

4-2 卷积神经网络 I

王中雷

厦门大学王亚南经济研究院和经济学院, 2025

内容摘要

1. 简介

2. 基本框架

3. 前向传播

4. 后向传播

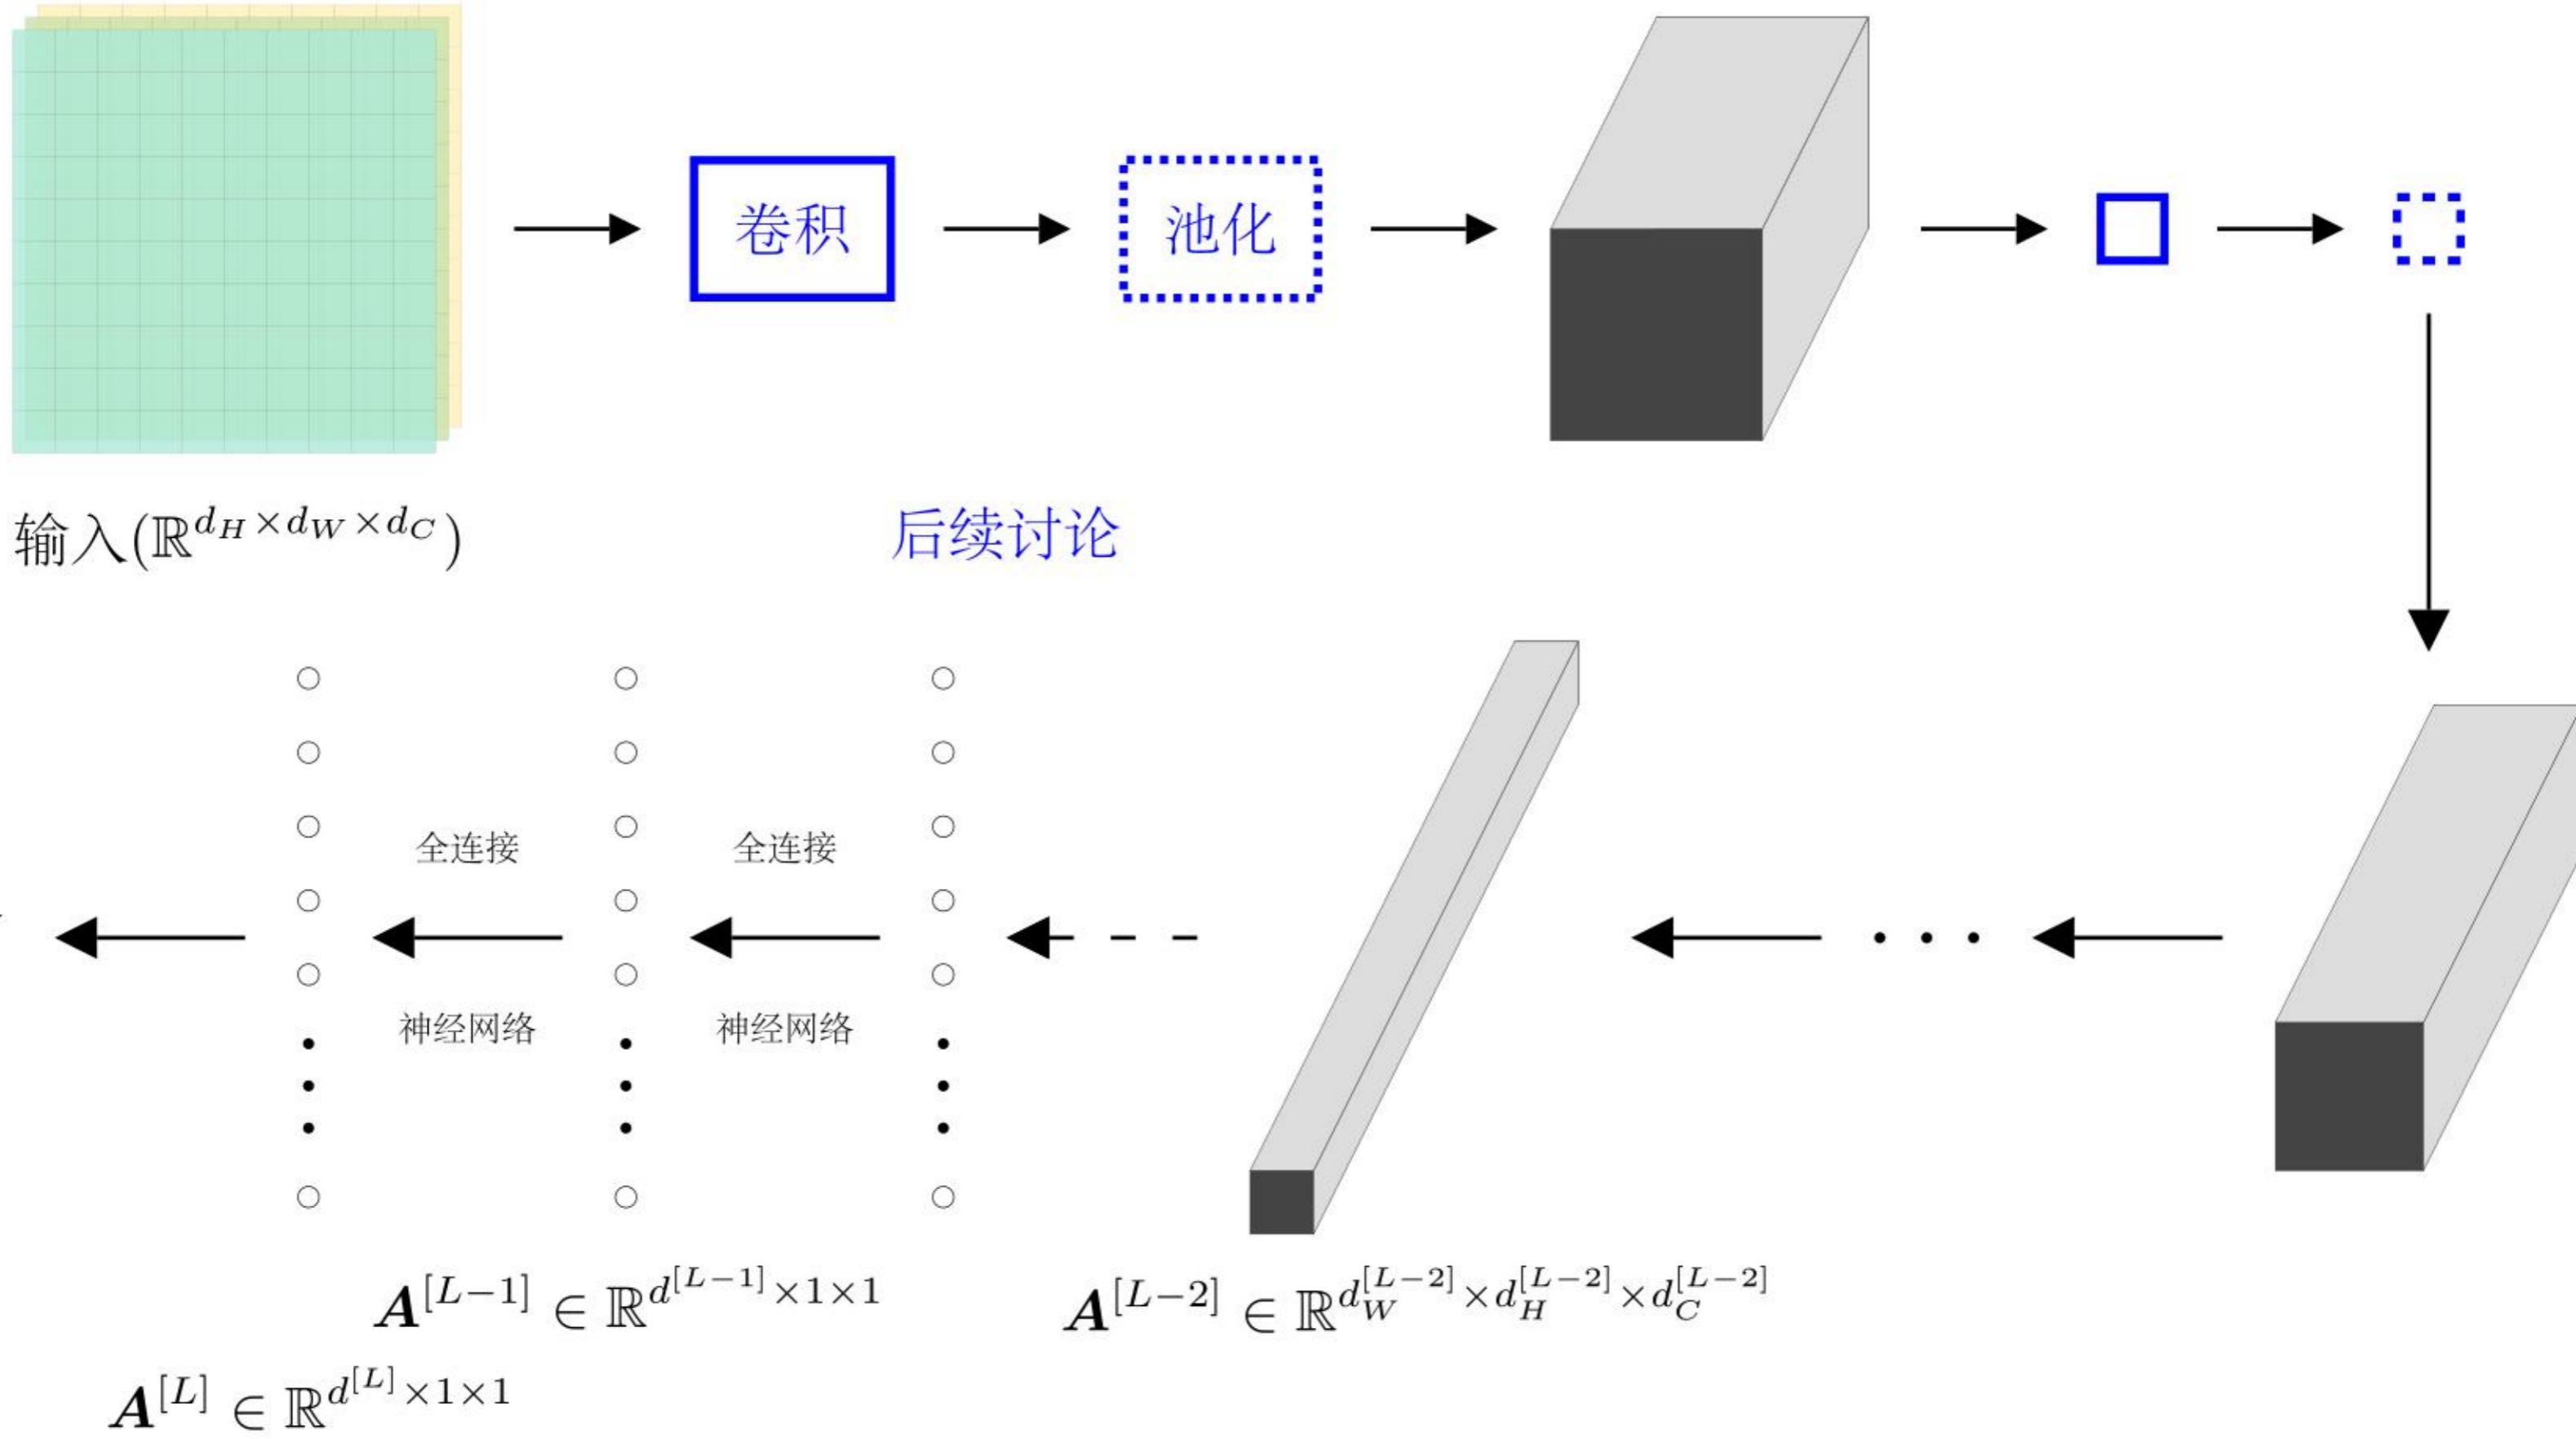
5. 理解卷积神经网络

简介

1. 当输入特征是图片时，为什么不考虑全连接神经网络

- 模型参数将变得**非常巨大**，容易造成过拟合
 - ▷ 为了解决这个问题，我们需要更多的训练样本、内存以及更快的算法
 - ▷ 实际上几乎不可能做到
- 忽略了图片中的空间结构
- 不具有空间平移不变性

2. 针对图片处理，我们需要考虑一个新的模型框架（卷积神经网络）



总结

1. 一般来讲， $d_C^{[l]}$ 随着层数 l 的增加而增加，但 $d_W^{[l]}$ 和 $d_H^{[l]}$ 降低
2. 向量化不涉及模型参数的估计
3. 通常来讲，卷积神经网络有如下三个“层”：
 - 卷积（Convolution）层（CONV）
 - 池化（Pooling）层（POOL）
 - 全连接（FC）层

符号

1. l : 层指标
2. $d_H^{[l]}$: 第 l 层对应“图片”的“高”
3. $d_W^{[l]}$: 第 l 层对应“图片”的“宽”
4. $d_C^{[l]}$: 第 l 层对应“图片”的“通道”数
5. $f^{[l]}$: 第 l 层对应卷积核的尺寸
6. $p^{[l]}$: 第 l 层对应填充 (padding) 数
7. $s^{[l]}$: 第 l 层对应步幅 (stride) 数

向量化

1. $A^{[l-1]} \in \mathbb{R}^{n \times d_H^{[l-1]} \times d_W^{[l-1]} \times d_C^{[l-1]}}$: 第 l 层的输入“图片”

2. $Z^{[l]} \in \mathbb{R}^{n \times d_H^{[l]} \times d_W^{[l]} \times d_C^{[l]}}$: 第 l 层的线性变换后的结果

$$Z^{[l]} = A^{[l-1]} * W^{[l]} + b^{[l]}$$

$$A^{[l]} = \sigma^{[l]}(Z^{[l]})$$

- $W^{[l]} \in \mathbb{R}^{d_C^{[l]} \times f^{[l]} \times f^{[l]} \times d_C^{[l-1]}}$: 第 l 层的卷积核

- $b^{[l]} \in \mathbb{R}^{d_C^{[l]} \times 1 \times 1 \times 1}$: 第 l 层的偏置项

- “*”: 卷积运算

- “+”: 每个通道与特定的偏置项相加

- $\sigma^{[l]}(\cdot)$: 第 l 层的激活函数

向量化

1. 简单起见，我们针对单一训练样本介绍前向和后向传播过程

- $A^{[l-1]} \in \mathbb{R}^{d_H^{[l-1]} \times d_W^{[l-1]} \times d_C^{[l-1]}}$
- $Z^{[l]} \in \mathbb{R}^{d_H^{[l]} \times d_W^{[l]} \times d_C^{[l]}}$

2. 前向传播

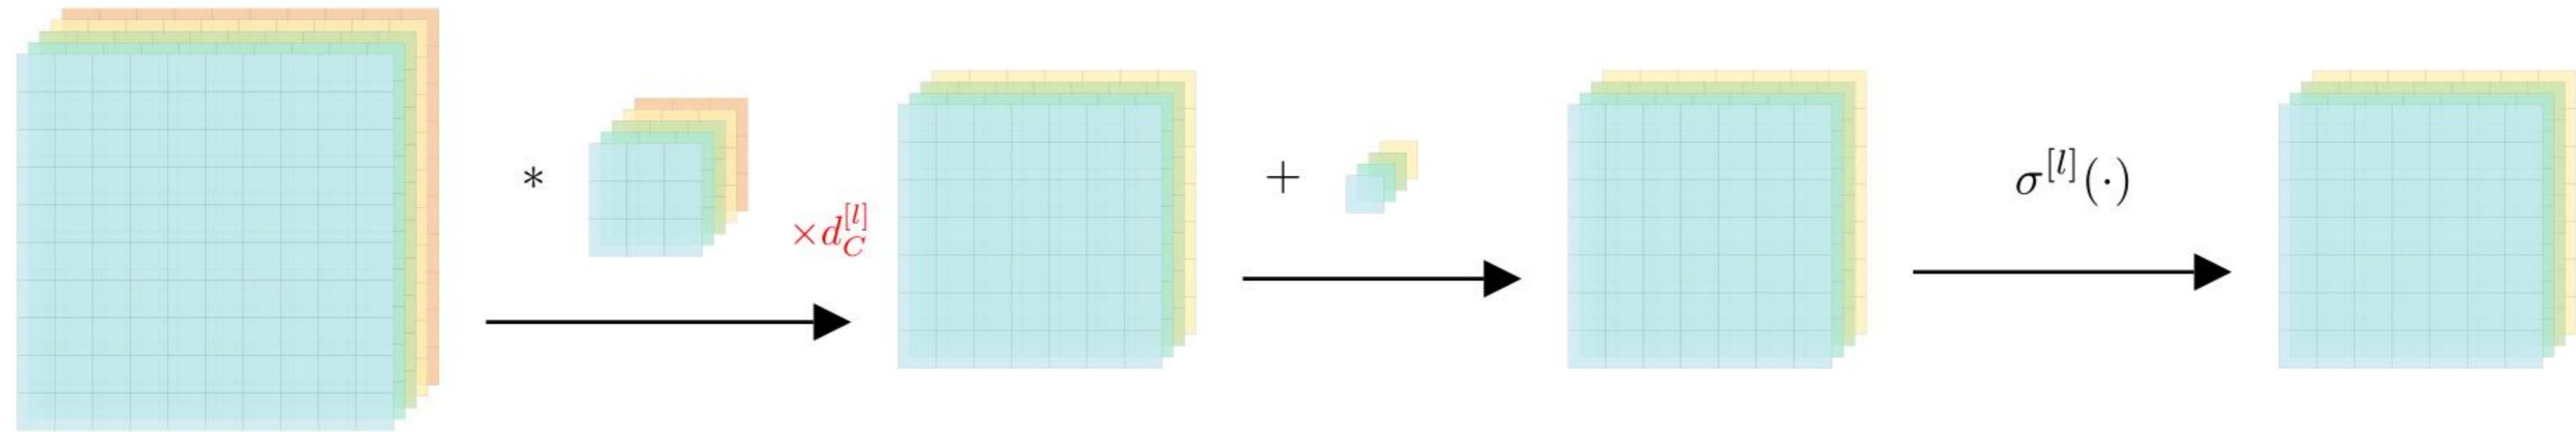
$$\begin{aligned} Z^{[l]} &= A^{[l-1]} * W^{[l]} + b^{[l]} \\ A^{[l]} &= \sigma^{[l]}(Z^{[l]}) \end{aligned}$$

卷积运算

1. 考虑:

- $p^{[l]} = 0$
- $s^{[l]} = 1$

卷积运算



$$A^{[l-1]} \in \mathbb{R}^{d_H^{[l-1]} \times d_W^{[l-1]} \times d_C^{[l-1]}}$$

$$Z_0^{[l]} = \mathbb{R}^{d_H^{[l]} \times d_W^{[l]} \times d_C^{[l]}}$$

$$Z^{[l]} \in \mathbb{R}^{d_H^{[l]} \times d_W^{[l]} \times d_C^{[l]}}$$

$$W^{[l]} \in \mathbb{R}^{d_C^{[l]} \times f^{[l]} \times f^{[l]} \times d_C^{[l-1]}}$$

$$b^{[l]} \in \mathbb{R}^{d_C^{[l]} \times 1 \times 1 \times 1}$$

$$A^{[l]} \in \mathbb{R}^{d_H^{[l]} \times d_W^{[l]} \times d_C^{[l]}}$$

池化 (Pooling)

1. 池化 (Pooling) 运算往往用于卷积运算之后,

- 在每个通道上, 降低“图片”尺寸
- 通过忽略重复或者无用信息, 提高模型稳健性
- 增加感受野 (receptive field)
- 对输入图片的小规模扰动、旋转以及其他不利变换达到稳健性
- 防止过拟合 (尤其与 dropout 同时使用时)

池化 (Pooling)

1. 常见的两种池化运算：

- 平均池化 (Average pooling)
- 最大池化 (Max pooling)

2. 注意：

- 池化运算针对每个通道单独进行
- 池化运算并不引入新的模型参数

平均池化 (Average pooling)

1. 输入尺寸: 6×6
2. (池化) 核尺寸: 2×2
3. 步幅大小 (Stride) : 2

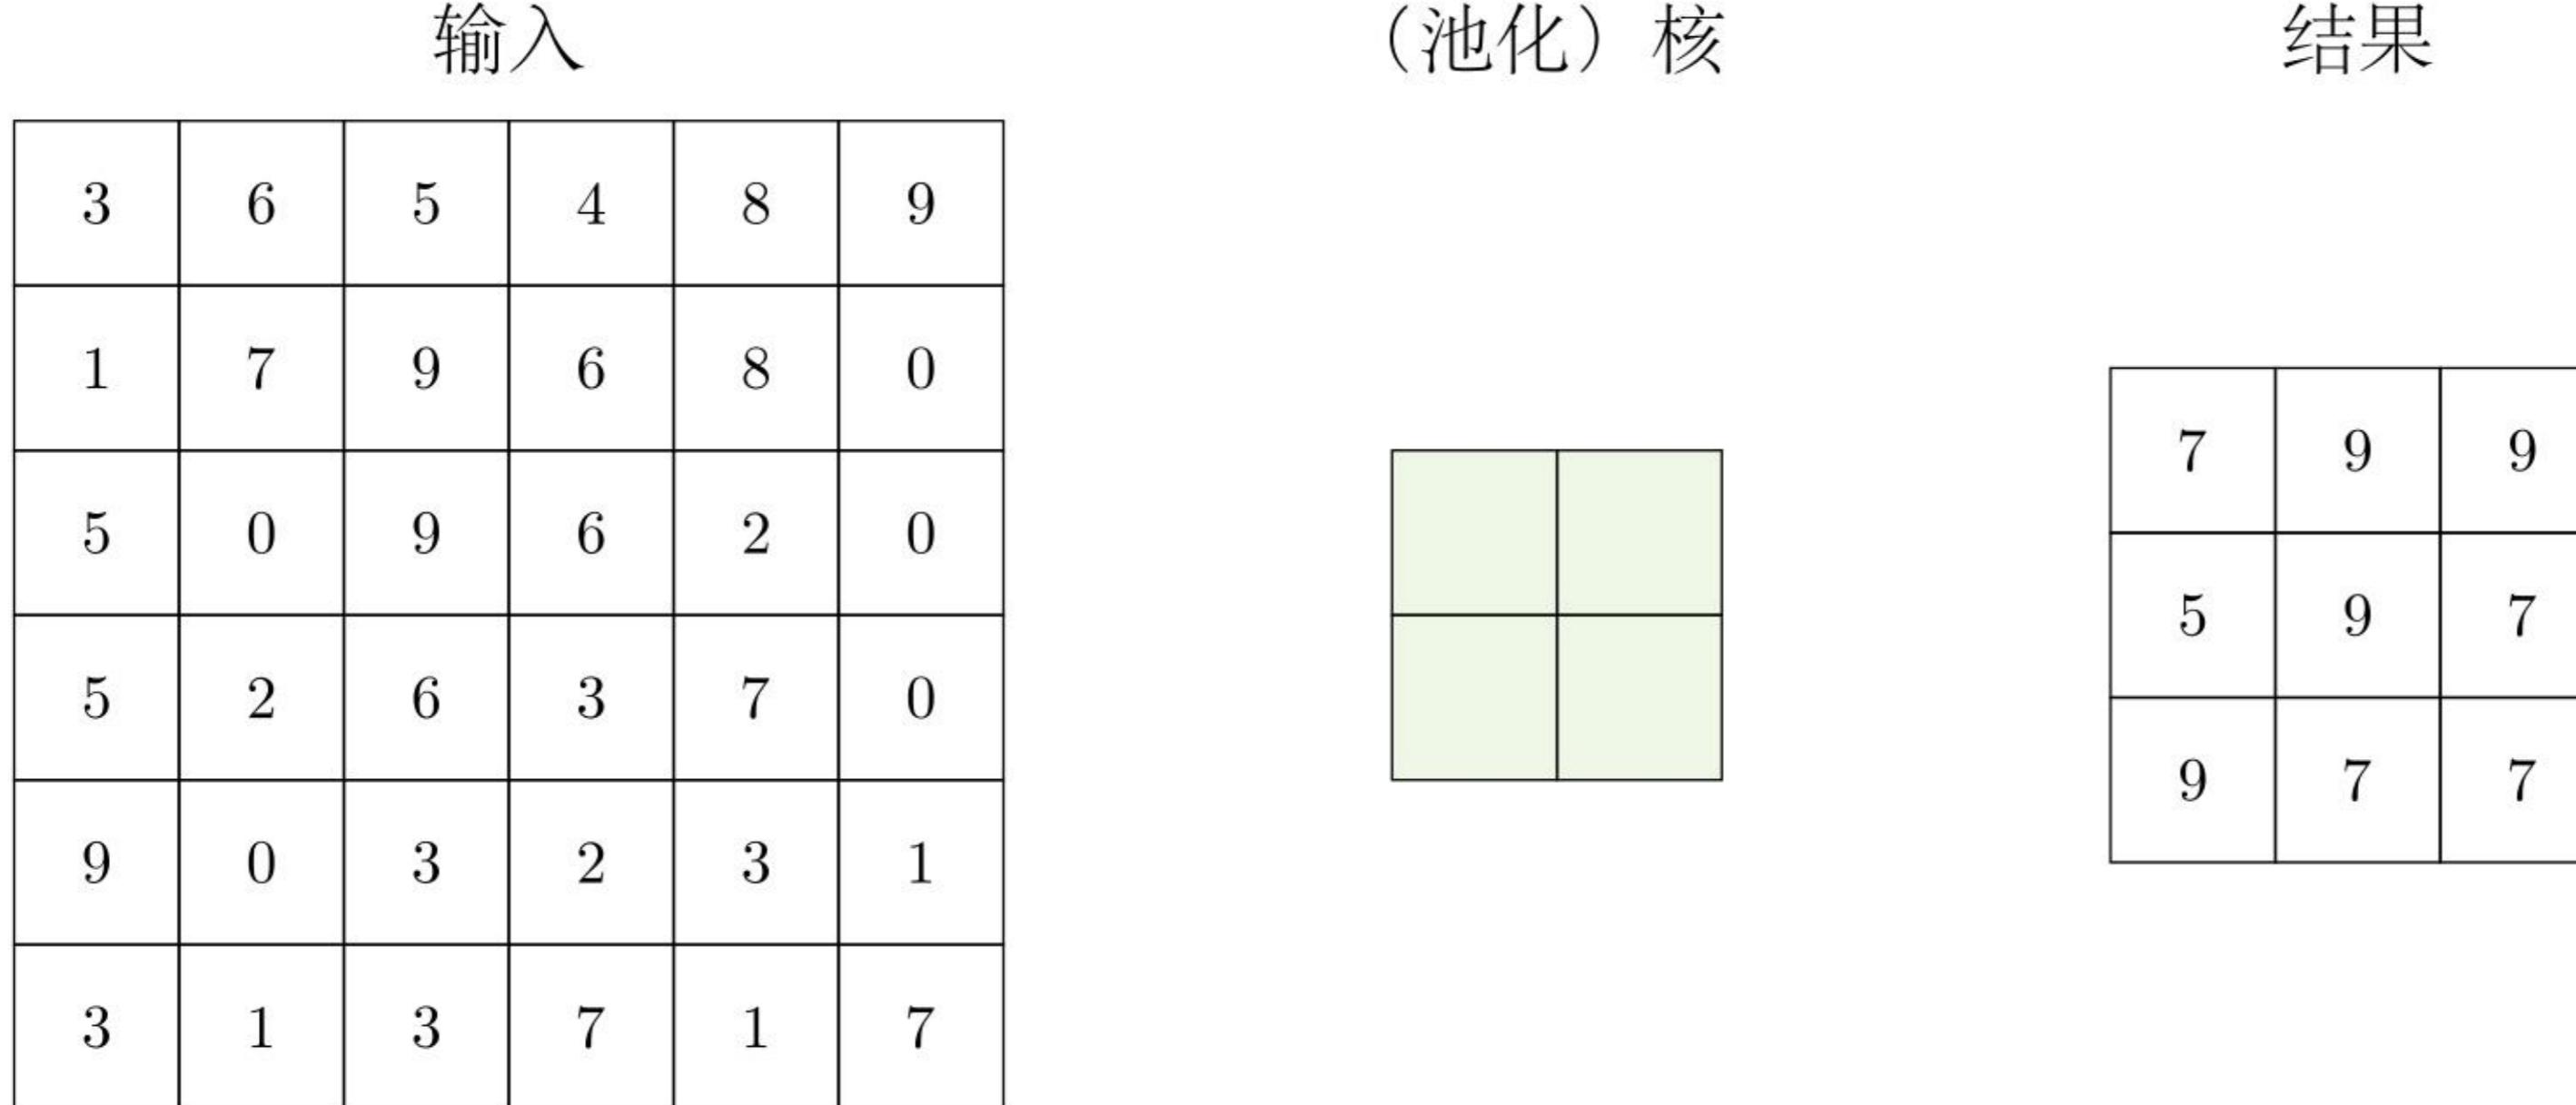
平均池化 (Average pooling)

输入	(池化) 核	结果
3 6 5 4 8 9		
1 7 9 6 8 0		
5 0 9 6 2 0	0.25 0.25	4.25 6.0 6.25
5 2 6 3 7 0	0.25 0.25	3.0 6.0 2.25
9 0 3 2 3 1		
3 1 3 7 1 7		

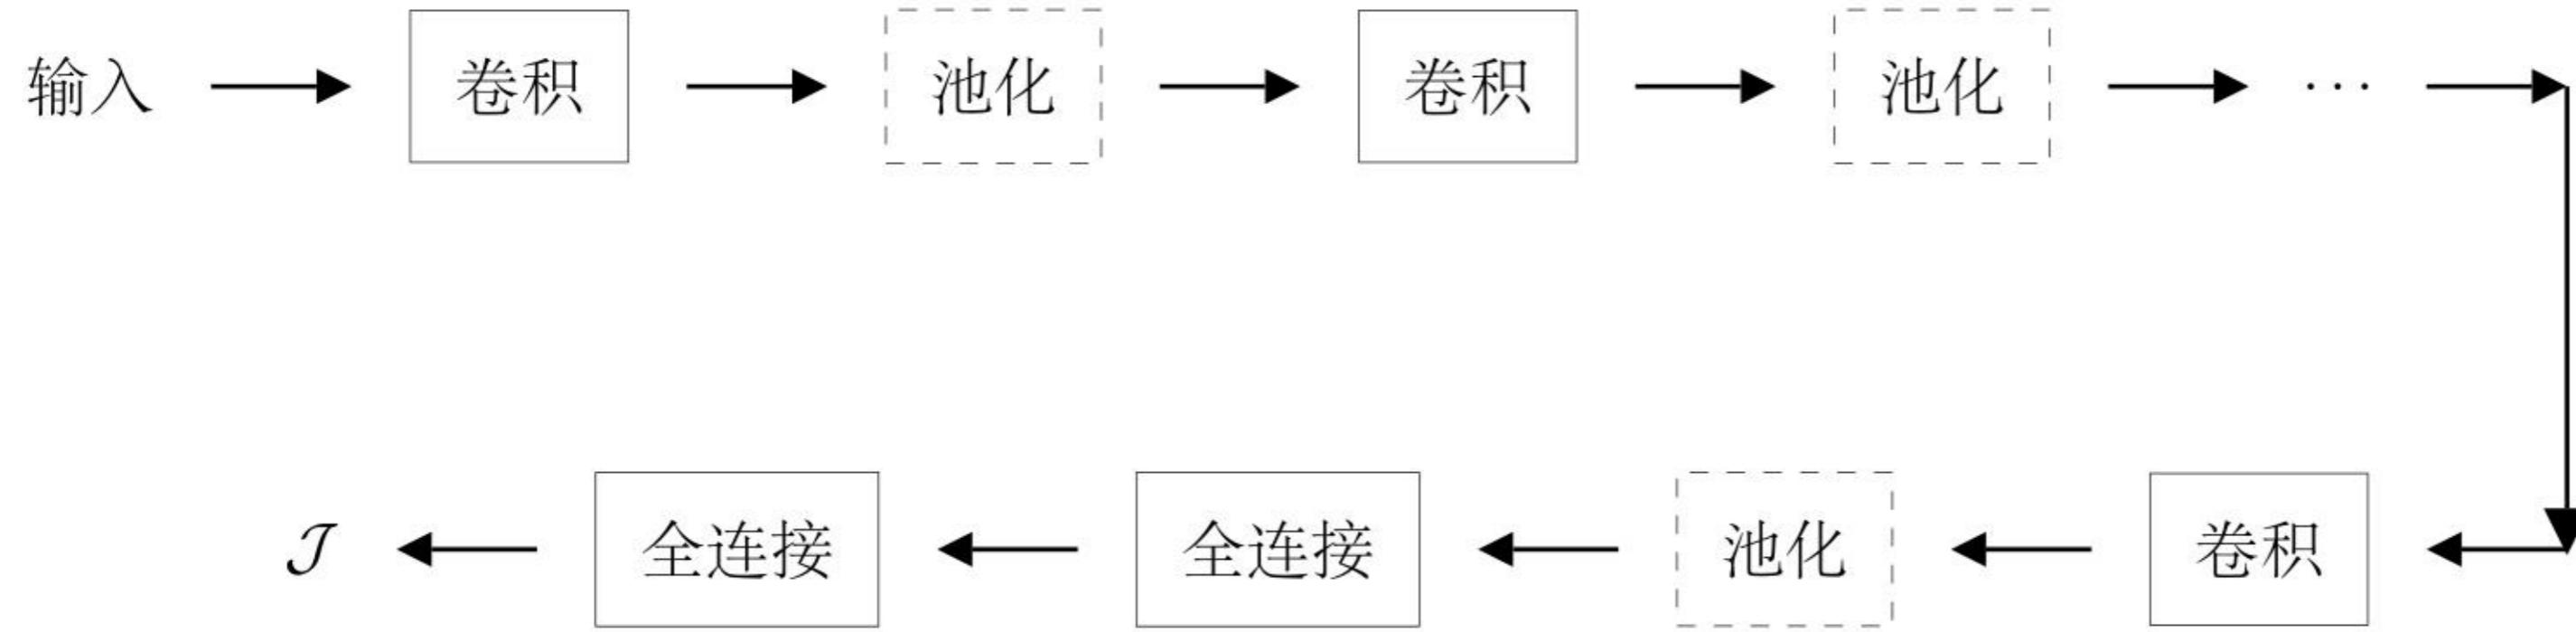
最大池化 (Max pooling)

1. 输入尺寸: 6×6
2. (池化) 核尺寸: 2×2
3. 步幅大小 (Stride) : 2

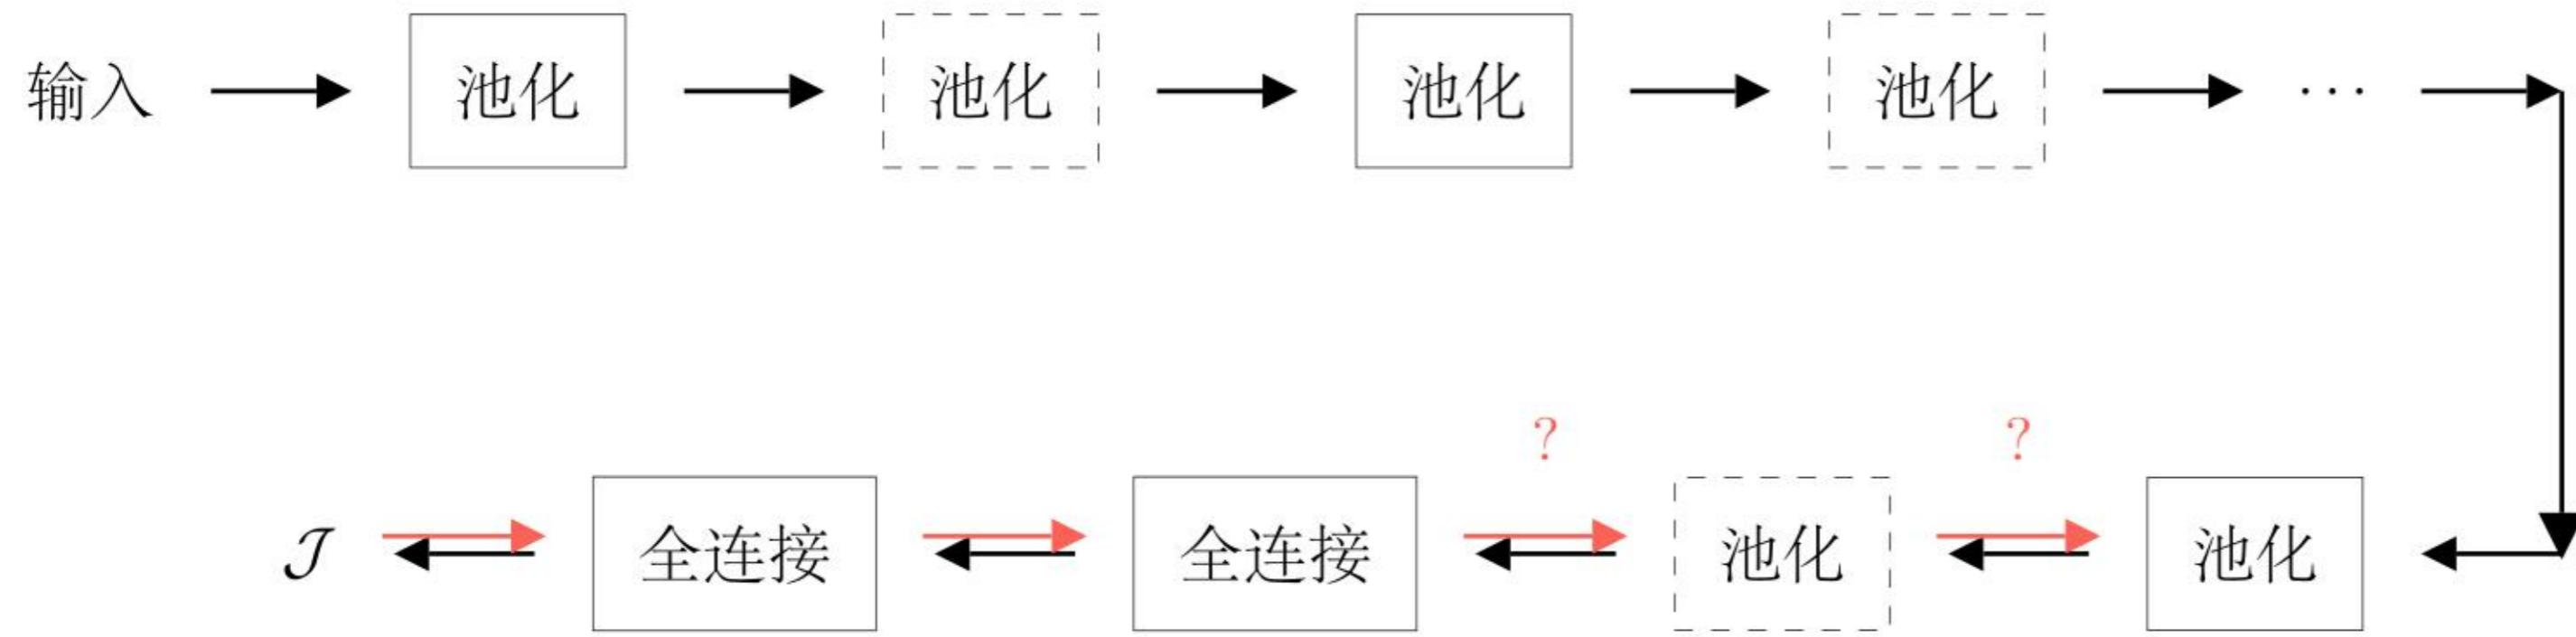
最大池化 (Max pooling)



前向传播



后向传播



后向传播

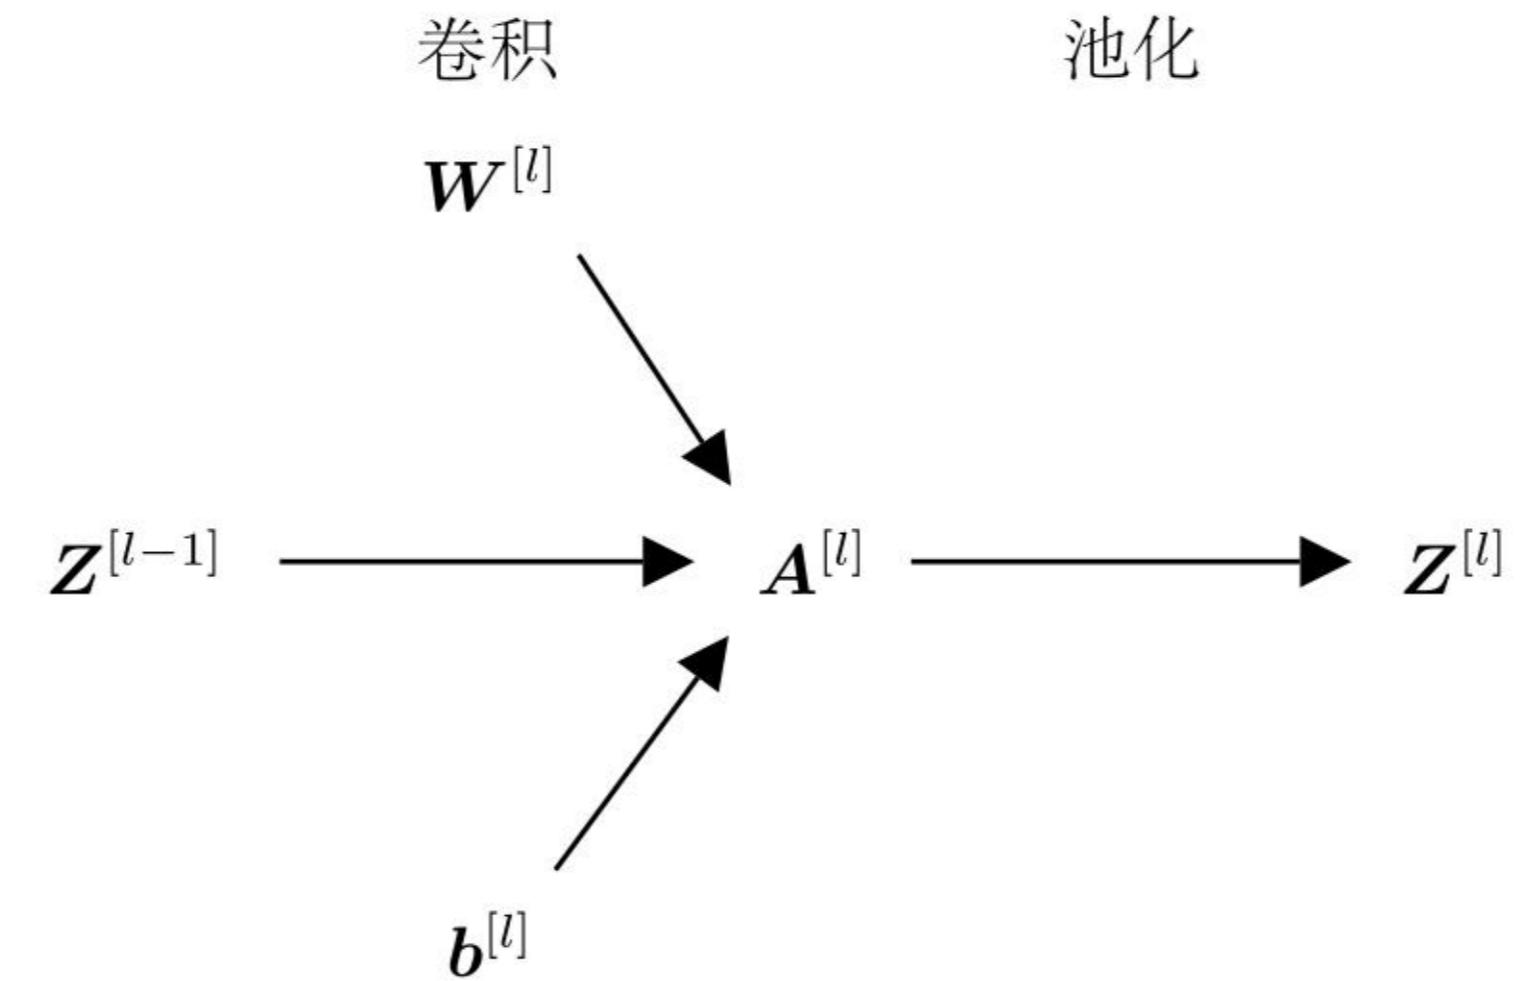
1. 我们已经学习过全连接神经网络的反向传播过程
2. 因此，我们只需讨论下列运算的反向传播过程
 - 池化层 (POOL)
 - 卷积层 (CONV)
3. 在下面的分析中，我们假设卷积运算后立即进行池化运算

后向传播

1. 记

- $\mathbf{A}^{[l-1]} \in \mathbb{R}^{? \times ? \times d_C^{[l-1]}}$: 第 $(l - 1)$ 层卷积运算输出
- $\mathbf{Z}^{[l-1]} \in \mathbb{R}^{d_H^{[l-1]} \times d_W^{[l-1]} \times d_C^{[l-1]}}$: 第 $(l - 1)$ 层池化运算输出，其输入为 $\mathbf{A}^{[l-1]}$
- $\mathbf{W}^{[l]} \in \mathbb{R}^{d_C^{[l]} \times f^{[l]} \times f^{[l]} \times d_C^{[l-1]}}$: 第 l 层卷积运算的卷积核，其输入为 $\mathbf{Z}^{[l-1]}$
- $\mathbf{b}^{[l]} \in \mathbb{R}^{d_C^{[l]} \times 1 \times 1 \times 1}$: 第 l 层卷积运算的偏置项，其输入为 $\mathbf{Z}^{[l-1]}$
- $\mathbf{A}^{[l]} \in \mathbb{R}^{? \times ? \times d_C^{[l]}}$: 第 l 层卷积运算输出
- $\mathbf{Z}^{[l]} \in \mathbb{R}^{d_H^{[l]} \times d_W^{[l]} \times d_C^{[l]}}$: 第 l 层池化运算输出，其输入为 $\mathbf{A}^{[l]}$

结构



1. 假设 $dZ^{[l]}$ 是已知的

平均池化的反向传播

$A^{[l]}$

3	6	5	4	8	9
1	7	9	6	8	0
5	0	9	6	2	0
5	2	6	3	7	0
9	0	3	2	3	1
3	1	3	7	1	7

(池化) 核 M

0.25	0.25
0.25	0.25

$Z^{[l]}$

4.25	6.0	6.25
3.0	6.0	2.25
3.25	3.75	3.0

平均池化的反向传播

1. 对于平均池化，我们有

$$d\mathbf{A}^{[l]} = d\mathbf{Z}^{[l]} \otimes \mathbf{M}$$

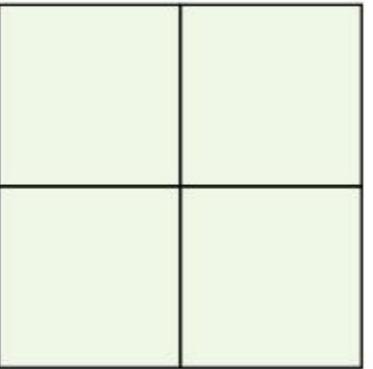
- $\mathbf{A} \otimes \mathbf{B}$ ：两个矩阵 \mathbf{A} 以及 \mathbf{B} 的 Kronecker 乘积

最大池化的反向传播

$A^{[l]}$

3	6	5	4	8	9
1	7	9	6	8	0
5	0	9	6	2	0
5	2	6	3	7	0
9	0	3	2	3	1
3	1	3	7	1	7

(池化) 核



$Z^{[l]}$

7	9	9
5	9	7
9	7	7

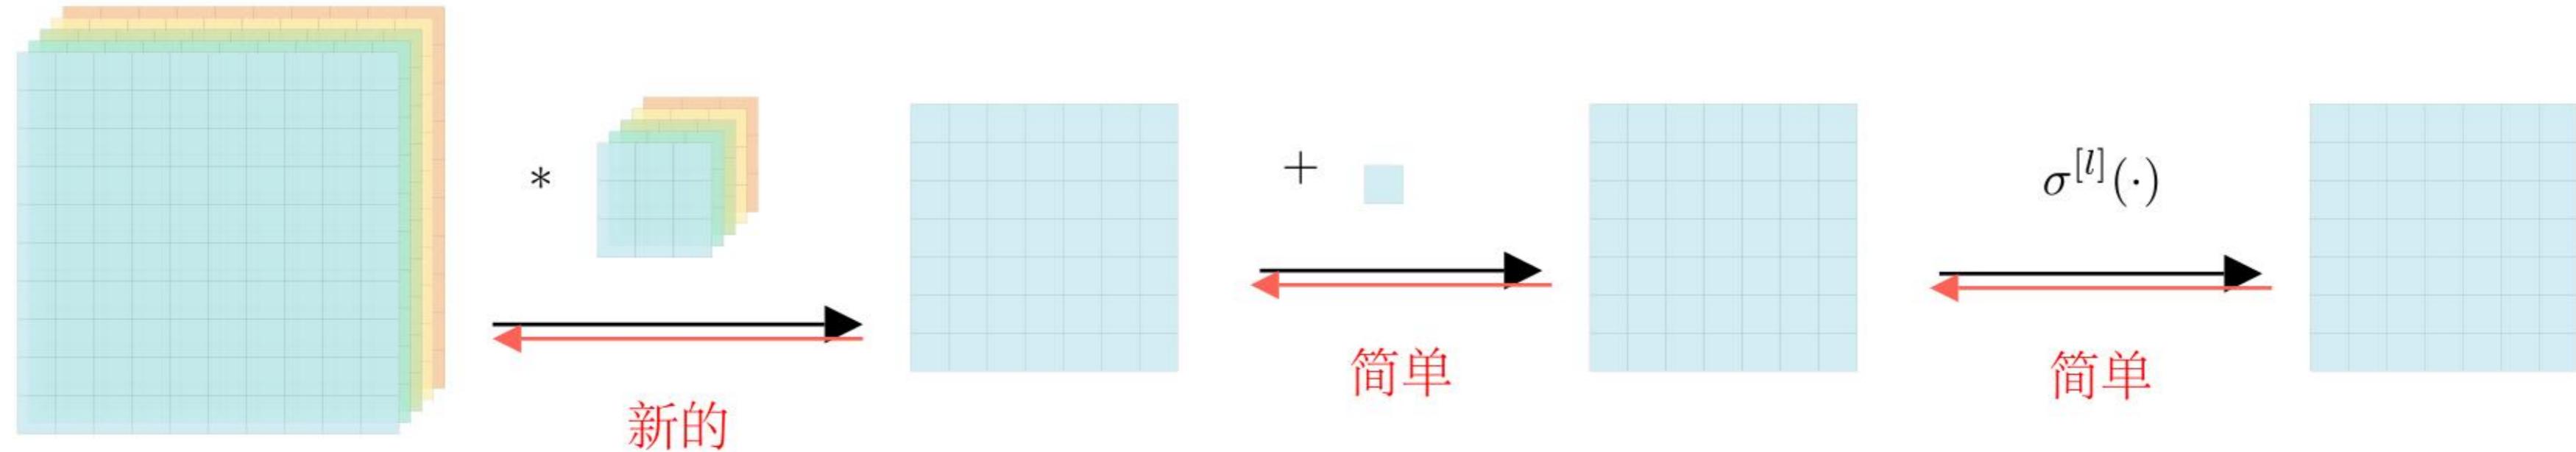
最大池化的反向传播

1. 对于最大池化而言， $d\mathbf{A}^{[l]}$ 是通过如下过程得到的
 - 将矩阵 $\mathbf{Z}^{[l]}$ 中每个元素乘上一个对应的 2×2 掩码矩阵，再相加
 - 这些 2×2 的掩码矩阵中，只有一个元素为 1，其他为 0
2. 我们已经介绍完了从 $d\mathbf{Z}^{[l]}$ 到 $d\mathbf{A}^{[l]}$ 的反向传播过程
 - 池化运算不涉及任何额外的模型参数
3. 在后续分析中，我们假设 $d\mathbf{A}^{[l]}$ 已知

卷积运算的后向传播

1. 简便起见，假设卷积运算结果的通道数为 $d_C^{[l]} = 1$.
2. 假设 $dA^{[l]}$ 已知

卷积运算的后向传播



$$\mathbf{Z}^{[l-1]} \in \mathbb{R}^{d_H^{[l-1]} \times d_W^{[l-1]} \times d_C^{[l-1]}}$$

$$\mathbf{Z}_0^{[l]} \in \mathbb{R}^{? \times ? \times 1}$$

$$\mathbf{Z}_1^{[l]} \in \mathbb{R}^{? \times ? \times 1}$$

$$\mathbf{W}^{[l]} \in \mathbb{R}^{f^{[l]} \times f^{[l]} \times d_C^{[l-1]}}$$

$$\mathbf{b}^{[l]} \in \mathbb{R}^{1 \times 1 \times 1}$$

$$\mathbf{A}^{[l]} \in \mathbb{R}^{? \times ? \times 1}$$

$$d\mathbf{W}^{[l]} = ?$$

$$d\mathbf{b}^{[l]} = \sum_{ij} dZ_{1,ij}^{[l]}$$

$$d\mathbf{Z}^{[l-1]} = ?$$

$$d\mathbf{Z}_0^{[l]} = d\mathbf{Z}_1^{[l]}$$

$$d\mathbf{Z}_1^{[l]} = \sigma^{[l]'}(\mathbf{Z}^{[l]}) \circ d\mathbf{A}^{[l]}$$

卷积运算的后向传播

1. 为了求函数对某自变量的导数，我们需要知道该自变量被用于哪些计算
2. 初始化 $d\mathbf{Z}^{[l-1]}$ 为一个 0 矩阵，其规模与 $\mathbf{Z}^{[l-1]}$ 相同
3. 符号不那么严格地，我们可以得到

$$d\mathbf{Z}_{\text{slice},ij}^{[l-1]} + = dZ_{0,ij}^{[l]} \times \mathbf{W}^{[l]}$$

- $\mathbf{Z}_{\text{slice},ij}^{[l-1]}$: $\mathbf{Z}^{[l-1]}$ 中被用于得到 $Z_{0,ij}^{[l]}$ 的部分

卷积运算的后向传播

1. 很明显, $Z_0^{[l]}$ 中的每个元素均包含 $W^{[l]}$ 的信息
2. 因此, 我们有

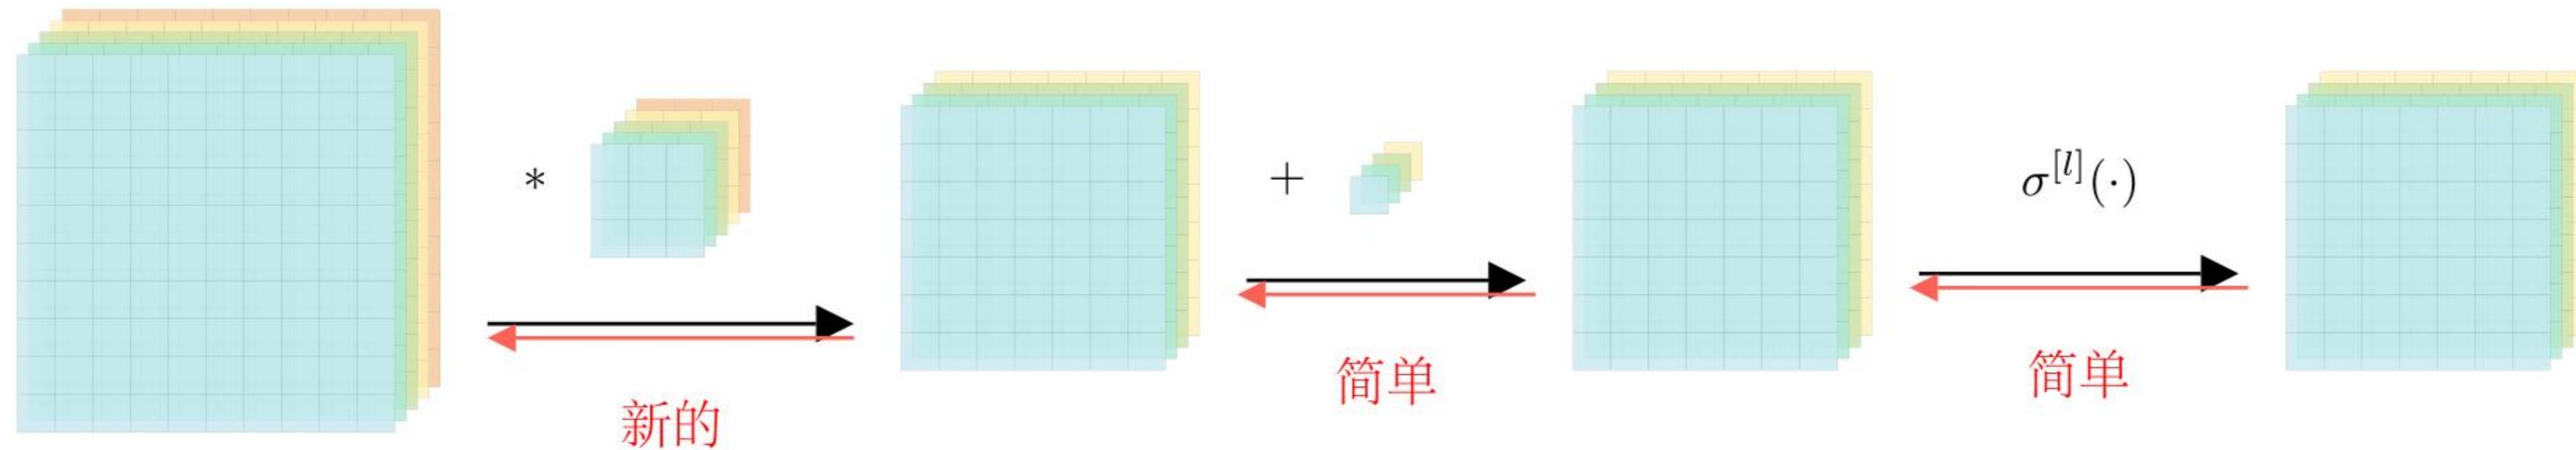
$$dW^{[l]} = \sum_{ij} dZ_{0,ij}^{[l]} \times B_{ij}^{[l-1]}$$

- $B_{ij}^{[l-1]}$: $Z^{[l-1]}$ 中被用于得到 $Z_{0,ij}^{[l]}$ 的部分

卷积运算的后向传播

1. 更一般地，考虑输出有 $d_C^{[l]}$ 个通道的情况

卷积运算的后向传播



$$\mathbf{Z}^{[l-1]} \in \mathbb{R}^{d_H^{[l-1]} \times d_W^{[l-1]} \times d_C^{[l-1]}}$$

$$\mathbf{Z}_0^{[l]} \in \mathbb{R}^{? \times ? \times d_C^{[l]}}$$

$$\mathbf{Z}_1^{[l]} \in \mathbb{R}^{? \times ? \times d_C^{[l]}}$$

$$\mathbf{W}^{[l]} \in \mathbb{R}^{d_C^{[l]} \times f^{[l]} \times f^{[l]} \times d_C^{[l-1]}}$$

$$\mathbf{b}^{[l]} \in \mathbb{R}^{d_C^{[l]} \times 1 \times 1 \times 1}$$

$$\mathbf{A}^{[l]} \in \mathbb{R}^{? \times ? \times d_C^{[l]}}$$

$$d\mathbf{W}^{[l]} = ?$$

$$d\mathbf{b}_c^{[l]} = \sum_{ij} dZ_{1,ijc}^{[l]} \quad (c = 1, \dots, d_C^{[l]})$$

$$d\mathbf{Z}^{[l-1]} = ?$$

$$d\mathbf{Z}_0^{[l]} = d\mathbf{Z}_1^{[l]}$$

$$d\mathbf{Z}_1^{[l]} = \sigma^{[l]'}(\mathbf{Z}^{[l]}) \circ d\mathbf{A}^{[l]}$$

卷积运算的后向传播

1. 在计算导数时，我们只需要找到对应自变量在哪些计算被用到即可
2. 矩阵 $\mathbf{Z}^{[l-1]}$ 的信息存在于 $\mathbf{Z}_0^{[l]}$ 的每个元素中
3. 将 $d\mathbf{Z}^{[l-1]}$ 初始化为一个 0 矩阵，其规模与 $\mathbf{Z}^{[l-1]}$ 相同
4. 符号不是那么严谨地，我们有

$$d\mathbf{Z}_{\text{slice},ij}^{[l-1]} + = \sum_{c=1}^{d_C^{[l]}} d\mathbf{Z}_{0,ijc}^{[l]} \times \mathbf{W}_{\textcolor{red}{c}}^{[l]}$$

- $\mathbf{Z}_{\text{slice},ij}^{[l-1]}$: 矩阵 $\mathbf{Z}^{[l-1]}$ 中被用于得到 $Z_{0,ijc}^{[l]}$ 的部分，其中 $c = 1, \dots, d_C^{[l]}$
- $\mathbf{W}_{\textcolor{red}{c}}^{[l]}$: 第 l 层中第 c 个卷积核

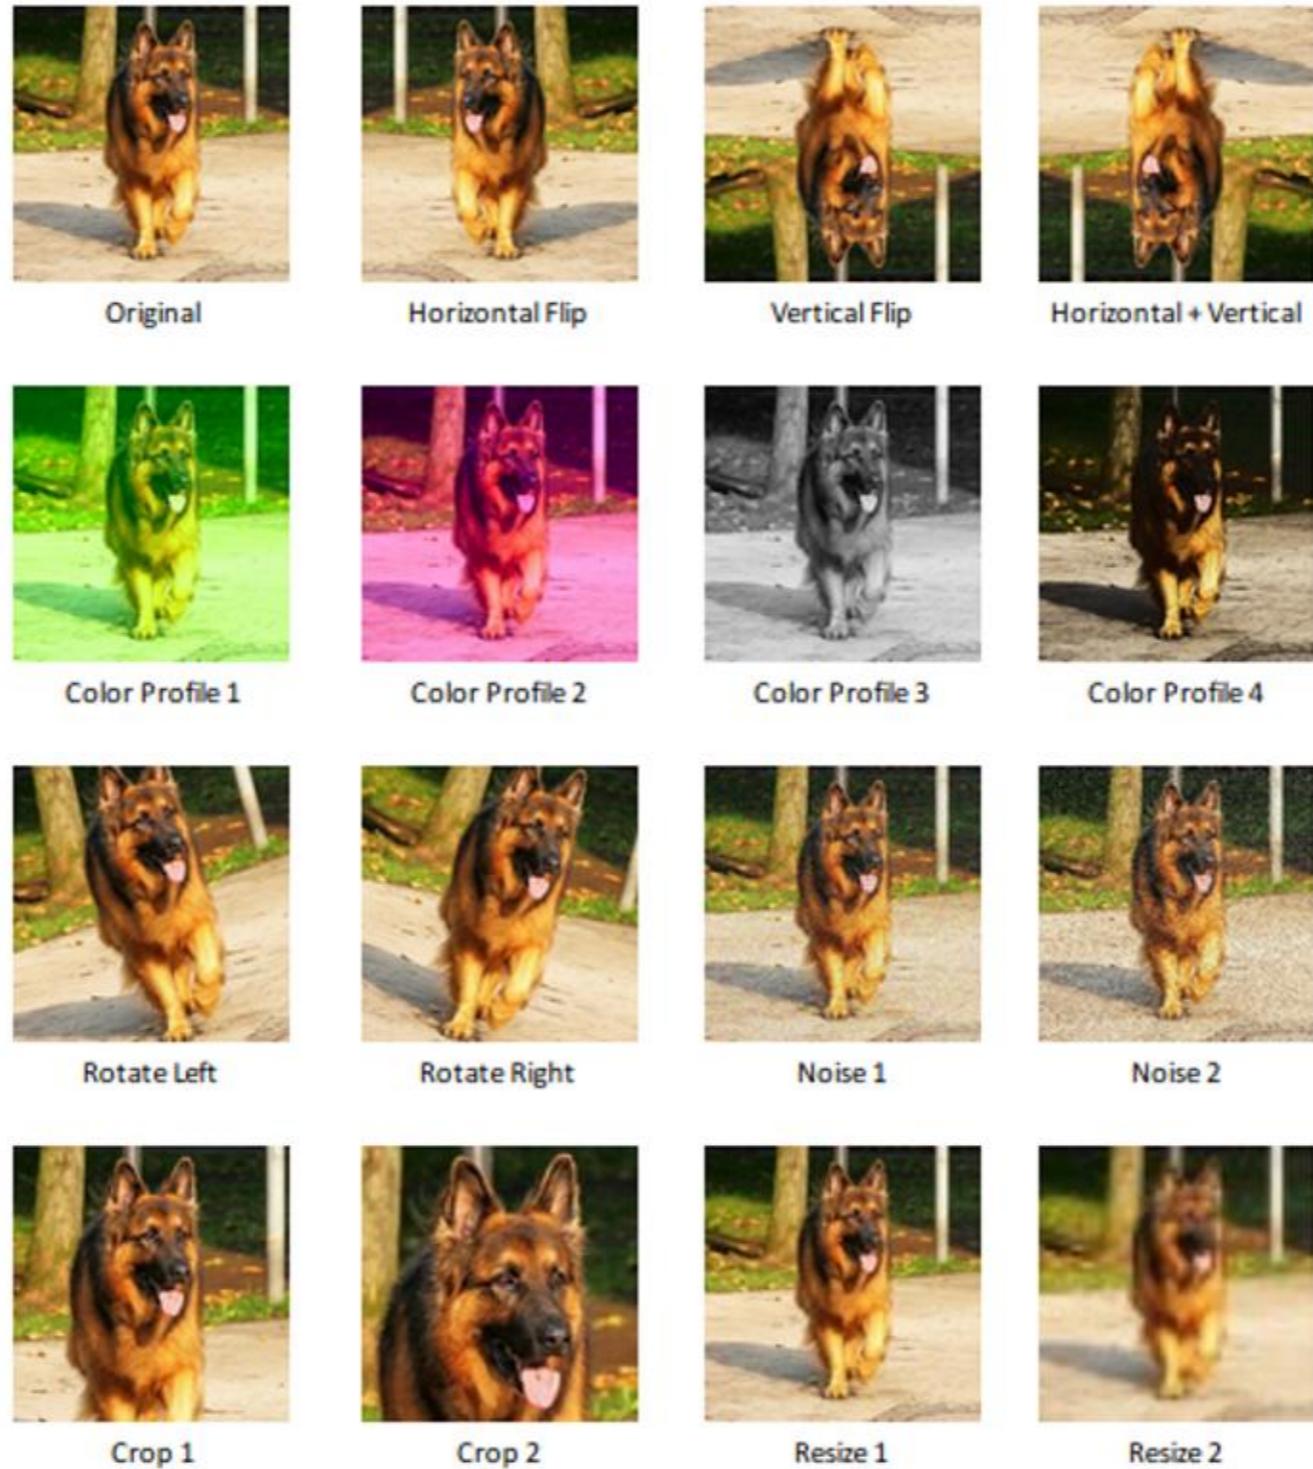
卷积运算的后向传播

1. 很明显, $Z_{0,c}^{[l]}$ 中的每个元素均包含 $\mathbf{W}_c^{[l]}$ 的信息, 其中 $c = 1, \dots, d_C^{[l]}$
2. 因此, 我们有

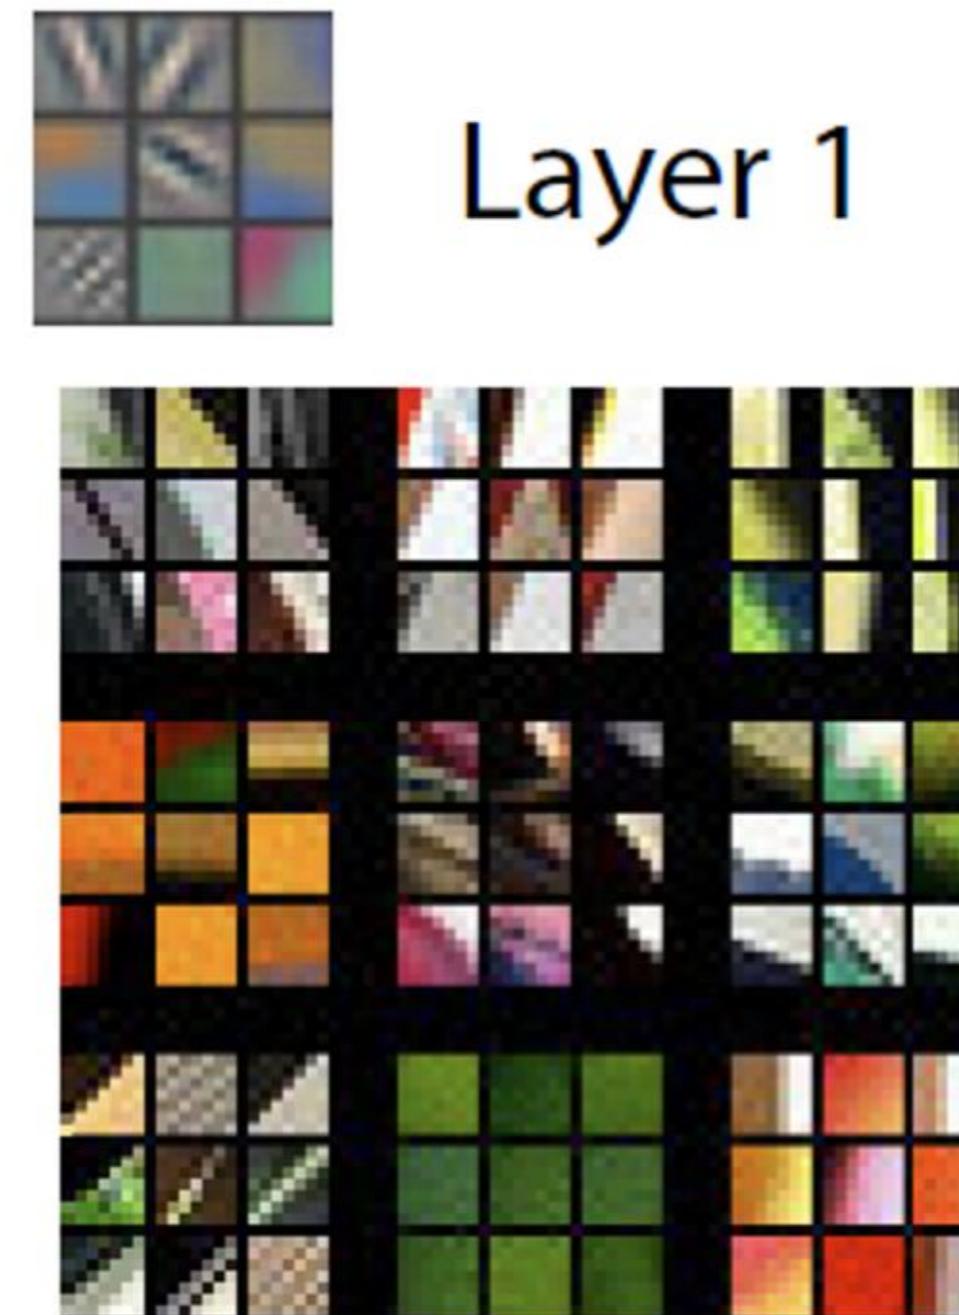
$$d\mathbf{W}_{\textcolor{red}{c}}^{[l]} = \sum_{ij} dZ_{0,ij\textcolor{red}{c}}^{[l]} \times \mathbf{B}_{ij}^{[l-1]} \quad (c = 1, \dots, d_C^{[l]})$$

- $\mathbf{B}_{ij}^{[l-1]}$: 矩阵 $\mathbf{Z}^{[l-1]}$ 中被用于计算 $Z_{0,ijc}^{[l]}$ 的部分

数据增强 (Data augmentation)

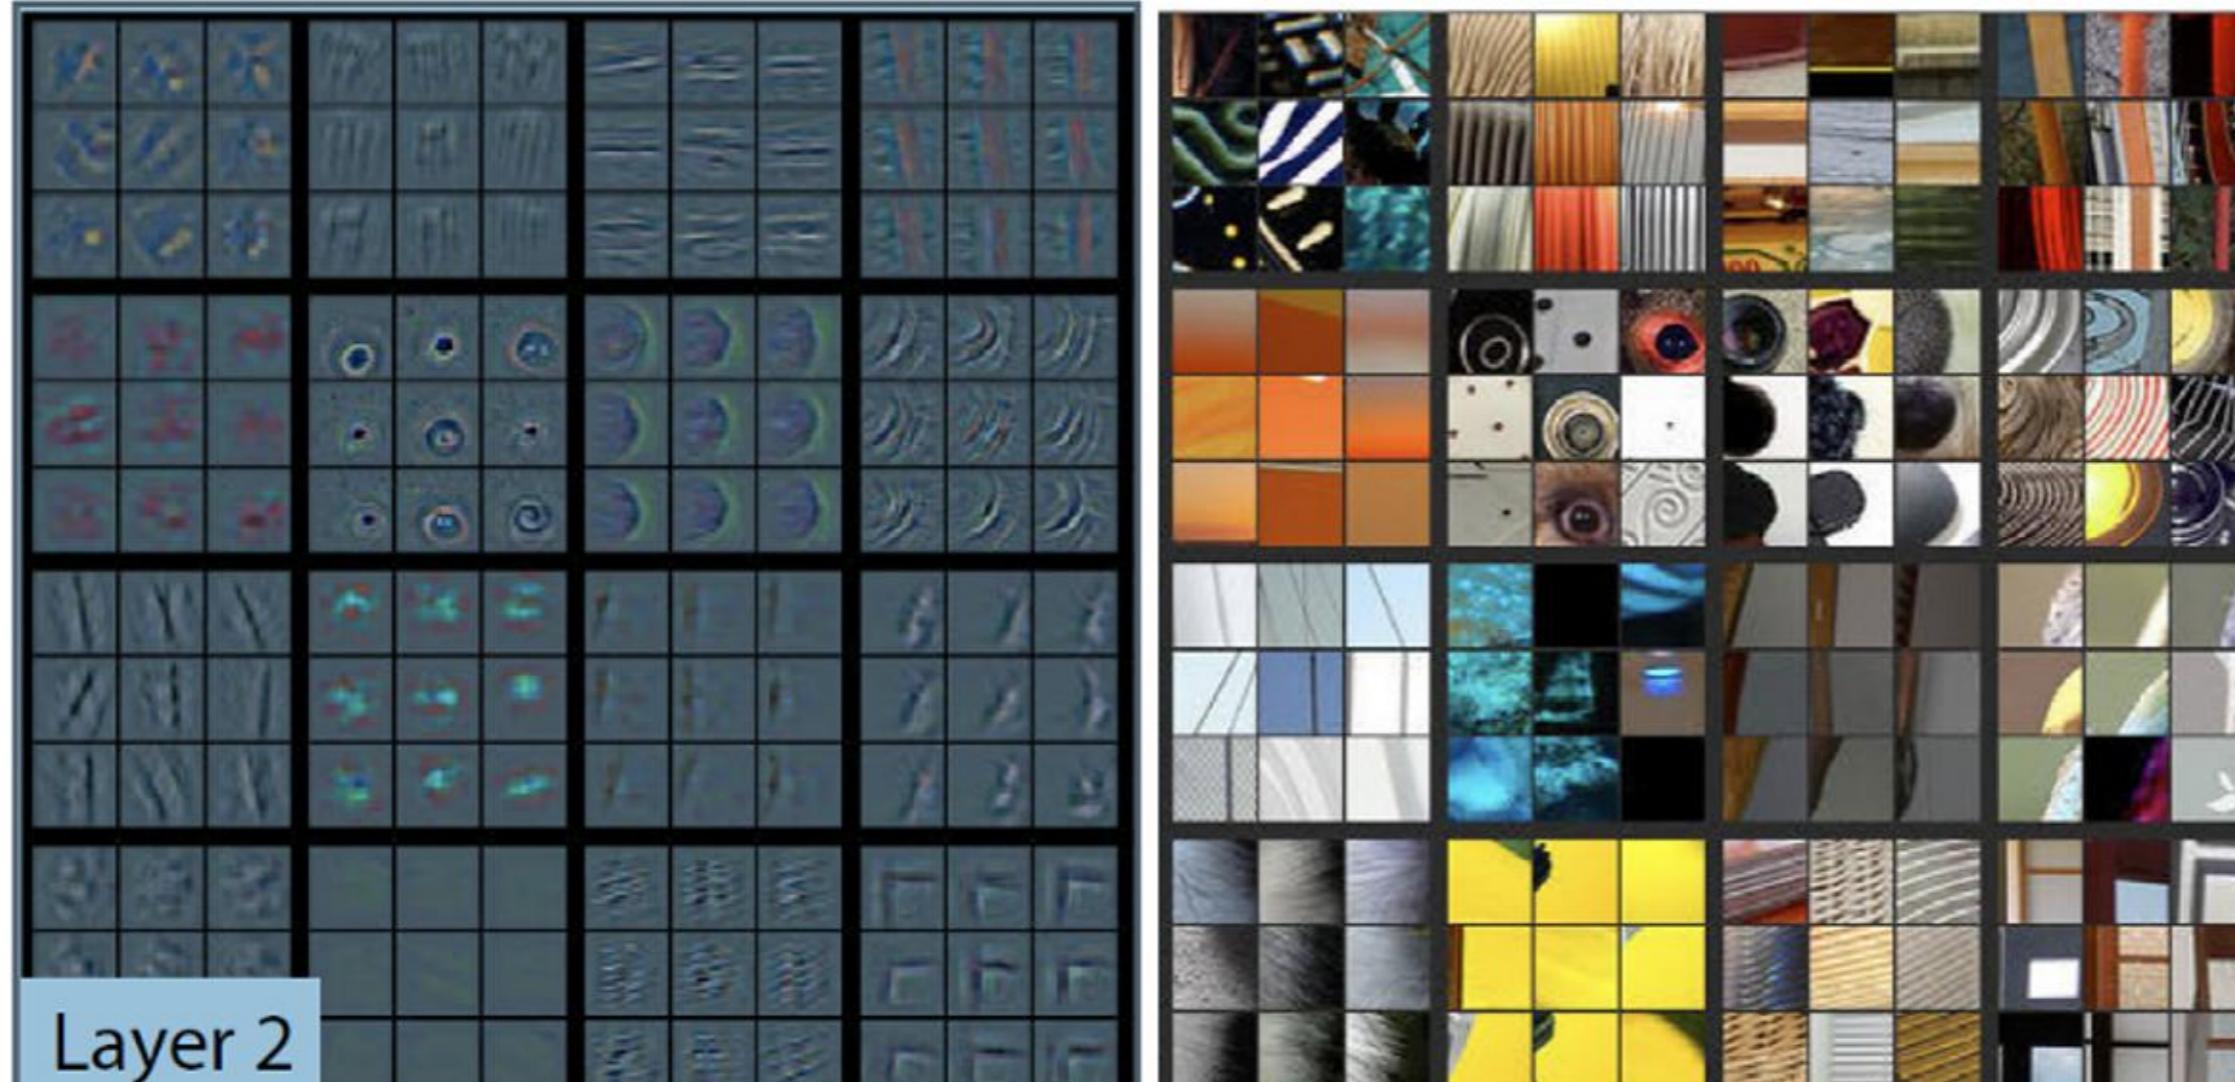


理解卷积神经网络



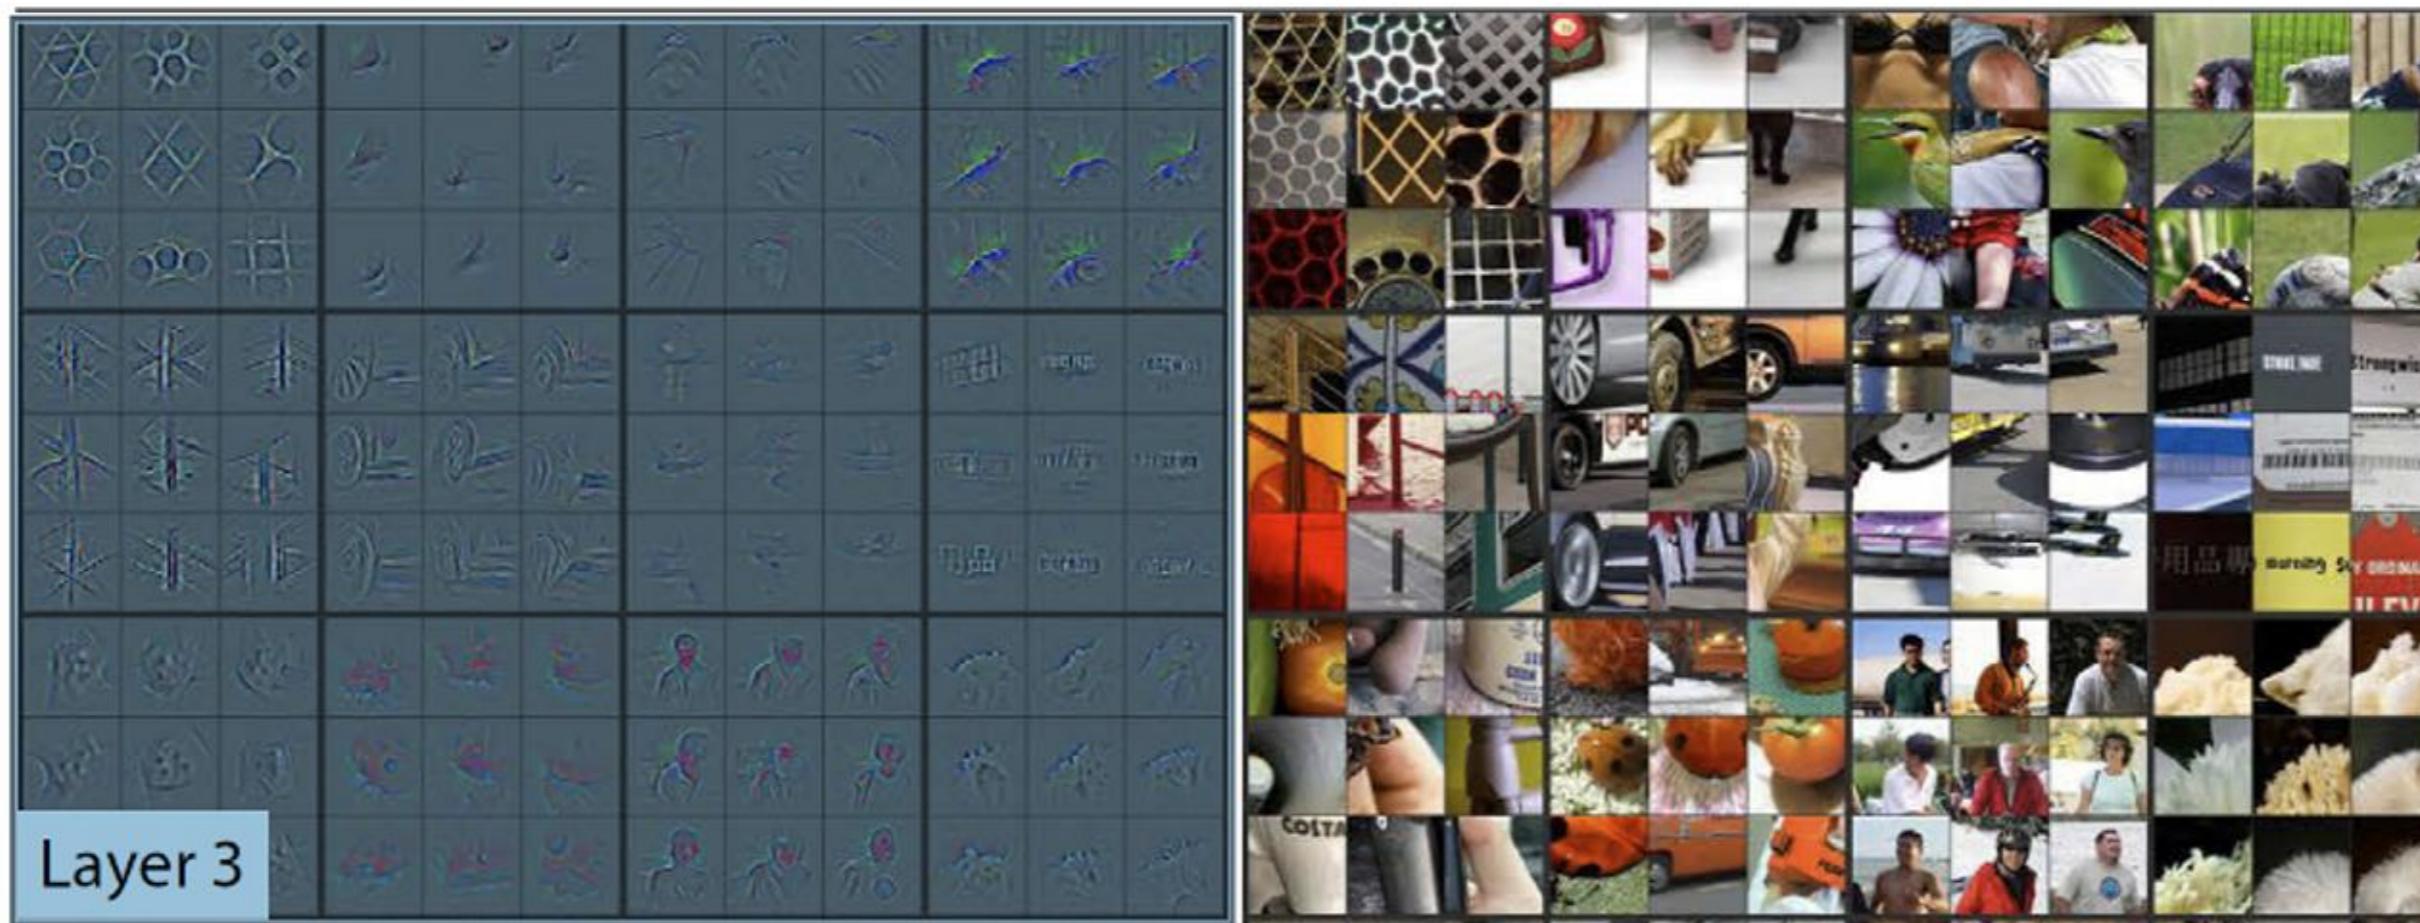
[Zeiler, M. D., & Fergus, R. (2014, September). Visualizing and understanding convolutional networks. In European conference on computer vision (pp. 818-833). Springer, Cham]

理解卷积神经网络



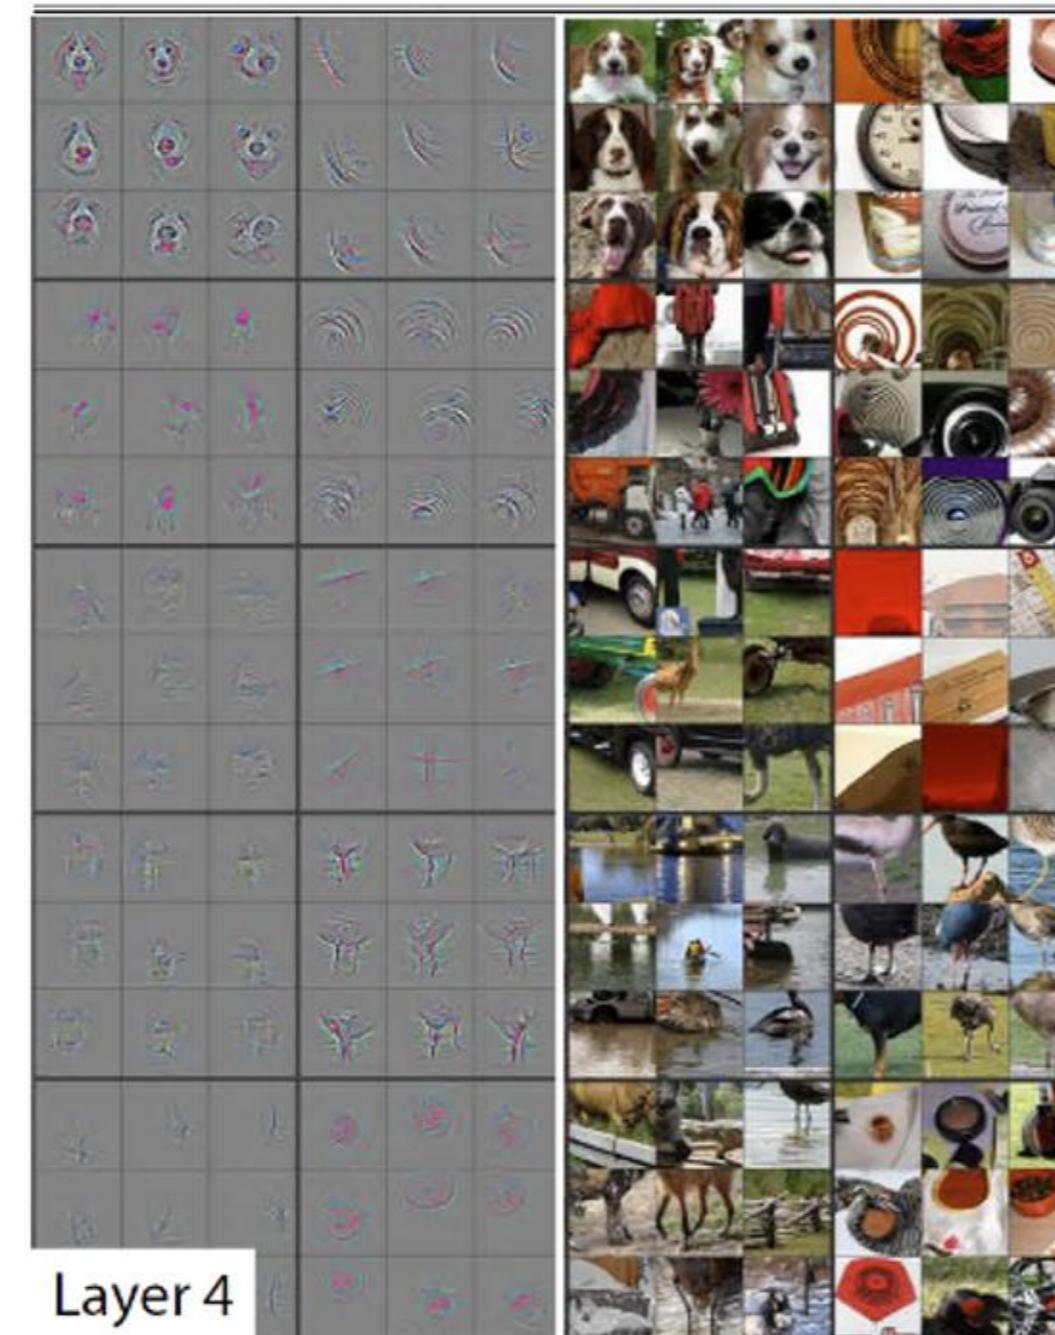
[Zeiler, M. D., & Fergus, R. (2014, September). Visualizing and understanding convolutional networks. In European conference on computer vision (pp. 818-833). Springer, Cham]

理解卷积神经网络



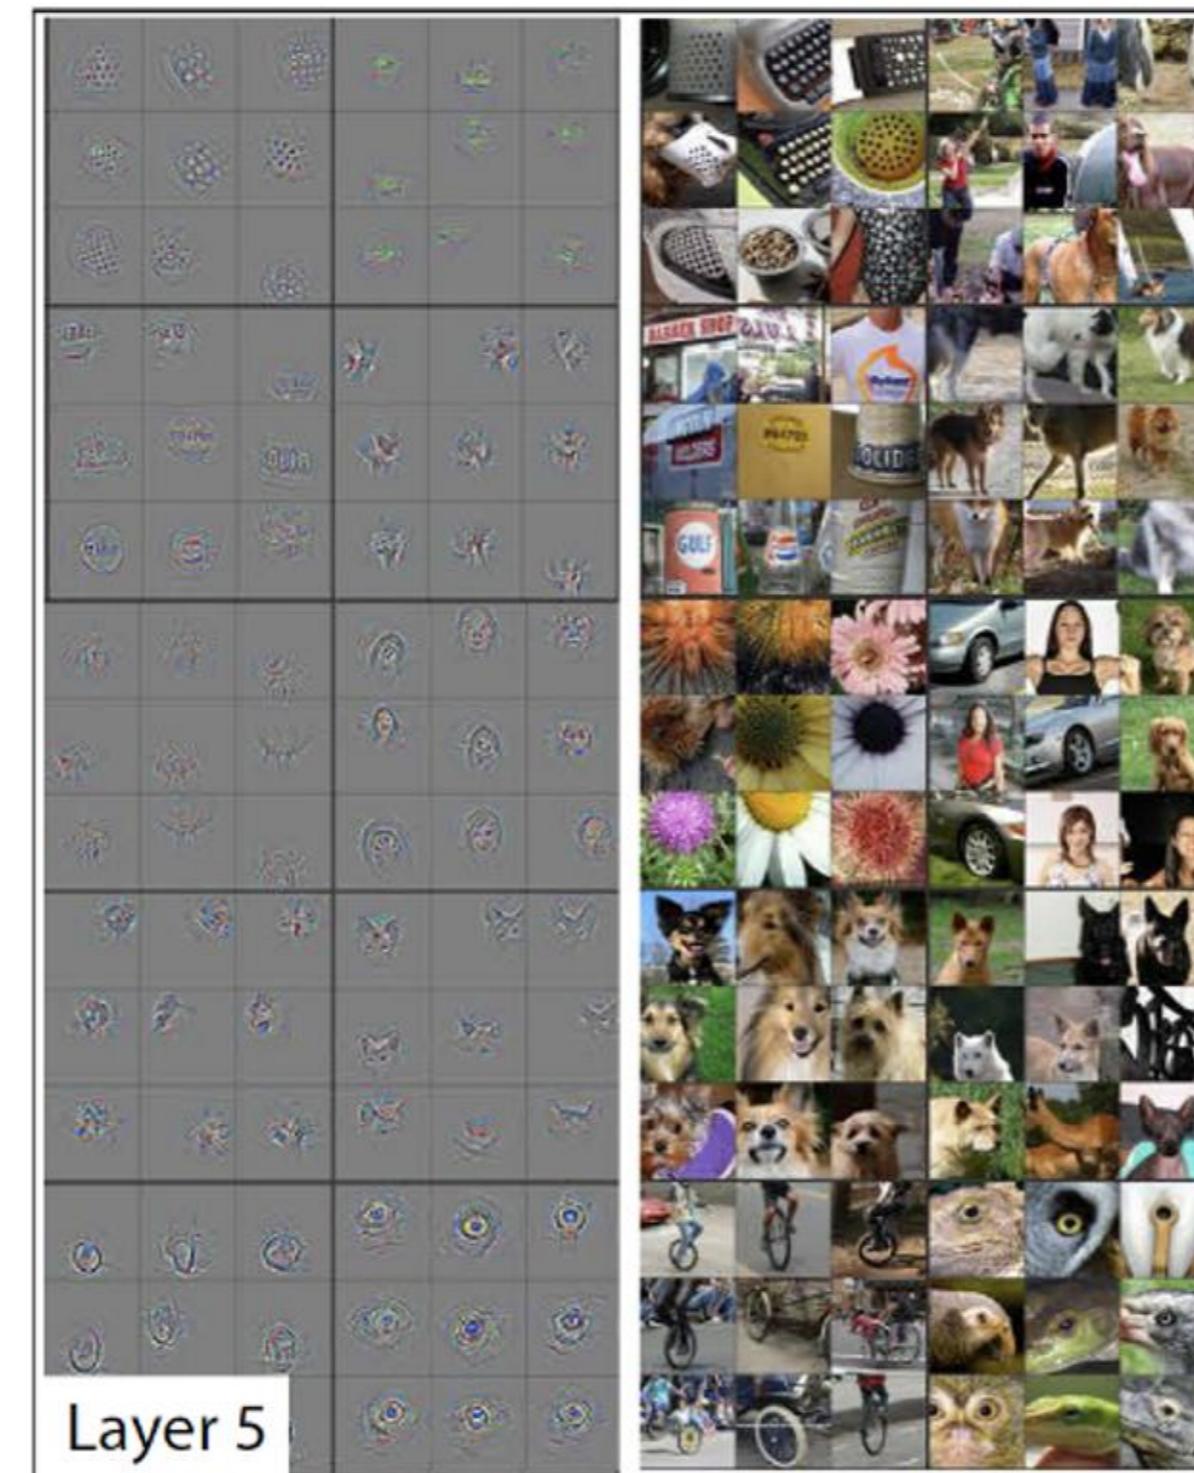
[Zeiler, M. D., & Fergus, R. (2014, September). Visualizing and understanding convolutional networks. In European conference on computer vision (pp. 818-833). Springer, Cham]

理解卷积神经网络



[Zeiler, M. D., & Fergus, R. (2014, September). Visualizing and understanding convolutional networks. In European conference on computer vision (pp. 818-833). Springer, Cham]

理解卷积神经网络



[Zeiler, M. D., & Fergus, R. (2014, September). Visualizing and understanding convolutional networks. In European conference on computer vision (pp. 818-833). Springer, Cham]