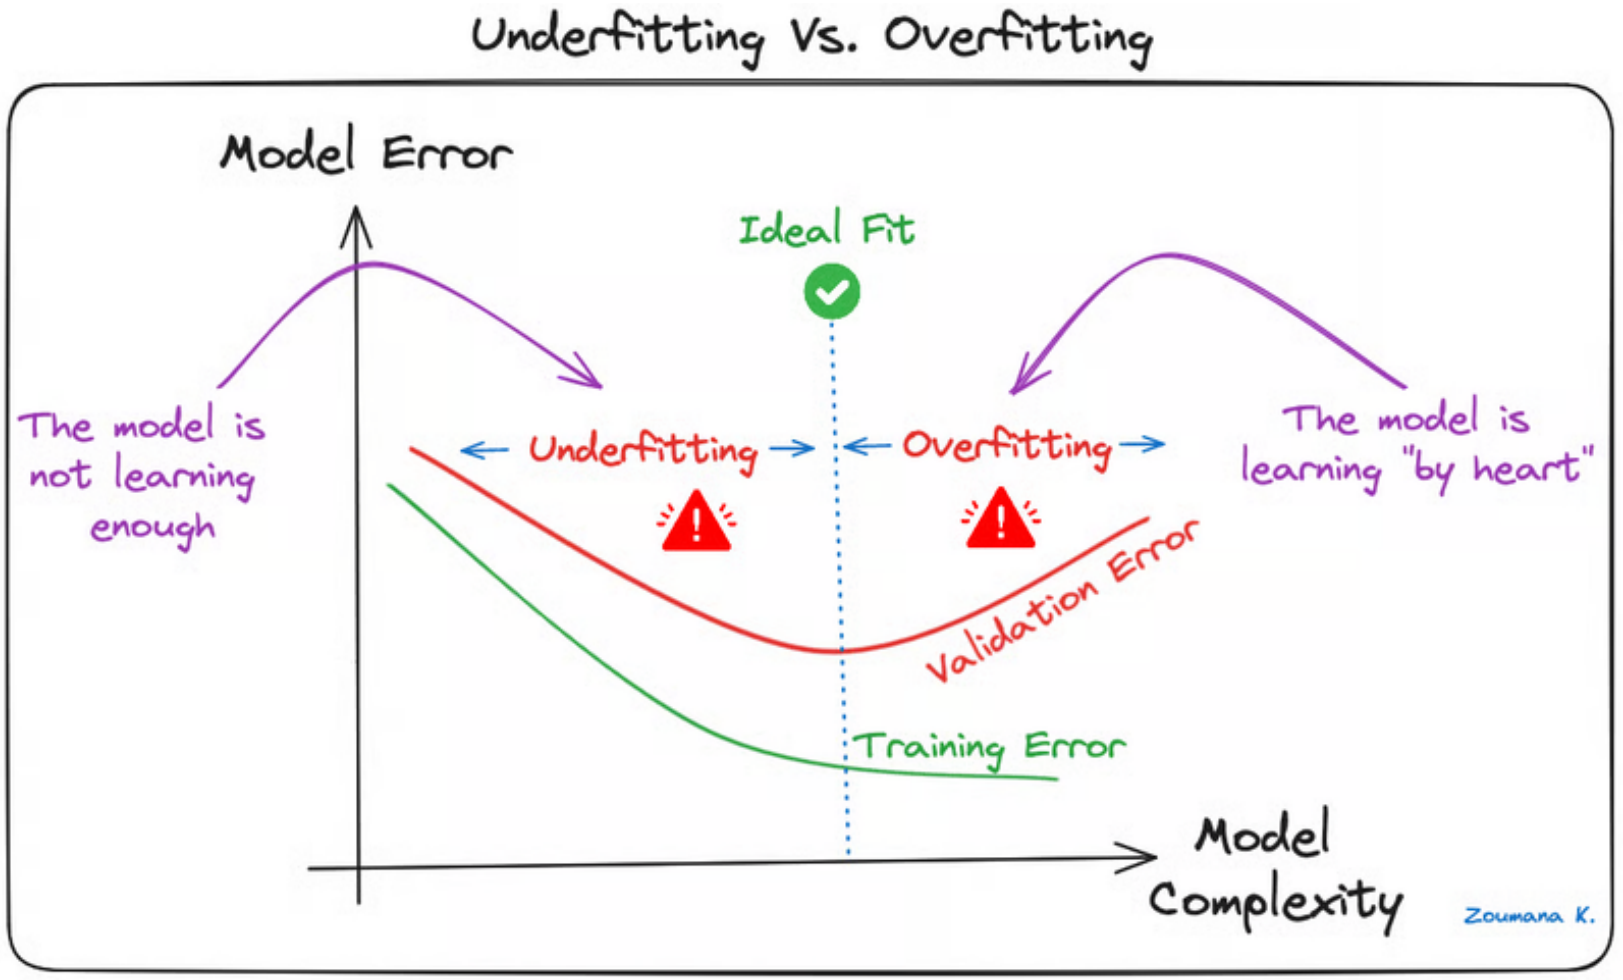

Underfitting versus Overfitting. Fonte: DataCamp.

Limitações da Rede MLP

- **Perda de Estrutura Espacial:** MLPs exigem que a imagem 2D/3D seja "achatada" (flattened) em um vetor 1D.
- Isso destrói a informação de localidade: pixels próximos (semânticos) são tratados da mesma forma que pixels distantes.

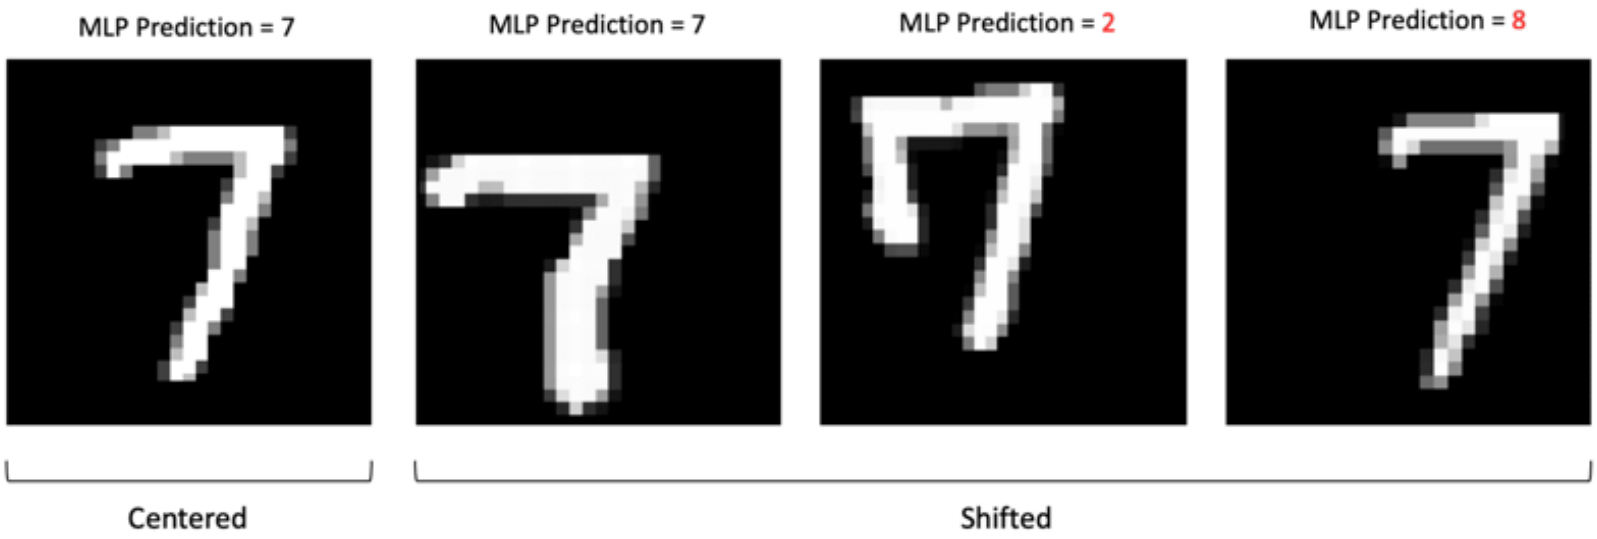

MLPs não são invariantes à translação. Fonte: LearnOpenCV.

Objetivos de Aprendizagem

- Explicar por que CNNs são adequadas para dados de imagem.
- Descrever os blocos fundamentais (convolução, padding, stride, pooling, ativação).
- Esboçar uma arquitetura simples de CNN e justificar cada componente.
- Implementar um CNN mínimo em PyTorch que classifica dígitos MNIST.

Redes Neurais Convolucionais

- Convolutional Neural Nets (**CNNs** ou ConvNets) são arquiteturas de redes neurais otimizadas para dados com estrutura de grade, como imagens.
- CNN aplica uma série de transformações na imagem original (veja esquema abaixo) com três tipos de camadas (**convolution, pooling e fully connected**).
- A sequência de camadas antes da camada fully connected é chamada de extrator de características.

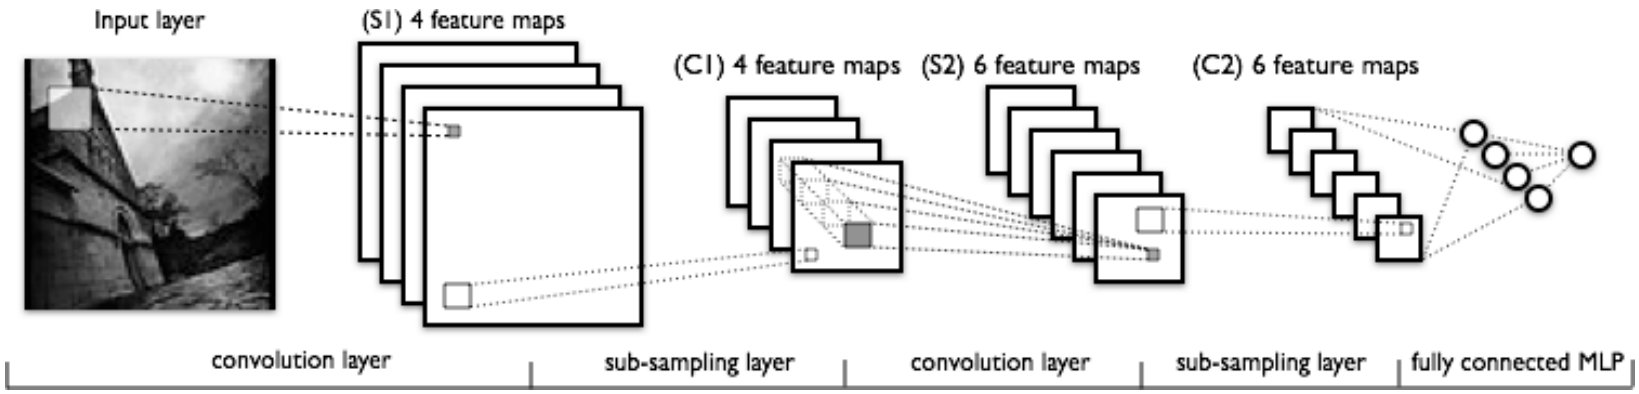

Estrutura geral de uma CNN. Fonte: pathmind.

Demo de CNN para o MNIST

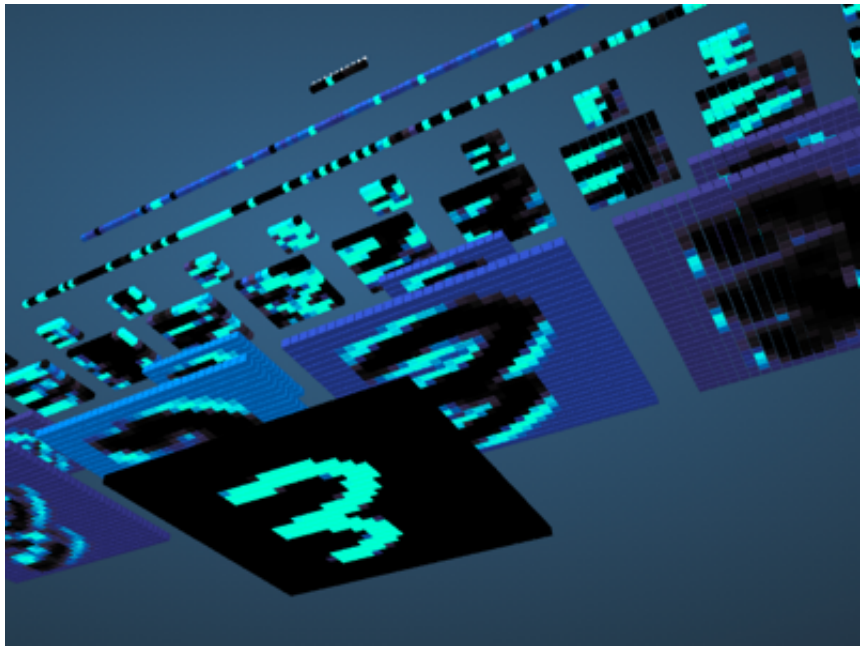

Estrutura geral de uma CNN. Fonte: Adam W. Harley.

CNN em Pytorch: Demo

Código completo no site do professor: https://denmartins.github.io.

In [1]:

```
import torch.nn as nn
import torch.nn.functional as F

class SimpleCNN(nn.Module):
    def __init__(self):
        super(SimpleCNN, self).__init__()
        self.sequential = nn.Sequential(
            # Primeira camada convolucional
            nn.Conv2d(in_channels=1, out_channels=32,
                      kernel_size=2, padding=1),
            nn.ReLU(),
            # Segunda camada convolucional
            nn.Conv2d(in_channels=32, out_channels=64,
                      kernel_size=2, padding=1),
            # Pooling Max: 2x2
            nn.MaxPool2d(kernel_size=2, stride=2),
            # Flatten de matriz para vetor.
            nn.Flatten(),
            # Definindo as camadas FC
            # Camada Totalmente Conectada 1
            nn.Linear(14400, 128),
            nn.ReLU(),
            # Camada de Saída (10 classes para MNIST)
            nn.Linear(128, 10)
        )

    def forward(self, x):
        return self.sequential(x)
```

In [7]:
```
train_model_mini_batch_with_validation(
    EPOCHS,
    train_loader,
    valid_loader,
    model,
    loss_function,
    optimizer)
```

```
Training:   0%|          | 0/10 [00:00<?, ?it/s]
```

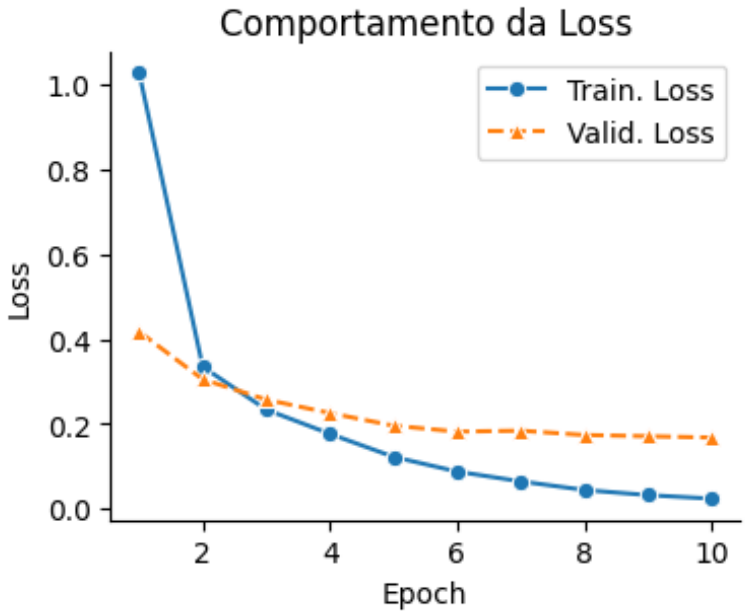

Convolução em CNNs

- O bloco fundamental de uma CNN é a **Camada Convolucional**.
- A convolução é uma busca por padrões: o filtro desliza sobre a imagem, procurando por uma característica específica.
- Se o padrão do filtro corresponder à região da imagem, o resultado será um valor alto (ativação).
- **Conectividade Local:** Os neurônios da CNN se conectam apenas a uma pequena região local do volume de entrada, chamada **campo receptivo**.
- Isso explora a correlação local, pois as características importantes (bordas, curvas) são localizadas.

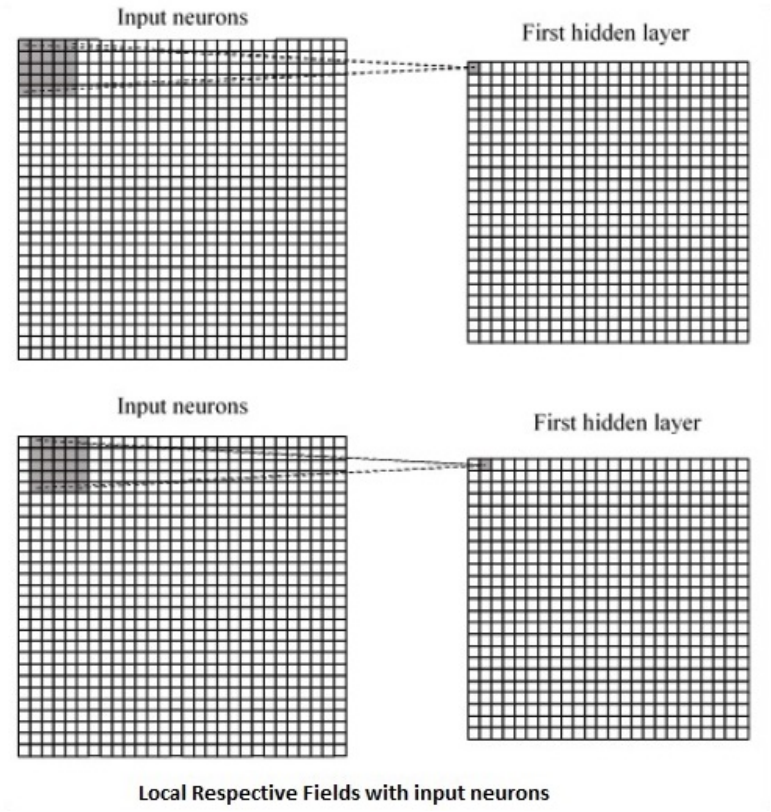

Convolução na camada escondida. Fonte: Michael Nielsen.

Convolução em CNNs

- Cada filtro na camada convolucional aprende a detectar um tipo de característica (**feature**).
- Nas camadas iniciais, os filtros detectam características de baixo nível, como bordas horizontais, verticais e curvas.
- **O filtro em si é uma matriz de pesos (parâmetros) cujos valores são aprendidos durante o treinamento via backpropagation.**

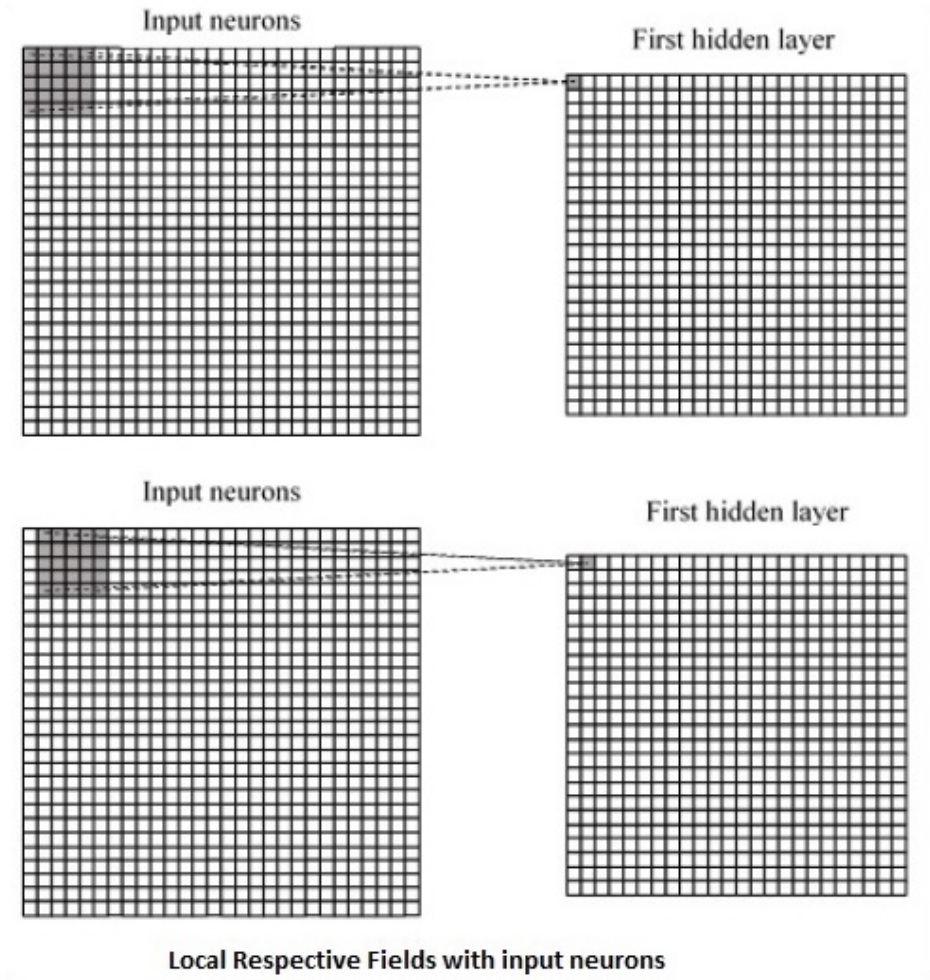

Convolução no primeiro neurônio da camada escondida. Fonte: Michael Nielsen.

Convolução em CNNs

- A operação de convolução (para fins de CNN) é o **produto escalar** (multiplicação elemento a elemento seguida por soma) entre o filtro e a região de entrada correspondente. $\text{Output} = \sum_{i,j}(\text{Input}_{i,j} \times \text{Filter}_{i,j}) + \text{Bias}$
- O resultado é um único número que mede o grau de correspondência do filtro com a região de entrada. Veja também: Convolution arithmetic.
- Esse processo é repetido para cada localização onde o filtro desliza.
- Os resultados são colocados em uma matriz de saída chamada **Mapa de Ativação** (Activation Map) ou **Mapa de Características** (Feature Map).

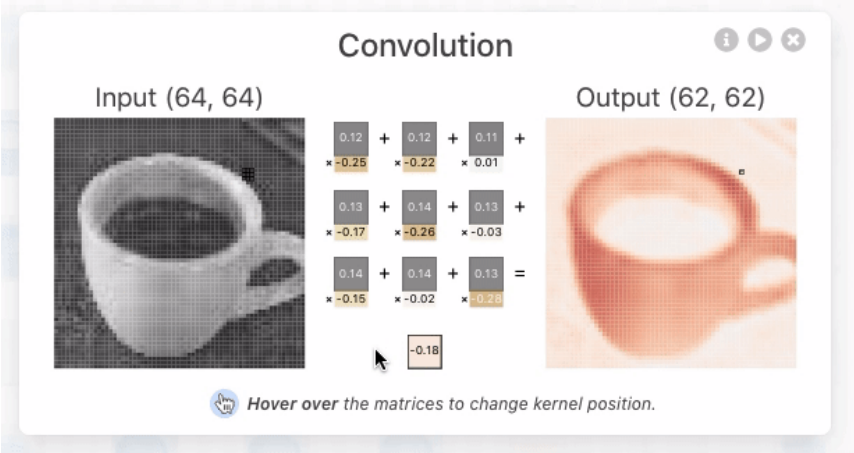

Convolução e Feature Map. Fonte: CNN Explainer.

Convolução 3D

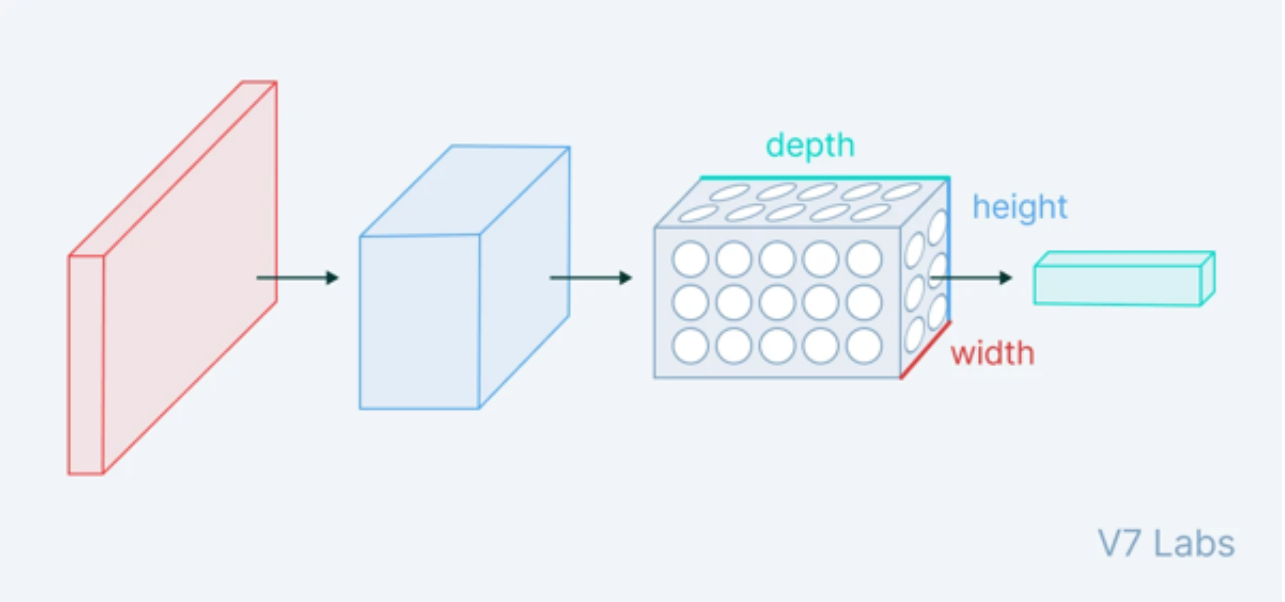

Convolução e Volume. Fonte: V7 Labs.

Hyperparâmetros da Convolução

- **Kernel Size (F):** Tamanhos comuns são 3×3 ou 5×5. Tamanhos menores são frequentemente preferidos para extrair features com menos parâmetros.
- **Número de Filtros:** Aumenta com a profundidade; geralmente começa em 32 e dobra (64, 128, etc.).
- **Stride (S):** É o número de pixels que o filtro se move (desloca) sobre a entrada a cada iteração.
    - **Stride = 1:** O filtro se move um pixel por vez, resultando em sobreposição de campos receptivos e um mapa de ativação grande.
    - **Stride > 1:** Causa um "salto" maior do filtro, resultando em menos etapas e um mapa de ativação espacialmente menor.
    - Um *stride* maior reduz a dimensionalidade e o custo computacional.
- **Padding**: É a adição de pixels extras (geralmente com valor zero, **Zero-Padding**) em torno das bordas da imagem de entrada.
    - **Problema de Redução:** Sem padding, a convolução geralmente reduz o tamanho espacial da saída. Padding garante que os pixels de borda (que seriam pouco usados) participem do campo receptivo.
    - **Padding "Same" (Igual):** Adiciona zeros o suficiente para que a dimensão espacial da saída seja a mesma da entrada (assumindo $S = 1$).
    - **Padding "Valid" (Válido):** Não usa padding, resultando em uma saída menor que a entrada.

Mapa de Ativação

Determinando o Tamanho do Mapa de Ativação:

- O tamanho espacial de saída O de uma camada convolucional é determinado pela dimensão de entrada (N), tamanho do kernel (F), Padding (P) e Stride (S).
- Para que o resultado seja um inteiro, a fórmula abaixo deve ser satisfeita.

$$O = \lfloor \frac{N - F + 2P}{S} \rfloor + 1$$

Exemplo: Imagem de entrada 32×32 ($N = 32$), Kernel 5×5 ($F = 5$).

- **Cenário 1 (Stride e Padding):** Stride $S = 1$. Para obter *Same Padding* (preservar 32x32), P deve ser: $P = (F - 1)/2 = (5 - 1)/2 = 2$.
    - $O = \frac{32 - 5 + 2(2)}{1} + 1 = \frac{31}{1} + 1 = 32$
    - A saída é 32×32 (tamanho preservado).
- **Cenário 2 (Sem Padding, Stride 1):** $P = 0, S = 1$.
    - $O = \frac{32 - 5 + 0}{1} + 1 = 27 + 1 = 28$
    - A saída é 28×28.

Compartilhamento de Parâmetros

- O **Compartilhamento de Parâmetros** é uma característica distintiva das CNNs.
- O mesmo filtro (conjunto de pesos) é usado em todas as posições espaciais da camada de entrada.
- Para um filtro 5x5: $\sigma\left(b + \sum_{l=0}^{4} \sum_{m=0}^{4} w_{l,m} a_{j+l,k+m}\right)$
- **Vantagem I: Redução de Parâmetros:** Em vez de cada neurônio ter seu próprio conjunto de pesos, muitos neurônios compartilham o mesmo filtro.
- **Vantagem II: Equivariância à Translação:** Se uma característica (ex: uma linha) for útil em uma parte da imagem, ela será útil em qualquer outra parte.
- O filtro aprende a detectar a característica independentemente da sua localização exata.

Função de Ativação (ReLU)

- Após a operação de convolução (que é linear), uma função de ativação é aplicada ao mapa de ativação para introduzir não-linearidade.
- **ReLU** é a função mais comum: $f(x) = \max(0, x)$.
- Ela remove valores negativos, ajustando-os para zero, o que pode ser visto como uma função de limiar (thresholding).

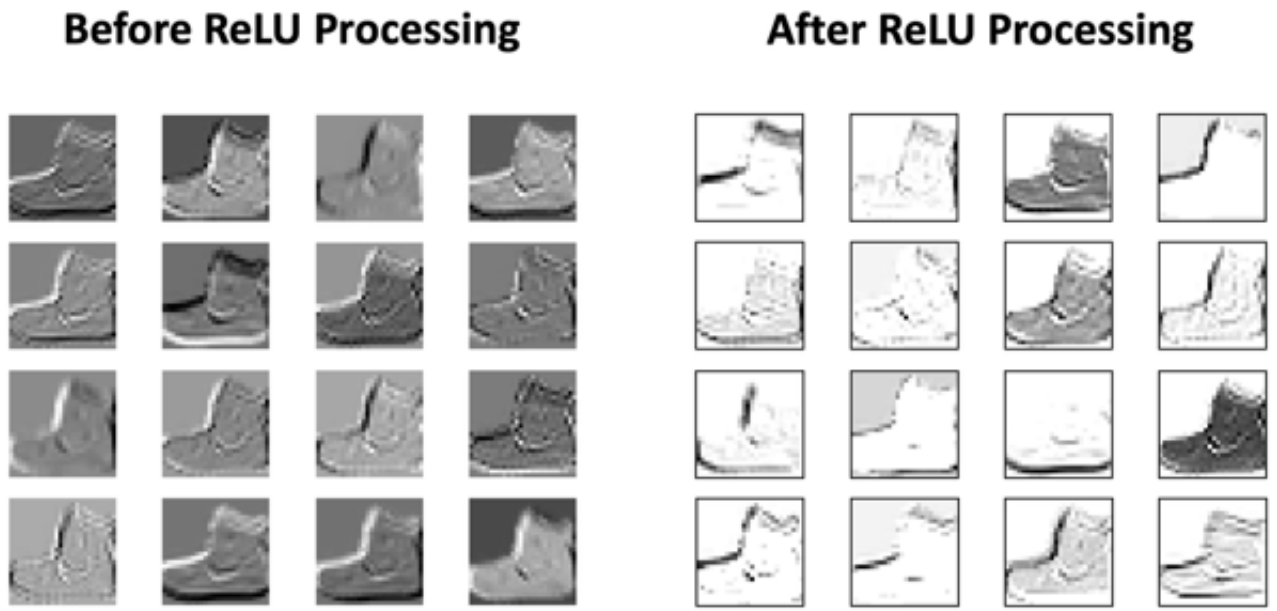

Efeito da ReLU. Fonte: Bouvet.

Pooling (Subamostragem)

- O **Pooling** é uma forma de subamostragem (downsampling) não linear, geralmente inserida periodicamente entre camadas convolucionais.
- **Objetivos Principais:**
    - Reduzir a dimensionalidade espacial (Altura e Largura).
    - Reduzir o número de parâmetros e a quantidade de computação.
    - Ajudar a controlar o overfitting.
    - Conceder um grau de **invariância local à translação**.
- O filtro de pooling **não tem parâmetros treináveis** (não tem pesos).
- Um 2×2 Max Pooling com $S = 2$ descarta 75% das ativações espaciais

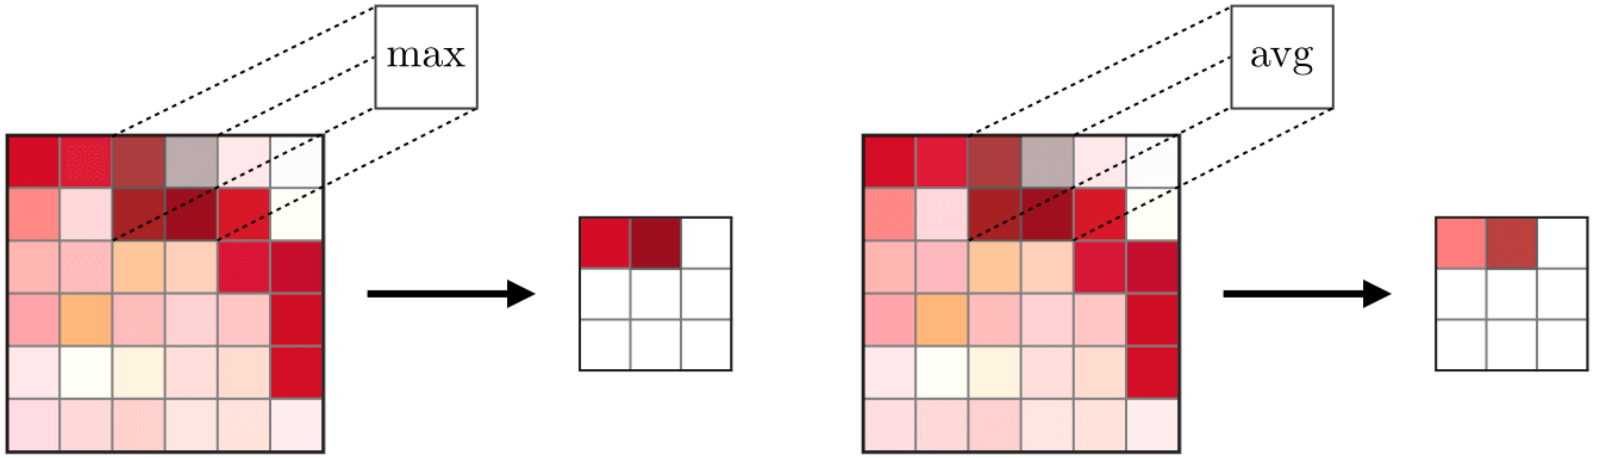

Max pooling. Fonte: Stanford.edu.

Average pooling. Fonte: Stanford.edu.

Pooling: Exemplo numérico

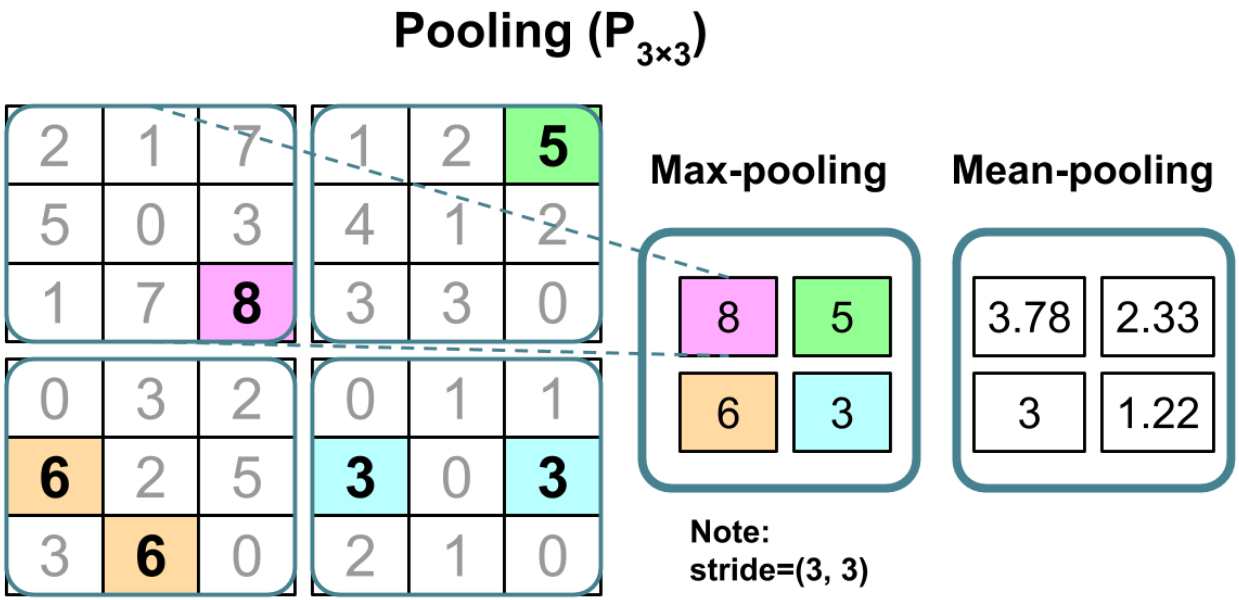

Pooling. Fonte: Sebastian Raschka.

Fully Connected (FC)

- Após uma série de camadas Convolucionais e de Pooling, o volume de dados contém características de alto nível.
- A última etapa é a classificação, realizada por camadas **Totalmente Conectadas (FC)** (ou densas).
- **Flattening (Achatamento):** O volume 3D final do extrator de características deve ser convertido em um vetor 1D antes de entrar na primeira camada FC.
- As camadas FC mapeiam as características extraídas para as probabilidades de classe.
- O número de neurônios na camada de saída é igual ao número de classes (e.g., 10 para MNIST).
- Para classificação de imagens: A camada de saída do classificador FC tipicamente usa a função de ativação **Softmax** para converter os valores brutos de saída da rede em probabilidades normalizadas.

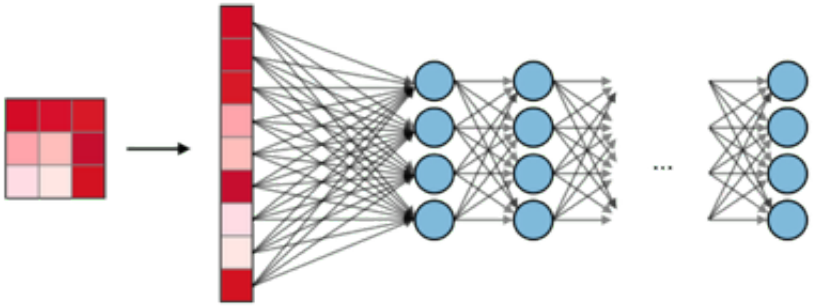

Camada FC. Fonte: Stanford.edu.

Arquitetura CNN

- Uma CNN de classificação é dividida em duas partes principais:
    1. **Extrator de Características (Feature Extractor):** Composto por blocos Conv + ReLU + Pooling (ou ConvBlocks). É comum empilhar 2 ou 3 camadas Conv/ReLU consecutivas antes de uma camada Pooling.
    2. **Classificador (Classifier):** Composto por camadas FC + Softmax.
- O fluxo de dados transforma o volume de entrada, tipicamente reduzindo as dimensões espaciais (H, W) e aumentando a profundidade (Canais/Filtros).
- **Hierarquia de Características:**
    - Camadas iniciais aprendem elementos simples (bordas, cores).
    - Camadas médias combinam elementos simples em formas mais complexas (e.g., olhos, rodas).
    - Camadas profundas aprendem conceitos abstratos de alto nível (e.g., faces, objetos inteiros).

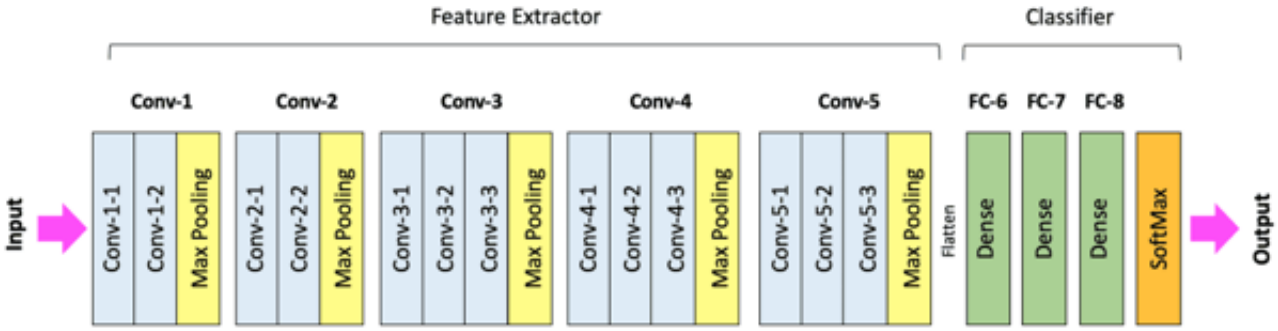

Exemplo de Arquitetura de uma CNN. Fonte: LearnOpenCV.

Treinamento

- As CNNs são tipicamente treinadas usando **Aprendizado Supervisionado**.
- Os pesos iniciais (elementos dos filtros) são definidos aleatoriamente.
- O processo de aprendizagem utiliza o **Backpropagation** e o **Gradiente Descendente**.
- **Loss Function (Função de Perda):** Mede o erro entre a previsão da rede e o rótulo verdadeiro (Ground Truth).
- **Otimização:** O algoritmo ajusta iterativamente os pesos (filtros e FC) para minimizar a perda.

Mais informações sobre o algoritmo de Backpropagation e Gradiente Descendente na próxima aula.

Resumo

- As CNNs são inerentemente adequadas para processar imagens devido a três propriedades principais:
    1. **Conectividade Local:** Foca na correlação espacial, que é forte em imagens.
    2. **Compartilhamento de Pesos:** Reduz drasticamente os parâmetros, mitigando o overfitting e tornando o modelo escalável.
    3. **Pooling:** Introduz downsampling, que reduz a complexidade e a memória, e concede invariância local a pequenas variações de posição.
- A capacidade de aprender características (filtros) automaticamente elimina a necessidade de definir manualmente os recursos visuais.
- **Arquitetura:** CNNs são formadas por um Extrator de Características (Conv/Pooling) seguido por um Classificador (FC/Softmax).
- **Leitura Recomendada**:
    - An Introduction to Convolutional Neural Networks.
    - CNN Explainer
    - ConvNets by Stanford

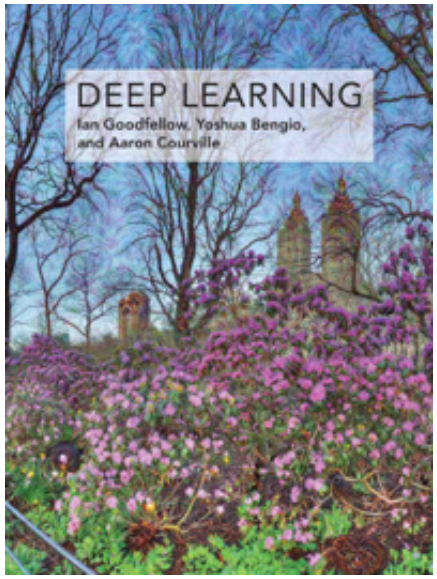

Leitura Recomendada:
Capítulo 9.

Perguntas e Discussão

1. O Perceptron Multicamadas (MLP) é a arquitetura básica de redes neurais. Por que os MLPs são inerentemente inadequados para processar imagens de alta resolução, e como a CNN supera a principal limitação de dimensionalidade do MLP?
2. As três principais operações em um extrator de características de CNN são **Convolução**, **ReLU** e **Pooling**. Qual é a contribuição fundamental de cada uma dessas operações para a capacidade de uma CNN aprender e generalizar, especialmente no contexto de downsampling?
3. O treinamento de uma CNN envolve o aprendizado automático de filtros (pesos). Descreva a natureza hierárquica das características aprendidas em CNNs profundas. O que um filtro (kernel) típico nas camadas iniciais detecta em comparação com as características detectadas nas camadas mais profundas?
4. Qual é o objetivo do **Zero-Padding** e qual o valor de padding (P) deve ser escolhido para um filtro de tamanho F se quisermos garantir que a saída espacial (O) seja exatamente a mesma que a entrada espacial (N), assumindo um Stride (S) de 1? Demonstre usando a fórmula do tamanho de saída.
5. Vimos que os filtros não são pré-definidos manualmente, mas sim aprendidos. Na fase de treinamento, como o algoritmo de Backpropagation (Retropropagação) "sabe" qual filtro deve ser ajustado para detectar uma curva ou uma linha, se os pesos são inicializados aleatoriamente? Por que esse processo não é considerado "sorte" ou aleatório?