

Processamento de Imagens Médicas

Co-registro de imagens

Prof. Luiz Otavio Murta Jr.

Depto. de Computação e Matemática (FFCLRP/USP)

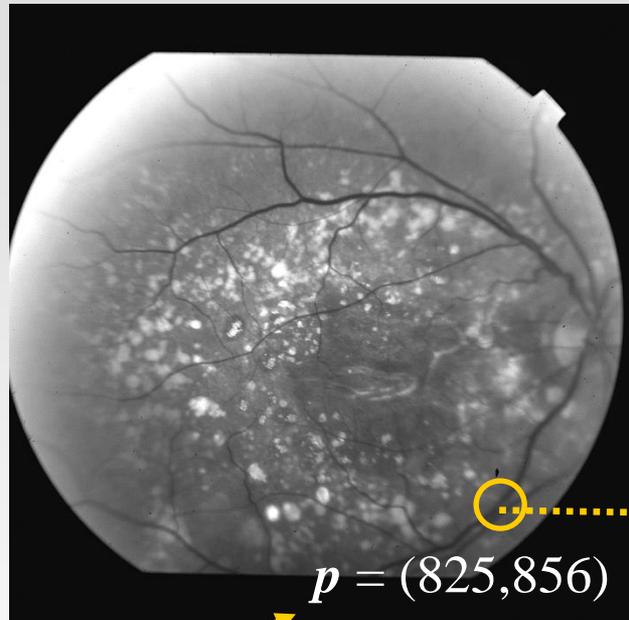
- **O problema do co-registro**
- **Aplicações de co-registro**
- **Componentes de uma solução**



Co-registro de imagens

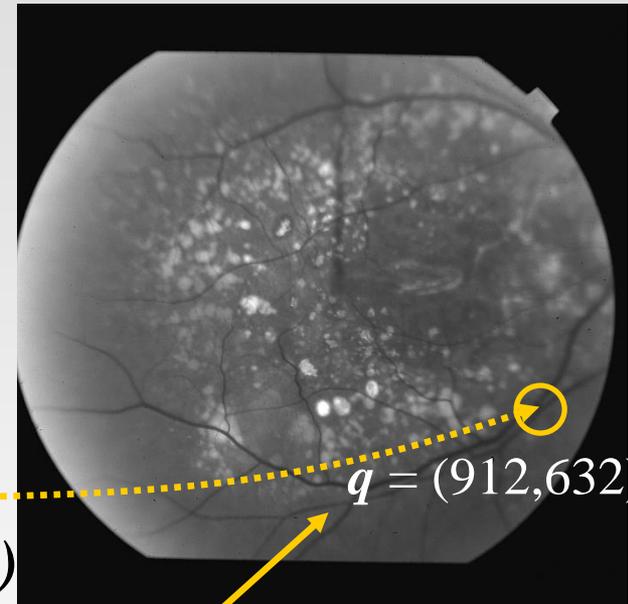
- **Objetivo:**
 - Determinação do mapeamento entre duas imagens do mesmo objeto, objetos similares, a mesma região ou regiões similares
- **Aspectos abordados:**
 - Matemática básica
 - Imagens
 - Algoritmos
 - Implementações
 - Aplicações

Definição do Problema de Co-registro



$p = (825, 856)$

Localização do pixel na primeira imagem



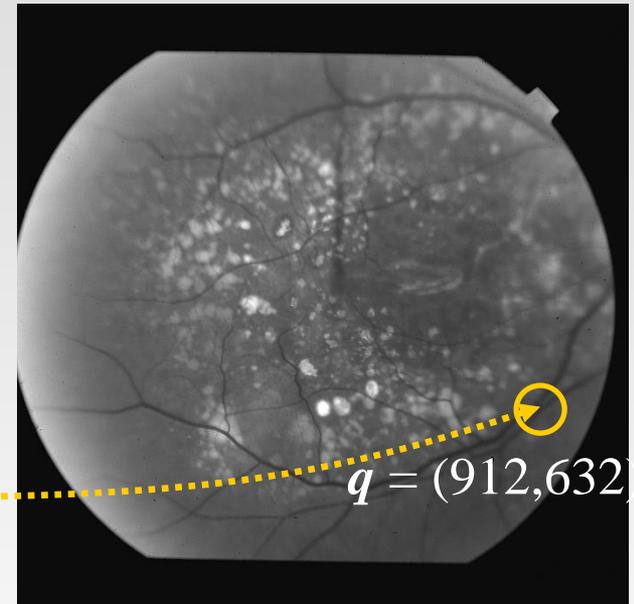
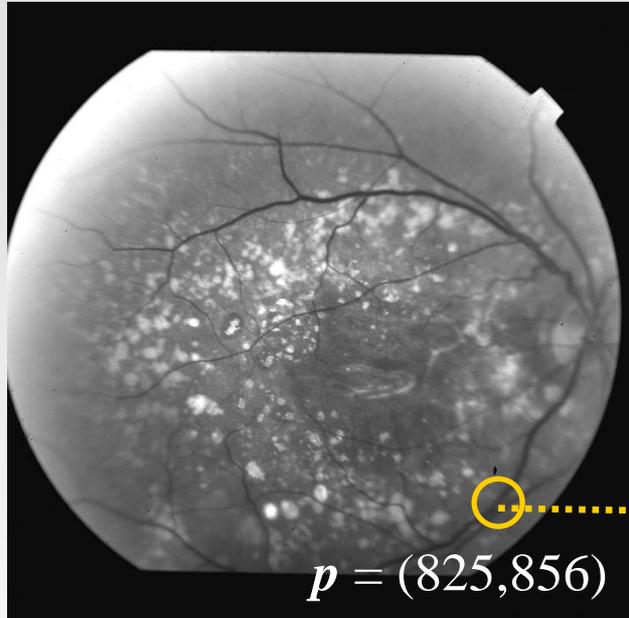
$q = (912, 632)$

Localização do pixel homólogo na segunda imagem

$$q = T(p; a)$$

Função de mapeamento de localização de pixels

Exemplo de Função de Mapeamento



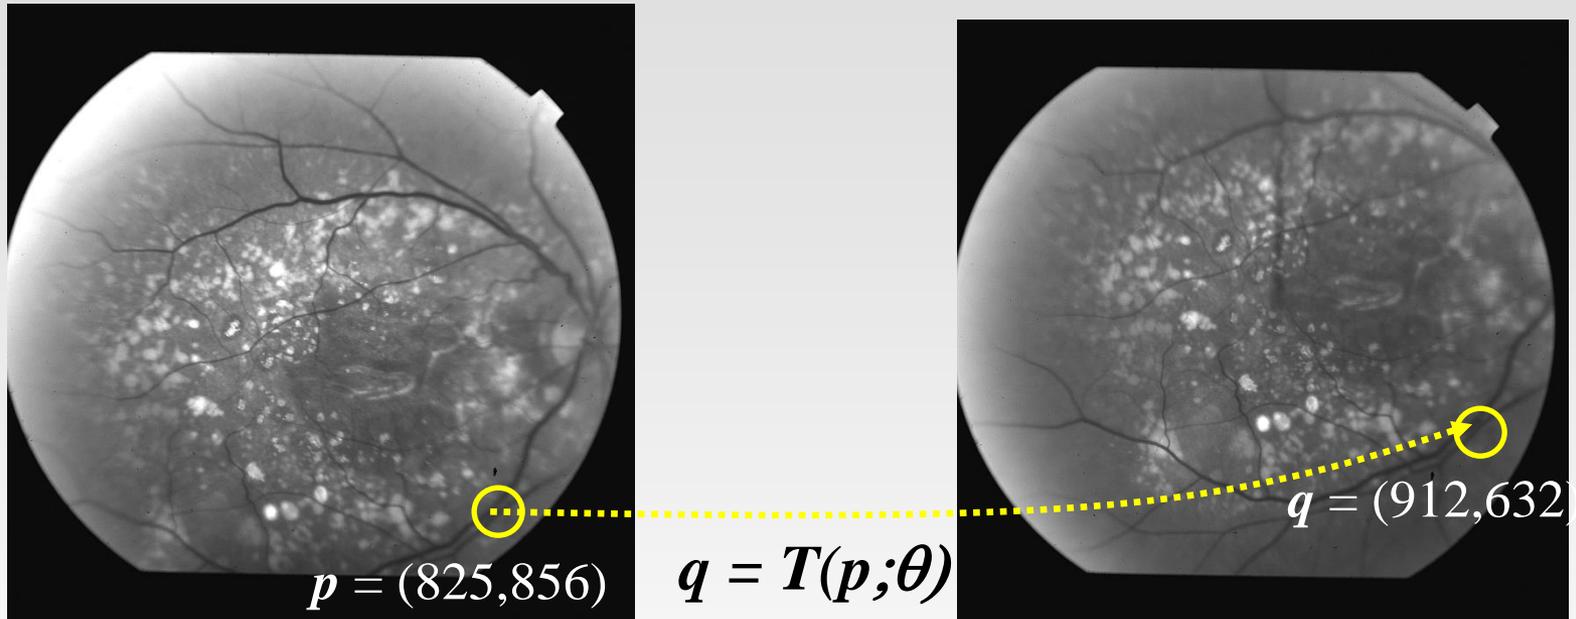
$$p = (x, y)^T$$

$$\Theta = (s, t_x, t_y)^T$$

$$T(p, \Theta) = \begin{pmatrix} s \cdot x + t_x \\ s \cdot y + t_y \end{pmatrix}$$

Pixel scaling and

Definição do Problema de Co-Registro



Problema:

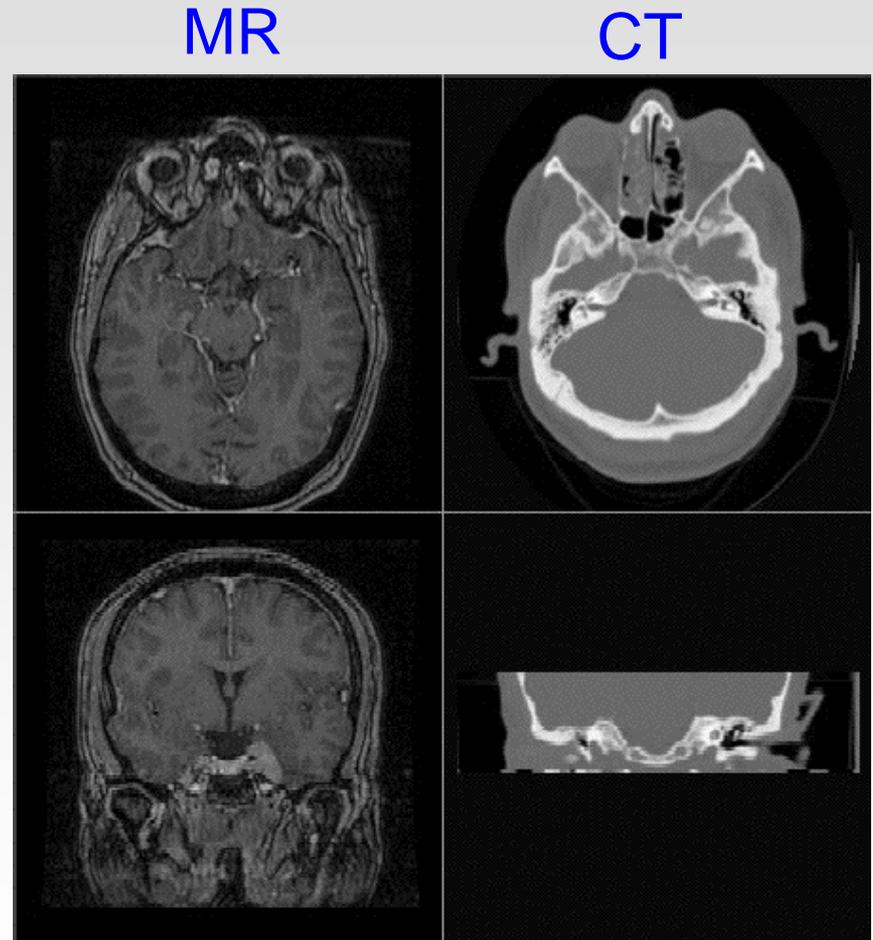
- Formular a função mapeamento T
 - Parâmetro desconhecido θ
 - Correspondências desconhecidas, p, q
- } Problema “galinha-ovo”

Aplicações: Integração Multimodal

- **Dois ou mais diferentes sensores visualizando a mesma região ou volume**
- **Diferentes pontos de vista**
 - (alguns sensores especializados tem duas ou mais modalidades coincidentes, então o co-registro não é necessário.)
- **Informações diferentes são proeminentes em cada imagem**
- **As imagens podem até possuir dimensões diferentes!**
 - Imagens Range vs. Imagens de intensidade
 - CT volumes vs. imagens de fluoro

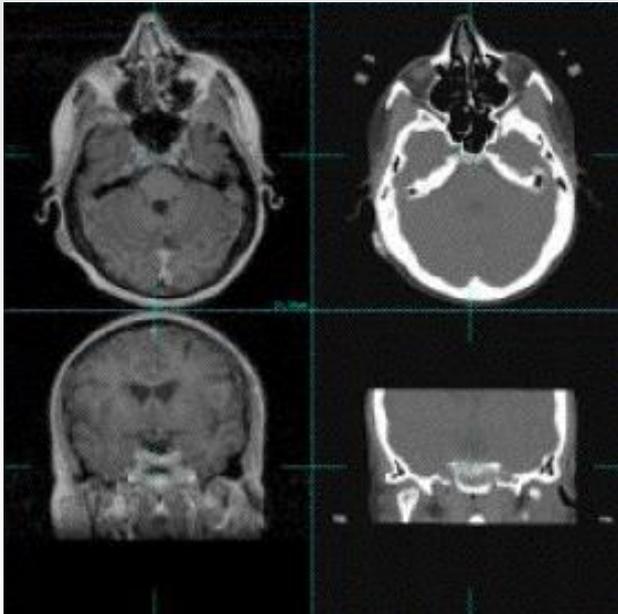
Exemplo: Co-registro cerebral MR-CT

- MR (ressonância magnética) mede conteúdo de água
- CT mede absorção de raios-x
- O osso é mais claro no CT e mais escuro MR
- Ambas as imagens são volumes 3d

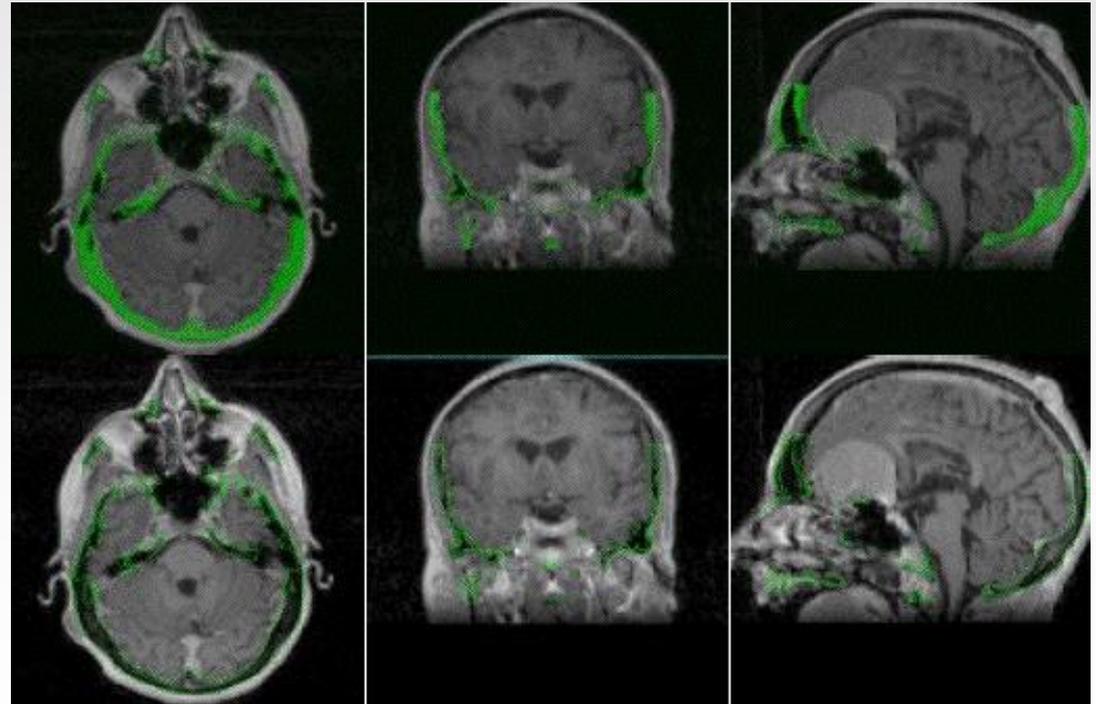


Resultados do co-registro MR-CT

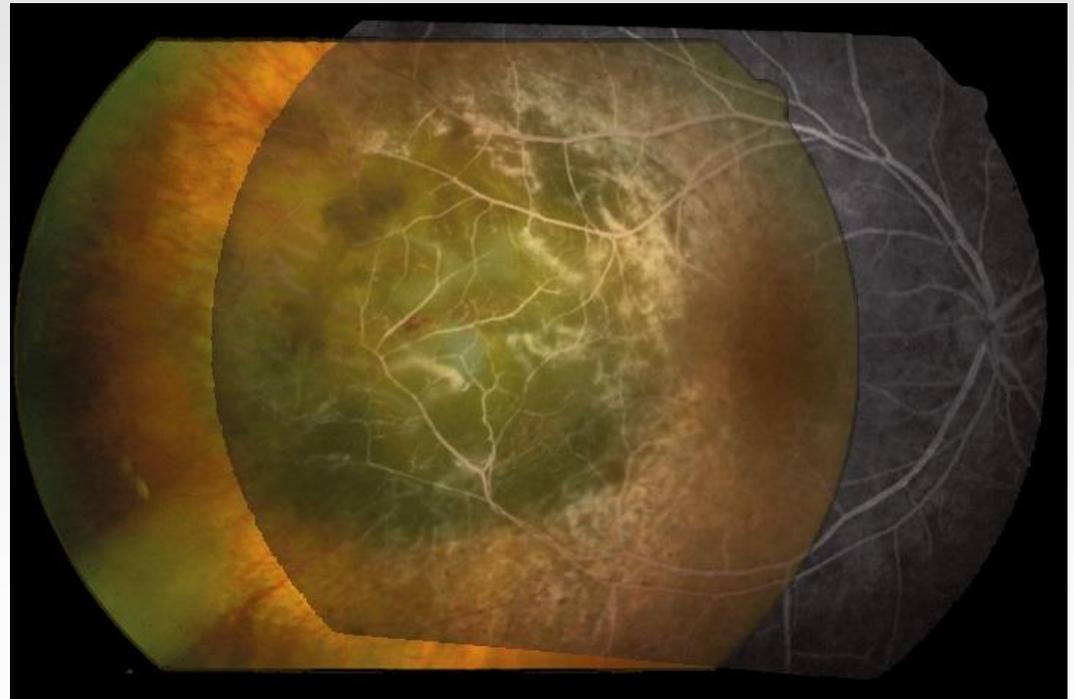
imagens alinhadas



imagens superpostas, com estruturas do crânio provenientes do CT em verde



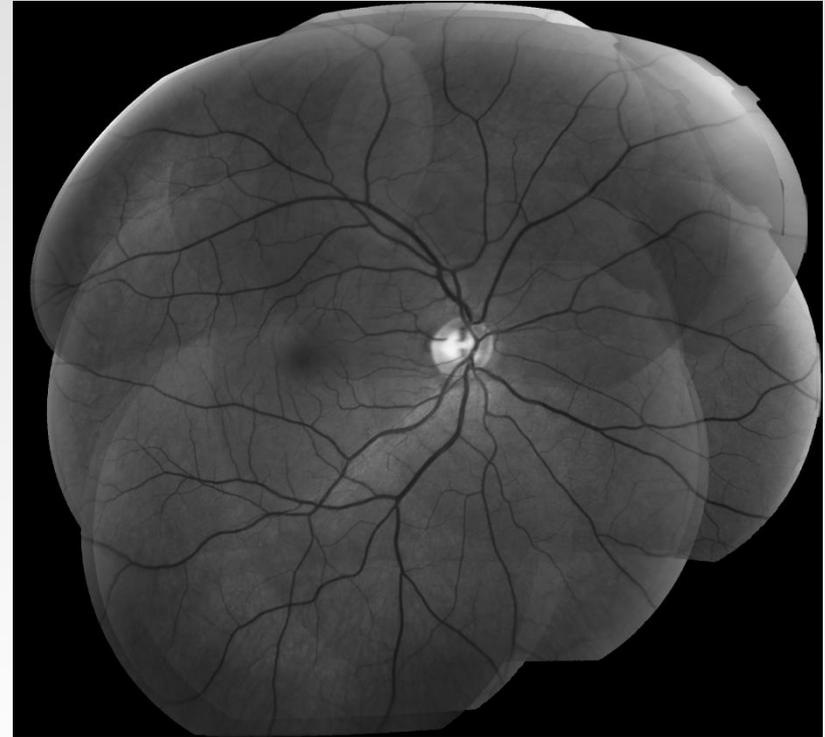
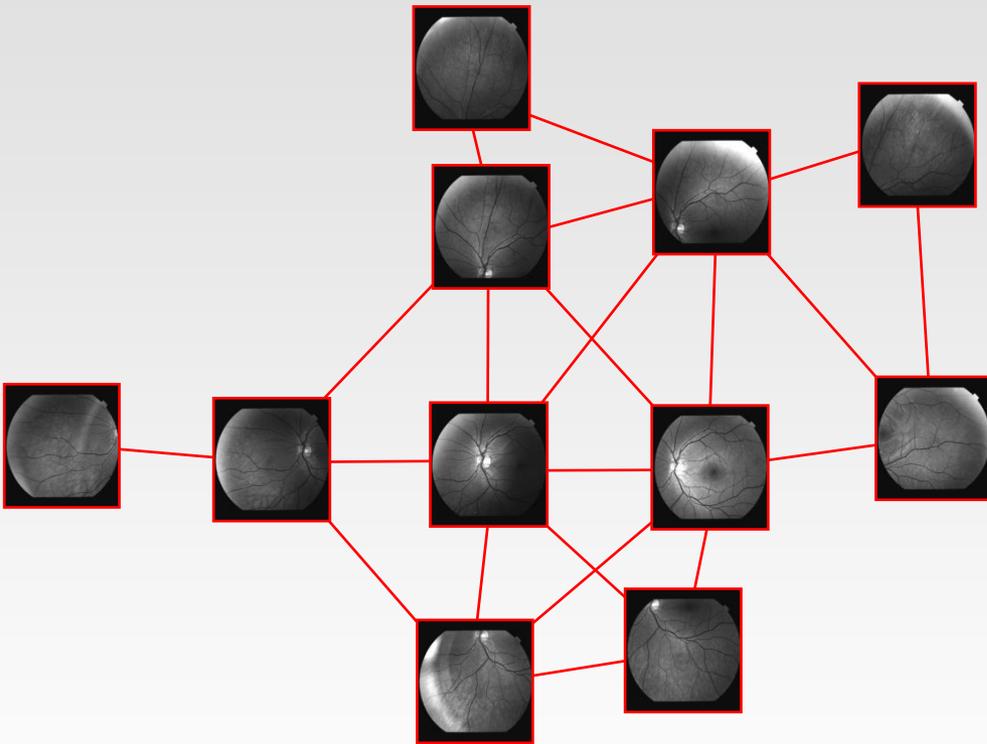
Angiograma da retina e imagem colorida



Aplicações: Mosaicos de imagens

- Em alguns casos, dispomos de várias imagens parciais com sobreposição
- Nenhuma delas nos fornece uma visão completa
- Neste caso o objetivo do co-registro é “encaixar” estas imagens juntas de modo a obter uma visão mais ampla
- Isto requer:
 - Uma câmara com o campo de visão limitado como é o caso da rotação em torno de centro ótico
 - Uma superfície de geometria simples, tal como plana ou quadrática

Imagem mosaico da retina



Mosaicos esféricos



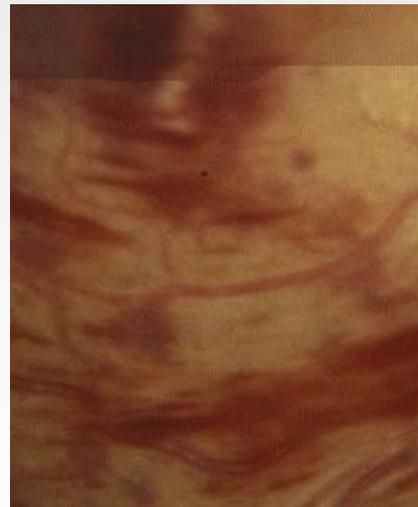
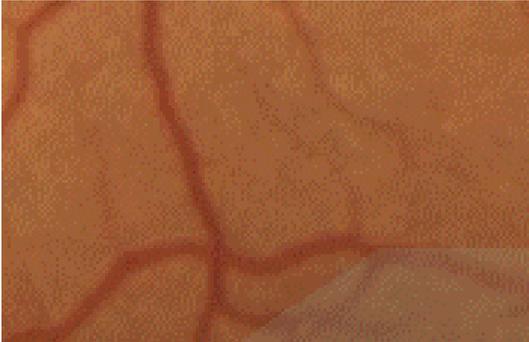
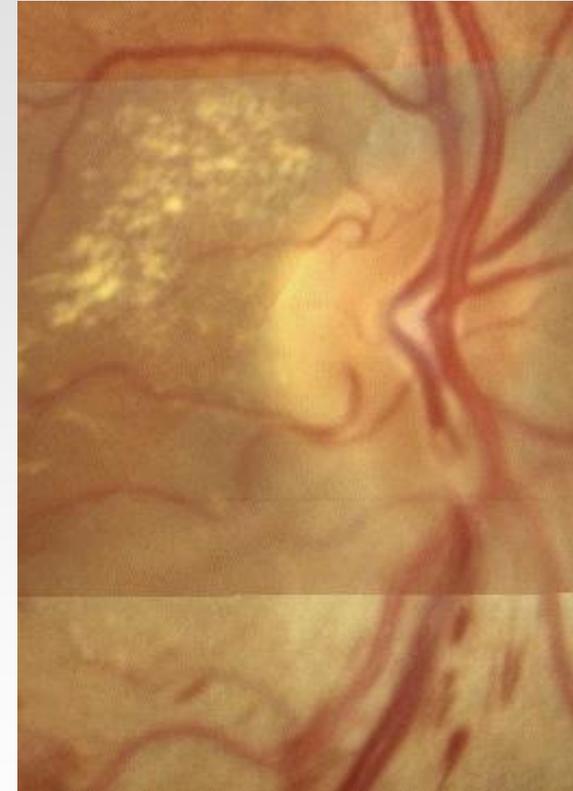
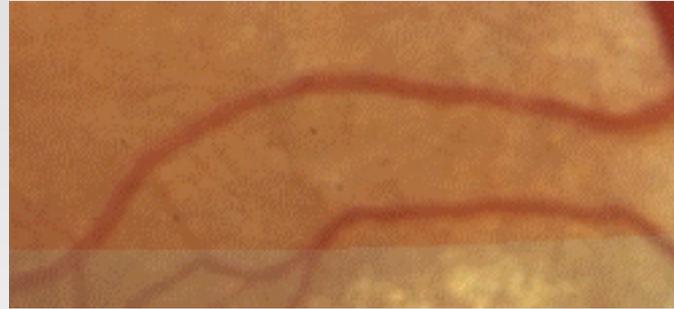
Aplicações: Detecção de mudanças

- **Imagens tomadas em tempos diferentes**
- **Com o conseqüente co-registro das imagens as mesmas passam a ter a mesma geometria, assim as diferenças nas imagens podem ser indicativas de mudanças ou variações**
- **Decidir se a mudança existe realmente pode ser difícil**
- **Exemplos:**
 - **Imagens de MR com contraste**
 - **Imagens de perfusão miocárdica**

Exemplo da Retina



Regiões mostrando mudanças



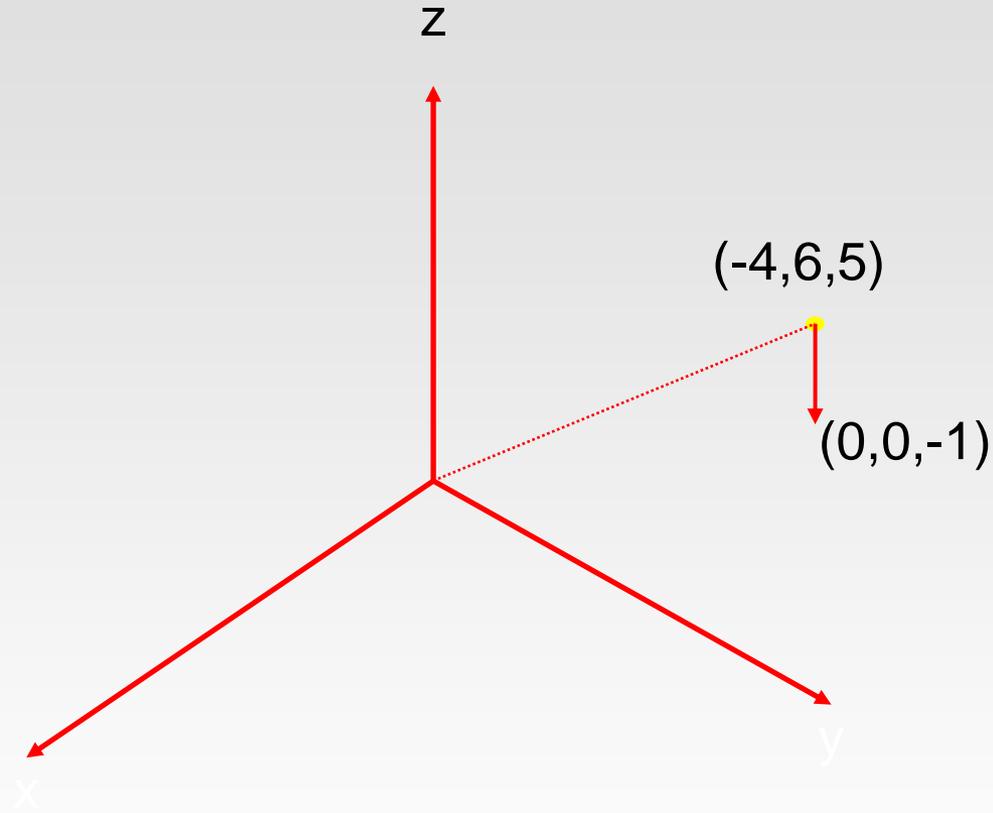
Outras Aplicações

- **Co-registro multi-sujeito para desenvolver atlas de variações para órgãos.**
 - Usado como base para detecção de variações anormais
- **Reconhecimento de objetos - alinhamento de instancia de modelos de objetos e imagem de objeto desconhecido**
- **Inspeção industrial**
 - Compare uma instancia modelo CAD com parte para determinar erros num processo de fabricação

Passos para uma solução

- **Análise as imagens**
- **Determine as primitivas de imagens adequadas**
- **Determine o modelo de transformação**
 - Geométrica e de intensidade
- **Especificar uma técnica de inicialização**
- **Estabelecer limites e uma métrica de erro para a estimativa da transformação**
- **Desenvolver um algoritmo de minimização**
- **Desenvolver um critério de convergência**

Vetores: Exemplo



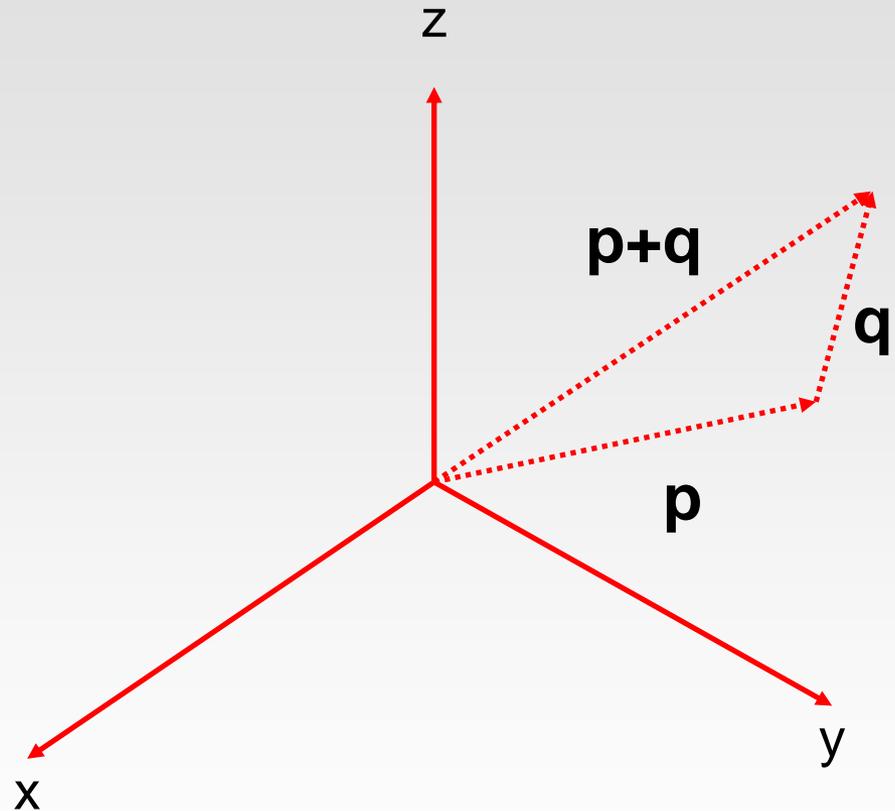
Vetores: Adição

- Adicionado componente a componente

$$\begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{pmatrix} + \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix} = \begin{pmatrix} x_1 + y_1 \\ x_2 + y_2 \\ \vdots \\ x_n + y_n \end{pmatrix}$$

- Exemplo:

$$\begin{pmatrix} 2 \\ 3 \\ -1 \end{pmatrix} + \begin{pmatrix} 4 \\ -1 \\ 1 \end{pmatrix} = \begin{pmatrix} 6 \\ 2 \\ 0 \end{pmatrix}$$



Interpretação
geométrica

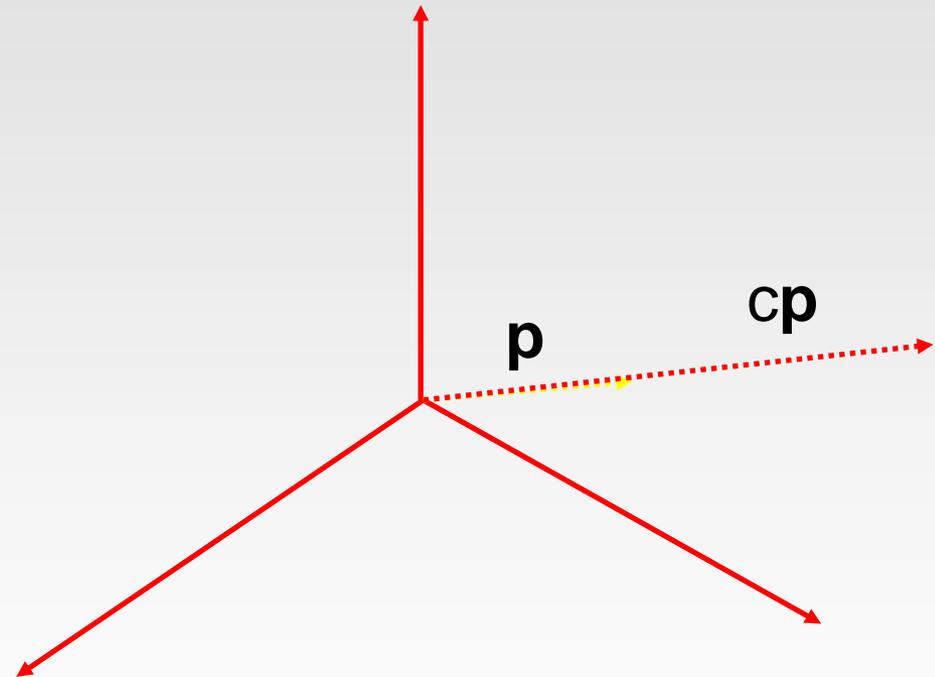
Vetores: Multiplicação escalar

- Forma mais simples de multiplicação envolvendo vetores
- Em particular:

$$c \cdot x = c \cdot \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{pmatrix} = \begin{pmatrix} cx_1 \\ cx_2 \\ \vdots \\ cx_n \end{pmatrix}$$

- Exemplo:

$$3 \cdot \begin{pmatrix} 0,5 \\ -3 \\ 8 \end{pmatrix} = \begin{pmatrix} 1,5 \\ -9 \\ 24 \end{pmatrix}$$



Vetores: Magnitudes, Distancias

- O comprimento ou magnitude de um vetor é

$$\|x\| = \left[\sum_{i=1}^n x_i^2 \right]^{1/2} = \sqrt{x_1^2 + x_2^2 + \dots + x_n^2}$$

- A distancia entre dois vetores é

$$\|x - y\| = \left[\sum_{i=1}^n (x_i - y_i)^2 \right]^{1/2} = \sqrt{(x_1 - y_1)^2 + \dots + (x_n - y_n)^2}$$

Vetores: Produto escalar

- Segundo nodo de multiplicação envolvendo vetores
- Em particular,

$$x \cdot y = \sum_{i=1}^n x_i y_i = (x_1 y_1 + x_2 y_2 + \cdots + x_n y_n)$$

- Veremos uma notação diferente para o produto escalar usando multiplicação de matrizes
- Note que

$$x \cdot x = \|x\|^2$$

Vetor unitário

- Um vetor unitário (direção) é um vetor de magnitude 1:

$$\|x\| = x \cdot x = 1$$

- Convencionalmente, usamos um “chapéu” para denotas vetor unitário, e.g.:

$$\hat{e} \quad \hat{n}$$

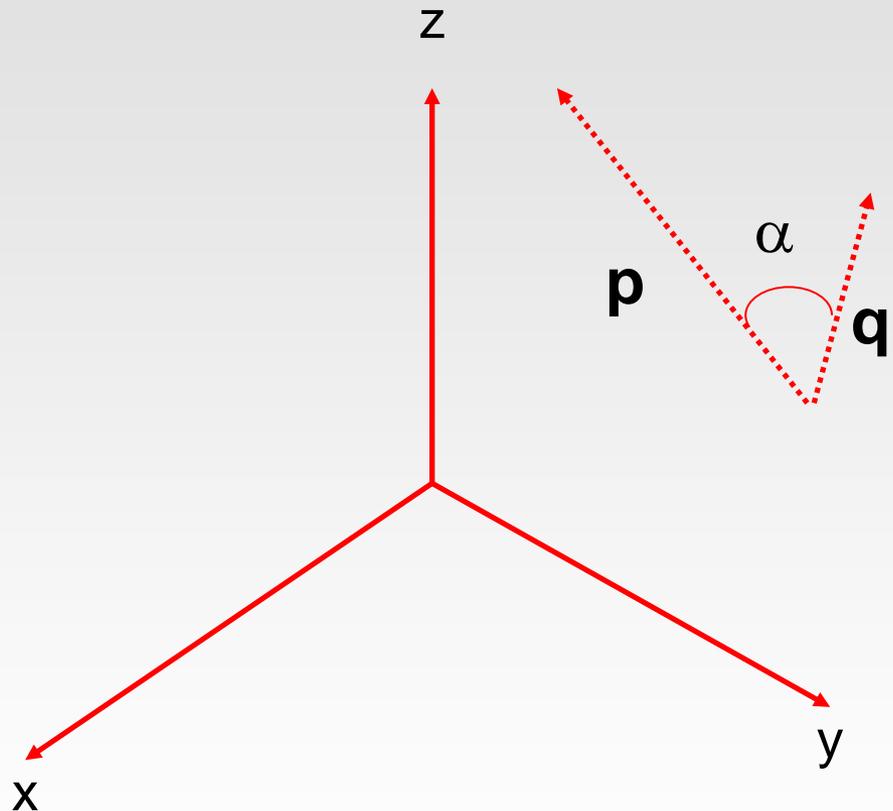
Angulo entre vetores

- Podemos computar o ângulo entre dois vetores usando o produto escalar:

$$\cos \alpha = \frac{p \cdot q}{\|p\| \cdot \|q\|}$$

- Dois vetores não nulos são ortogonais se, e apenas se:

$$p \cdot q = 0$$



Produto vetorial

- Dados três vetores em 3 dimensões, p e q , o produto vetorial dos dois é perpendicular a ambos

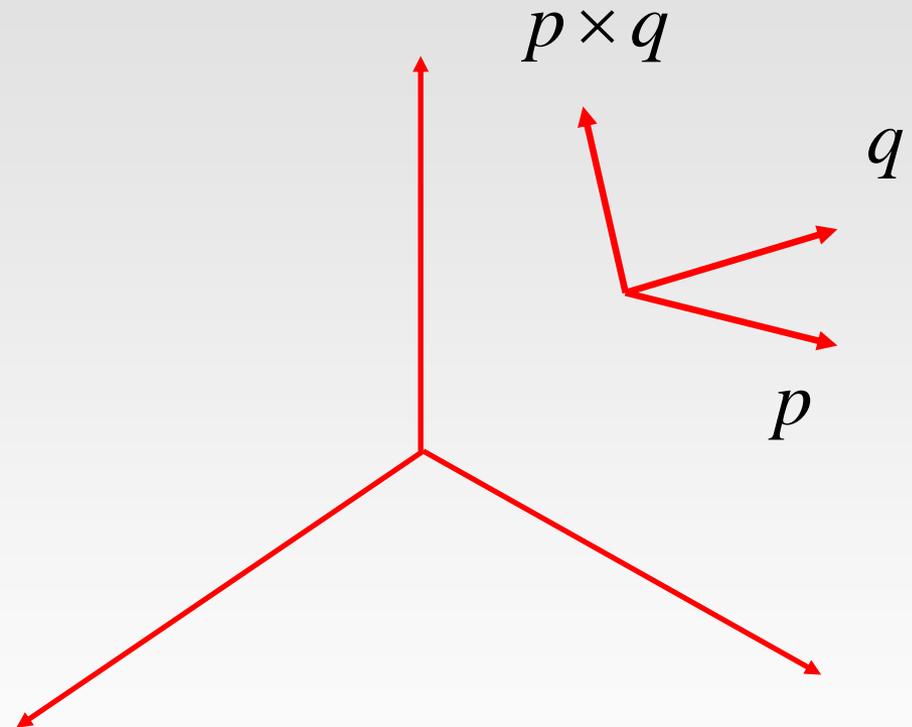
$$r = p \times q$$

- Na forma componente,

$$r = \begin{pmatrix} p_2q_3 - p_3q_2 \\ p_3q_1 - p_1q_3 \\ p_1q_2 - p_2q_1 \end{pmatrix}$$

- Finalmente,

$$\|p \times q\| = \sin \alpha \|p\| \cdot \|q\|$$



Matrizes - Definição

- Matrizes são arranjos numéricos retangular, no qual cada número é subscrito por dois índices:

$$A = \begin{pmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \cdot & \cdot & \cdots & \cdot \\ \cdot & \cdot & \cdots & \cdot \\ a_{m1} & a_{m2} & \cdots & a_{mn} \end{pmatrix}$$

m linhas

n colunas

- Uma notação curta para isto é

$$A = (a_{ij})$$

Matrizes especiais: Identidade

- A matriz identidade, denotada I , I_n ou $I_{n \times n}$, é uma matriz quadrada, com n linhas e colunas tendo 1's na diagonal principal e 0's em qualquer outro lugar:

$$I_3 = \begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{pmatrix}$$

$$I_{2 \times 2} = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}$$

Matrizes Diagonal

- A *matriz diagonal* é uma matriz quadrada que tem 0's em toda a matriz exceto na diagonal principal.
- Por exemplo:

$$A = \begin{pmatrix} 2 & 0 & 0 & 0 \\ 0 & -1 & 0 & 0 \\ 0 & 0 & 3 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix} = \underbrace{\text{diag}(2, -1, 3, 0)}$$

Notação curta

Matriz Transposta e Simetria

- A transposta de uma matriz é aquela que as inscrições de linhas e colunas são invertidas:

$$A^T = \begin{pmatrix} a_{11} & a_{21} & \cdots & a_{1m} \\ a_{12} & a_{22} & \cdots & a_{2m} \\ \cdot & \cdot & \cdots & \cdot \\ \cdot & \cdot & \cdots & \cdot \\ a_{1n} & a_{2n} & \cdots & a_{nm} \end{pmatrix}$$

- **Se $A = A^T$ então a matriz é simétrica.**
 - Somente matrizes quadradas ($m=n$) são simétricas

Adição de Matrizes

- Duas matrizes são somadas se, e somente se elas tem o mesmo número de linhas e colunas.
- Matrizes são somadas componente a componente:

$$A + B = (a_{ij} + b_{ij})$$

- Exemplo:

$$\begin{pmatrix} 3 & 4 & 5 \\ 4 & -1 & 6 \end{pmatrix} + \begin{pmatrix} 5 & -2 & 0 \\ -1 & 0 & 1 \end{pmatrix} = \begin{pmatrix} 8 & 2 & 5 \\ 3 & -1 & 7 \end{pmatrix}$$

Multiplicação escalar de matrizes

- Qualquer matriz pode ser multiplicada por um escalar

$$cA = Ac = (ca_{ij})$$

Multiplicação de matrizes

- O produto de uma matriz $m \times n$ e uma matriz $n \times p$ é uma matriz $m \times p$:

$$A \times B = \left(\sum_{k=1}^n a_{ik} b_{ki} \right)$$

- As inscrições i, j da matriz resultante é o produto escalar da linha i de A e coluna j de B
- Exemplo

$$\begin{pmatrix} 2 & 2 & 5 \\ 4 & -1 & 0 \end{pmatrix} \times \begin{pmatrix} 5 & 2 \\ -1 & 0 \\ 0 & 1 \end{pmatrix} = \begin{pmatrix} 8 & 1 \\ 21 & -8 \end{pmatrix}$$

Vetores como matrizes

- Vetores, os quais usualmente escritos como vetor coluna, podem ser pensados como matrizes $n \times 1$
- A transposta de um vetor é uma matriz $1 \times n$ – um vetor linha.
- Isto permite escrever o produto escalar como multiplicação de matrizes:

$$a \cdot b = a^T b = b^T a$$

- Por exemplo,

$$\begin{pmatrix} -1 \\ 3 \\ 2 \end{pmatrix} \cdot \begin{pmatrix} -2 \\ -1 \\ 0 \end{pmatrix} = (-1 \quad 3 \quad 2) \begin{pmatrix} -2 \\ -1 \\ 0 \end{pmatrix} = -5$$

Matrizes quadradas

- **Muito da nossa discussão aqui concentrará em matrizes quadradas :**
 - Traço
 - Determinante
 - Inversa
 - Autovalores
 - Matriz ortogonal / ortonormal
- **Quando discutimos decomposições de valores singulares voltaremos em matrizes não quadradas**

Traço de uma Matriz

- Somados termos da diagonal principal de uma matriz:

$$tr(A) = \sum_{i=1}^n a_{ii}$$

- O traço é igual a soma dos autovalores da matriz.

- **Notação:**

$$\det(A) = |A|$$

- **recursiva:**

- quando $n=1$,

$$\det(A) = a_{11}$$

- quando $n=2$

$$\det(A) = a_{11}a_{22} - a_{12}a_{21}$$

Determinante (continuando)

- Para $n > 2$, escolha qualquer linha i de \mathbf{A} , e defina $\mathbf{M}_{i,j}$ sendo $(n-1) \times (n-1)$ matriz formada apagando a linha i e coluna j de \mathbf{A} , então

$$\det(A) = \sum_{i=1}^n (-1)^{i+j} a_{ij} \det(M_{ij})$$

- Temos a mesma formula escolhendo uma coluna j qualquer de \mathbf{A} e somando sobre as linhas.

Algumas propriedades do determinante

- Se duas linhas ou duas colunas quaisquer são iguais, o determinante é 0
- Trocando duas linhas ou trocando duas colunas inverte o sinal do determinante
- O determinante de A é igual ao produto dos autovalores de A
- Para matrizes quadradas

$$\det(AB) = \det(A) \det(B)$$

$$\det(A) = \det(A^T)$$

Matriz inversa

- A matriz inversa de uma matriz quadrada A é a única matriz A^{-1} tal que

$$A^{-1}A = AA^{-1} = I$$

- Matrizes que não tem inversa são ditas não inversíveis ou *singular*
- Uma matriz é inversível se, e somente se seu determinante é não nulo
- Não preocuparemos com os mecanismo de cálculos de matrizes inversas, a não ser usando decomposição de valor singular

Autovalores e autovetores

- Um escalar λ e um vetor v são, respectivamente, um autovalor e um autovetor unitário associado de uma matriz quadrada A se

$$Av = \lambda v$$

- Por exemplo, se pensarmos em A como uma transformação e se $\lambda=1$, então $Av=v$ implica que v é um “ponto-fixo” da transformação.
- Auto valores são encontrados resolvendo a equação

$$\det(Av - \lambda v) = 0$$

- Uma vez que os auto valores são conhecidos, autovetores são encontrados achando o espaço nulo de

$$A - \lambda I$$

Autovlores de matrizes simétricas

- São reais (não imaginários), o que pode ser visto estudando a seguinte equação

$$\|Av\|^2 = v^T A^T Av = v^T A^T (\lambda v) = \lambda v^T A^T v = \lambda^2 v^T v$$

- Podemos também mostrar que autovetores associados com autovalores distintos de uma matriz simétrica são ortogonais
- Podemos, portanto, escrever uma matriz simétrica como:

$$A = \sum_{i=1}^n \lambda_i v_i v_i^T$$

Matrizes ortonormais

- Uma matriz quadrada é ortonormal (também chamada ortogonal) se

$$AA^T = I$$

- Em outras palavras A^T é a matriz inversa.
- Baseado nas propriedades de inversas, isto implica

$$A^T A = I$$

- Isto significa que para vetores formados por duas linhas quaisquer ou duas colunas quaisquer

$$a_i^T a_j = \delta_{i,j}$$

delta de Kronecker, o qual é 1 se $i=j$ e 0 caso contrário

Matrizes ortonormais - Propriedades

- O determinante de uma matriz ortonormal é 1 ou -1, porquê:

$$\det(QQ^T) = \det(Q) \det(Q^T) = \det(I) = 1$$

- Multiplicando um vetor por uma matriz ortonormal não muda o comprimento do vetor:

$$\|Qv\|^2 = v^T Q^T Qv = v^T Iv = v^T v = \|v\|^2$$

- Uma matriz ortonormal a qual o determinante é 1 (-1) é chamada uma rotação (reflexão).
- É claro que, como já discutimos

$$Q^{-1} = Q^T$$

Decomposição de valor singular (SVD)

- Considere uma matriz $m \times n$, A , e assumamos $m \geq n$.
- A pode ser “decomposta” no produto de 3 matrizes:

$$A = U W V^T$$

- Onde:
 - U é $m \times n$ com colunas ortonormais
 - W é uma matriz diagonal $n \times n$ de “valores singulares”, e
 - V é matriz ortonormal $n \times n$
- Se $m = n$ então U é uma matriz ortonormal

Propriedades dos valores singulares

$$W = \text{diag}(w_1, w_2, \dots, w_n)$$

- **com**

$$w_1 > w_2 > \dots > w_n > 0$$

- **e**

- o número valores singulares não zeros é igual ao grau de **A**

SVD e inversão de matriz

- Para uma matriz não-singular, quadrada, com

$$A = U W V^T$$

- A inversa de A é

$$A^{-1} = V \text{diag}(1/w_1, 1/w_2, \dots, 1/w_n) U^T$$

- Você pode confirmar isto!
- **Note, contudo, esta nem sempre é a melhor maneira de computar a inversa**

SVD e solução de sistemas lineares

- Muitas vezes o problema se reduz a achar o vetor x que minimiza

$$\|Ax - b\|^2$$

- Tomando a derivada em relação a x , e igualando o resultado a 0 e resolvendo implica

$$A^T Ax = A^T b$$

- Computando o SVD de A (assumindo grau máximo) resulta em

$$x = VW^{-1}U^T b$$

- **Imagens:**
 - Tipos de imagens
 - Sistemas de coordenadas
- **Transformações**
 - Transformações de similaridade em 2d e 3d
 - Transformações affine em 2d e 3d
 - Transformações projetivas
 - Transformações não-lineares e deformáveis

- **Imagens tomográficas:**
 - CT e MRI
- **Imagens de intensidade / vídeo**
- **Imagens de intervalo**

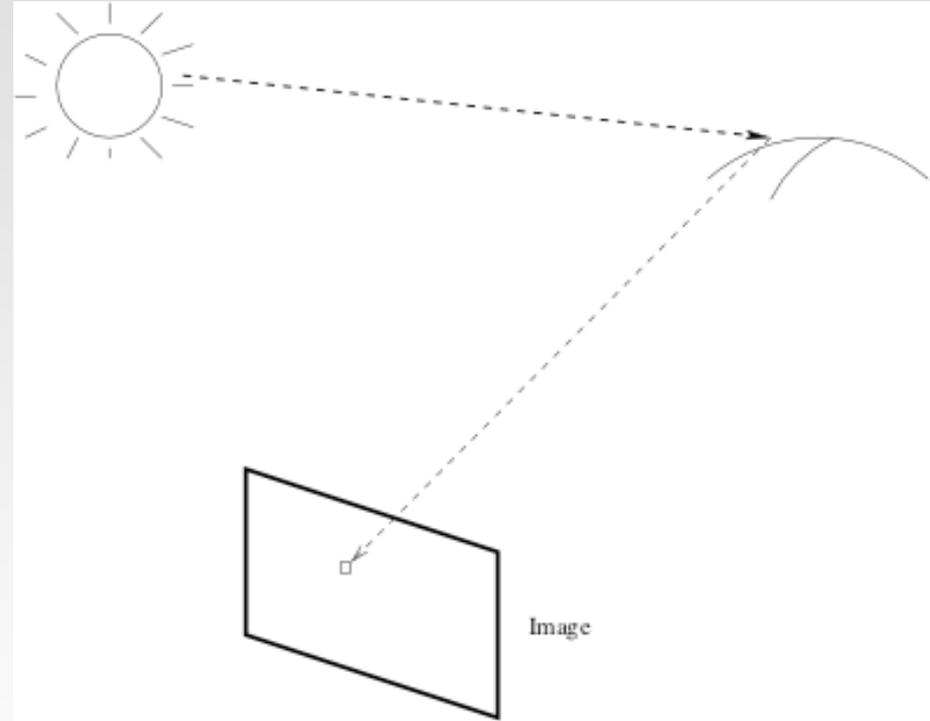
Imagens de vídeo

- **Intensidades de pixel dependem de:**

- Iluminação
- Orientação de superfícies
- Refletância
- Direção da projeção
- Digitalização

- **Por si só:**

- Dimensões de pixels não tem significados físicos
- Intensidades de pixels não tem significados físicos

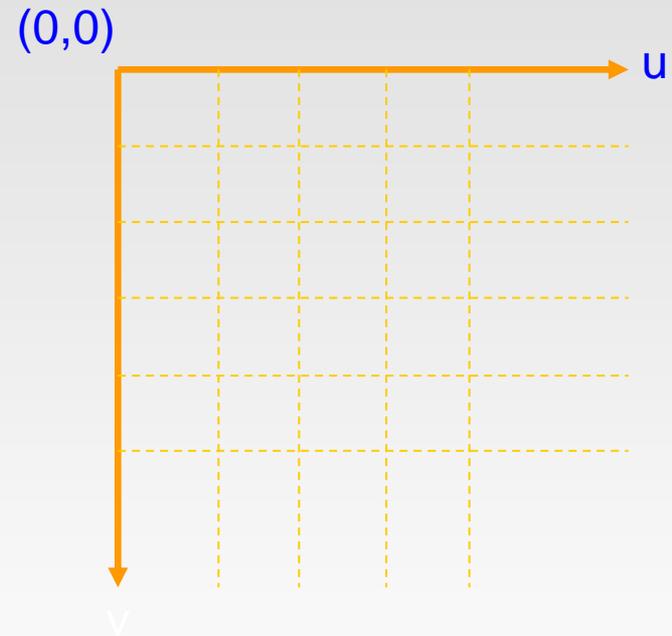


Sistemas de coordenadas

- **Temas:**
 - Coordenadas da imagem
 - Coordenadas físicas
 - Mapeamento entre elas
- **Deve-se ficar atento a isto, especialmente na implementação de detalhes de algoritmo do co-registro**

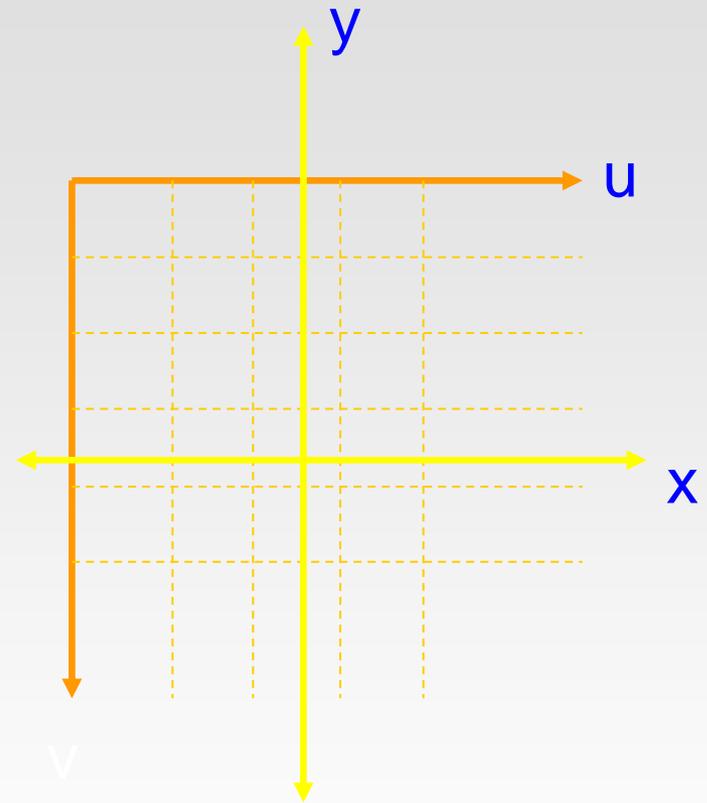
Sistema de coordenadas da imagem

- A origem é geralmente no canto da imagem, freqüentemente esquerdo superior
- Eixos:
 - Eixo x é para direita
 - Eixo y é para baixo
- Difere das coordenadas da matriz e das coordenadas Cartesianas
- As unidades são incrementos inteiros nos índices da grade



Coordenadas físicas

- **Origem:**
 - Próximo ao centro em imagens de vídeos
 - Definido pelo scanner em imagens medicas
- **Eixos:**
 - Coordenadas frame “mão direita”
- **Unidades são millímetros (imagens medicas)**

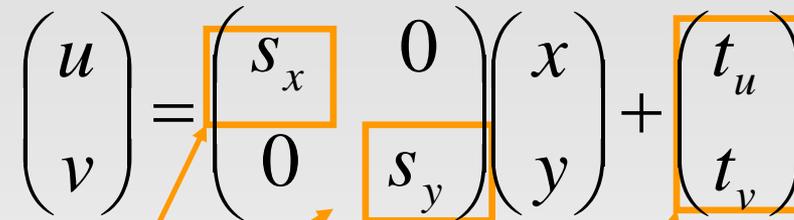


Voxels não isotrópicos em imagens médicas

- **Dimensão axial (z) é freqüentemente maior que as dentro da fatia (dimensões x e y)**
- **Na pior das hipóteses, a ordem de grandeza é próxima**
- **Novos scanners estão se aproximando das dimensões isotrópicas**

Mudanças de coordenadas como multiplicação de matrizes

- Coordenadas físicas para coordenadas de pixels :

$$\begin{pmatrix} u \\ v \end{pmatrix} = \begin{pmatrix} s_x & 0 \\ 0 & s_y \end{pmatrix} \begin{pmatrix} x \\ y \end{pmatrix} + \begin{pmatrix} t_u \\ t_v \end{pmatrix}$$


Escalonamento das unidades físicas para pixels: parâmetros são pixels por mm

Translação da origem em unidades de pixels

Forma homogênea

- Usando coordenadas homogêneas --- nos termos mais simples, adicionando 1 no fim de cada vetor --- nos permite escrever usando uma única multiplicação de matriz:

$$\begin{pmatrix} u \\ v \\ 1 \end{pmatrix} = \begin{pmatrix} s_x & 0 & t_u \\ 0 & -s_y & t_v \\ 0 & 0 & 1 \end{pmatrix} \begin{pmatrix} x \\ y \\ 1 \end{pmatrix}$$

Transformações

- **Transformações geométricas**
- **Transformações de intensidades**

Transformação geométrica direta

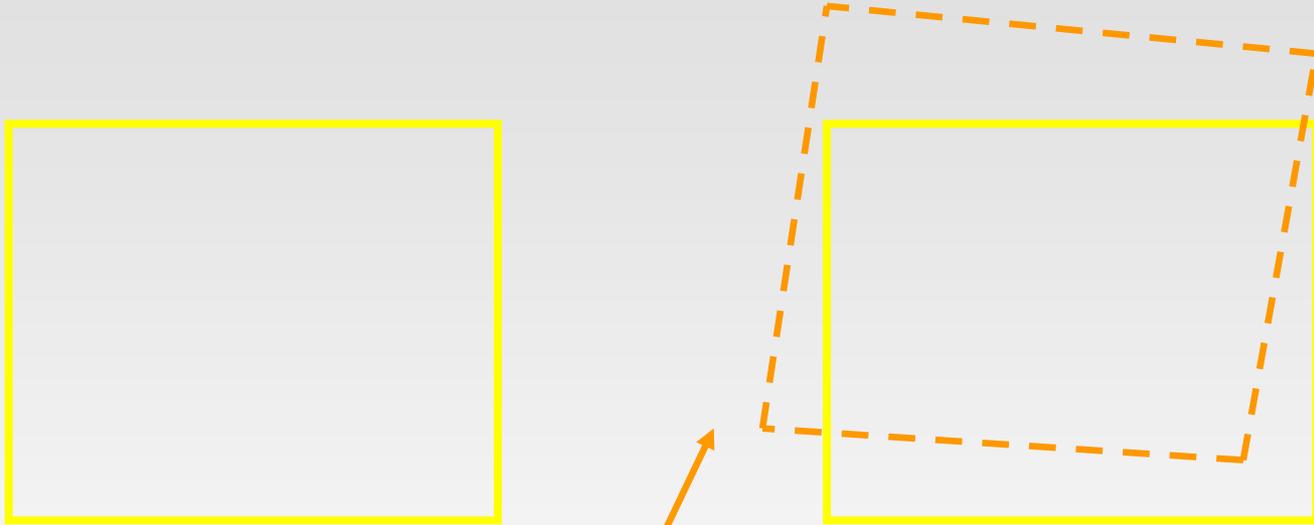


Imagem em “Movimento”, I_m

Imagem “Fixa”, I_f

Imagem em movimento transformada, I_m' . Ela é mapeada no sistema de coordenadas de I_f

Mapeando valores de pixels

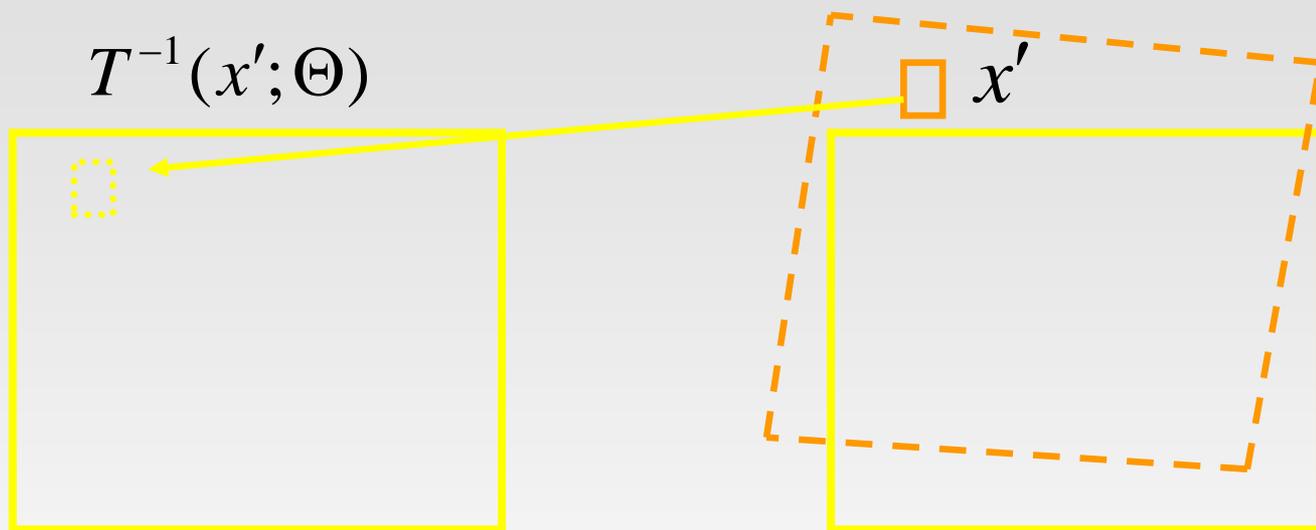


Imagem em “Movimento”, I_m

Imagem “Fixa”, I_f

$$I'_m(x') = I_m(T^{-1}(x'; \Theta))$$

É preciso retornar para obter o valor do pixel. Isto geralmente não mapeia num pixel exato, mas sim entre pixels. Por isso é necessário interpolação.

Transformação reversa

- **Pelo que já foi dito, algumas técnicas estimam os parâmetros da transformação reversa, T^{-1} :**
 - Da imagem fixa para a imagem em movimento
- **Isto pode se tornar um problema se a função de transformação é não reversível**
- **Algoritmos baseados em intensidades geralmente estimam a transformação reversa**

Transformações de intensidades

- Quando as intensidades devem ser também transformadas, as equações se tornam mais complicadas:

$$I'_m(x') = S\left(I_m\left(T^{-1}(x' : \Theta)\right) : \gamma\right)$$

Função de mapeamento
de intensidade

Parâmetros do mapeamento
de intensidade

Felizmente, não estaremos muito preocupados com mapeamentos de intensidades

Modelos de transformação

- **Translação e escalonamento em 2d e 3d**
- **Transformações de similaridade em 2d e 3d**
- **Transformações affine em 2d e 3d**

Translação e escalonamento

- **Nós já vimos em 2d:**

- Transformações entre coordenadas de pixels e coordenadas físicas
- Translação e escalonamento na aplicação da retina

- **Na forma matricial:**

$$T(x; \Theta) = \begin{pmatrix} s_x & 0 \\ 0 & s_y \end{pmatrix} x + \begin{pmatrix} t_x \\ t_y \end{pmatrix}$$

- **onde**

$$\Theta = (s_x \quad s_y \quad t_x \quad t_y)^T$$

- **Na forma homogênea:**

$$T(x; \Theta) = \begin{pmatrix} s_x & 0 & t_x \\ 0 & s_y & t_y \\ 0 & 0 & 1 \end{pmatrix} \begin{pmatrix} x \\ 1 \end{pmatrix}$$

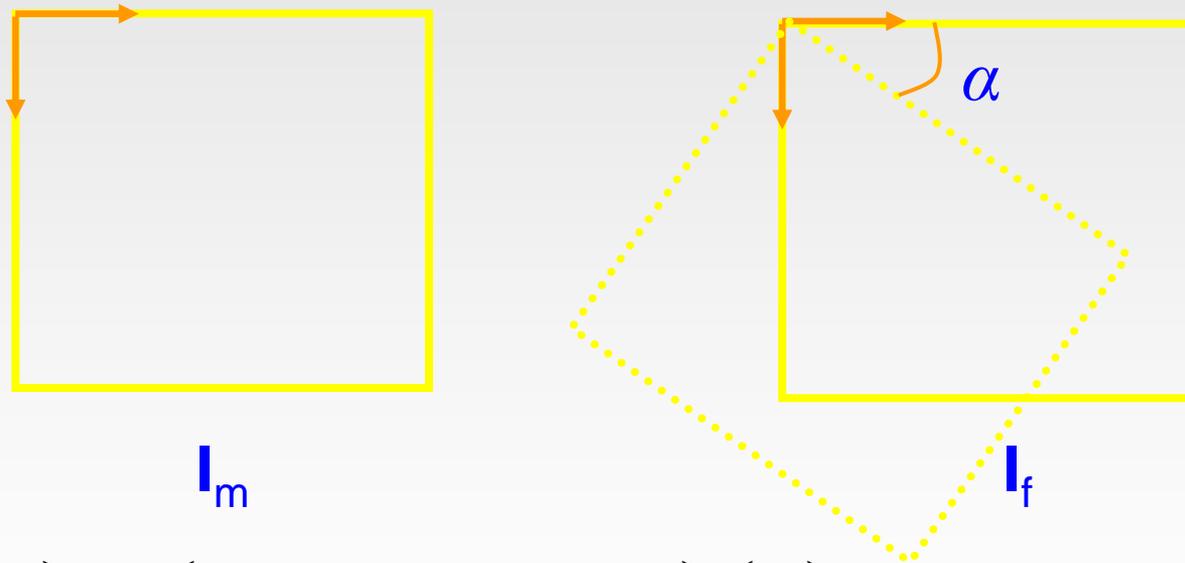
Vetor de duas componentes

Transformações de Similaridade

- **Componentes:**
 - Rotação (próximo slide)
 - Translação
 - Escalonamento independente
- **“Invariantes”**
 - Ângulos entre vetores permanecem fixos
 - Todos os comprimentos escalonam proporcionalmente, então as razões entre os comprimentos são preservadas
- **Exemplo de aplicação:**
 - Multi-modalidade, co-registro cerebral intra-subjetivo (mesma pessoa)

Rotações em 2d

- Assumam (por enquanto) que a transformação direta é somente uma rotação
- A origem das imagens são os cantos superiores direito; angulos são mensurados no sentido horário no eixo x



$$\begin{pmatrix} x' \\ y' \end{pmatrix} = \begin{pmatrix} \cos \alpha & -\text{sen} \alpha \\ \text{sen} \alpha & \cos \alpha \end{pmatrix} \begin{pmatrix} x \\ y \end{pmatrix}$$

Transformações de Similaridade em 2d

- Como resultado:

$$T(x : \Theta) = s \begin{pmatrix} \cos \alpha & -\text{sen} \alpha \\ \text{sen} \alpha & \cos \alpha \end{pmatrix} x + \begin{pmatrix} t_x \\ t_y \end{pmatrix}$$

$$\Theta = (s, \alpha, t_x, t_y)^T$$

- Ou:

$$T(x : \Theta) = \begin{pmatrix} s \cdot \cos \alpha & -s \cdot \text{sen} \alpha \\ s \cdot \text{sen} \alpha & s \cdot \cos \alpha \end{pmatrix} x + \begin{pmatrix} t_x \\ t_y \end{pmatrix} = \begin{pmatrix} a & -b \\ a & a \end{pmatrix} x + \begin{pmatrix} t_x \\ t_y \end{pmatrix}$$

$$\Theta = (a, b, t_x, t_y)^T$$

Matrizes de rotação e rotações 3d

- A matriz de rotação 2d é ortonormal com determinante 1:

$$R = \begin{pmatrix} \cos \alpha & -\operatorname{sen} \alpha \\ \operatorname{sen} \alpha & \cos \alpha \end{pmatrix}$$

- em dimensões arbitrárias, estas duas propriedades preservam.
- Portanto, escrevemos a transformação de similaridade em dimensões arbitrárias como:

$$T(x : \Theta) = sRx + t \qquad T(x : \Theta) = \begin{pmatrix} sR & t \\ 0^T & 1 \end{pmatrix} \begin{pmatrix} x \\ 1 \end{pmatrix}$$

Representando Rotações em 3d

- **R é uma matriz 3x3, dando 9 parametros, mas tem somente 3 graus de liberdade.**
 - Suas propriedades de ortonormalidade removem os outros 6.
- **Questão: Como representar R?**
- **Algumas respostas (de muitas):**
 - Aproximações para pequenos angulos em torno de cada eixo
 - Quaternions

Transformações Affine

- **Geometria:**
 - Rotação, escalonamento (cada dimensão separadamente), translação e cisalhamento
- **Invariantes:**
 - Linhas paralelas permanecem paralelas
 - Razão de comprimentos de segmentos numa linha permanecem fixas
- **Exemplo de aplicação:**
 - Construção de mosaicos para imagens de superfície da terra (superfície plana e câmaras relativamente não oblíquas)

Transformações Affine em 2D

- Em 2D, multiplique a localização x por uma matriz 2x2 arbitrária mas inversível

$$T(x : \Theta) = \begin{pmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{pmatrix} x + \begin{pmatrix} t_x \\ t_y \end{pmatrix}$$

- generalizando,

$$T(x : \Theta) = Ax + t$$

- ou, na forma homogênea,

$$T(x : \Theta) = \begin{pmatrix} A & t \\ \mathbf{0}^T & 1 \end{pmatrix} x + \begin{pmatrix} x \\ 1 \end{pmatrix}$$

Transformações Affine e SVD

- Considere o SVD da matriz affine A:

$$A=UWV^T$$

- (se necessário, volte e reveja as propriedades do SVD.)

- Fazendo

$$Q=UV^T$$

- Temos

$$A=QVWV^T$$

- A transformação geométrica

Transformações projetivas

- **Transformação linear geral**
- **Comprimentos, ângulos, e linhas paralelas NÃO são preservadas**
- **Coincidência, tangência, e razões de comprimentos complicadas são invariantes**
- **Aplicação:**
 - Mosaicos de imagens tiradas de câmaras girando sobre o centro ótico
 - Mosaico de imagens de superfícies planares

Algebra de transformações projetivas

- Adicione uma linha “não zerada” abaixo na matriz homogênea:

$$T(x; \Theta) = \begin{pmatrix} A_0 & t \\ v^T & a_{nn} \end{pmatrix} \begin{pmatrix} x \\ 1 \end{pmatrix}$$

- Localização do ponto transformada:

$$x' = \frac{Ax + t}{v^T x + a_{nn}}$$

- O calculo do estimador é um pouco complicada que a transformação affine

Transformações não-lineares

- Transformação usada em imagens mosaico da retina é uma função não linear das coordenadas da imagem:

$$T(x; \Theta) = \begin{pmatrix} \theta_{11} & \theta_{12} & \theta_{13} & \theta_{14} & \theta_{15} & \theta_{16} \\ \theta_{21} & \theta_{22} & \theta_{23} & \theta_{24} & \theta_{25} & \theta_{26} \end{pmatrix} \begin{pmatrix} x^2 \\ xy \\ y^2 \\ x \\ y \\ 1 \end{pmatrix}$$

Modelos deformáveis

- **Funções não-globais**
- **Freqüentemente baseadas em PDE:**
 - Splines placas-finas
 - Mecânica de fluidos
- **Representações**
 - B-splines
 - Elementos finitos
 - Bases de Fourier
 - Bases de funções radiais

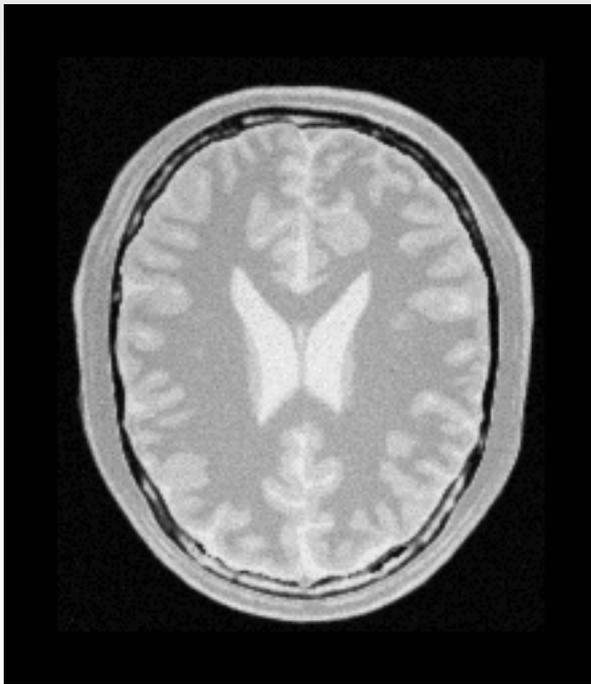
- **Exemplo**
- **Co-registro baseado em intensidade**
- **Função de erro SSD**
- **Mapeamento de imagens**
- **Minimização de funções:**
 - Gradiente descendente
 - Cálculo variacional
- **Algoritmo**
- **Resultados e discussão**

Material para leitura

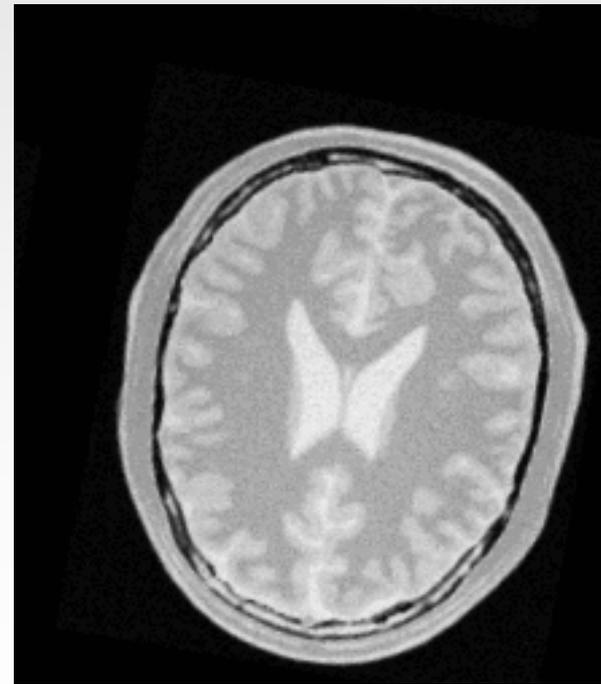
- **Paper:**
 - Hill, Batchelor, Holden and Hawkes, Medical Image Registration, *Physics of Medicine and Biology* **46** (2001) R1-R45.
- **Artigo disponível na internet**
- **Excelente introdução ao problema do co-registro, porem muito focalizado em aplicações médicas utilizando transformações de similaridade**

Exemplo

- Co-registro de imagens de MRI, transformação de similaridade (rodada por 10 graus, com uma translação de 17mm e 13mm)



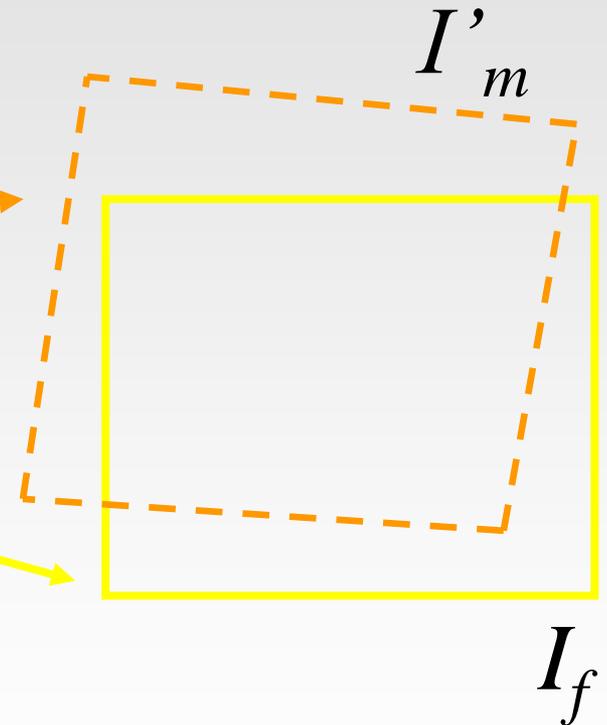
I_m



I_f

Co-registro baseado em intensidade

- Use a intensidade mais ou menos diretamente
- Compare intensidades entre
 - Versão mapeada (transformada) da imagem movimentada I_m (baseada na transformação estimada) e
 - Imagem fixa I_f
- Precisa:
 - Medida de erro pixel-a-pixel
 - Técnica de mapeamento
 - Técnica de Minimização



Exemplo de medida de erro: SSD

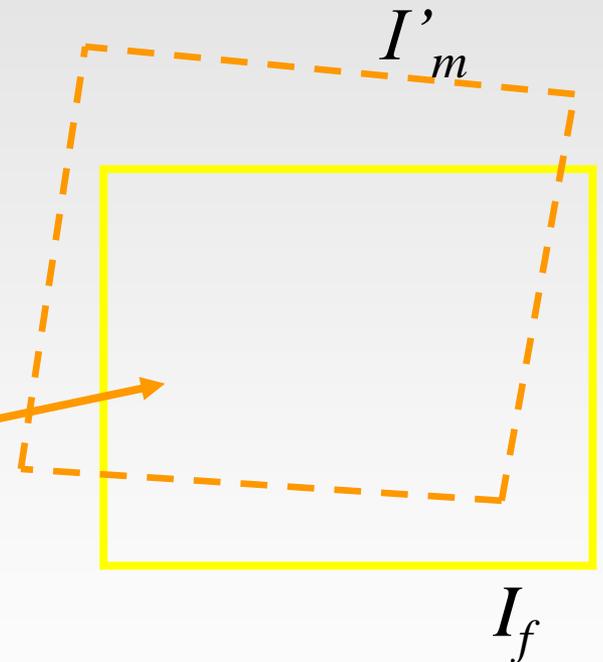
$$\sum_{p \in \Omega} [I_f(p) - I'_m(p)]^2$$

Ω →

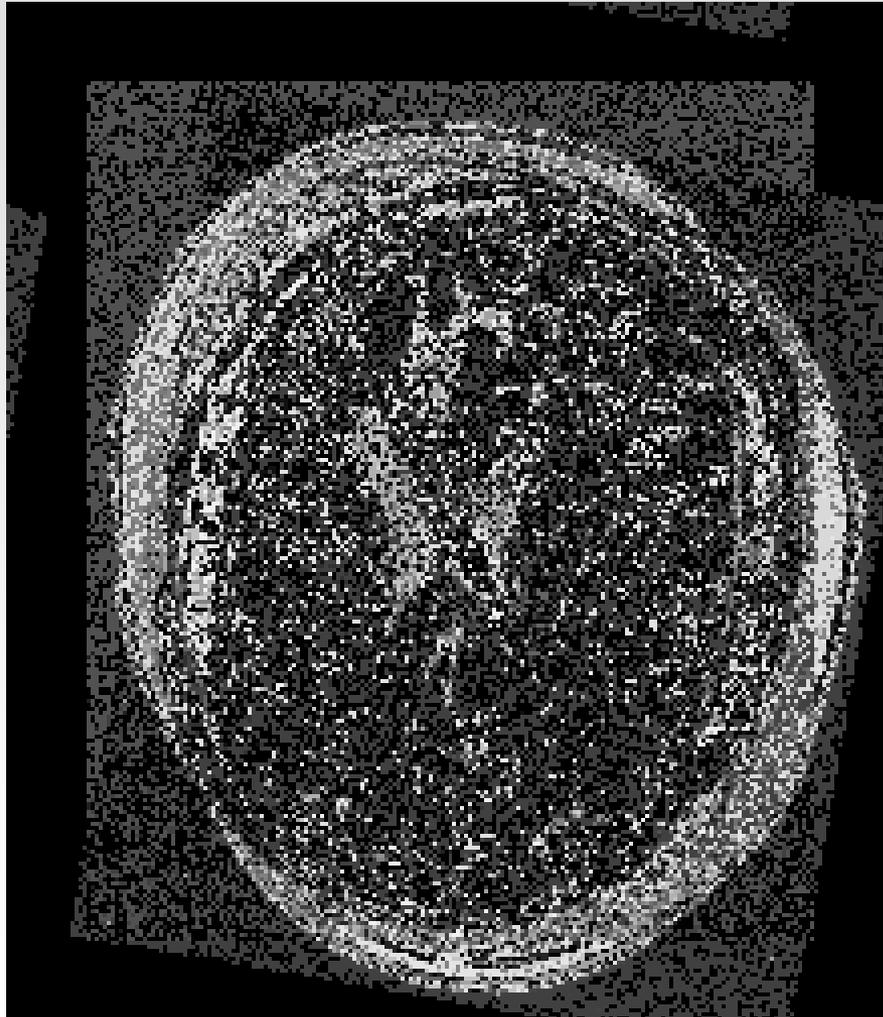
Região de intersecção
entre imagens

\mathbf{p} →

Localizações de pixels
dentro da região



Exemplo SSD: Alinhamento Inicial



SSD: soma dos quadrados dos erros

- **Vantagens:**

- Simples de computar
- Diferenciável
- Ótimo para distribuição de erro Gaussiana

- **Desvantagens:**

- Não permite ganho variável entre as imagens, o qual pode ser causado por iluminação diferente ou conjunto de câmeras
- Viesado por grandes erros em intensidades
 - » Ex. Causado por injeção de agente de contraste

Trabalhando nos parâmetros

- **Lembre:**

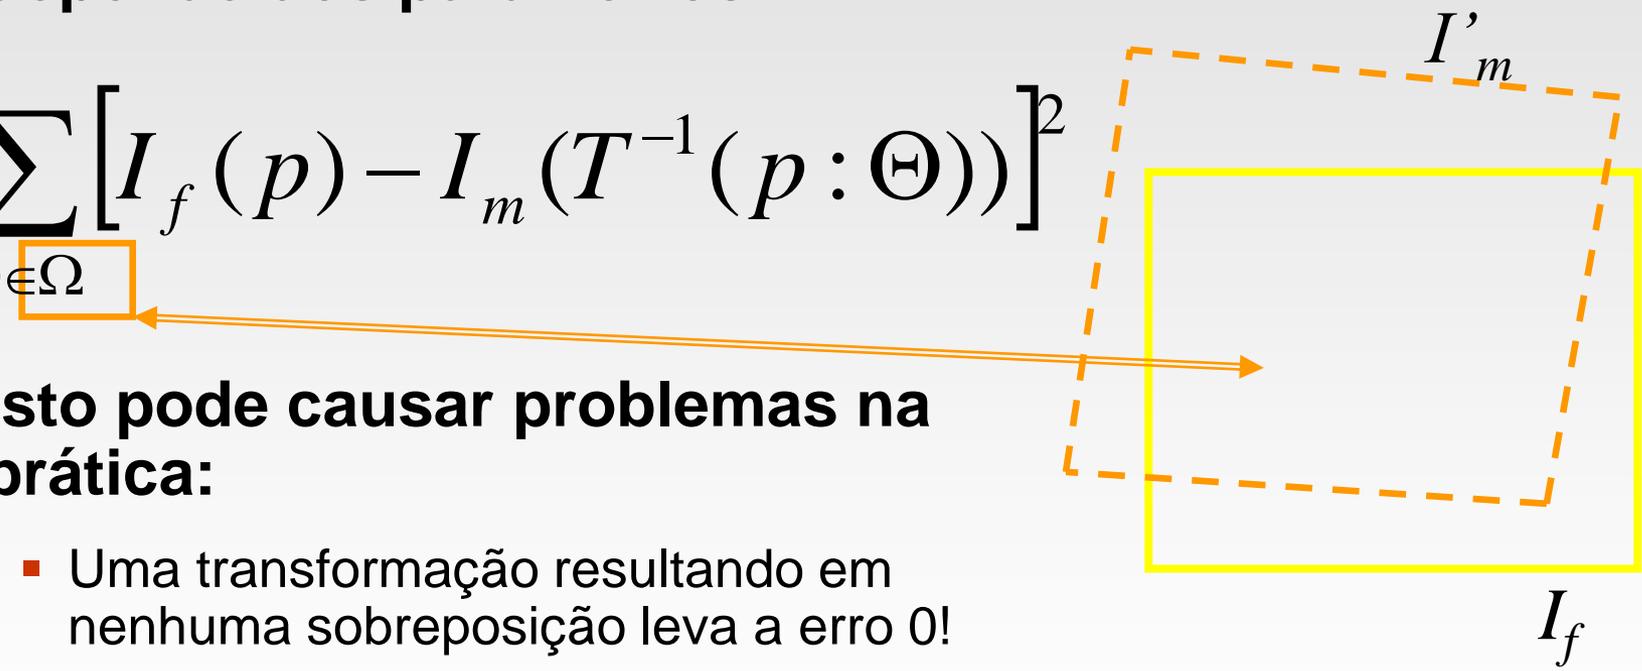
$$I'_m(p) = I_m(T^{-1}(p : \Theta))$$

- **Isto significa que para avaliar o efeito da estimativa da transformação, o que devemos avaliar é**

$$\sum_{p \in \Omega} \left[I_f(p) - I_m(T^{-1}(p : \Theta)) \right]^2$$

O papel da região

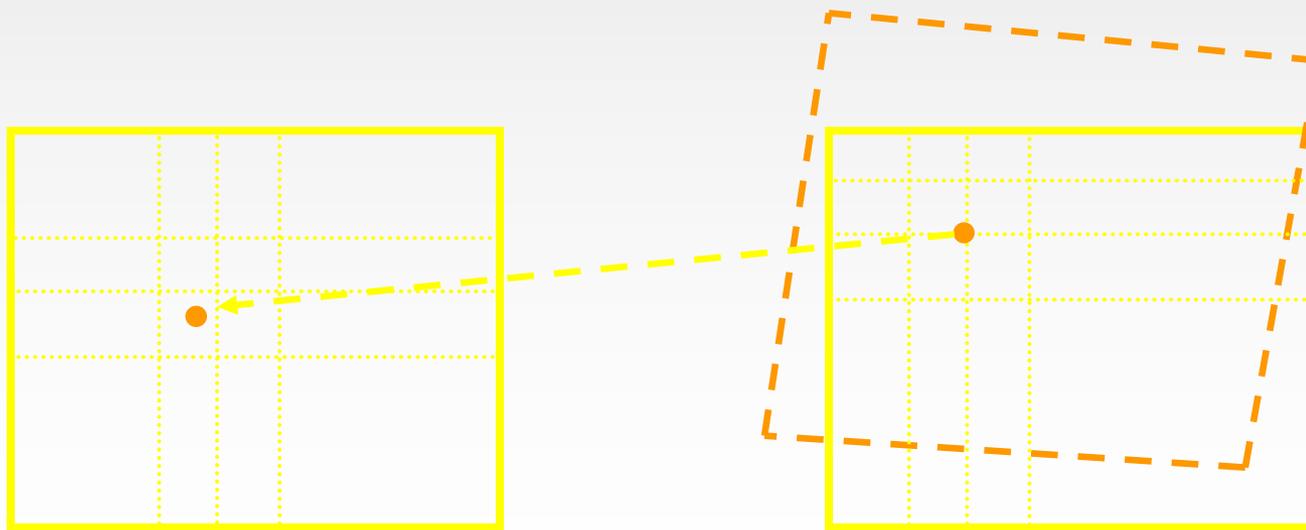
- Observe: a região sobre a qual a transformação é avaliada depende dos parâmetros:

$$\sum_{p \in \Omega} \left[I_f(p) - I_m(T^{-1}(p : \Theta)) \right]^2$$


- Isto pode causar problemas na prática:
 - Uma transformação resultando em nenhuma sobreposição leva a erro 0!

Avaliando função custo

- Avaliação pixel-a-pixel dentro da região
- Apique o mapeamento inverso mapping em cada pixel
- Problem: mapeamento inverse de pixel não leva a localização discreta de pixels!

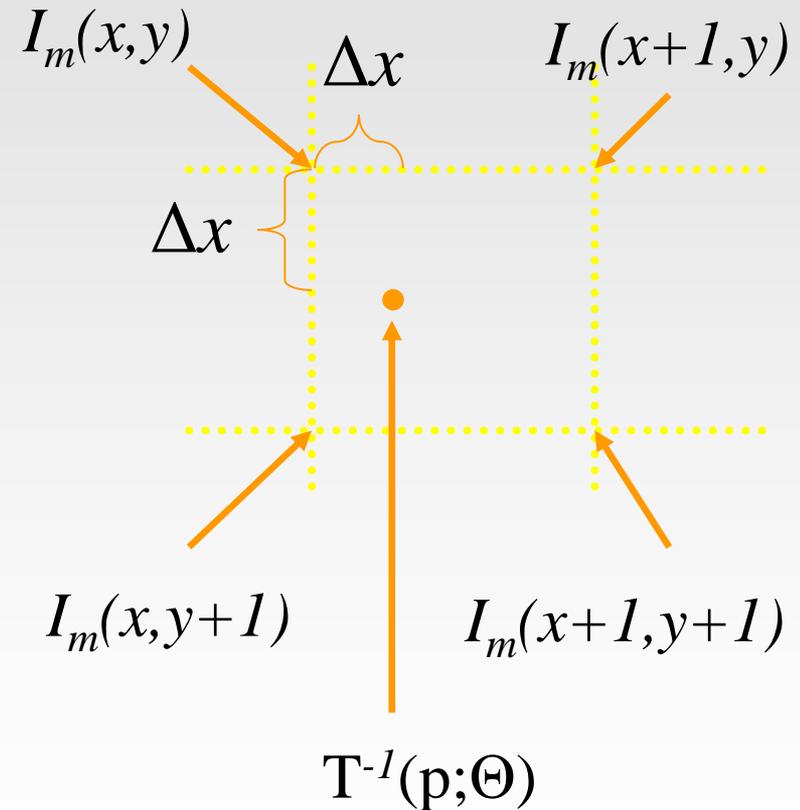


Muitas opções de interpolação

- **Nearest neighbor (vizinhos próximos)**
- **Bilinear (ou trilinear em 3d)**
- **Spline**
- **Sinc**

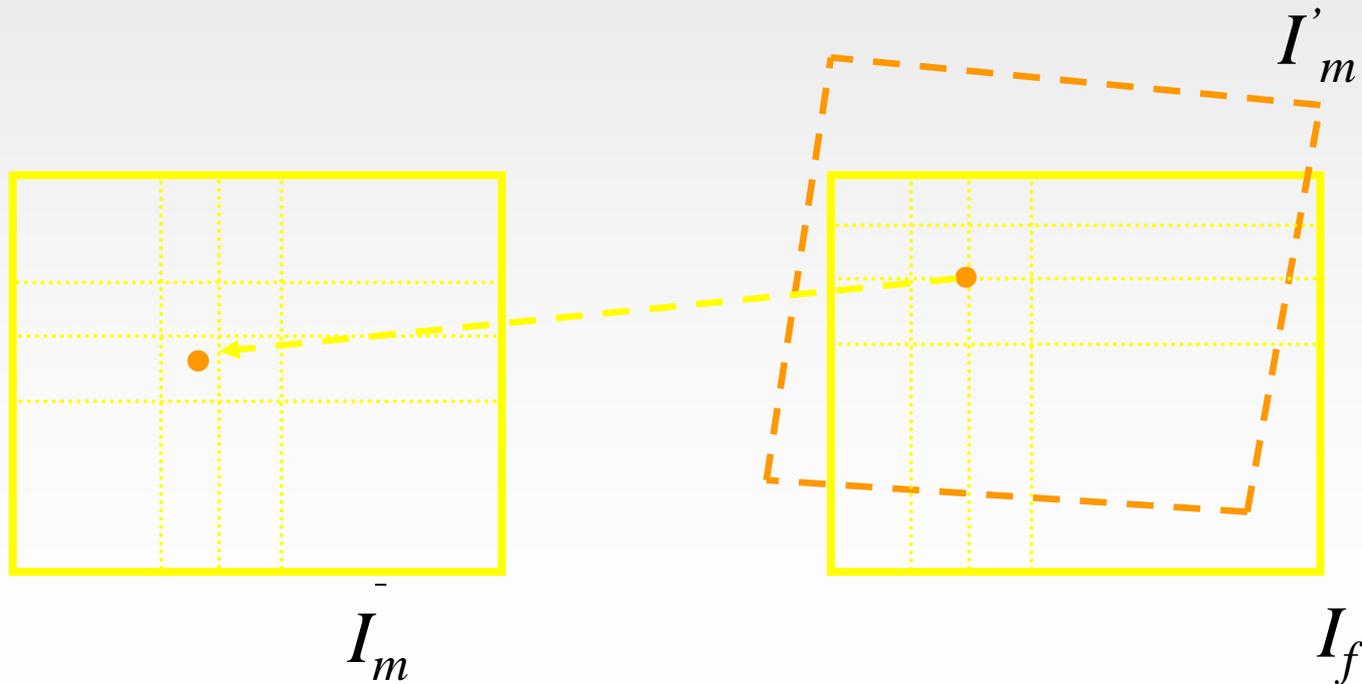
Interpolação Bilinear

- Média ponderada sobre 4 pixels vizinhos
 - 8 pixels vizinhos em 3d
- Pesos proporcional as distancia em x e em y



Duas opções na prática

- Criar intensidades, pixel-a-pixel, mas não cria uma imagem explícita I'_m
- Criar imagem real I'_m



Estagio de otimização

- **Temos:**
 - Formulada a função peso SSD;
 - Discutido como avaliá-la.
- **Próximo passo é como minimizá-la em relação aos parâmetros de transformação.**

Antes de prosseguir

- Estimaremos os parâmetros da transformação reversa
- Minimizaremos a equação:

$$\sum_{p \in \Omega} \left[I_f(p) - I_m(T^{-1}(p : \Theta)) \right]^2$$

- Devemos entender (implicitamente) que esta é a transformação inversa e os valores dos parâmetros serão diferentes

Minimização de função

- **Função para minimizar:**

$$E(\Theta) = \sum_{p \in \Omega} \left[I_f(p) - I_m(T^{-1}(p; \Theta)) \right]^2$$

- **Possibilidades**

- Método simplex - não-diferencial
- Gradiente descendente
- Linearização (levando ao “mínimos quadrados”)
- Método de Newton
- Muitos outros...



Gradiente Descendente

- **Compute o gradiente da função peso (com relação aos parâmetros de transformação), avaliado na estimativa atual dos parâmetros**

$$\nabla E(\Theta_t) = \frac{\partial E}{\partial \Theta}(\Theta_t)$$

- **Faça uma pequena mudança nos parâmetros na direção contrária ao gradiente**

$$\Theta_{t+1} = \Theta_t - \eta \nabla E(\Theta_t)$$

- η é chamado “taxa de aprendizagem”
- **Reavalie a função peso e aceite se for reduzido (caso contrário reduza a taxa de aprendizagem)**
- **Continue até não ser possível mais mudanças**

Computando a derivada

- **problema:**
 - Imagens são discretas
 - Parâmetros são contínuos
- **Dois métodos**
 - Numérico
 - Contínuos (eventualmente numérico também)
- **Definição abstrata de vetor de parâmetros:**

$$\Theta_{t+1} = (\theta_1 \theta_2 \dots \theta_k)^T$$

Derivadas numéricas

- **Forme cada derivada parcial tomando um pequeno passo em cada parâmetro, $i = 1, \dots, k$:**

$$\frac{\partial E}{\partial \theta_i} \approx \frac{E(\theta_1, \dots, \theta_i + \Delta \theta_i, \dots, \theta_k) - E(\theta_1, \dots, \theta_i, \dots, \theta_k)}{\Delta \theta_i}$$

- **A escolha do tamanho do passo pode ser difícil**
- **Requer $k+1$ avaliações da função para computar a derivada**
- **As vezes isto é tudo que se pode fazer!**

Computação contínua da derivada

- Aplique a regra da cadeia:

$$\frac{\partial E}{\partial \theta_i} = \sum_{p \in \Omega} -2 \underbrace{\left[I_f(p) - I_m(T(p; \Theta)) \right]}_{\Delta I(p)} \underbrace{\frac{\partial I_m}{\partial T}}_{\text{gradiente na imagem movimentada}} \underbrace{\frac{\partial T}{\partial \Theta}}_{\text{variação na transformação para variação nos parâmetros}}$$

erro corrente no pixel atual $\Delta I(p)$

gradiente na imagem movimentada

variação na transformação para variação nos parâmetros

Computando derivadas da imagem

- **Muitas maneiras.**

- A mais simples é diferenças de pixels

$$I_x \equiv \frac{\partial I}{\partial x} \approx \frac{I(x + \Delta x, y) - I(x, y)}{\Delta x}$$

$$I_y \equiv \frac{\partial I}{\partial y} \approx \frac{I(x, y + \Delta y) - I(x, y)}{\Delta y}$$

- Métodos mais sofisticados levam em conta ruídos da imagem
- **Computado a cada pixel**

Derivada da imagem em movimento

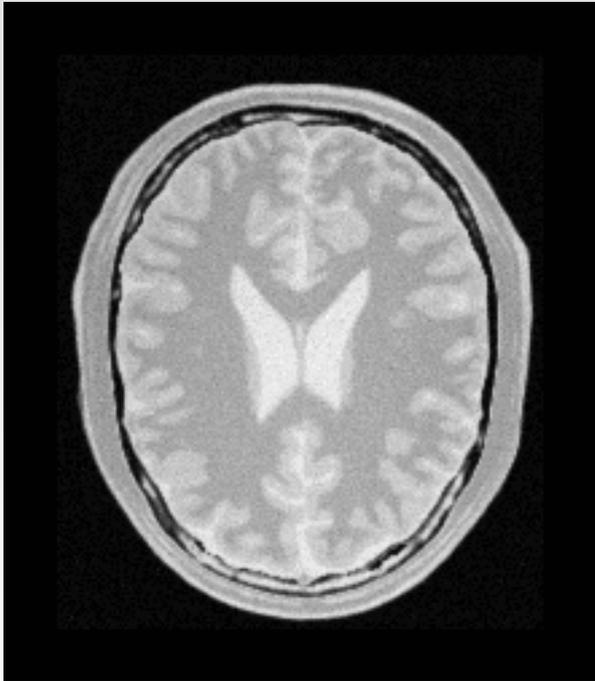
- **Equação**

$$\frac{\partial I_m}{\partial T}(p) = \begin{pmatrix} I_{mx}(T(p; \Theta)) & I_{my}(T(p; \Theta)) \end{pmatrix}$$

- **Em detalhes**

- Pre-compute derivadas na imagem movimentada I_m
- Durante minimização, mapeie os pixels de volta para o sistema de coordenadas da imagem movimentada e interpole

Exemplo de derivada da imagem



I_m



I_{mx}



I_{my}

- **Transformação de similaridade :**

$$T(p; \Theta) = \begin{pmatrix} ax - by + t_x \\ bx + ay + t_y \end{pmatrix}$$

- onde

$$\Theta = (a \quad b \quad t_x \quad t_y)^T \quad p = (x, y)^T$$

- **Então a derivada é a matriz 2x4 (Jacobian):**

$$\frac{\partial T}{\partial \Theta} = \begin{pmatrix} x & -y & 1 & 0 \\ y & x & 0 & 1 \end{pmatrix}$$

- **Para cada pixel na região de sobreposição:**
 - Calcule diferença de intensidade (escalar)
 - Multiplique pelo vetor gradiente 1×2 computado mapeando a localização do pixel de volta para a imagem movimentada
 - Multiplique pela Jacobiana 2×4 da transformação, avaliada no pixel
 - O resultado é o vetor gradiente 1×4 em cada pixel
- **Some cada componente do vetor sobre todos os pixels**

- **Inicialize a transformação**
- **Repita**
 - Compute gradiente
 - Dê um passo na direção do gradiente
 - Atualize a equação de mapeamento
 - Remapeie a imagem
- **Até convergência**

- Como é uma técnica de minimização, uma estimativa inicial é preciso,

$$\Theta_0$$

- Existem várias maneiras de gerar esta estimativa:

- Por ex., transformação identidade

$$a = 1, b = 0, tx = ty = 0$$

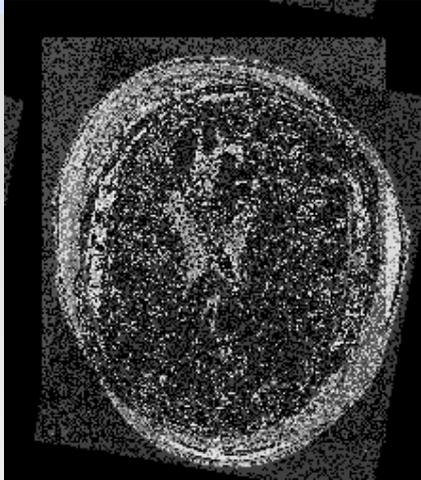
- Informação a priori
- Técnica diferente

- Gradiente descente acha somente um mínimo local da função peso

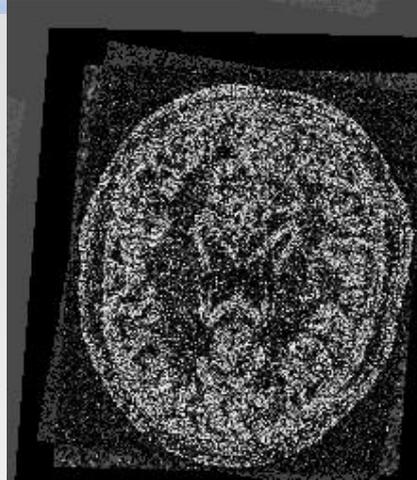
Convergência

- **Ideal é que o gradiente seja 0.**
- **Na pratica, o algoritmo é parado quando:**
 - Tamanho do passo se torna muito pequeno
 - A função peso se torna suficientemente pequena
 - Um número máximo de iterações é alcançado

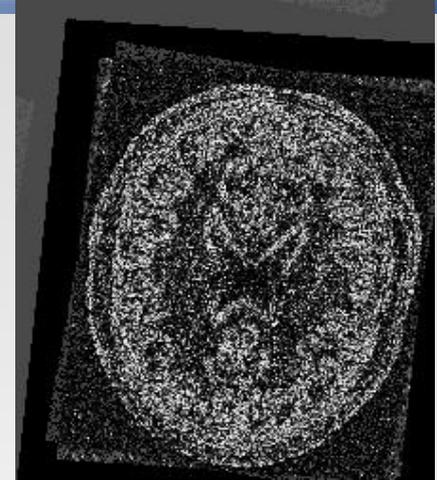
Exemplo



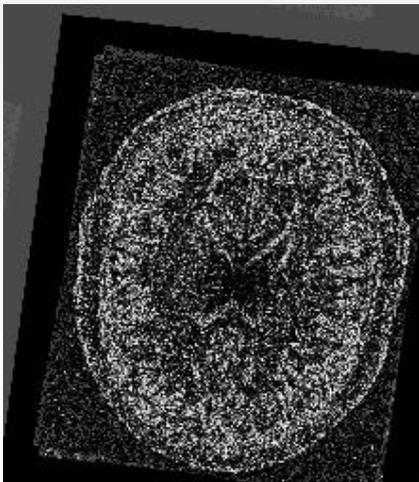
Erros iniciais



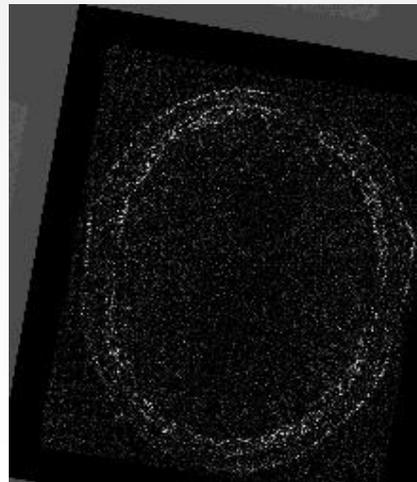
Iteração 100



Iteração 200



Iteração 300



Final: 498 iterações

- **Gradiente descendente é simples, mas possui limitações:**
 - Mínimo local
 - Convergência lenta (linear)