

# MO815/MC861 - Análise de Imagem Orientada a um Problema do Mundo Real

Alexandre Xavier Falcão

Instituto de Computação - UNICAMP

afalcao@ic.unicamp.br

- Operadores baseados em adjacência podem considerar um **peso**  $K(i)$  associado a cada adjacente  $q_i \in \mathcal{A}(p)$ ,  $i = 1, 2, \dots, |\mathcal{A}(p)|$ .

- Operadores baseados em adjacência podem considerar um **peso**  $K(i)$  associado a cada adjacente  $q_i \in \mathcal{A}(p)$ ,  $i = 1, 2, \dots, |\mathcal{A}(p)|$ .
- Neste caso, o par  $(\mathcal{A}, K)$  é denominado **kernel**.

- Operadores baseados em adjacência podem considerar um **peso**  $K(i)$  associado a cada adjacente  $q_i \in \mathcal{A}(p)$ ,  $i = 1, 2, \dots, |\mathcal{A}(p)|$ .
- Neste caso, o par  $(\mathcal{A}, K)$  é denominado **kernel**.
- Sendo  $\mathcal{A}$  uma relação de adjacência invariante à translação, o kernel  $\hat{K} = (\mathcal{A}, K)$  pode ser visto como uma imagem móvel.

- Operadores baseados em adjacência podem considerar um **peso**  $K(i)$  associado a cada adjacente  $q_i \in \mathcal{A}(p)$ ,  $i = 1, 2, \dots, |\mathcal{A}(p)|$ .
- Neste caso, o par  $(\mathcal{A}, K)$  é denominado **kernel**.
- Sendo  $\mathcal{A}$  uma relação de adjacência invariante à translação, o kernel  $\hat{K} = (\mathcal{A}, K)$  pode ser visto como uma imagem móvel.
- Ao considerar cada pixel  $p \in D_I$ , estamos essencialmente deslocando uma imagem  $\hat{K}$  sobre a imagem  $\hat{I}$  para realizar a operação.

- Operadores baseados em adjacência podem considerar um **peso**  $K(i)$  associado a cada adjacente  $q_i \in \mathcal{A}(p)$ ,  $i = 1, 2, \dots, |\mathcal{A}(p)|$ .
- Neste caso, o par  $(\mathcal{A}, K)$  é denominado **kernel**.
- Sendo  $\mathcal{A}$  uma relação de adjacência invariante à translação, o kernel  $\hat{K} = (\mathcal{A}, K)$  pode ser visto como uma imagem móvel.
- Ao considerar cada pixel  $p \in D_I$ , estamos essencialmente deslocando uma imagem  $\hat{K}$  sobre a imagem  $\hat{I}$  para realizar a operação.
- Nesta aula, vamos estudar o caso particular de filtros lineares, onde  $\hat{I} * \hat{K}$  é uma operação de "convolução".

- Operadores baseados em adjacência podem considerar um **peso**  $K(i)$  associado a cada adjacente  $q_i \in \mathcal{A}(p)$ ,  $i = 1, 2, \dots, |\mathcal{A}(p)|$ .
- Neste caso, o par  $(\mathcal{A}, K)$  é denominado **kernel**.
- Sendo  $\mathcal{A}$  uma relação de adjacência invariante à translação, o kernel  $\hat{K} = (\mathcal{A}, K)$  pode ser visto como uma imagem móvel.
- Ao considerar cada pixel  $p \in D_I$ , estamos essencialmente deslocando uma imagem  $\hat{K}$  sobre a imagem  $\hat{I}$  para realizar a operação.
- Nesta aula, vamos estudar o caso particular de filtros lineares, onde  $\hat{I} * \hat{K}$  é uma operação de "convolução".
- No código da aula veremos suas aplicações no realce para seleção de regiões candidatas a placas de veículos.

- A relação de adjacência  $\mathcal{A}$  em  $\hat{K}$  tem sempre uma origem  $(0,0)$  referente ao pixel  $p$ .

- A relação de adjacência  $\mathcal{A}$  em  $\hat{K}$  tem sempre uma origem  $(0,0)$  referente ao pixel  $p$ .
- A diferença entre correlação e convolução está na reflexão  $\hat{K}'$  de  $\hat{K}$  em relação à origem.

- A relação de adjacência  $\mathcal{A}$  em  $\hat{K}$  tem sempre uma origem  $(0, 0)$  referente ao pixel  $p$ .
- A diferença entre correlação e convolução está na reflexão  $\hat{K}'$  de  $\hat{K}$  em relação à origem.
- A rigor, a convolução  $\hat{I} * \hat{K}$  requer a reflexão  $\hat{K}'$  de  $\hat{K}$ :

$$\hat{K}' = (\mathcal{A}', K)$$

$$\mathcal{A}' = \{(-dx_1, -dy_1), (-dx_2, -dy_2), \dots, (-dx_d, -dy_d)\}$$

para  $d = |\mathcal{A}|$ .

- A relação de adjacência  $\mathcal{A}$  em  $\hat{K}$  tem sempre uma origem  $(0,0)$  referente ao pixel  $p$ .
- A diferença entre correlação e convolução está na reflexão  $\hat{K}'$  de  $\hat{K}$  em relação à origem.
- A rigor, a convolução  $\hat{I} * \hat{K}$  requer a reflexão  $\hat{K}'$  de  $\hat{K}$ :

$$\hat{K}' = (\mathcal{A}', K)$$

$$\mathcal{A}' = \{(-dx_1, -dy_1), (-dx_2, -dy_2), \dots, (-dx_d, -dy_d)\}$$

para  $d = |\mathcal{A}|$ .

- Vamos assumir que  $\hat{K}$  já vem refletido.

A imagem  $\hat{J} = (D_J, J)$  resultante da operação  $\hat{I} * \hat{K}$  pode ser definida para todo  $p \in D_I$ :

$$J(p) = \sum_{i=1}^d I(q_i)K(i).$$

# Algoritmo de Filtragem Linear

Entrada:  $\hat{I} = (D_I, I)$  e  $\hat{K} = (\mathcal{A}, K)$ .

Saída:  $\hat{J} = (D_J, J)$ ,  $D_J = D_I$ .

- 1 Para todo  $p \in D_J$ , faça
- 2      $J(p) \leftarrow 0$ .
- 3 Para todo  $q_i \in \mathcal{A}(p)$ ,  $1 \leq i \leq d$ , tal que  $q_i \in D_I$ , faça
- 4      $J(p) \leftarrow J(p) + I(q_i)K(i)$ .

Considerando uma adjacência circular,  $q \in \mathcal{A}(p)$  se  $\|q - p\|^2 \leq r^2$ , de raio  $r$ , os coeficientes do filtro Gaussiano podem ser calculados por:

$$K(i) = \frac{\exp\left(-\frac{\|q_i - p\|^2}{2\sigma^2}\right)}{\sum_{i=1}^d K(i)}$$

para  $i = 1, 2, \dots, d$ , onde  $\sigma = r/3$  e  $p$  é o centro do disco (origem de  $\mathcal{A}(p)$ ).

Considerando uma adjacência circular,  $q \in \mathcal{A}(p)$  se  $\|q - p\|^2 \leq r^2$ , de raio  $r$ , os coeficientes do filtro Gaussiano podem ser calculados por:

$$K(i) = \frac{\exp\left(-\frac{\|q_i - p\|^2}{2\sigma^2}\right)}{\sum_{i=1}^d K(i)}$$

para  $i = 1, 2, \dots, d$ , onde  $\sigma = r/3$  e  $p$  é o centro do disco (origem de  $\mathcal{A}(p)$ ).

Esta operação "borra" a imagem eliminando ruídos de alta frequência.

# Realce de Bordas

Filtros de realce de bordas destacam bordas da imagem em uma dada direção, mas podem amplificar o ruído.

- Realce por filtros de Sobel

$$K_y = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix} \quad K_x = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix}$$

# Realce de Bordas

Filtros de realce de bordas destacam bordas da imagem em uma dada direção, mas podem amplificar o ruído.

- Realce por filtros de Sobel

$$K_y = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix} \quad K_x = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix}$$

- $K_x$  e  $K_y$  realçam bordas nas direções  $x$  (bordas verticais) e  $y$  (bordas horizontais), respectivamente.

Filtros de realce de bordas destacam bordas da imagem em uma dada direção, mas podem amplificar o ruído.

- Realce por filtros de Sobel

$$K_y = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix} \quad K_x = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix}$$

- $K_x$  e  $K_y$  realçam bordas nas direções  $x$  (bordas verticais) e  $y$  (bordas horizontais), respectivamente.
- Sendo  $\hat{G}_x = \hat{I} * \hat{K}_x$  e  $\hat{G}_y = \hat{I} * \hat{K}_y$ ,  $\vec{G}(p) = G_x(p)\vec{i} + G_y(p)\vec{j}$  é dito **vetor gradiente** em  $p$ , o qual aponta para a direção de maior crescimento de brilho na imagem  $\hat{I}$  em torno de  $p$ . Sua magnitude  $|\vec{G}(p)|$  pode ser usada como imagem de realce de bordas.

A magnitude de um vetor gradiente deve realçar bordas em todas as direções. De um modo mais geral:

A magnitude de um vetor gradiente deve realçar bordas em todas as direções. De um modo mais geral:

Considerando uma adjacência circular,  $q \in \mathcal{A}(p)$  se  $\|q - p\|^2 \leq r^2$  de raio  $r$ , o vetor gradiente  $\vec{G}(p)$  pode ser calculado por

A magnitude de um vetor gradiente deve realçar bordas em todas as direções. De um modo mais geral:

Considerando uma adjacência circular,  $q \in \mathcal{A}(p)$  se  $\|q - p\|^2 \leq r^2$  de raio  $r$ , o vetor gradiente  $\vec{G}(p)$  pode ser calculado por

$$\vec{G}(p) = \sum_{\forall q \in \mathcal{A}(p)} [I(q) - I(p)] \exp\left(-\frac{\|q - p\|^2}{2\sigma^2}\right) \vec{p}\vec{q},$$

onde  $\sigma = r/3$  e  $\vec{p}\vec{q} = \left(\frac{x_q - x_p}{\sqrt{(x_q - x_p)^2 + (y_q - y_p)^2}}, \frac{y_q - y_p}{\sqrt{(x_q - x_p)^2 + (y_q - y_p)^2}}\right)$ .

A normalização de uma imagem  $\hat{I} = (D_I, I)$  trata a variação de iluminação ressaltando bordas e gerando  $\hat{J} = (D_J, J)$ ,  $D_J = D_I$ .

$$J(p) = \frac{I(p)}{\sqrt{\sum_{i=1}^d I(q_i)I(q_i)}},$$

onde  $q_i \in \mathcal{A}(p)$ . A relação  $\mathcal{A}$  pode ser circular de raio  $r$  (e.g.,  $r = \sqrt{2}, \sqrt{5}, \dots$ ).

A normalização de uma imagem  $\hat{I} = (D_I, I)$  trata a variação de iluminação ressaltando bordas e gerando  $\hat{J} = (D_J, J)$ ,  $D_J = D_I$ .

$$J(p) = \frac{I(p)}{\sqrt{\sum_{i=1}^d I(q_i)I(q_i)}},$$

onde  $q_i \in \mathcal{A}(p)$ . A relação  $\mathcal{A}$  pode ser circular de raio  $r$  (e.g.,  $r = \sqrt{2}, \sqrt{5}, \dots$ ).

O denominador da normalização pode ser visto como uma convolução entre uma imagem  $\hat{X}$  com os valores quadráticos de brilho da imagem  $\hat{I}$  e um kernel uniforme  $\hat{K}$ , onde  $K(i) = 1$ ,  $i = 1, 2, \dots, d$ .

O pooling visa ressaltar regiões com altos valores em uma dada adjacência. O pooling de uma imagem  $\hat{I} = (D_I, I)$  pode considerar uma subamostragem da imagem (stride) para fins de acumular valores mais espaçados, seguida de reamostragem. Neste caso,

$$J(p) = \sqrt[\alpha]{\sum_{i=1}^d I(q_i)^\alpha},$$

onde  $q_i \in \mathcal{A}(p)$  e  $\alpha \geq 1$  controla a intensidade da operação, *i.e.*, quanto maior, mais importância será dada ao maior valor de entrada.

O pooling visa ressaltar regiões com altos valores em uma dada adjacência. O pooling de uma imagem  $\hat{I} = (D_I, I)$  pode considerar uma subamostragem da imagem (stride) para fins de acumular valores mais espaçados, seguida de reamostragem. Neste caso,

$$J(p) = \sqrt[\alpha]{\sum_{i=1}^d I(q_i)^\alpha},$$

onde  $q_i \in \mathcal{A}(p)$  e  $\alpha \geq 1$  controla a intensidade da operação, *i.e.*, quanto maior, mais importância será dada ao maior valor de entrada.

Similarmente, a somatória do pooling pode ser vista como uma convolução entre uma imagem  $\hat{X}$  com os valores de  $\hat{I}$  elevados à  $\alpha$  e o kernel uniforme  $\hat{K}$ , onde  $K(i) = 1, i = 1, 2, \dots, d$ .

- Podemos interpretar os coeficientes do kernel como elementos de um vetor  $\vec{K} = (K(1), K(2), \dots, K(d))$  e os valores dos adjacentes como elementos de outro vetor  $\vec{I}(p) = (I(q_1), I(q_2), \dots, I(q_d))$ , de modo que a cada pixel  $p$  temos o produto interno  $\vec{K} \cdot \vec{I}(p)$ .

# Filtragem Linear: Pontos de Vista Diferentes

- Podemos interpretar os coeficientes do kernel como elementos de um vetor  $\vec{K} = (K(1), K(2), \dots, K(d))$  e os valores dos adjacentes como elementos de outro vetor  $\vec{I}(p) = (I(q_1), I(q_2), \dots, I(q_d))$ , de modo que a cada pixel  $p$  temos o produto interno  $\vec{K} \cdot \vec{I}(p)$ .
- Seja  $M_K$  uma matriz  $1 \times d$  cujos valores são os elementos de  $\vec{K}$  e  $M_I$  uma matriz  $d \times |D_I|$  onde os vetores  $\vec{I}(p)$  são colocados em cada coluna  $p$ . A filtragem linear equivale ao produto  $M_K M_I$ .

# Filtragem Linear: Pontos de Vista Diferentes

- Uma imagem  $\hat{I} = (D_I, I)$  e uma relação de adjacência  $\mathcal{A}$  definem um grafo  $(D_I, \mathcal{A})$  onde os nós são os pixels e os arcos são formados por pixels adjacentes.

# Filtragem Linear: Pontos de Vista Diferentes

- Uma imagem  $\hat{I} = (D_I, I)$  e uma relação de adjacência  $\mathcal{A}$  definem um grafo  $(D_I, \mathcal{A})$  onde os nós são os pixels e os arcos são formados por pixels adjacentes.
- Neste grafo, os pesos  $K(i)$  do kernel  $\hat{K} = (\mathcal{A}, K)$  são os pesos  $w(p, q_i)$  das arestas  $(p, q_i) \in \mathcal{A}$ ,  $i = 1, 2, \dots, d$ .

# Filtragem Linear: Pontos de Vista Diferentes

- Uma imagem  $\hat{I} = (D_I, I)$  e uma relação de adjacência  $\mathcal{A}$  definem um grafo  $(D_I, \mathcal{A})$  onde os nós são os pixels e os arcos são formados por pixels adjacentes.
- Neste grafo, os pesos  $K(i)$  do kernel  $\hat{K} = (\mathcal{A}, K)$  são os pesos  $w(p, q_i)$  das arestas  $(p, q_i) \in \mathcal{A}$ ,  $i = 1, 2, \dots, d$ .
- Então temos que  $\hat{J} = \hat{I} * \hat{K} = (D_J, J)$ , onde

$$J(p) = \sum_{\forall (p,q) \in \mathcal{A}} I(q)w(p, q),$$

essencialmente calcula um peso para cada nó do grafo em função dos valores dos adjacentes e dos pesos dos arcos com esses adjacentes.

# Filtragem Linear: Pontos de Vista Diferentes

- Uma imagem  $\hat{I} = (D_I, I)$  e uma relação de adjacência  $\mathcal{A}$  definem um grafo  $(D_I, \mathcal{A})$  onde os nós são os pixels e os arcos são formados por pixels adjacentes.
- Neste grafo, os pesos  $K(i)$  do kernel  $\hat{K} = (\mathcal{A}, K)$  são os pesos  $w(p, q_i)$  das arestas  $(p, q_i) \in \mathcal{A}$ ,  $i = 1, 2, \dots, d$ .
- Então temos que  $\hat{J} = \hat{I} * \hat{K} = (D_J, J)$ , onde

$$J(p) = \sum_{\forall (p,q) \in \mathcal{A}} I(q)w(p, q),$$

essencialmente calcula um peso para cada nó do grafo em função dos valores dos adjacentes e dos pesos dos arcos com esses adjacentes.

- No caso de operadores baseados em conexidade, os caminhos entre nós do grafo são considerados.