

Uso da análise de textura para a avaliação cerebral estrutural de jovens adultos sujeitos a um programa de treino de corrida de intensidade moderada

Palavras-Chave: Processamento de Imagens Digitais, Ressonância Magnética, Exercícios Cardiorrespiratórios

Autores(as):

Mateus Santos Bonadia - IFGW - UNICAMP

Rafael Vinícius da Silveira - IFGW - UNICAMP

Profa. Dra. Gabriela Castellano (orientadora), IFGW - UNICAMP

INTRODUÇÃO:

A análise de imagens consiste na extração de parâmetros descritores dos níveis de cinza e suas características. Em análise de textura, especificamente, utilizam-se parâmetros que correlacionam os níveis de cinza e suas respectivas distribuições e formatos. Neste projeto, utilizamos um tipo específico de parâmetros de textura, baseados na Matriz de Coocorrência de Níveis de Cinza (GLCM, do inglês *gray level co-occurrence matrix*), que tabela as quantidades de vezes em que dois voxels, em uma dada vizinhança, tiveram valores específicos de nível de cinza. A partir dela, parâmetros descritores foram calculados, cujos valores serão analisados. O cálculo desta matriz, assim como seus parâmetros, foi feito utilizando a linguagem MatLab. Enquanto a linguagem de programação Python foi utilizada para cálculo e manipulações estatísticas.

METODOLOGIA:

Uma imagem digital é lida pela unidade computacional como uma matriz $I_{a \times b}$ no caso de uma imagem bidimensional, ou $I_{a \times b \times c}$ no caso de imagens tridimensionais. Seus elementos $I_{a \times b}(i;j)$ e $I_{a \times b \times c}(i;j;k)$, denominados respectivamente pixel e voxel, definem a intensidade do nível de cinza naquela posição. Cada voxel (ou pixel) pode adquirir valores discretos de intensidade entre dois limites, o que é definido pelo tipo de imagem utilizado, sendo, geralmente, o maior valor referente ao pixel branco (aceso), e o menor, ao preto (apagado).

Já a textura de uma imagem pode ser interpretada como a estrutura em pequena escala percebida em uma imagem, com base no arranjo espacial de cores ou intensidades. Existem, na literatura, vários métodos para caracterizar a textura de uma imagem, neste projeto, utilizou-se a GLCM.

A GLCM M é uma matriz bidimensional de dimensões $N \times N$ em que cada elemento $M(l,c) = n$ denota a quantidade n de vezes em que um voxel de valor $A(i_1, j_1, k_1) = l$ e outro voxel de valor $A(i_2, j_2, k_2) = c$ foram

encontrados a uma certa distância d pré-determinada, a um ângulo θ definido. A Figura 1 mostra um exemplo de uma imagem e a GLCM desta imagem para uma distância $d = 1$ e $\theta = 0$.




Figura 1 Imagem de entrada (a), sua representação matricial (b) e a matriz de coocorrência para $d = 1$ e $\theta = 0$ (c). Note que, por exemplo, o valor $M(1,2) = 2$ em (c) denota que houve, em (b), um total de 2 vezes em que, a uma distância $d = 1$ e um ângulo $\theta = 0$, a partir de um pixel com valor $M(i,j) = 1$ houve outro pixel $M(i, j+1) = 2$ (marcações vermelhas em (b)). Imagem extraída de [5]

Dado que cérebro não possui sentido preferencial de textura, uma melhor abordagem foi realizar o cálculo da matriz de coocorrência para variados d e de forma isotrópica (isto é, para todos os ângulos possíveis). Tratando-se de imagens, cujo domínio é discreto, usou-se uma vizinhança de raio d sendo uma casca cúbica de voxels centrados no voxel central. O valor d foi variado de 1 a 3, gerando 3 GLCMs distintas.

Para cada GLCM, foram calculados parâmetros para análise:

- Uniformidade
- Contraste
- Homogeneidade
- Entropia
- Correlação
- Entropia da Soma
- Entropia da Diferença

Dos parâmetros calculados, focou-se na Correlação, que é dada de forma seguinte:

Dada a probabilidade de co-ocorrência de dois níveis de cinza definida como:

$$P(i, j) = \frac{M(i, j)}{\sum_{i=1}^N \sum_{j=1}^N M(i, j)} \quad (1)$$

Calcula-se:

Médias

$$\mu_x = \sum_{i=1}^N i \sum_{j=1}^N P(i, j) \quad \mu_y = \sum_{j=1}^N j \sum_{i=1}^N P(i, j) \quad (2)$$

Desvios Padrão e Variância

$$\begin{aligned}\sigma_x^2 &= \sum_{i=1}^N \sum_{j=1}^N P(i, j)(i - \mu_x)^2 & \sigma_y^2 &= \sum_{j=1}^N \sum_{i=1}^N P(i, j)(j - \mu_y)^2 \\ \text{Var}x &= \sigma_x^2 & \text{Var}y &= \sigma_y^2\end{aligned}\quad (3)$$

Correlação

$$\text{Corr} = \sum_{i=1}^N \sum_{j=1}^N \frac{(i - \mu_x)(j - \mu_y)P(i, j)}{\sigma_x \sigma_y} \quad (4)$$

Mede o quanto cada par de voxels é esperado

Foi necessário também segmentar regiões específicas do encéfalo (utilizando máscaras) para melhores resultados. Isso foi feito com o software SPM12 (*Statistical Parametric Mapping*), um software de uso livre para processar imagens de ressonância magnética, juntamente com o plugin AAL (*Anatomic Automatic Labeling*) para a utilização das segmentações (máscara) embutidas.

A máscara presente no AAL é uma imagem anatômica do cérebro cujo valor de cada voxel é um número N associado à região anatômica de número N a que corresponde este voxel, tabelada na própria documentação do AAL.

Baseado tanto em estudos relatando aperfeiçoamento de memórias de idosos e crianças [3], quanto em pesquisas que mostram mudança hipocampal em cérebro de pequenos mamíferos [4], ambas situações em que indivíduos foram submetidos a treinos aeróbicos, pretende-se dar enfoque no hipocampo e ao córtex frontal (áreas responsáveis pela memória).

Além disso, o Globo Pálido, a Gânglia Basal e o Cerebelo, regiões associadas à coordenação motora propriamente dita, também serão estudadas.

Para cada momento do conjunto de participantes (antes e depois) foi gerado uma tabela com os valores de textura.

Por meio do Python, calculou-se o teste t de Student entre estes momentos para os mesmos valores de distância d e região cerebral N .

O teste t de Student é um teste estatístico para mensurar a probabilidade de correlação entre duas distribuições de um dado específico. Ele resulta em um valor t correspondente à variação entre as médias das distribuições, e um valor p , que representa a probabilidade de que as duas distribuições sejam diferentes por acaso. Neste projeto, o limiar de significância utilizado foi de 5%.

O cálculo é feito da seguinte forma:

Desvio Padrão

$$s = \sqrt{\frac{\sum_{i=1}^{22} W_i - \mu}{21}} \quad (5)$$

(Em que W_i é o valor do parâmetro W do sujeito i e μ é a média do parâmetro W).

Valor t

$$t = \frac{(\mu_2 - \mu_1)}{s} \sqrt{22} \quad (6)$$

(Em que μ_2 é a média do parâmetro W após o treinamento de corrida, enquanto μ_1 é no momento anterior).

Graus de Liberdade

$$df = 2n - 2 = 42 \quad (7)$$

(Quando o número de participantes antes (n_1) e após (n_2) o acesso é igual.)

Valores p

$$p = 2P(T > |t|) \quad (8)$$

Os valores da distribuição cumulativa P são tabelados para os graus de liberdade encontrados e podem ser consultados.

Como diversas ROIs com 3 distâncias diferentes foram utilizadas, é possível que apareça algum p significativo devido à grande quantidade de testes feitos. Portanto, os p significantes deverão permanecer significantes após a multiplicação pelo fator m , em que m é quantidade de testes estatísticos realizados:

$$m = 16 (ROIs) \cdot 3 (distancias) = 48$$

Esta multiplicação é uma correção por múltiplas comparações, conhecida como correção de Bonferroni.

RESULTADOS E DISCUSSÃO:

De todos os parâmetros e regiões (total de 220) somente permaneceram significativas após a correção o globo pálido e o hipocampo para as 3 distâncias.

Por meio dos boxplots é possível ver que a correlação foi significativamente diferente entre antes e após o treinamento de corrida nas regiões do globo pálido esquerdo e direito e hipocampo esquerdo.

No entanto, nenhum outro parâmetro para qualquer outra região apresentou significância após a correção de Bonferroni para o teste t de Student.

Todos os valores de correlação correspondentes tiveram um aumento após o treinamento de corrida. A alteração no parâmetro de correlação nas




Figura 2 Boxplots dos valores da correlação antes e depois para todas as regiões com distâncias 1, 2 e 3. A significância somente nos índices 41, 79 e 80 (correspondentes ao Hipocampo esquerdo e Globo Pálido Esquerdo e Direito respectivamente)

regiões citadas indica que houve uma mudança na textura dessas regiões. Por outro lado, espera-se que a textura reflita o tecido subjacente e, portanto, estes resultados indicam uma possível alteração estrutural nessas regiões.

Contudo, a correspondência entre textura e anatomia para correlação não é clara, principalmente devido ao fato de que não houve mudanças significativas em parâmetros como entropia (que indicaria variação no ruído) nem no contraste e homogeneidade (que denotariam variação na condensação da textura). Portanto, a análise ainda está sendo feita.

CONCLUSÕES:

As imagens digitais geradas por ressonância magnética podem fornecer informações importantes a respeito da estrutura de um tecido e órgão. Por meio da análise de textura, estamos estudando as características do encéfalo de homens jovens sujeitos a um programa de treino de corrida de intensidade moderada antes e após o programa.

Esta análise de textura tem como base o uso de diversos parâmetros associados às matrizes de coocorrência, que estão sendo calculadas em MatLab, com o auxílio de ferramentas de manipulação de imagem (SPM12) e parcelamento anatômico (AAL).

Encontramos diferenças significantes no parâmetro de textura correlação entre as instâncias (antes e depois do treinamento), para as regiões córtex frontal inferior direito, hipocampo e globo pálido, mas ainda é necessário pesquisar o papel destas regiões cerebrais neste contexto para poder interpretar esses resultados.

BIBLIOGRAFIA

- [1] R. Pérez de Alejo *et al.*, "Computer-assisted enhanced volumetric segmentation magnetic resonance imaging data using a mixture of artificial neural networks.," *Magn. Reson. Imaging*, vol. 21, no. 8, pp. 901–12, Oct. 2003.
- [2] P. Klepits *et al.*, "Effects of a seven-week running intervention with moderate intensity on the volume of the hippocampus and depressive symptoms in young men from the general population". Doi:10.18112/openneuro.ds004937.v1.0.1, Feb. 2024.
- [3] C. Vorkpic-Ferreira, "Born to run: the importance of exercise for brain health" *Rev Bras Med Esporte* 2017; v.23, no.6.. Doi: <https://doi.org/10.1590/1517-869220172306175209>
- [4] C. Zhao *et al.*, "Distinct Morphological Stages of Dentate Granule Neuron Maturation in the Adult Mouse Hippocampus" *J. Neurosci* 2006; v.26(1) : 3-11. Doi: 10.1523/JNEUROSCI.3648-05.2006
- [5] A. F. Nascimento *et al.*, "*Uso da matriz de coocorrência para diferenciação longitudinal de imagens de ressonância magnética de pacientes de Alzheimer, pacientes de comprometimento cognitivo leve e saudáveis*", 2021, Disponível: <https://proceedings.science/unicamp-pibic/pibic-2021/trabalhos/uso-da-matriz-de-coocorrencia-para-a-diferenciacao-longitudinal-de-imagens-de-re?lang=pt-br> ; Acesso: 7 de outubro de 2024