A CORRELAÇÃO ENTRE AS MEDIDAS DO COEFICIENTE DE ATENUAÇÃO HEPÁTICA OBTIDAS POR ALGORITMOS DE SEGMENTAÇÃO SEMI-AUTOMÁTICA E CARACTERÍSTICAS RADIÔMICAS APLICADAS EM EXAMES DE TOMOGRAFIA COMPUTADORIZADA NO DIAGNÓSTICO DA DOENÇA HEPÁTICA GORDUROSA NÃO ALCOÓLICA

Luis Miguel Leuch (PROVIC), Arthur Garani Narciso, Renan Maeda de Souza, Marcelo de Oliveira Dreweck(Orientador), e-mail: modreweck@uepg.br

Universidade Estadual de Ponta Grossa / Departamento de Medicina.

Ciências da saúde, Medicina, Radiologia, Diagnóstico por imagem

Palavras-Chave: *fígado gorduroso, tomografia computadorizada, radiômica, segmentação de imagem, quantificação de gordura.*

Resumo

Este estudo avaliou a eficácia da radiômica processadas por algoritmos de aprendizado de máquina para a quantificação da esteatose hepática em tomografias computadorizadas (TC), comparando-a com métodos manuais tradicionais. A análise incluiu 450 pacientes, cujas imagens foram processadas por algoritmos de "machine learning" (ML). As características radiômicas apresentaram boa correlação com as medições manuais (R^2 = 0,733) o que abre a possibilidade da incorporação do seu uso como forma de melhorar a precisão diagnóstica no diagnóstico da esteatose.

Introdução

A Doença Hepática Gordurosa Não Alcoólica (DHGNA) afeta cerca de 25% da população sendo a principal doença hepática crônica da atualidade (YOUNOSSI *et al.*, 2016). O diagnóstico da DHGNA pela TC é feito pelas medidas da densidade hepática e apresenta limitações especialmente nos casos leves. A radiômica surge como uma alternativa promissora ao extrair características quantitativas das imagens possibilitando diagnósticos mais precisos (AERTS *et al.*, 2014; HOMAYOUNIEH *et al.*, 2020). O objetivo foi avaliar a correlação entre um algoritmo preditivo da fração de gordura hepática determinada por um modelo baseado na radiômica e a densidade hepática determinada pela TC.

Materiais e Métodos

Estudo retrospectivo, sendo analisadas 450 TCs de abdome realizadas entre janeiro e junho de 2022. As imagens foram segmentadas de forma semi-automática para extração de características radiômicas de primeira, segunda e terceira ordem. Para a análise preditiva, as variáveis não correlacionadas mais relevantes foram selecionadas via regressão LASSO, resultando em um modelo de regressão linear multivariada processadas por ML. O desempenho do modelo foi avaliado utilizando R^2, MSE e MAE.

Resultados e Discussão

O modelo apresentou R^2 de 0,73 (IC95%: 0,62 – 0,85), MSE de 47,86 (IC95%: 23,86 – 79,74) e MAE de 4,14 (IC95%: 3,29 – 5,13). As variáveis incluídas no modelo de predição e seus coeficientes são demonstrados na figura 1 a seguir.

	coef	std err	t	P>|t|	[0.025	0.975]
const	30.3741	4.063	7.475	0.000	22.376	38.372
glszmSmallAreaEmphasis	-3.9550	2.503	-1.580	0.115	-8.882	0.972
glrlmLongRunLowGrayLevelEmphasis	-14.1980	6.646	-2.136	0.034	-27.280	-1.116
ngtdmBusyness	-5.5356	3.435	-1.612	0.108	-12.297	1.226
gldmSmallDependenceLowGrayLevelEmphasis	14.7230	8.009	1.653	0.100	-2.812	32.258
ngtdmComplexity	2.6966	5.629	0.479	0.632	-8.383	13.777
shape_Elongation	-0.3289	2.058	-0.160	0.873	-4.380	3.722
glrlmRunVariance	4.9981	4.116	1.214	0.226	-3.103	13.099
glszmGrayLevelNonUniformityNormalized	-6.3597	2.990	-2.127	0.034	-12.246	-0.474
gldmDependenceNonUniformityNormalized	-8.0454	3.160	-2.546	0.011	-14.265	-1.826
glszmLargeAreaHighGrayLevelEmphasis	-14.8682	3.960	-3.754	0.000	-22.663	-7.073
glszmGrayLevelVariance	7.9647	3.865	2.061	0.040	0.357	15.573
firstorderKurtosis	4.3099	4.671	0.923	0.357	-4.884	13.504
shapeSurfaceVolumeRatio	53.5987	3.592	14.923	0.000	46.529	60.668
firstorderTotalEnergy	224.7163	7.908	28.417	0.000	209.151	240.281
glcmSumSquares	-326.0241	11.303	-28.844	0.000	-348.272	-303.776

Estatísticas do modelo de regressão:

OLS Regression Results

Dep. Variable:	Dmedia_ponderada	R-squared:	0.834
Model:	OLS	Adj. R-squared:	0.826
Method:	Least Squares	F-statistic:	95.77
Date:	Sun, 22 Sep 2024	Prob (F-statistic):	9.82e-102
Time:	12:59:28	Log-Likelihood:	-936.34
No. Observations:	301	AIC:	1905.
Df Residuals:	285	BIC:	1964.
Df Model:	15		
Covariance Type:	nonrobust		

Figura 1. Modelo de regressão linear multivariada na determinação da densidade tomográfica do fígado a partir das características radiômicas.

Conclusões

O estudo demonstrou boa correlação entre o modelo preditivo baseado nas características radiômicas e a densidade hepática abrindo a possibilidade do seu uso como método não invasivo de diagnóstico e quantificação da esteatose pela TC.

Agradecimentos

Agradeço à PROPESP/UEPG pela possibilidade de desenvolver esse trabalho dentro do programa PROVIC desta instituição. Agradeço também o professor Marcelo de Oliveira Dreweck.

AERTS, H. J. W. L. *et al.* Decoding tumour phenotype by noninvasive imaging using a quantitative radiomics approach. *Nature Communications*, v. 5, 2014.

HOMAYOUNIEH, F. *et al.* Accuracy of radiomics for differentiating diffuse liver diseases on non-contrast CT. *International Journal of Computer Assisted Radiology and Surgery*, v. 15, n. 10, p. 1727–1736, 1 out. 2020.

YOUNOSSI, Z. M. *et al.* Global epidemiology of nonalcoholic fatty liver disease—Meta-analytic assessment of prevalence, incidence, and outcomes. *Hepatology*, v. 64, n. 1, p. 73–84, 2016.