

UNIVERSIDADE ABERTA



UNIVERSIDADE
AbERTA
www.uab.pt

Estado de Hidratação e Compressibilidade das Pregas Cutâneas

Gilberto Alves Neves

Mestrado em Estatística, Matemática e Computação, na área de especialização em
Estatística Computacional

Setembro de 2017

UNIVERSIDADE ABERTA



UNIVERSIDADE
AbERTA
www.uab.pt

Estado de hidratação e compressibilidade das pregas cutâneas

Gilberto Alves Neves

Mestrado em Estatística, Matemática e Computação, na área de especialização de
Estatística Computacional

Orientadora: Catarina Sofia da Costa Nunes Duarte (Catarina S. Nunes) – Professora
Auxiliar, Departamento de Ciências e Tecnologia, Universidade Aberta.

Setembro de 2017

Resumo

Para estudar a relação entre a saúde e o estado nutricional de um indivíduo, é essencial ter informações sobre a composição corporal. Essa informação é obtida estimando a gordura corporal por meio da compressibilidade das pregas cutâneas. Para coletar essa informação foi aplicado um método antropométrico por ser não invasivo e mais aplicado na avaliação do estado nutricional de amostras clínicas e não-clínicas. No presente estudo foi analisado, com o uso do SPSS Statistics, dados referentes a 66 indivíduos, com idade entre os 18 e 83 anos, sendo 74.2% mulheres e 25.8% homens, que se dignaram a responder a um questionário e a submeter a medições antropométricas para efeito de investigação sobre a relação do estado de hidratação e a compressibilidade das pregas cutâneas e esta com as características sócio-demográficas. Os dados da compressibilidade das pregas foram recolhidos com uso do LipoTool, um sistema novo baseado num lipocalibrador, o Adipsmeter (estrutura mecânica, instrumentação eletrónica, capacidade de registo da evolução temporal da compressibilidade das pregas, comunicação sem fio) e numa aplicação de software integrando uma base de dados, LipoSoft. Com este trabalho, e através da aplicação da regressão linear múltipla, concluiu-se: (1) que as pregas cutâneas possuem, em termos de estimativa pontual, uma alta fiabilidade entre as várias medições, entre os vários locais, apresentando um Alpha de Cronbach acima dos 0.90, mas passa de uma fiabilidade moderada a alta quando aplicado uma estimativa intervalar, [0.893; 0.937]; (2) que a percentagem da variabilidade total do estado de hidratação explicada pela compressibilidade das pregas cutâneas é muito baixa, não alcançando o esperado que seria um valor acima de 0.90 em caso das ciências exatas e acima de 0.50 em caso das ciências sociais, ou seja, a medição das pregas (método fácil e não invasivo) pode, ainda, não ser vista como um estimador ou preditor do estado de hidratação de um indivíduo; (3) que, com relação à média de todos os pontos, a média dos últimos 3 pontos e outras medidas utilizadas, a média dos últimos 10 pontos (ponto 170 a 180) mostrou-se ser a medida que mais qualidade trouxe aos modelos de regressão construídos, pois apresentou-se com maior coeficiente de determinação ajustado e menor erro-padrão; (4) que a compressibilidade das pregas é caracterizada pelas variáveis Sexo, Índice de massa corporal, Massa gorda (%), Atividade física, Estado de saúde, Idade, Ocupação e Escolaridade; (5) que a presença de *outliers* multivariados bem como pontos influentes, se mostraram ter uma grande influência sobre a qualidade do modelo de regressão.

Palavras chave: Pregas Cutâneas, Hidratação, Fiabilidade, Regressão, Correlação.

Summary

To study the relationship between health and an individual's nutritional status, information on body composition is essential. This information is obtained by estimating body fat through the compressibility of the skin folds. To collect this information, anthropometric methods were applied, since they are noninvasive and more applied in assessing the nutritional status of clinical and nonclinical samples. In the present study, data of 66 individuals were analysed using SPSS Statistics, aged between 18 and 83 years old, 74.2% female and 25.8% male, who deigned to respond to a questionnaire and submit to anthropometric measurements for Research purposes, with the aim of studying the relationship between the hydration state and the compressibility of the skin folds and the relationship with the socio-demographic characteristics. With this work, and through the application of multiple linear regression, it was concluded: (1) that the skinfolds have, in terms of point estimate, a high reliability, presenting a Cronbach Alpha above 0.90, but presents a moderate to high reliability when applied an interval estimate, [0.893; 0.937]; (2) that the percentage of the total variability of the hydration state explained by the skin folds is very low, not reaching what was expected to be above 0.90 in the case of the exact sciences and above 0.50 in the case of the social sciences, that is, the measurement of the folds (easy and non-invasive method) may still not be seen as an estimator or predictor of the hydration state of an individual; (3) that, with respect to the average of all points, the average of the last 3 points and other measures used, the average of the last 10 points (point 170 to 180) proved to be the measure that brought more quality to the regression models, since it presented a higher coefficient of adjusted determination and smaller standard error; (4) that the compressibility of the folds is characterized by the variables Gender, Body Mass Index, Fat Mass (%), Physical Activity, Health Status, Age, Occupation and Schooling; (5) that the presence of multivariate *outliers* as well as influential points, were shown to have a great influence on the quality of the regression model.

Key words: Skinfolds, Hydration, Reliability, Regression, Correlation.

Dedicatória

Dedico este trabalho a todos os seres criados por Deus que falam a língua portuguesa quer estejam ou sejam de Portugal Continental, dos Açores, da Madeira, na diáspora, em Cabo Verde ou nos PALOP, que sonharam um sonho possível e optaram por ingressar nesta maratona que foi o mestrado, sacrificando horas de sono e dias de convívio com a família e amigos para que a corrida fosse chegada ao fim.

Agradecimento

Em primeiro lugar ao meu Deus e ao nosso Deus por tudo.

A todos os docentes do programa de Mestrado em Estatística, Matemática e Computação, pelos conhecimentos compartilhados, com profissionalismo e paciência.

Aos professores que me orientaram e ajudaram neste trabalho, a Professora Doutora Catarina S. Nunes, a Professora Doutora Maria Teresa Restivo (Faculdade de Engenharia da Universidade do Porto), Professora Doutora Teresa Amaral (Faculdade de Ciências da Nutrição da Universidade do Porto) e a Doutora Rita Guerra.

A Professora Doutora Catarina S. Nunes que me propôs o tema para a dissertação quando viu o meu interesse pelas análises relacionadas com temas envolvendo a saúde e também pelas palavras de motivação durante os exercícios na cadeira de Análise multivariada.

Ao departamento de informática da UAB pela gentileza na partilha do SPSS Statistics.

A secretária deste curso, a Doutora Teresa Ramos, pela forma gentilícia em facultar as informações a tempo e precisas.

A toda a comunidade UAB, em especial a Associação dos estudantes.

Aos meus colegas de curso que virtualmente muito me ajudaram com bibliografias e partilha de conhecimento, por meio das discussões na execução dos trabalhos de grupos, em especial a Claudia, Jailson e José.

Ao meu antigo colega do ensino básico e companheiro deste curso de mestrado que me informou da abertura das inscrições para este curso e me ajudou com a documentação – Fidel.

A todos que direta ou indiretamente me proporcionou tempo, paciência, motivação e conhecimento para cumprir esta tarefa.

E por último ao meu Deus e ao nosso Deus por tudo.

Índice

Resumo.....	i
Dedicatória.....	iii
Agradecimento.....	iv
Lista de abreviaturas.....	vii
Índice de figuras.....	viii
Índice de tabelas.....	x
1. Introdução.....	1
1.1. Fundamentação e objetivos.....	2
1.2. Objetivos da dissertação.....	6
Capítulo 1: Enquadramento teórico.....	8
1.1. Valores ausentes.....	9
1.2. Definição de valores ausentes.....	9
1.2.1. Mecanismos associados aos valores ausentes.....	10
1.2.2. Padrão dos valores ausentes.....	11
1.2.3. Quantidade dos valores ausentes.....	13
1.2.4. Prevenção dos valores ausentes.....	14
1.2.5. Seleção do método apropriado.....	14
1.2.5.1. Método de imputação única pela média.....	15
1.3. Correlação.....	16
1.3.1. Diagrama de dispersão.....	17
1.3.2. Coeficiente de correlação.....	18
1.3.3. Coeficiente de correlação linear R de <i>Pearson</i>	18
1.3.3.1. Interpretação e significância do valor do R de <i>Pearson</i>	19
1.3.3.1.1. Interpretação do valor do R de <i>Pearson</i>	17
1.4. Distribuição Normal.....	20
1.4.1. Distribuição Normal Univariada.....	21
1.4.2. Distribuição Normal Multivariada.....	22
1.5. Fiabilidade.....	23
1.5.1. Fiabilidade de uma medida.....	23
1.5.2. Índice Alpha de Cronbach (α)	26
1.5.2.1. Interpretação das do índice de Cronbach.....	27
1.5.2.2. Critérios de fiabilidade estimado pelo Alpha de Cronbach.....	27
1.5.2.3. Estimativa do Alpha de Cronbach.....	28
1.5.2.4. Fatores que afetam a magnitude do índice da fiabilidade.....	29
1.6. Regressão	30
1.6.1. Regressão Linear.....	30
1.6.2. Modelo de Regressão Linear Múltipla (Univariado).....	31
1.6.2.1. Pressupostos para a aplicação do modelo de Regressão Linear Multivariado (MRLM).....	33
1.7. Inferência e escolha do modelo.....	51

1.7.1. Inferência sobre o modelo de regressão.....	51
1.7.2. Análise de variância.....	51
1.7.3. Testes aos coeficientes do modelo de regressão.....	53
1.7.4. Coeficiente de determinação.....	54
1.7.5. Métodos de seleção de preditores.....	56
Capítulo 2: Opções Metodológicas.....	59
2.1. Metodologia.....	60
2.2. Recolha de dados.....	60
2.3. A base de dados.....	61
2.4. Limpeza da base de dados.....	63
2.5. Análise dos dados.....	64
Capítulo 3: Apresentação dos Resultados.....	66
3.1. Explorando e adequando a base de dados.....	67
3.1.1. Observação de dados ruidosos.....	67
3.1.2. Observação e tratamento dos valores ausentes.....	67
3.2. Análise de Fiabilidade e inferência estatística sobre os dados de compressibilidade das pregas cutâneas.....	71
3.2.1. Análise das oito pregas (com a média de todos os pontos).....	71
3.2.2. Análise das oito pregas (com a média dos últimos 10 pontos).....	77
3.2.3. Análise das oito pregas (com a mediana de todos os pontos).....	78
3.2.4. Análise das oito pregas (com a mediana dos últimos 10 pontos)....	79
3.3. Análise de associação e regressão.....	81
3.3.1. Média de todos os pontos da prega Tricipital.....	81
3.3.1.1. Aplicação do método <i>Stepwise</i>	91
3.3.1.2. Aplicação do método <i>Backward</i>	93
3.3.1.3. Modelo final da prega Tricipital.....	94
3.3.1.4. Característica do <i>Outlier</i> (observação nº44).....	99
3.3.1.5. Característica dos pontos influentes.....	100
3.4. Relação das pregas com o estado de hidratação.....	103
Conclusão.....	107
Bibliografia.....	111
Anexos.....	118
Anexo I a VIII: Resumo da pregas cutâneas com e sem a presença do <i>outlier</i>	119
Anexo IX: Disposição inicial da medição dos pontos em cada prega cutânea.....	128
Anexo X: Resumo dos valores dos pontos de cada prega.....	129
Anexo XI: Identificação de pontos influentes nos modelos de cada prega.....	130

Lista de abreviaturas

AICR (American Institute for Cancer Research)

ANOVA (Analysis of Variance)

BIA (Impedância bioelétrica)

FCT (Fundação para a Ciência e Tecnologia)

HWO (World Health Organization)

K-S (Kolmogorov-Smirnov)

LAETA (Laboratório Associado de Energia, Transportes e Aeronáutica)

MCAR (Missing Completely at Random)

MAR (Missing at Random)

MNAR (Missing Not at Random)

MRLM (Modelo de Regressão Linear Multivariado)

OMS (Organização Mundial da Saúde)

OUP (Oxford University Press)

S-W (Shapiro-Wilk)

SPSS (Statistics Package for the Social Sciences)

UAB (Universidade Aberta)

UISPA (System and Process, Automation Unit)

VIF (Variance Inflation Factor)

Índice de figuras

Figura 1.1: Padrões de não respostas.....	13
Figura 1.2: Tipo de relação entre variáveis.....	17
Figura 1.3: Análise da normalidade com o histograma e o Normal probability plot.....	22
Figura 1.4: Gráfico Normal Q-Q Plot.....	35
Figura 1.5: Gráfico Detrended Normal Q-Q plot.....	36
Figura 1.6: Histogramas dos resíduos estandardizados.....	37
Figura 1.7: Colocação dos resíduos ZPRED e ZRESID.....	38
Figura 1.8: Variação dos resíduos.....	38
Figura 1.9: Correlação, outliers e pontos influentes.....	40
Figura 1.10: Boxplot para três variáveis simuladas.....	41
Figura 3.11 – Histograma da variável “N_Medico_3m”	68
Figura 3.12 – Histograma da variável “Ing_Qtas_h”	68
Figura 3.13 – Histograma da variável “Café_Alcool_Qtas_h”	68
Figura 3.14: Análise da normalidade dos resíduos na prega tricipital para a média de todos os pontos.....	85
Figura 3.15: Distribuição dos resíduos em torno do zero da prega Tricipital para a média de todos os pontos.....	86
Figura 3.16: Distribuição dos resíduos em torno do zero com press na prega Tricipital para a média de todos os pontos.....	86
Figura 3.17: Análise de outliers pelos valores de Leverage na prega Tricipital para a média de todos os pontos.....	87
Figura 3.18: Análise de pontos influentes com DFFIT na prega Tricipital para a média de todos os pontos.....	87

Figura 3.19: Análise de normalidade e dispersão dos dados da prega Tricipital com o método Stepwise.....	93
--	----

Índice de tabelas

Tabela 1.1: Valores de R e sua interpretação.....	19
Tabela 1.2: critérios de recomendação de fiabilidade estimada pelo α de Cronbach.....	28
Tabela 1.3: Testes de Normalidade K-S e S-W.....	34
Tabela 1.4: Condições para identificar outliers segundo o nível de significância.....	42
Tabela 1.5: Tabela de Durbin-Watson.....	46
Tabela 1.6: Anova de regressão.....	53
Tabela 2.7: Descrição das variáveis da base de dados.....	61
Tabela 3.8: Estatísticas da variável “N_Medico_3m”.....	68
Tabela 3.9: Estatísticas da variável “Ing_Qtas_h”.....	68
Tabela 3.10: Estatísticas da variável “Café_Alcool_Qtas_h”.....	68
Tabela 3.11: Testes de Normalidade para as variáveis “N_Medico_3m”, “Ing_Qtas_h” e “Café_Alcool_Qtas_h”.....	69
Tabela 3.12: Matriz de Correlação entre as pregas cutâneas com a média de todos os pontos.....	72
Tabela 3.13: Estatísticas de item-total entre as pregas cutâneas com a média de todos os pontos.....	73
Tabela 3.14: Estatística de escala Tabela 3.13: Estatísticas de item-total entre as pregas cutâneas com a média de todos os pontos.....	74
Tabela 3.15: Estatísticas de confiabilidade entre as pregas cutâneas com a média de todos os pontos.....	74
Tabela 3.16: Resumo da fiabilidade e correlações em cada medida-resumo.....	76
Tabela 3.17: Estatísticas de confiabilidade entre as pregas cutâneas com a média dos últimos 10 pontos.....	78

Tabela 3.18: Estatísticas de confiabilidade entre as pregas cutâneas com a mediana de todos os pontos.....	79
Tabela 3.19: Estatísticas de confiabilidade entre as pregas cutâneas com a mediana dos últimos 10 pontos.....	81
Tabela 3.20: Testes de Normalidade da prega Tricipital para a média de todos os pontos.....	82
Tabela 3.21: Sumarização do modelo da prega Tricipital para a média de todos os pontos.....	82
Tabela 3.22: ANOVA na prega Tricipital para a média de todos os pontos.....	82
Tabela 3.23: Coeficientes da prega Tricipital para a média de todos os pontos.....	83
Tabela 3.24: Sumarização do modelo da prega Tricipital para a média de todos os pontos.....	84
Tabela 3.25: Estatísticas de resíduos da prega Tricipital para a média de todos os pontos.....	84
Tabela 3.26: Testes de Normalidade dos resíduos standardizados na prega Tricipital para a média de todos os pontos.....	85
Tabela 3.27: Teste de Kolmogorov-Smirnov de uma amostra na prega Tricipital para a média de todos os pontos.....	88
Tabela 3.28: Testes de Normalidade para as variáveis Massa gorda (kg e %).....	89
Tabela 3.29: Efeito da variável “Peso” na qualidade do modelo na presença da variável “Massa Gorda”	91
Tabela 3.30: Variáveis inseridas/removidas do modelo na prega Tricipital para a média de todos os pontos.....	91
Tabela 3.31: Sumarização do modelo na prega Tricipital para a média de todos os pontos.....	91

Tabela 3.32: Coeficientes do modelo da prega tricipital para a média de todos os pontos com o método stepwise.....	92
Tabela 3.33: Variáveis excluídas do modelo Tricipital para a média de todos os pontos com o método Stepwise.....	92
Tabela 3.34: Sumarização do modelo da prega Tricipital com o método Backward para a média de todos os pontos.....	94
Tabela 3.35: Coeficientes do modelo da prega Tricipital com o método Backward para a média de todos os pontos.....	94
Tabela 3.36: Variáveis inseridas/removidas do modelo final da prega Tricipital para a média de todos os pontos.....	95
Tabela 3.37: Sumarização do modelo final do modelo final da prega Tricipital para a média de todos os pontos.....	95
Tabela 3.38: ANOVA no modelo final do modelo final da prega Tricipital para a média de todos os pontos.....	95
Tabela 3.39: Coeficientes do modelo final do modelo final da prega Tricipital para a média de todos os pontos.....	95
Tabela 3.40: Variáveis inseridas/removidas do novo modelo final da prega Tricipital para a média de todos os pontos.....	96
Tabela 3.41: Sumarização do novo modelo final da prega Tricipital para a média de todos os pontos.....	96
Tabela 3.42: ANOVA para o novo modelo final da prega Tricipital para a média de todos os pontos.....	96
Tabela 3.43: Coeficientes do novo modelo final da prega Tricipital para a média de todos os pontos.....	96
Tabela 3.44: Estatísticas de amostras emparelhadas para a prega Crural.....	98
Tabela 3.45: Correlações de amostras emparelhadas para a prega Crural.....	98

Tabela 3.46: Teste de amostras emparelhadas para a prega Crural.....	98
Tabela 3.47: Testes de Normalidade para os estados de hidratação.....	104
Tabela 3.48: Relação das pregas com o estado de hidratação.....	106

1. Introdução

O excesso de peso e a obesidade são atualmente duas das principais causas de mortalidade a nível mundial, e podem levar ao desenvolvimento de doenças coronárias, de hipertensão, de diabetes tipo 2, de doença pulmonar obstrutiva crónica, de artrose e de alguns tipos de cancro (National Institutes of Health, 2000; American Institute for Cancer Research, 2009; World Health Organization, 2014). A antropometria é a técnica não invasiva mais aplicada na avaliação do estado nutricional e possibilita o conhecimento da composição corporal (Frisancho, 2008). Recorrendo a equações de regressão, a espessura das pregas cutâneas permite estimar a gordura corporal (Siri, 1961; Brozek *et al.*, 1963; Durnin & Womersley, 1974; Jackson & Pollock, 1978; Jackson, Pollock & Ward, 1980; Slaughter *et al.*, 1988; Visser, Van den Heuvel & Deurenberg, 1994; Peterson, Czerwinski & Siervogrl, 2003). A variabilidade na compressibilidade das pregas poderá ser característica de cada indivíduo, mas esta não foi ainda caracterizada. O avanço do conhecimento nesta área poderá contribuir para a otimização do processo de medição da gordura subcutânea e da estimativa da composição corporal. A medição consecutiva de uma mesma prega pode levar a medições consecutivamente menores devido a diminuição no conteúdo hídrico, sendo este fenómeno mais comum em indivíduos obesos. Contudo, os estudos efetuados sobre a relação entre estado de hidratação e compressibilidade das pregas não são conclusivos. Esta quantificação é importante para descrever alterações no estado de hidratação corporal.

Este projeto de dissertação, prende-se com a análise de dados de 66 indivíduos aparentemente saudáveis de ampla faixa etária, e tem por objetivo clarificar a relação entre o estado de hidratação corporal e a compressibilidade das pregas cutâneas. Serão aplicadas técnicas de inferência estatística multivariada, caso da análise de regressão múltipla, que irá permitir, obter uma caracterização da compressibilidade das pregas cutâneas, definir a existência de relação entre as variáveis sócio-demográficas das pessoas e a compressibilidade das pregas cutâneas e clarificar a relação entre o estado de hidratação corporal e a compressibilidade das pregas cutâneas.

O *software* escolhido e utilizado na realização dessas análises é o *SPSS Statistics* versão 24.0. Através deste *software* foi realizada a limpeza da base de dados, análise descritiva dos dados, a análise de fiabilidade e inferência estatística sobre os dados de compressibilidade das pregas cutâneas, a análise de associação e regressão. O efeito computacional foi de uma grande valia, mas o grande desafio se encontrou na escolha dos métodos apropriados a cada tipo de dado, no uso adequado dos mesmos, na interpretação dos resultados e no como retirar conclusões mais plausíveis.

O corpo do trabalho ora apresentado está dividido, para além da introdução e conclusão, em três capítulos: sendo o primeiro capítulo referente a revisão da literatura, onde se descreve os conceitos dos principais assuntos que envolvem as análises feitas neste trabalho, de uma forma mais relacionada com a computação em vez de apresentar vastas fórmulas matemáticas e suas demonstrações; o segundo capítulo referente às opções metodológicas, onde se descreve a forma como foi feita a aplicação do questionário, o tratamento dos dados e como foram analisados no SPSS; e o terceiro capítulo referente a apresentação dos resultados, onde se ilustra todas as análises feitas por meio do SPSS e à luz da literatura pesquisada.

1.1. Fundamentação e objetivos

O excesso de peso e a obesidade são atualmente duas das principais causas de mortalidade a nível mundial. De acordo com a World Health Organization (HWO), cerca de 46% dos adultos tem excesso de peso ou é obesa e cerca de 3.4 milhões de adultos morrem anualmente devido a estas condições (World Health Organization, 2014). Para além disso, o excesso de peso e a obesidade podem levar ao desenvolvimento de doenças coronárias, de hipertensão, de diabetes tipo 2, de doença pulmonar obstrutiva crónica, de artrose e de alguns tipos de cancro (National Institutes of Health, 2000; American Institute for Cancer Research, 2009; World Health Organization, 2014). Apesar de a HWO definir excesso de peso e obesidade como a acumulação excessiva ou anormal de massa gorda que apresenta um risco acrescido para a saúde (World Health Organization, 2014), a definição corrente

de falta e de excesso de peso e obesidade está baseada erradamente no índice de massa corporal e não na composição corporal (Heymsfield *et al.*, 2005).

Assim, segundo Clasey *et al.* (1999) a medição de pregas cutâneas e de perímetros tem sido muito popular e conveniente para estimar a composição corporal (Clasey *et al.*, 1999).

A antropometria é a técnica não invasiva mais aplicada na avaliação do estado nutricional de amostras clínicas e não-clínicas e possibilita o conhecimento da composição corporal (Frisancho, 2008). Os lipocalibradores permitem obter dados antropométricos importantes de forma simples e portátil, não invasiva e a baixo custo (Frisancho, 2008). Recorrendo a equações de regressão (Siri, 1961; Brozek *et al.*, 1963; Durnin & Womersley, 1974; Jackson & Pollock, 1978; Jackson, Pollock & Ward, 1980; Slaughter *et al.*, 1988; Visser, Van den Heuvel & Deurenberg, 1994; Peterson, Czerwinski & Siervogrl, 2003), a espessura das pregas cutâneas permite estimar a gordura corporal.

Esta metodologia apresenta, contudo, algumas limitações. De todas as medições antropométricas, as pregas cutâneas são as que apresentam menor fiabilidade (Marfell-Jones *et al.*, 2006). Assim, a pesquisa sobre os fatores que poderão levar ao aperfeiçoamento desta metodologia de avaliação da composição corporal, reveste-se da maior importância.

Um aspeto a ter em consideração é a compressibilidade da prega. As leituras das espessuras das pregas diminuem após a aplicação do lipocalibrador e os protocolos da *International Society for the Advancement of Kinanthropometry* (Marfell-Jones *et al.*, 2006) e de Lohman (Lohman, 1981) recomendam efetuar-se a medição, respetivamente, 2 e 3 segundos após a aplicação do lipocalibrador. Uma vez que o tecido adiposo é compressível (Martin *et al.*, 1985) e a compressibilidade das pregas cutâneas não é constante (Clarys *et al.*, 1987), recorre-se a esta uniformização do tempo de leitura 2 ou 3 segundos após a aplicação do lipocalibrador de forma a tornar possíveis comparações teste/re-teste (Marfell-Jones *et al.*, 2006). Contudo, estudos realizados em jovens adultos saudáveis (Clegg & Kent, 1967; Himes, Roche & Siervogel, 1979; Hattori & Okamoto, 1993), em crianças (Himes, Roche & Siervogel, 1979), em atletas (Muller *et al.*, 2013), em idosos (Brozek & Kinzey, 1960) e em cadáveres de indivíduos adultos (Claris, Provyn & Marfell-Jones, 2005) mostraram que a compressibilidade das pregas cutâneas varia com o local de

medição e com os indivíduos, sendo o sexo (Clegg & Kent, 1967; Himes, Roche & Siervogel, 1979; Hattori & Okamoto, 1993) e a idade (Brozek & Kinzey, 1960) fatores de variação. Assim, mesmo uniformizando o tempo de leitura da espessura da prega, espessuras semelhantes podem produzir diferentes valores de leitura devido a diferentes graus de compressibilidade do tecido cutâneo e subcutâneo (Claris, Provyn & Marfell-Jones, 2005). Esta variabilidade pode originar erros nas estimativas da percentagem de massa gorda obtidas por esta metodologia e pode dever-se a vários fatores, entre eles diferenças na tensão e espessura da pele, na tensão provocada pelo tecido subcutâneo e na distribuição do tecido conetivo e dos vasos sanguíneos.

A compressibilidade das pregas poderá ser característica de cada indivíduo, mas esta não foi ainda caracterizada. O avanço do conhecimento nesta área poderá contribuir para a otimização do processo de medição da gordura subcutânea e da estimativa da composição corporal. Uma das razões que poderá justificar o facto de este padrão de compressibilidade das pregas cutâneas não ter sido explorado, é a ausência de capacidade do equipamento disponível. Assim foi desenvolvido, um novo sistema, o LipoTool. Este é baseado num lipocalibrador, o Adipsmeter (estrutura mecânica, instrumentação eletrónica, capacidade de registo da evolução temporal da compressibilidade da prega, comunicação sem fios) e numa aplicação de *software* integrando uma base de dados, LipoSoft.

A variabilidade na compressibilidade das pregas pode ser mediada por fatores genéticos ou resultar de alterações no estado nutricional e no grau de hidratação (Himes, Roche & Siervogel, 1979; Hattori & Okamoto, 1993). De facto, a proporção de água intra e extracelular afeta a espessura das pregas cutâneas. A medição consecutiva de uma mesma prega pode levar a medições consecutivamente menores devido a diminuição no conteúdo hídrico, sendo este fenómeno mais comum em indivíduos obesos (Marfell-Jones *et al.*, 2006).

Contudo, os estudos efetuados sobre a relação entre estado de hidratação e compressibilidade das pregas não são conclusivos. Enquanto um trabalho mostrou que a desidratação aumenta a espessura das pregas devido a alterações na turgescência ou tensão da pele (Consolazio, Johnson & Pecora, 1963), um outro estudo não encontrou

diferenças na espessura entre mediações feitas antes e após desidratação moderada induzida por calor e/ou exercício (Norton *et al.*, 2000).

A impedância bioelétrica (BIA) mede a impedância elétrica do corpo determinada pela relação entre dois componentes, a resistência e a reactância (Chumlea & Shumei, 2005). A resistência é a oposição de um condutor biológico, no caso do corpo a água, à passagem de corrente (Baumgartner, Chumlea & Roche, 1988; Chumlea & Shumei, 2005) enquanto a reactância corresponde ao atraso que a corrente elétrica sofre devido à componente celular do organismo (Chumlea & Shumei, 2005). Os equipamentos de BIA utilizam uma corrente elétrica de baixa intensidade e segura para o indivíduo (Kyle *et al.*, 2004; Chumlea & Shumei, 2005). Os equipamentos multifrequência apresentam maior capacidade, comparativamente com os que operam com uma única frequência, em quantificar a proporção de água intra e extra-celular. Esta quantificação é importante para descrever alterações no estado de hidratação corporal (Gudivaka *et al.*, 1999; Chumlea & Shumei, 2005).

Realizou-se um estudo transversal em que se recrutou uma amostra de 100 estudantes e funcionários da Universidade do Porto, aparentemente saudáveis e de ampla faixa etária, que forneceram o consentimento livre e informado para a presente investigação. Pretende-se com este projeto, a ser realizado em indivíduos aparentemente saudáveis de ampla faixa etária, clarificar a relação entre o estado de hidratação corporal e a compressibilidade das pregas cutâneas. Esse projecto de investigação conta com investigadores principais a Prof^a Doutora Maria Teresa Restivo (FEUP) e a Prof^a Doutora Teresa Amaral (FCNUP) que integram a UISPA (System and Process, Automation Unit) do Laboratório Associado de Energia, Transportes e Aeronáutica (LAETA), unidade ID da Fundação para a Ciência e Tecnologia (FCT).

Definiu-se como critérios de exclusão a existência de pacemaker, a amputação *major*, lipodistrofia, paquidermia e terapias dialíticas, visto tratarem-se de situações que inviabilizam a realização do exame de BIA ou diminuem a sua validade (Kyle *et al.*, 2004). A avaliação da composição corporal e de estado de hidratação foi efetuada com o uso do BIA tetrapolar (modelo Tanita Multi Frequency Body Corporation Analyser MC – 180 MA).

As medições antropométricas recolhidas foram: peso, estatura e as pregas cutâneas tricípital, subescapular, bicipital, iliocrystal, supraespinal, abdominal, crural e geminal (Marfell-Jones *et al.*, 2006). A medição das pregas cutâneas foi feita com o sistema LipoTool. De forma a obter uma melhor caracterização da amostra procedeu-se, também, à avaliação da capacidade muscular por dinamometria.

A todos participantes lhes foram aplicados um questionário onde foi recolhida informações sobre o estado de saúde, capacidade cognitiva, estado nutricional, ingestão alimentar (etanol e cafeína), exercício físico e variáveis sócio-demográficas.

A entrevista e todos os procedimentos que fizeram parte do estudo teve lugar no Pavilhão da Faculdade de Ciências da Nutrição e Alimentação da Universidade do Porto e foram conduzidos por uma Nutricionista treinada e membro da equipa de investigação do UISPA-LAETA. O projecto foi devidamente aprovado pelo comité de ética da instituição.

Os participantes foram devidamente informados sobre o objetivo e a metodologia do estudo, os benefícios associado a participação e a confidencialidade dos dados, através de um termo de que foi assinado em duplicado tendo o participante ficado com um exemplar e o investigador com outro. Esses benefícios incluíram comunicar aos participantes os seus resultados pessoais das avaliações realizadas, nomeadamente sobre a composição corporal, bem como quaisquer desvios face à normalidade.

Os dados recolhidos da aplicação do questionário e das medições antropométricas, foram inseridos em Excel. Inicialmente os dados foram inseridos em duas folhas de um mesmo ficheiro de Excel, uma para os dados das pregas cutâneas e outra para as restantes medições realizadas e informações recolhidas.

Este ficheiro de dados foi cedido para este trabalho de dissertação pela Prof^a Doutora Teresa Restivo, no âmbito da cooperação existente dentro da UISPA-LAETA do qual a Prof^a Doutora Catarina Nunes também é investigadora.

1.2 Objetivos da dissertação

O objetivo desta dissertação visa essencialmente aplicar todos os passos possíveis da regressão linear múltipla, como uma das técnicas estatística multivariada, para clarificar a

relação entre o estado de hidratação corporal e a compressibilidade das pregas cutâneas e a relação destas com as variáveis socio-demográficas das pessoas, aplicando e comparando vários modelos (*Enter, Stepwise, Forward e Backward*) disponíveis no *SPSS Statistics* para chegar no melhor modelo que explicam essas relações.

Também, explorar de forma exaustiva e comparativa as diferentes formas de resumo dos dados (média de todos os pontos, média dos últimos 10 pontos, mediana de todos os pontos, mediana dos últimos 10 pontos, desvio-padrão de todos os pontos, desvio-padrão dos últimos 10 pontos, média dos últimos 3 pontos, diferença entre o primeiro e o último ponto, diferença entre o ponto mínimo e o ponto máximo) extraídos dos 180 pontos de medição na busca de clarificar os locais de medição onde se possa extrair melhores informações sobre a compressibilidade das pregas cutâneas que permitirá clarificar melhor o objeto de estudo.

Para verificar as relações acima referidas, é necessário que os dados sejam no mínimo fiáveis. Assim, um outro objetivo é verificar, com o uso da estatística *Alpha de Cronbach*, a fiabilidade dos dados de compressibilidade das pregas cutâneas e determinar se o instrumento usado para recolher os dados das pregas é fiável.

Capitulo 1
Enquadramento teórico

1.1. Valores ausentes

Nesta parte do capítulo serão explorados alguns conceitos com o objetivo de proporcionar melhor compreensão sobre as análises estatísticas. Veremos o que são valores ausentes, quais os padrões e mecanismos que os geram, como podemos evitar que elas ocorram, e caso ocorram, quais as formas de tratamento.

1.2. Definição de valores ausentes

Durante a coleta de dados é frequente o aparecimento de valores ausentes derivado da ausência de respostas em uma ou mais questões do instrumento de recolha ou da ausência de respostas em todas as questões do questionário (Castro, 2014), o que provoca uma certa dificuldade na análise estatística dos dados (Nunes, Kluck & Fachel, 2010; Castro, 2014).

Geralmente as análises estatísticas são feitas ignorando os valores ausentes. Mas tal não é uma melhor opção, visto que poderá ocorrer enviesamento nas estimativas obtidas, logo deverão ser levados em consideração (Nunes, Kluck & Fachel, 2010 ; Castro, 2014). Assim tem vindo a surgir desde os anos 1970 métodos que permitam substituir os valores ausentes por valores ‘plausíveis’ para que se possa realizar as análises com respostas completas em todos os casos (Castro, 2014).

Os valores ausentes ou as não respostas, segundo Pestana e Gageiro (2008) resultam de erros de inserção de dados ou da recolha dos mesmos.¹

Pilati e Porto (2015) define um valor ausente como “uma ausência de resposta, ou seja, por algum motivo o participante não atribuiu valor a uma pergunta do questionário” (Pilati & Porto (2015): 24)

Segundo Mcknight *et al.* (2007) “De um modo geral, o termo dados faltantes significa que está faltando algum tipo de informação sobre o fenómeno em que estamos interessados” (Mcknight *et al.*, 2007 ; Veroneze, 2011: 7)

¹ Os *missing data* são traduzidos em algumas bibliografias por: dados faltantes, valores ausentes, não respostas, dados não observados ou casos omissos.

Para Wu *et al.* (2004), se um atributo (campos ou variáveis) de um objeto (registro ou caso) se encontra vazio, então é um valor ausente (Wu *et al.*, 2004; Veroneze, 2011: 7).

Pilati e Porto (2015) recomenda que o primeiro passo na análise de dados é fazer a limpeza da base de dados, ou seja, verificar se não existe erros de inserção dos dados. Estes erros podem ser de duplicação, incorreção e inconsistência (chamados de valores ruidosos) e que podem ser substituídos por valores ausentes (Myrtveit *et al.*, 2001; Wu *et al.*, 2004; Veroneze, 2011: 7). O procedimento de substituição é feito no SPSS através dos seguintes comandos: Analyse → Descriptives Statistics → Explore

Segundo Pestana e Gageiro (2008) “Quando as não respostas atingem 20% dos dados ou um valor superior, deverão ser analisadas com cuidado, pois se não tiverem um comportamento aleatório irão enviesar os resultados do questionário, podendo caracterizar o segmento da população que se recusou responder” (Pestana & Gageiro, 2008: 49)

Segundo Pilati e Porto (2015) “O excesso de casos omissos em determinado item de um questionário pode trazer várias indicações e pode, inclusive, ser considerado como escopo de um relatório, pois a incapacidade dos respondentes em avaliar questões pode indicar inadequação do instrumento, entre muitas outras possibilidades” (Pilati & Porto [?]: 24)

Os valores ausentes podem ser identificados no SPSS através dos seguintes comandos:

Analyse → Descriptives statistics → Frequencies

1.2.1. Mecanismos associados aos valores ausentes

Segundo Pilati e Porto (2015) a forma de tratamento dos valores ausentes deve ser diferenciada por causa da sistematicidade dos mesmos e estão classificados da seguinte forma: (i) ausentes completamente aleatórios (MCAR – *Missing Completely at Random*), omissos aleatórios (MAR – *Missing at Random*) e ausentes sistemáticos (MNAR – *Missing Not at Random*). Esta classificação pertence a uma das características chamada *mecanismo*, sendo o *padrão* e *quantidade* outras características dos dados a ser levado em consideração para um tratamento adequado dos valores ausentes, segundo Veroneze

(2011). Esses mecanismos (MCAR, MAR e MNAR) são geradores de valores ausentes e foram desenvolvidos, segundo Castro (2014), por Little e Rubin (2002). A diferença entre estes três mecanismos é resumida por Veroneze (2011):

O mecanismo é MCAR se os dados faltantes são causados por processos aleatórios. O mecanismo é MAR se os dados faltantes são causados por uma ou mais variáveis observadas. O mecanismo é MNAR se os dados faltantes são causados por uma ou mais variáveis não-observadas; além disso, pode ou não existir uma relação entre os dados observados e os dados faltantes quando o mecanismo é MNAR.

(Veroneze, 2011:10)

Segundo Mcknight *et al.* (2007) conhecer o tipo de mecanismo ajuda a entender a natureza dos valores ausentes, o impacto nos resultados e na interpretação dos mesmos (Mcknight *et al.*, 2007 ; Veroneze, 2011) e permite escolher a técnica mais adequada para tratá-los (Castro, 2014). Assim, em primeiro lugar é verificado se o mecanismo é MCAR através do teste chi-quadrado, onde as médias de um atributo para cada padrão de valores ausentes é comparada com as médias calculadas para todo o conjunto de dados por meio de um método robusto de estimação de parâmetros. Caso o mecanismo não for MCAR, o lógico seria verificar se é MAR ou MNAR, mas ainda não existe um método formal para tal verificação (Veroneze, 2011).

Segundo Allison (2001) esses mecanismos são classificados como *ignoráveis* – o mecanismo (MAR ou MCAR) que gerou os valores ausentes não é considerado no modelo, e *não-ignoráveis* – o mecanismo (MNAR) que gerou os valores ausentes deve ser considerado no modelo para que a variável de interesse seja estimada (Allison, 2011 ; Castro, 2014).

1.2.2. Padrão dos valores ausentes

Segundo Little e Rubin (2002) o padrão descreve, numa matriz de dados, os valores observados e os valores ausentes e ajuda a identificar qual o mecanismo que gerou os valores ausentes (Little & Rubin, 2002; Veroneze, 2011).

Segundo Enders (2010) o padrão dos valores ausentes descreve a configuração dos dados observados e os não observados numa matriz de dados. Também permite verificar como aparecem os dados não observados e onde estão localizados (Enders, 2010 ; Castro, 2014).

A Figura 1.1 mostra quatro tipos de padrão mais comumente discutido na literatura e descritos por Enders (2010):

A – Padrão Univariado: quando os valores ausentes aparecem somente em uma variável isolada. Na figura essa variável é o Y_4 . (Enders, 2010 ; Castro, 2014).

Segundo Veroneze (2011) este padrão, que é “consistente, único e detectável”, “pode acontecer, por exemplo, em caso em que alguns participantes de uma pesquisa não respondem a um item do questionário” (Veroneze, 2011: 13).

B – Padrão Não resposta unidades: quando alguns entrevistados da pesquisa (quer seja uma amostra ou um censo) se recusam a responder pelo menos um item do questionário. Na figura essas variáveis são o Y_3 e Y_4 (Enders, 2010 ; Castro, 2014)

C – Padrão de não resposta Monotônico: quando participantes de uma pesquisa desistem de participar. Este tipo de padrão é usado com mais frequência em estudos longitudinais e neste contexto a proporção de respostas aumenta a cada momento do tempo (Enders, 2010 ; Castro, 2014).

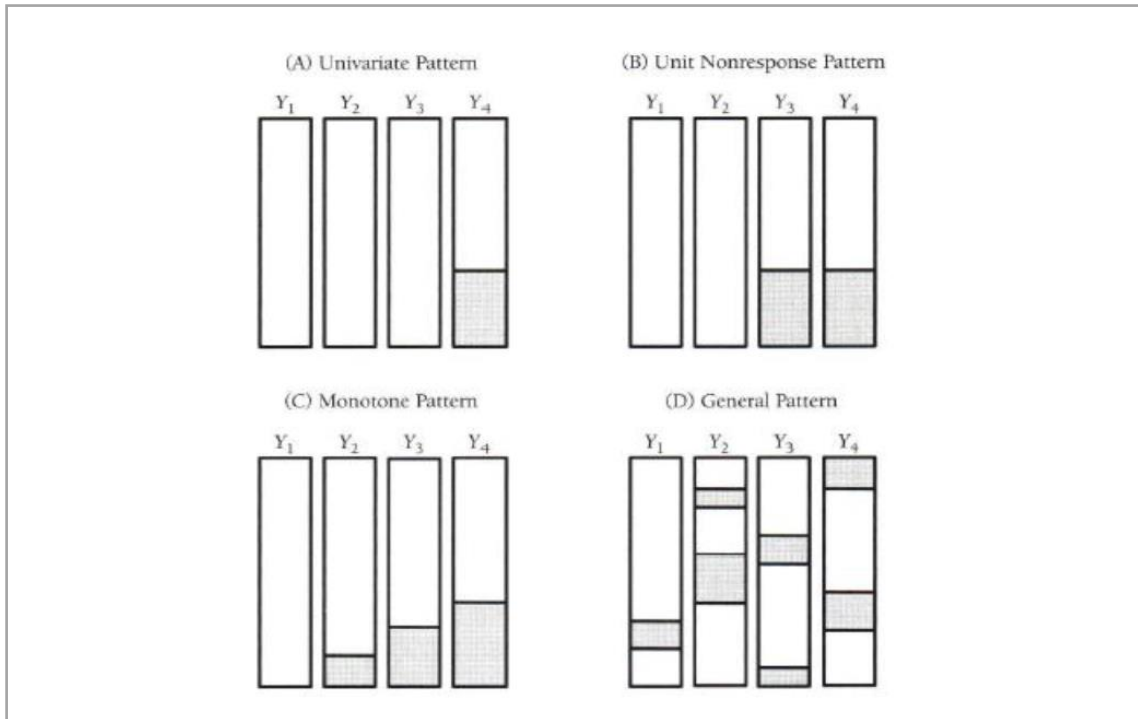
D – Padrão de não resposta Geral: é um tipo de padrão que se verifica com mais frequência. É identificado pela dispersão dos valores ausentes na base de dados, figurando de forma aleatória, sendo por vezes sistemáticas (Enders, 2010 ; Castro, 2014). Veroneze (2011) lhe chama de padrão arbitrário.

Dado que o padrão nos permite saber se os valores ausentes ocorreram de forma sistemática ou não-estruturada (Veroneze, 2011), convêm fazer a diferença entre o que é não estruturado e sistemático:

Os dados faltantes são não-estruturados quando existem múltiplos padrões de dados faltantes entre os objetos do estudo, o que indica que o mecanismo pode ser aleatório. Em contrapartida, se os dados faltantes são sistemáticos, ou seja, estruturados ou capazes de expressar alguma tendência, há um indicador de que o mecanismo que governa os dados faltantes não é aleatório.

(Mcknight *et al.*, 2007 ; Veroneze, 2011: 14)

Figura 1.1: Padrões de não respostas



Fonte: Castro (2014)

1.2.3. Quantidade de valores ausentes

Segundo Mcknight *et al.* (2007) a precisão da estimativa dos parâmetros está muito relacionada com a quantidade de valores ausentes; e quando estes existem em grande quantidade, fica mais fácil fazer o seu devido tratamento com os mecanismos MCAR e MAR (chamados de *ignoráveis*) do que pelo mecanismo MNAR em pequenas quantidades. Entretanto, quanto maior a quantidade de valores ausentes maior é a dificuldade em obter bons resultados (Mcknight *et al.*, 2007 ; Veroneze, 2011).

Segundo Veroneze (2011) a quantidade de valores ausentes não está ainda bem definido, “um conceito ambíguo”, pois ela pode estar relacionada com objetos ou atributos que contêm valores ausentes ou com valores ausentes em um determinado atributo (ou em um conjunto específico de atributos) ou em toda a matriz de dados.

1.2.4. Prevenção dos valores ausentes

Apesar de ser difícil eliminar completamente os valores ausentes, atuar na prevenção é muito melhor do que tratá-los (Veroneze, 2011). Essa prevenção, para minimizar a ocorrência dos valores ausentes, poderá começar ainda no planejamento da pesquisa e algumas dicas é dada por Vieira (2011): saber abordar as questões sensíveis, por exemplo quando o assunto se refere à drogas ou finanças; escolher o melhor momento ou época para realizar a pesquisa que não seja durante as férias, feriados ou grandes eventos; ter um corpo de entrevistadores bem treinado; ter cuidado com a extensão do questionário, de forma que o seu preenchimento seja o mais breve possível; envolver os entrevistados na pesquisa e criar mecanismos de incentivo para responderem; e procurar insistir com os respondentes em caso de insucesso em encontra-los para a entrevista (Vieira, 2012 ; Veroneze, 2011).

As estratégias de prevenção dos valores ausentes podem ser levadas a cabo durante as análises por meio de técnicas estatísticas adequadas (Castro, 2014).

1.2.5. Seleção do método apropriado

Verificar informações úteis que possam ajudar na escolha da técnica adequada é uma etapa que antecede o tratamento dos valores ausentes (Veroneze, 2011) e que segundo Mcknight *et al.* (2007) essa etapa divide em alguns passos seguintes: identificar quais os atributos são relevantes na análise a ser feita; caso os dados possuam uma estrutura hierárquica deve-se identificar qual o nível de análise a ser feita (ex. nível macro ou micro); e identificar o mecanismo, o padrão e a quantidade de valores ausentes (Mcknight *et al.*, 2007; Veroneze, 2011).

Apesar de existir vários métodos para o tratamento de valores ausentes, apenas alguns tem merecido algum destaque dentre os demais, sendo eles: caso completo, casos disponíveis, caso completo ponderado, imputação única, máxima verossimilhança e imputação múltipla (Veroneze, 2011).

Neste trabalho será destacado o método de imputação única, pois, segundo Nunes (2007), no SPSS Statistics existe apenas esse método (Nunes, 2007; Castro, 2014).

A imputação única apresenta como vantagem o fato de ser de fácil aplicação e como desvantagens “a subestimação da variabilidade da variável imputada e a dificuldade de levar em consideração a variabilidade que possa existir entre diferentes imputações (Nunes, Kluck & Fachel, 2010; Castro, 2014:11).

Uma outra vantagem é que, em geral, a imputação única fornece estimativas pontuais consistentes (Baracho, 2003; Castro, 2014:21).

A subestimação dos erros padrão das estimativas resulta em intervalos de confiança de amplitude muito pequena ou estatísticas dos testes com valores elevados (Robert *et al.*, 2009 ; Castro, 2014:21).

Para Pilati e Porto (2015) percentagem de valores ausentes superiores a 3% podem ser considerados um problema, merecendo uma investigação cuidadosa. Caso for igual ou abaixo dos 3% deverão ser substituídos através do procedimento: Transform → Replace Missing Values

1.2.5.1. Método de imputação única pela média

O método de imputação única é utilizado quando se pretende que cada valor ausente seja substituído apenas uma única vez. Dentre o método de imputação única, segundo Castro (2014), temos por exemplo a *imputação pela média* (substituir os valores ausentes pela média dos valores observados no atributo de interesse), a *imputação pelo vizinho mais próximo* (substituir os valores ausentes com informações de variáveis auxiliares) e a *imputação por regressão* (substituir os valores ausentes por informações de outras variáveis que não possuem valores ausentes, tendo como pressuposto que as variáveis são correlacionadas).

Segundo Veroneze (2011) os métodos de imputação única têm o papel de substituir os valores ausentes de um determinado atributo por um único valor constante. A imputação

de zeros, a imputação da média e a imputação da mediana são alguns exemplos desses métodos. Desses métodos falaremos da imputação pela média:

O procedimento para este método, como referido anteriormente, é substituir os valores ausentes identificados na variável de interesse pela média dos valores observados nesta mesma variável (Veroneze, 2011).

Apesar de ser de fácil implementação tem a desvantagem de subestimar a variância das variáveis com valores ausentes, caso houver nelas a presença de valores extremos que ficarão sub-representadas ao aplicar a imputação da média (Mcknight *et al.*, 2007; Veroneze, 2011).

Segundo Mcknight (2007), caso a percentagem de valores ausentes em uma base de dados for baixa os efeitos negativos do método de imputação pela média são minimizados (Mcknight *et al.*, 2007 ; Veroneze, 2011).

Uma outra vantagem e desvantagem da imputação pela média refere a distribuição normal:

Também é importante enfatizar que a média é a melhor medida de tendência central para variáveis normalmente distribuídas. Desse modo, quando a distribuição normal não se verifica, os resultados deste método podem ser bastante pobres.

Basicamente, a imputação da mediana é bem parecida com a imputação da média, apresentando as mesmas vantagens e desvantagens. Porém, a imputação da mediana é uma alternativa melhor para variáveis que não são normalmente distribuídas, pois a mediana representa melhor a tendência central de uma distribuição que possui grandes desvios da distribuição normal.

(Veroneze, 2011: 26)

Quando as variáveis são do tipo ordinal ou nominal (categórica), a moda é preferível em relação a média (Farhangfar *et al.*, 2004 ; Veroneze, 2011).

1.3. Correlação

Nesta parte do capítulo apresentaremos o diagrama de dispersão que mostra graficamente a relação que existe entre duas variáveis e veremos, dentre vários tipos de coeficientes de correlação, a interpretação e o significado do coeficiente linear R de Pearson.

1.3.1. Diagrama de dispersão

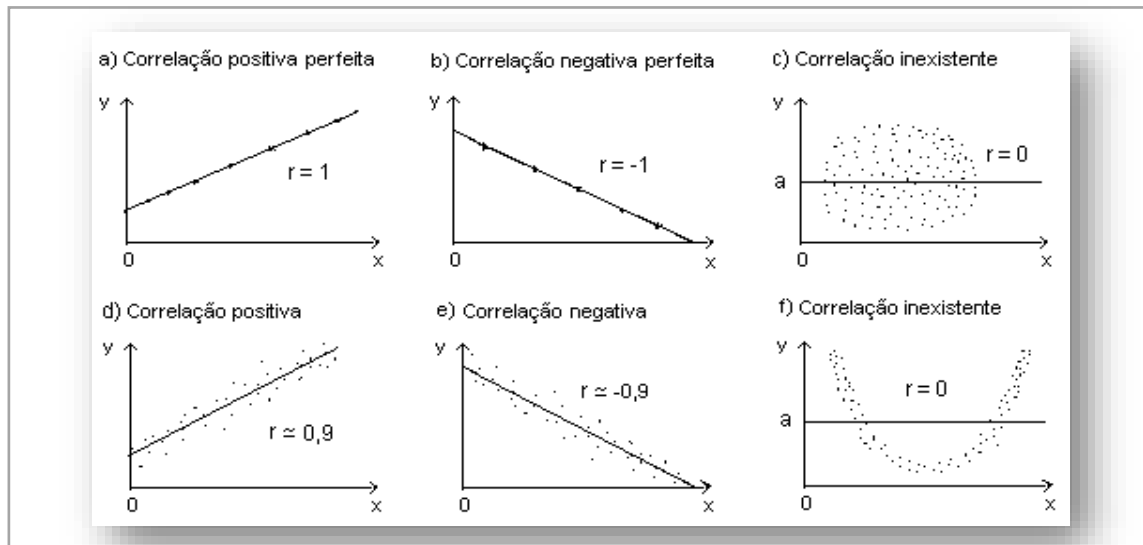
“O diagrama de dispersão é um gráfico que representa em simultâneo variáveis de nível quantitativo, e permite ver se existe relação entre elas, se essa relação é ou não linear, e se tem ou não casos *outliers* que podem distorcer os resultados dos coeficientes da correlação” (Pestana e Gageiro, 2008: 174)

O SPSS dispõe de cinco tipos de gráficos, mas segundo Pestana e Gageiro (2008) apenas três são mais utilizados: *Simple Scatter* (usado quando se pretende representar apenas duas variáveis quantitativas), *Overlay Scatter* (usado quando se pretende representar no mesmo gráfico vários pares de variáveis, em que se repete uma delas) e *Matrix Scatter* (usado quando existem vários pares de variáveis).

Os diagramas de dispersão podem ser obtidos no SPSS através dos seguintes comandos: Graphs→Scatter/Dot

A Figura 1.2 mostra todos os tipos de relação existente entre duas ou vários pares de variáveis:

Figura 1.2: Tipo de relação entre variáveis



Fonte: www.ebah.com.br

1.3.2. Coeficientes de correlação

Dependendo da natureza das variáveis assim é o tipo de correlações paramétricas, nomeadamente: (i) o coeficiente e correlação *Bi-serial* – usado quando uma das variáveis é categórica de apenas duas categorias; (ii) o coeficiente de correlação *Point bi-serial* – usado quando uma das variáveis é do tipo nominal com, no máximo duas categorias; (iii) o coeficiente de correlação *Tetrachoric* – usado quando ambas as variáveis são dicotômicas; (iv) o coeficiente de correlação *Eta* – usado quando uma das variáveis é métrica e a outra é nominal contendo pelo menos três categorias e (v) o coeficiente de correlação de *Pearson* (Hill & Hill, 2005).

Todos esses diferentes tipos de correlação têm algo em comum – requererem que ao menos uma das variáveis sejam de natureza métrica. Mas dado o Coeficiente de correlação de *Pearson* ser o mais utilizado (Hill & Hill, 2005) e por adequar melhor à análise levada a cabo neste trabalho, será objeto de mais detalhes.

1.3.3. Coeficiente de correlação linear *R* de *Pearson*

“Um coeficiente de correlação é uma *estatística descritiva* que indica a natureza da relação entre os valores de duas variáveis. Os valores vêm de um só grupo de casos, mas fornecem duas amostras” (Hill & Hill, 2005: 202)

“O coeficiente de correlação *R* de *Pearson* é uma medida de associação linear entre variáveis quantitativas [...]” (Pestana & Gageiro, 2008:181)

“O coeficiente de correlação linear é uma medida do grau de associação linear entre variáveis. É simples quando definido para duas variáveis e múltiplo quando se pretende medir a relação linear entre mais de duas variáveis” (Reis, 2012:185)

Segundo Murteira (1993), “A correlação indica que os fenómenos não estão indissolúvelmente ligados, mas, sim, que a intensidade de um é acompanhada tendencialmente (em média, com maior frequência) pela intensidade do outro, no mesmo sentido ou em sentido inverso” (Murteira, 1993 ; Pestana & Gageiro, 2008:181)

Segundo Pestana e Gageiro (2008) o coeficiente de correlação R de *Pearson* se aplica a variáveis de nível intervalo ou rácio e possui os seguintes pressupostos: (i) que as duas variáveis tenham uma relação linear, e (ii) que os dados sejam oriundos de uma distribuição normal bidimensional, para se poder inferir. Para Hill e Hill (2005) esses pressupostos não são de muita importância.

A aplicação do coeficiente de correlação de *Pearson* deve ser feita quando o tamanho mínimo de uma amostra for trinta ($n \geq 30$, para um nível de significância de 0.05) ou quarenta ($n \geq 40$, para um nível de significância de 0.10) (Pestana e Gageiro, 2008).

1.3.3.1. Interpretação e significância do valor do R de *Pearson*

Hill e Hill (2005) indica o intervalo $[-1, +1]$ onde varia o valor do coeficiente. Caso o coeficiente for igual a $+1$ significa que existe uma relação linear perfeita positiva entre as variáveis, querendo isto dizer que quando uma aumenta a outra também aumenta em média num valor proporcional. Caso o valor do coeficiente for -1 significa uma correlação perfeita negativa entre as variáveis, querendo isto dizer que os aumentos de uma variável estão associados, em média, a diminuições da outra variável. Se o coeficiente for igual a zero significa ausência de correlação entre as variáveis (Pestana & Gageiro, 2008).

A Tabela 1.1 indica os valores de R e sua interpretação adaptadas nas ciências exatas (Pestana & Gageiro, 2008):

Tabela 1.1: Valores de R e sua interpretação

Valor do R	Interpretação
$R < 0.2$	Associação linear muito baixa
$0.2 \leq R \leq 0.39$	Associação linear baixa
$0.4 \leq R \leq 0.69$	Associação linear moderada
$0.7 \leq R \leq 0.89$	Associação linear alta
$0.9 \leq R \leq 1$	Associação linear muito alta

Fonte: adaptado de Pestana e Gageiro (2008)

Hill e Hill (2005) chama atenção quanto a maneira de tirar conclusões sobre o valor do R :

O valor do coeficiente [...] é igual a -0.53 . Que significa este valor? – Como devemos interpretá-lo? [...] não significa que as duas variáveis mostram um grau de relacionamento de 53%.

Podemos dizer que o valor -0.53 indica que, nas duas amostras, a relação entre as duas variáveis é uma relação inversa, [...].

(Hill & Hill, 2005: 202)

A expressão matemática do R de *Pearson* é dada por: “

$$R = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y}) / (n-1)}{\sqrt{\frac{\sum (X_i - \bar{X})^2}{n-1}} \sqrt{\frac{\sum (Y_i - \bar{Y})^2}{n-1}}} = \frac{COV(X, Y)}{S_x S_y} = \frac{\sum (Z_x \times Z_y)}{n-1} \quad (1)$$

Onde Z_x e Z_y correspondem às variáveis X e Y estandardizados” (Pestana & Gageiro, 2008: 182). $COV(X, Y)$ covariância entre as variáveis X e Y , \bar{X} média amostral da variável X , \bar{Y} média amostral da variável Y , $S_x S_y$ desvio-padrão da variável X e Y respetivamente.

Hill e Hill (2005) sugere outras formas de interpretar o coeficiente de *Pearson*, nomeadamente o coeficiente de determinação R^2 . Segundo esse autor, não basta apenas interpretar um valor [por exemplo] de $R = -0.53$ como uma relação inversa entre duas variáveis pois os valores dessas duas variáveis apenas são amostras de um universo. Assim sugere que

Temos de aceitar a possibilidade de o erro associado às amostras ser tão grande que, no Universo, a correlação entre as duas variáveis é igual a zero. Em termos mais formais, esta possibilidade representa uma Hipótese nula que podemos testar com um teste estatístico indutivo (o teste t é o tipo mais vulgar). Suponhamos agora que aplicamos este teste e verificamos que o coeficiente de correlação -0.53 não é significativo ao nível $\alpha = 0.05$. Este resultado diz-nos que não temos evidência que o coeficiente de correlação no Universo seja diferente de zero. Por outro lado, se o coeficiente de correlação for significativo ao nível $\alpha < 0.05$ (e isto é verdade para uma amostra com $N=400$) podemos concluir que, *provavelmente*, o coeficiente de correlação do Universo não é zero. A palavra ‘provavelmente’ indica que a probabilidade de a nossa conclusão estar errada é menor que 0,05. É importante recordar que quando aplicamos um teste indutivo para avaliar a significância de um coeficiente de correlação estamos sempre a testar a seguinte Hipótese nula: ‘O coeficiente de correlação no Universo é igual a zero’.

(Hill & Hill, 2005: 202)

1.4. Distribuição Normal

Nesta fase do capítulo incidiremos sobre a parte mais prática do conceito de distribuição normal univariada e multivariada, os testes e gráficos que nos permitem avaliar se uma


distribuição é ou não normal e os diferentes tipos de transformações lineares que nos permitem normalizar os dados.

1.4.1. Distribuição Normal Univariada

Segundo Hill e Hill (2005), existe três métodos, disponíveis no SPSS, de avaliar se uma variável segue uma distribuição normal, sendo eles: o histograma, o *Normal probability plot* (Q-Q *plot* ou P-P *plot*) e Testes estatísticos (Kolmogorov-Smirnov ou Shapiro-Wilk). Pereira (2003) aponta mais um método – o diagrama *stem-and-leaf*. Esses métodos são obtidos no SPSS através dos seguintes comandos: Analyse → Descriptive Statistics → Explore → Graphs

Na Figura 1.3 o histograma está representado na esquerda e o *Normal probability plot* na direita. No histograma é inserido a curva de uma distribuição normal para ajuizar melhor sobre a normalidade da distribuição de uma variável, sendo que raras vezes se depara com um histograma cuja distribuição é perfeitamente normal. No caso dos gráficos Q-Q e P-P, estes se apresentam perfeitamente lineares, caso a distribuição de uma variável for perfeitamente normal. Quando uma variável tem distribuição normal, os pontos do gráfico colocam-se sobre a linha diagonal. Caso os pontos estiverem próximos da linha, a distribuição está relativamente perto da normal. No caso do histograma, a distribuição normal perfeita é difícil de ser verificada. Os testes de Kolmogorov-Smirnov e Shapiro-Wilk são os mais vulgarmente usados para avaliar a normalidade da distribuição dos dados de uma variável. Se os valores dos testes não forem significativos para a estatística, considera-se que a distribuição é normal ($p > \alpha$). Entretanto, na prática deve-se analisar todos os métodos disponíveis para verificar se uma dada variável segue ou não distribuição normal, devido a que muitos dos testes paramétricos serem pouco influenciados por pequenos desvios da normalidade (Hill & Hill, 2005). Para Pereira (2003) “Se os níveis de significância dos testes forem baixos, pode duvidar-se da normalidade da população” (Pereira, 2003: 135). Segundo Maroco (2011) o teste de Shapiro-Wilk é preferível quando a amostra é pequena ($n < 30$).

Figura 1.3: Análise da normalidade com o histograma e o *Normal probability plot*



Fonte: Elaboração própria

Hill e Hill (2005) sugere que se examine outras evidências sobre a normalidade dos dados através de indicadores como a assimetria e curtose.

Segundo Pilati e Porto (2015), através de alguns indicadores, nomeadamente a assimetria (*skewness*) e o achatamento (*kurtosis*) pode-se concluir se a distribuição de uma variável se aproxima da normal. Quanto mais próximos os seus valores estiverem do valor zero, mais evidente é essa conclusão. Também ao dividir o valor de cada um dos indicadores mencionados pelo valor do seu erro padrão e o resultado desta divisão for maior que 1.96 é um indicativo que o indicador é significativo. Uma outra forma de verificar a normalidade é observar o valor do desvio-padrão que se for inferior ao valor da média é um indicativo de que a distribuição da variável aproxima da normal (Pilati & Porto, (2015): 34).

1.4.2. Distribuição Normal Multivariada

As técnicas multivariadas, segundo Hill e Hill (2005) pressupõe que as variáveis dependentes tenham distribuição normal multivariada. Segundo Maroco (2011), se esse pressuposto for violado não acarreta grandes problemas por serem robustas as técnicas multivariadas, principalmente quando o tamanho da amostra é grande. Mesmo assim é da opinião de que o pressuposto seja verificado para que as conclusões do estudo sejam mais confiantes.

Segundo Hill e Hill (2005) e Maroco (2003) não existe no SPSS nenhum teste para avaliar o pressuposto da multi-normalidade. Uma forma computacional para averiguar tal pressuposto, proposta por esses autores, é aplicar o *p*-vezes testes de Kolmogorov-Smirnov para cada *p* variáveis X_1, X_2, \dots, X_p separadamente e verificar se seguem uma distribuição normal univariada $N_p(\mu_i, \sigma_i)$ ($i = 1, \dots, p$). Caso isto acontecer, é sinal de que a distribuição multivariada possa ser normal, ou seja é provável que um vetor de *p*-variáveis tenha distribuição $N_p(\mu, \Sigma)$, sendo Σ a matriz de variância-covariância de \tilde{X} .

Hill e Hill (2005) sugere, em caso de haver alguma variável que não siga uma distribuição normal univariada, a aplicação de uma das transformações seguintes: (i) calcular o inverso de $1/X$ (para uma distribuição platicúrtica), (ii) calcular a raiz quadrada \sqrt{X} (para uma distribuição com assimetria negativa) e (iii) calcular o logaritmo natural $\log X$ (para uma distribuição assimétrica positiva). Em SPSS essa transformação é feita com os seguintes comandos: Transform→Compute

1.5. Fiabilidade

Nesta parte do capítulo apresentaremos o conceito de fiabilidade de uma medida sob perspectivas de diversos autores. Destacaremos o estimador de fiabilidade mais utilizado – o índice Alpha de Cronbach, sua interpretação, critérios, limitações e sua estimativa através do intervalo de confiança e teste de hipótese.

1.5.1. Fiabilidade de uma medida

“A fiabilidade de uma medida refere a capacidade desta ser *consistente*” e a “Consistência é assim o termo fundamental para definir o conceito de *fiabilidade*” (Maroco & Garcia-Marques, 2006:66)

Segundo Sampieri (2006)

O conceito de confiabilidade esta relacionado ao grau em que um instrumento aplicado repetidas vezes mantém sua coerência e, constância, ou seja, se for repetido o mesmo objeto com os mesmos sujeitos deverá produzir resultados iguais. Demonstrando assim a estabilidade de seus resultados, advindo daí a confiança na medida.

Se um instrumento de medida dá sempre os mesmos resultados quando aplicado a alvos estruturalmente iguais, podemos confiar no significado da medida e dizer, com maior ou menor grau de certeza, que a medida é fiável (Maroco & Garcia-Marques, 2006). Para Lobiondo-Wood (2001) essa confiança [no significado da medida] advém quando em sucessivas medições encontrarmos os mesmos resultados (Lobiondo-Wood, 2001 ; Corrêa, 2012).

Segundo Maroco e Garcia-Marques (2006), qualquer medida, tem sempre duas componentes aditivas: a medida (τ) do objeto e o erro de medida do atributo ou capacidade do objeto (ε_x), dado por:

$$X = \tau + \varepsilon_x \quad (2)$$

Esse erro está associado à variabilidade observada no processo de medição de um mesmo objeto e é um erro aleatório, podendo ser sistemático. Caso for sistemático, podemos falar não da fiabilidade, mas da validade do instrumento. Essa validade é reduzida e o instrumento tende a medir algo diferente do esperado. Entretanto, para que uma medida seja valida precisa ser fiável. Essa condição de validade é necessária, mas não suficiente. Mas se uma medida não é fiável, então os seus dados são aleatórios, ou seja, sem significado, não fiáveis, logo dados não válidos. Assim para se saber se uma dada medida tem validade é necessário, mas não suficiente, saber da sua fiabilidade. Garantindo a fiabilidade, pode-se descartar a hipótese de erro sistemático, para que se possa garantir a validade (Maroco & Garcia-Marques, 2006).

Segundo Hill e Hill (2005) “Fiabilidade e validade de uma medida não são a mesma coisa e têm uma relação estranha. Uma medida pode ter boa fiabilidade e ter pouca validade, mas, sem fiabilidade adequada, a medida não pode ter validade adequada” (Hill & Hill, 2005: 149).

Se o erro aleatório for considerado como variabilidade intra-sujeito, então a fiabilidade dos dados de uma medida pode ser inferida através da variância observada intra e inter-sujeitos/objetos. Assim, quanto maior a variância inter-sujeitos $[V(\tau)]$ maior é a informação

que essa medida transporta. Caso esta variância for nula, a informação transportada é reduzida (Maroco & Garcia-Marques, 2006).

Agora, supondo que a característica mensurada (τ) é independente do erro de medida (ε_x), então a variância geral dos dados [$V(X)$] é dada por (Maroco & Garcia-Marques, 2006):

$$V(X) = V(\tau) + V(\varepsilon_x) \quad (3)$$

Finalmente a fiabilidade de um instrumento é definida pela “fração da variância (informação) do score verdadeiro (não medido diretamente) que é retida pelo score observado” (Maroco & Garcia-Marques, 2006:68):

$$\Phi = \frac{V(\tau)}{V(X)} = \frac{V(\tau)}{V(\tau) + V(\varepsilon_x)} \quad (4)$$

Segundo Hill, e Hill (2005) o termo *consistência* pode ser definida de três maneiras diferentes: (i) Consistência em termos de estabilidade temporal, que “avalia a consistência com que uma medida se perpetua ao longo do tempo”; (ii) Consistência em termos de equivalência, que “avalia a consistência com que diferentes formas de um teste ou instrumento medem um mesmo constructo latente; (iii) Consistência interna (tipo «*split-half*»), que “avalia a consistência com que um determinado conjunto de itens de medida estima um determinado constructo ou dimensão latente” (Maroco & Garcia-Marques, 2006: 70).

Pestana e Gageiro (2008) apresenta cinco medidas para analisar a consistência interna:

1. o Alpha de Cronbach (α),
2. o coeficiente de bipartição (*split-half*),
3. os modelos paralelos (*parallel*) e estritamente paralelo (*strictly parallel*),
4. os limites inferiores de *Guttman*, e
5. os coeficientes de correlação intra classe (*intraclass correlation coefficients*).

Neste trabalho será apresentado, com mais detalhes, o Alpha de Cronbach por ser o mais aceite universalmente e por ser considerado, pela maioria dos usuários, como o melhor

estimador de fiabilidade (Maroco & Garcia-Marques, 2006) e por apresentar valor maior que os outros coeficientes (Hill & Hill 2005).

1.5.2. Índice Alpha de Cronbach (α)

Segundo Maroco e Garcia-Marques (2006), o índice Alpha de Cronbach é considerado pela maioria dos investigadores como um índice aceite universalmente para o estudo métrico de uma escala e também por ser visto como o melhor estimador de fiabilidade de uma escala. É utilizado para *estimar* por não ser possível fazer medições precisas de fiabilidade (Hill & Hill, 2005).

Para Pestana e Gageiro (2008), o Alpha de Cronbach, sendo uma medida mais utilizada para verificar a consistência interna de um grupo de variáveis ou itens, defina-se “como a correlação que se espera obter entre a escala usada e outras escalas hipotéticas do mesmo universo, com igual número de itens, que meçam a mesma característica.” (Pestana & Gageiro, 2008: 527, 528)

A expressão matemática proposta por L. J. Cronbach é (Maroco e Garcia-Marques, 2006):

$$\alpha = \frac{k}{(k-1)} \times \left(1 - \frac{\sum_{j=1}^k S_j^2}{S_T^2} \right) \quad (5)$$

Onde k é o nº de itens do instrumento, $S_j^2 = \frac{1}{n-1} \sum_{i=1}^n (X_{ij} - \bar{X}_j)^2$ é a variância do item j ($j=$

$1, \dots, k$) e S_T^2 é a variância dos resultados totais do teste dada por $S_T^2 = \frac{1}{n-1} \sum_{i=1}^n (T_i - \bar{T})^2$ e

$$T_i = \sum_{j=1}^k X_{ij}.$$

Segundo Maroco e Garcia-Marques (2006) a fórmula do Alpha de Cronbach por não levar em consideração a homogeneidade das variâncias-covariâncias inter-itens, tende a subavaliar a fiabilidade total de uma medida. No entanto essa subavaliação pode ser ultrapassada usando, como alternativa, o Alpha de Cronbach standardizado calculado a

partir da correlação média (\bar{r}) dos $k(k-1)/2$ coeficientes de correlação não-redundantes inter-itens (Maroco e Garcia-Marques, 2006):

$$\alpha' = \frac{k \times \bar{r}}{1 + (k-1) \times \bar{r}} \quad (6)$$

1.5.2.1. Interpretações dadas ao índice de Cronbach

Segundo o próprio Cronbach (1951) o Alpha de Cronbach “pode ser interpretado como coeficiente médio de todas as estimativas de consistência interna que se obteriam se todas as divisões possíveis da escala fossem feitas” (Cronbach, 1951, ; Maroco & Garcia-Marques, 2006: 73)

Cortina (1993) interpreta o Alpha como “uma medida estável de fiabilidade pois não está sujeito à variabilidade resultante da forma como o instrumento ou teste é dividido para calcular a fiabilidade *split-half* (Cortina, 1993 ; Maroco & Garcia-Marques, 2006: 73).

Para Maroco e Garcia-Marques (2006) “o (α) é, por vezes, interpretado como uma medida de saturação de um factor comum (ou construto latente) de primeira ordem (i.e., uma medida do grau em que um único fator latente motiva a correlação entre todos os itens de uma escala)” (Maroco & Garcia-Marques, 2006:73)

1.5.2.2. Critérios de fiabilidade estimado pelo Alpha de Cronbach

Segundo Pestana e Gageiro (2008) o (α) varia entre zero (0) e um (1), não assumindo valores abaixo do zero “pois as variáveis, que medem a mesma realidade, devem estar *categorizadas no mesmo sentido*” (Pestana e Gageiro, 2008:528). Entretanto pode assumir valores abaixo de zero quando as correlações inter-itens são, em si, negativas (Maroco & Garcia-Marques, 2006), o que segundo Pestana e Gageiro (2008) viola o modelo de consistência interna. A Tabela 1.2 indica os valores recomendados por diversos autores, para o qual o Alpha de Cronbach é considerado aceitável sob uma determinada condição (Maroco & Garcia-Marques, 2006):

Tabela 1.2: critérios de recomendação de fiabilidade estimada pelo (α) de Cronbach

Autor	Condição	Alpha considerado aceitável
Davis, 1964, p. 24	Previsão individual	Acima de 0.75
	Previsão para grupos de 25-50 indivíduos	Acima de 0.5
Kaplan & Sacuzzu, 1982, p. 106	Investigação fundamental	0.7-0.8
	Investigação aplicada	0.95
	Fiabilidade inaceitável	<0.6
Murphy & Davidsholder, 1988, p. 89	Fiabilidade baixa	0.7
	Fiabilidade moderada a elevada	0.8-0.9
	Fiabilidade Elevada	>0.9
Nunnally, 1978, p. 245-246	Investigação preliminar	0.7
	Investigação fundamental	0.8
	Investigação aplicada	0.9-0.95

Fonte: (Peterson, 1994 ; Maroco & Garcia-Marques, 2006:73)

Segundo Maroco e Garcia-Marques (2006) o valor de fiabilidade estimado pelo (α) tem o significado de nos informar sobre a precisão do instrumento e não ser uma característica do instrumento.

1.5.2.3. Estimativa do Alpha de Cronbach

Apesar do Alpha de Cronbach ser uma estimativa da fiabilidade de uma medida, não deixa de ser insuficiente quando dispomos da inferência estatística que nos permite recorrer, por exemplo, ao intervalo de confiança para estimar o verdadeiro valor de (α) em vez de utilizarmos apenas um valor pontual como estimativa (Maroco & Garcia-Marques, 2006).

Maroco e Garcia-Marques (2006) apresenta um intervalo de confiança exato para Alpha a $(1 - \gamma) \times 100\%$:

$$\left[1 - (1 - \hat{\alpha}) \times f_{1-\gamma/2; [(n-1), (n-1)(k-1)]}; 1 - (1 - \hat{\alpha}) \times f_{\gamma/2; [(n-1), (n-1)(k-1)]} \right] \quad (7)$$

onde $\hat{\alpha}$ é a estimativa amostral do Alpha, $f_{\gamma/2; [(n-1), (n-1)(k-1)]}$ e $f_{1-\gamma/2; [(n-1), (n-1)(k-1)]}$ os quantis da distribuição F-Snedecor nos percentis $\gamma/2$ e $1 - \gamma/2$ com $(n-1)$ e $(n-1)(k-1)$ graus de liberdade respetivamente e com o pressuposto de que os itens tenham distribuição normal multivariada com matriz de variâncias-covariâncias homogéneas.

Para Duhacheck e Iacobucci (2004) esse intervalo de confiança apresenta melhores resultados em comparação com outras fórmulas alternativas, quando as amostras são de tamanho moderada (Duhacheck e Iacobucci, 2004 ; Maroco & Garcia-Marques, 2006).

Também a estimação do Alpha pode ser feita através de um teste de hipóteses dada por (Charter e Feldt, 1996 ; Maroco & Garcia-Marques, 2006):

$$\begin{cases} H_0 : \alpha = \alpha_0 \\ H_1 : \alpha \neq \alpha_0 \end{cases}$$

Usando a seguinte estatística de teste:

$$W = \frac{1 - \alpha_0}{1 - \hat{\alpha}} \sim F[(n-1), (k-1)(n-1)] \quad (8)$$

Regra de decisão:

Se $W \leq f_{\gamma/2; [(n-1), (n-1)(k-1)]}$ ou se $W \geq f_{1-\gamma/2; [(n-1), (n-1)(k-1)]}$ rejeita-se a hipótese nula, para um determinado nível de significância γ .

Caso a formulação do teste de hipóteses for do tipo mais generalizada:

$$\begin{cases} H_0 : \alpha \leq \alpha_0 \\ H_1 : \alpha > \alpha_0 \end{cases}, \text{ então a hipótese nula é rejeitada se } W \geq f_{1-\gamma; [(n-1), (n-1)(k-1)]}.$$

1.5.2.4. Fatores que afetam a magnitude do índice de fiabilidade

Variabilidade inter e intra-sujeito, homogeneidade, heterogeneidade e heteroscedasticidade são fatores que influenciam o valor do Alpha de Cronbach, como se demonstra as citações seguintes:

“A mesma medida, quando administrada a uma amostral de sujeitos mais homogêneos ou mais heterogêneos produzirá scores com diferentes fiabilidades” (Thompson, 2002; Maroco & Garcia-Marques, 2006:76)

“De uma forma geral quanto menor a variabilidade das respostas intra-sujeitos e maior a variabilidade das respostas inter-sujeitos, maior o (α)” (Maroco & Garcia-Marques, 2006: 76)

“[...] o (α) é, geralmente, maior quando existe homogeneidade de variâncias inter-itens do que quando não existe” (Maroco & Garcia-Marques, 2006: 76)

“[...] é assim de esperar que instrumentos de medida com um maior número de itens tenham valores de (α) superiores e de erro-padrão inferiores aos instrumentos com um menor número de itens” (Maroco & Garcia-Marques, 2006: 76)

“[...] a presença de covariâncias heterogéneas não apresenta um efeito considerável sob a estimação do (α) mas aumenta o erro-padrão da estimativa” (Maroco & Garcia-Marques, 2006: 76)

“[...] a heteroscedasticidade de variâncias provoca a redução do (α) com um aumento reduzido do erro-padrão da estimativa” (Duhacheck & Iacobucci, 2004 ; Maroco & Garcia-Marques, 2006: 76)

O Alpha de Crombach é calculado no SPSS por meio dos seguintes comandos: Analyse→Scale→Reliability Analysis→Model=Alpha→Items-→Scale→ Continue→Ok

1.6. Regressão

Nesta fase do capítulo incidiremos sobre o conceito de regressão linear e, principalmente, sobre o modelo de regressão linear múltipla, dado ser a ferramenta estatística principal usado neste trabalho; e verificaremos cada um de seus pressupostos para sua aplicação, através de gráficos e testes.

1.6.1. Regressão linear

O termo *Regressão* segundo Maroco (2011) foi proposto em 1885 por Francis Galton num estudo onde demonstrou e concluiu que a altura dos filhos com relação a dos pais se regredia para a média da população.

Para Pestana e Gageiro (2008) a regressão é um modelo estatístico que permite prever o comportamento de uma variável dependente (ou *Y* ou endógena), sendo esta quantitativa,

a partir de uma ou mais variáveis independentes (ou X 's ou exógena), sendo este (s) do tipo essencialmente intervalo ou rácio; permitindo conhecer a margem de erro dessas previsões.

Maroco (2011) define o termo regressão como: “um conjunto vasto de técnicas estatísticas usadas para modelar relações entre variáveis e prever o valor de uma variável dependente (ou de resposta) a partir de um conjunto de variáveis independentes (ou preditoras)” (Maroco, 2011:673).

Segundo Reis (2012), na tomada de uma decisão sobre uma determinada variável é necessário, muitas vezes, fazer previsões, mas apenas quando se consegue estabelecer uma relação de causa-efeito entre essa variável e uma outra em que se conhece seu comportamento. Para a autora, apurar se a relação que existe entre as duas variáveis é ou não por mero acidente corresponde ao primeiro passo a ser dado no estudo da regressão.

Essa relação entre duas ou mais variáveis, citando Maroco (2011): “pode ser de dependência funcional (*i.e.*, a magnitude da variável dependente é função da magnitude da(s) variável(eis) independente(s), mas o contrário já não se aplica) ou de mera associação (*i.e.*, nenhuma das variáveis pode ser tida como dependente da outra, mas apenas que elas variam em conjunto)” (Maroco, 2011:673).

Quando o modelo possui apenas uma variável independente (X), é denominado por *Regressão Linear Simples* e quando possui pelo menos uma variável X 's, é designado por *Regressão Linear Múltipla* (Pestana & Gageiro, 2008).

1.6.2. Modelo de Regressão Linear Múltipla (Univariado)

A palavra *Univariado* vem do fato de haver apenas uma variável dependente e pelo menos uma variável independente (Maroco, 2011).

Segundo Maroco (2011) a regressão linear pode ser usada para modelar a relação funcional entre duas variáveis podendo ser expressa através de uma função matemática, independentemente de existir ou não uma relação de tipo causa-efeito.

Para Hill e Hill (2005), o objetivo principal da regressão linear múltipla “[...] é prever valores de uma variável dependente a partir de uma combinação ponderada de duas ou mais variáveis independentes” (Hill & Hill, 2005:207)

O modelo de regressão linear múltipla univariado é expressa através da seguinte função matemática dada por (Pestana & Gageiro, 2008):

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_k x_{ik} + \varepsilon_i = \beta_0 + \sum_{j=1}^k \beta_j x_{ij} + \varepsilon_i \quad (9)$$

onde β_j são os coeficientes de regressão; ε_i representa o erro aleatório ou resíduos do modelo que reflete os erros de medição e a variação natural em y . β_0 é a ordenada na origem quando $x_{ij} = 0$ ($i = 1, \dots, n; j = 1, \dots, k$) e β_j ($i = 1, \dots, k$) representa os declives parciais. A reta estimada \hat{y}_i , obtida através do método dos mínimos quadrados, é a que minimiza a soma do quadrado dos resíduos dado por:

$$\hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_{i1} + \hat{\beta}_2 x_{i2} + \dots + \hat{\beta}_k x_{ik} = \hat{\beta}_0 + \sum_{j=1}^k \hat{\beta}_j x_{ij} \quad (10)$$

em que $\hat{\beta}_0$ e $\hat{\beta}_j$ são os parâmetros estimados, obtidos através da seguinte fórmula matricial:

$$\hat{\beta} = (\tilde{X}' \tilde{X})^{-1} (\tilde{X}' y) \quad (11)$$

onde \tilde{X} é a matriz dos coeficientes da regressão (Pestana & Gageiro, 2008).

Quando no modelo existir apenas uma variável preditora ou independente Y , a expressão (9) simplifica-se

$$y_i = \beta_0 + \beta_1 x_{i1} + \varepsilon_i \quad (12)$$

e é denominado por modelo de regressão linear simples (Maroco, 2011).

Para que o modelo de regressão linear múltipla (MRLM) seja utilizado, duas condições são necessárias (Pestana & Gageiro, 2008):

- ✓ Que as variáveis sejam de níveis intervalo ou rácio e que a relação entre elas seja linear e aditiva. No entanto estas restrições não são absolutas, visto que por um lado, as variáveis preditoras de nível qualitativo podem ser introduzidas no modelo através do uso de variáveis artificiais e por outro lado, as relações não lineares e não aditivas podem também ser usadas através de transformações das variáveis originais ou através da introdução do produto de variáveis.
- ✓ Que se cumpra cinco pressupostos, a saber: (1) A normalidade dos resíduos; (2) Homocedasticidade; (3) Outliers e Observações influentes; (4) Autocorrelação; (5) Independência das variáveis preditoras, ou seja, a sua não multicolinearidade.

1.6.2.1. Pressupostos para a aplicação do Modelo de Regressão Linear Multivariado (MRLM)

De seguida são descritos cada pressuposto, enumerados anteriormente, que deverão ser verificados na aplicação do MRLM:

1 - Normalidade dos resíduos

Para analisar a normalidade dos resíduos, quatro formas são possíveis (Pestana & Gageiro, 2008):

- Teste de Kolmogorov-Smirnov com correção de Lilliefors

Esse teste permite testar a normalidade dos resíduos e é obtido no SPSS através dos seguintes comandos:

Analise → Estatísticas descritivas → Explorar (inserir a variável *ZRE_1*) → Gráfico
(selecionar 'Gráfico de normalidade com testes')

A Tabela 1.3 é o *Output* (exemplo) resultante dos comandos acima mencionados e apresenta os níveis de significância do teste de Kolmogorov-Smirnov (K-S) e de Shapiro-Wilk (S-W) iguais a 0.200 e 0.977 respetivamente. Assim para um nível de significância de 5% ou de 10%, ou seja, para um *p-value* > 0.05 ou *p-value* > 0.10, não se rejeita a hipótese

nula da normalidade dos resíduos, pois segundo Maroco (2003) a hipótese de haver normalidade é rejeitada em caso do *p-value ser igual ou inferior ao nível de significância α* .

Tabela 1.3: Testes de Normalidade K-S e S-W

	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Estatística	gl	Sig.	Estatística	gl	Sig.
Standardized Residual	,075	34	,200*	,989	34	,977

*. Este é um limite inferior da significância verdadeira.

a. Correlação de Significância de Lilliefors

Fonte: Elaboração própria

Dado que o teste K-S pressupõe o conhecimento dos parâmetros populacionais e como na maioria das vezes conhecemos apenas as estimativas amostrais desses parâmetros μ e σ , então, segundo Maroco (2003), para haver maior rigor na aplicação da estatística de K-S é feito o uso do teste K-S com correção de Lilliefors, ou seja, é usado “[...] quando comparamos a distribuição de frequências acumuladas das observações da variável com uma distribuição teórica cujas parâmetros foram estimados a partir da amostra” (Lilliefors, 1967; Maroco, 2003: 113)

Segundo Maroco (2003) e Hill e Hill (2005) pode-se utilizar o teste Shapiro-Wilk no caso de amostras pequenas, inferior a 50. Também sublinha, Hill e Hill (2005), ser vantajoso o uso desses testes por não precisarem de uma análise subjetiva por parte do investigador, ainda mais se tiver pouca experiência. A diferença principal entre os dois testes, K-S e S-W, se encontra na *potência* [na eficiência em não aceitar a hipótese nula de que os dados são oriundos de uma distribuição normal], ou seja, segundo Zar (1999) e Torman, Coster e Ribolti (2012) existem muitas situações em que o teste K-S não consegue rejeitar a hipótese nula quando os dados realmente não são oriundos de uma distribuição normal. Assim o S-W é considerado por alguns autores como sendo o teste de normalidade mais poderoso (Mendes & Pala, 2003; Keskin, 2006; Razali & Wah, 2011).


- Gráfico Normal Q-Q Plot

Este gráfico (ver figura 1.4) baseia-se na distribuição de probabilidades

[...] onde no eixo das abcissas se representa a probabilidade observada acumulada dos erros, e no eixo das ordenadas se representa a probabilidade acumulada que se observaria se os erros possuísem distribuição normal. Caso os erros possuírem distribuição normal, então os valores representados no gráfico devem distribuir-se mais ou menos na diagonal principal dos valores observados acumulados dos erros e esperados numa distribuição normal [...]. Uma vez que a maioria dos pontos está mais ou menos em cima da diagonal principal, podemos concluir que os resíduos apresentam, pelo menos aproximadamente distribuição normal.

(Maroco, 2011:694, 704)

Figura 1.4: Gráfico Normal Q-Q Plot



Fonte: Elaboração própria

De acordo com Hill e Hill (2005) existem dois tipos de gráficos alternativos disponíveis no SPSS: O gráfico *Q-Q plot* que está disponível nas opções *Explore* e *Graphs* e o gráfico *P-P plot* que está disponível na opção *Graphs*. Uma das diferenças mais importantes entre os dois gráficos são enumerados por SAS Institute Inc. (1999):

- A construção de um gráfico QQ não requer que os parâmetros de localização ou escala de $F(\cdot)$ [função de distribuição cumulativa específica] sejam especificados. Os quantiles teóricos são calculados a partir de uma distribuição padrão dentro da família especificada. Um padrão de ponto linear indica que a família especificada descreve razoavelmente a distribuição de dados e os parâmetros de localização e escala podem ser estimados visualmente como a intercepção e inclinação do padrão linear. Em contraste, a construção de um gráfico de PP requer os parâmetros de localização e escala de $F(\cdot)$ para avaliar o cdf nos valores de dados ordenados.


- A linearidade do padrão de ponto em um gráfico QQ não é afetada por mudanças na localização ou na escala. Em um gráfico de PP, mudanças na localização ou escala não necessariamente preservam a linearidade.
- Em um gráfico QQ, a linha de referência que representa uma distribuição teórica particular depende dos parâmetros de localização e escala dessa distribuição, tendo interceptação e inclinação iguais aos parâmetros de localização e escala. Em um gráfico de PP, a linha de referência para qualquer distribuição é sempre a linha diagonal $y = x$.

(SAS Institute Inc., 1999)

- Gráfico Detrended Normal Q-Q plot

Este gráfico se assume a normalidade quando as observações se distribuem aleatoriamente à volta da linha horizontal zero (ver figura 1.5).

Figura 1.5: Gráfico Detrended Normal Q-Q plot




Fonte: Elaboração própria

Tanto o gráfico Normal Q-Q plot e Detrended Normal Q-Q plot permitem analisar as observações que se desviam da normalidade (Pestana & Gageiro, 2008).

- Histogramas dos resíduos estandardizados.

Para Pestana e Gageiro (2008) a normalidade dos resíduos significa que existe uma distribuição normal da variável dependente para cada variável independente. A Figura 1.6 é um exemplo de um histograma onde se pode verificar a normalidade dos resíduos estandardizados.

Figura 1.6: Histogramas dos resíduos estandardizados



Fonte: Elaboração própria

2. Homocedasticidade

A homocedasticidade, ou seja, para verificar se a variância dos resíduos é constante,

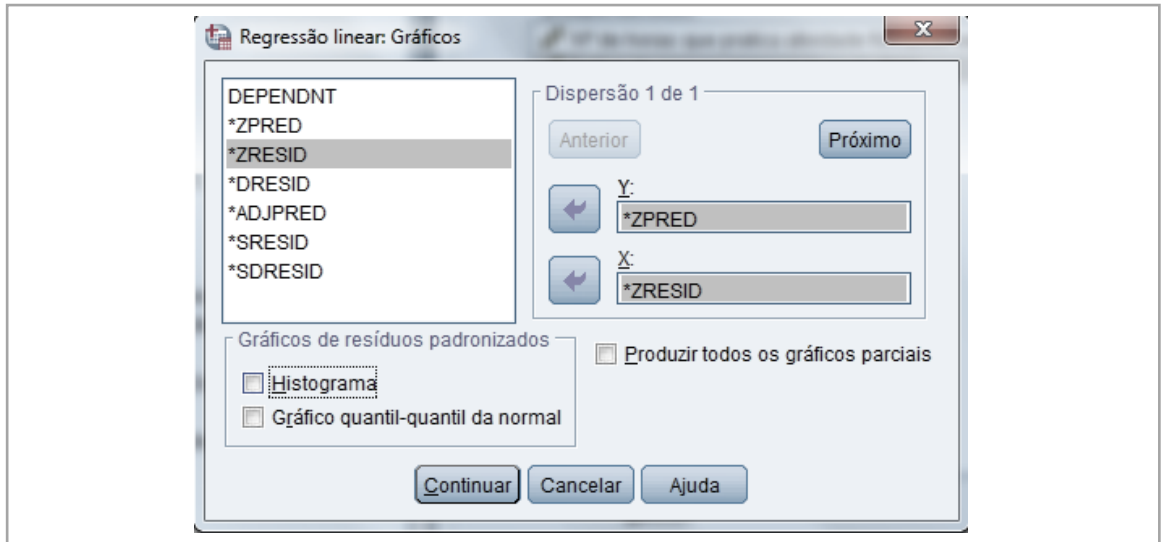
$$V(\varepsilon_i) = \sigma^2, i = 1, 2, \dots, n \quad (13)$$

relaciona-se os resíduos estudentizados *SRESID* com os resíduos estandardizados *ZPRED* (Pestana & Gageiro, 2008).

Essa verificação pode ser feita usando o SPSS Statistics, onde irá produzir um gráfico semelhante ao da Figura 1.8. Mas para que esse gráfico seja gerado, Maroco (2011) sugere que os resíduos estandardizados (*ZPRED*) seja inserida na área Y e os valores estimados estandardizados (*ZRESID*) na área X (ver figura 1.7). Se os resíduos aumentarem ou

diminuirem com os valores da variável independente em torno da linha zero, a constância da variância para cada valor de X pode ser posta em causa.


Figura 1.7: Colocação dos resíduos ZPRED e ZRESID



Fonte: SPSS

A variância constante equivale a supor que não existem observações incluídas na variável residual, para as quais se considera existir uma influência mais intensa na variável dependente (Pestana & Gageiro, 2008).

Figura 1.8: Variação dos resíduos



Fonte: Elaboração própria

3. *Outliers* e Observações influentes

3.1. *Outliers*. O que são?

Para Moore e McCabe (2003), “An outlier is an observation that lies outside the overall pattern of the other observations. Points that are outliers in the y direction of a scatterplot have large regression residuals, but other outliers need not have large residuals” (Moore & McCabe, 2003; Figueiredo Filho *et al.*, 2014:75)

Para Rodrigues e Paulo (2007), “As observações atípicas (ou *outliers*) são observações com uma combinação única de características identificáveis, sendo notavelmente diferentes das outras observações (parecem ser inconsistentes com o restante da amostra)” (Rodrigues & Paulo, 2007 ; Figueiredo Filho *et al.*, 2014:75).

Hawkins (1980) define *outlier* assim: “*as an observation that deviates so much from other observations as to arouse suspicion that it was generated by a different mechanism*” (Hawkins, 1980 ; Figueiredo Filho *et al.*, 2014:75).

Segundo Pestana e Gageiro (2008), “Os *outliers* são observações distintas das demais, que estão associadas a resíduos com valores elevados.” (Pestana & Gageiro, 2008:583)

De acordo com Chandola, Banerjee e Kumar (2007), existem quatro principais motivos que explicam a presença de outliers: (1) atividade maliciosa; (2) erro de instrumento; (3) mudança no meio ambiente e (4) erro humano (Chandola, Banerjee & Kumar, 2007 ; Filho *et al.*, 2014:77).

Cada tipo de motivos que explicam a presença de outliers são ilustradas por Figueiredo Filho *et al.* (2014):

O exemplo típico da atividade maliciosa como gerador de casos desviantes é quando a central do cartão de crédito liga para o indivíduo para confirmar uma determinada compra. O outlier causado por erro de instrumento é aquele que recebe uma determinada característica/atributo muito diferente das demais observações por falha do instrumento. Imagine uma balança desregulada ou um termômetro defeituoso. Se o pesquisador depende desses instrumentos para atribuir valores para os seus casos, ele corre o risco de incluir uma observação destoante em sua amostra. Mudanças abruptas no meio ambiente, como uma tempestade, tendem a produzir observações muito diferentes do esperado. É comum observar esse tipo de ocorrência em reportagens sobre os índices pluviométricos, quando o jornalista afirma que em determinada semana choveu mais do que o esperado para todo o mês. Por fim, o caso destoante gerado por erro humano é um dos mais recorrentes na pesquisa científica. Muitos bancos de dados são efetivamente elaborados por estudantes de graduação e pós-graduação

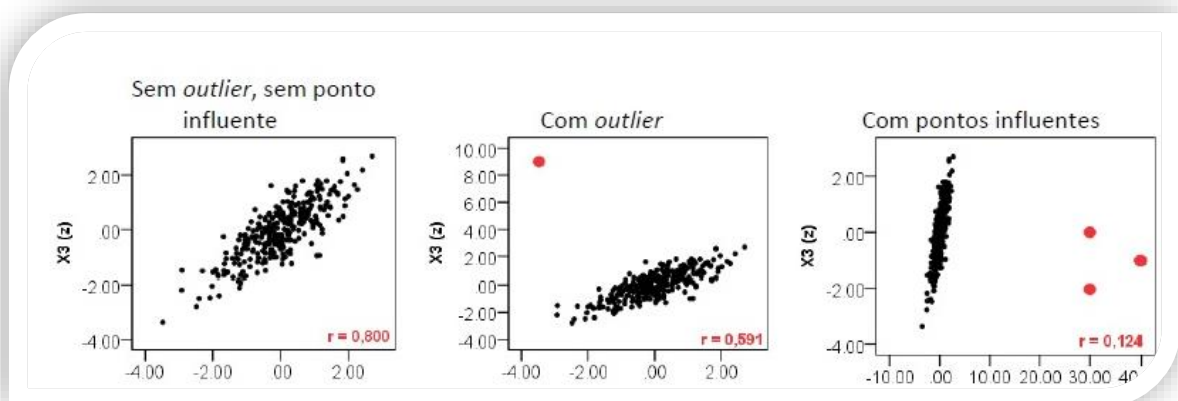
com diferentes níveis de treinamento técnico. Mesmo pesquisadores experientes muitas vezes cometem erros durante o processo de coleta e/ou tabulação de dados.

(Figueiredo Filho *et al.*, 2014:77)

Os *outliers*, segundo Pestana e Cageiro (2008), devem ser identificados, pois caso não derivarem de erros de introdução dos dados, haverá a possibilidade de se poder conhecer características peculiares da população, que de outro modo não seriam possíveis encontrar. Ainda salienta que o fato de na análise univariada poder não ser detetado *outliers* não implica que o mesmo possa acontecer numa análise conjunta, ou seja, com pelo menos duas variáveis.

Figueiredo Filho *et al.* (2014) chama atenção para a diferença que existe na literatura entre *outliers* e pontos influentes: “Analiticamente, *outliers* são destoantes no y (variável dependente), enquanto pontos influentes são destoantes no x (variável independente)” (Figueiredo Filho *et al.*, 2014:78). A Figura 1.9 ilustra essa diferença entre um *outlier* e um ponto influente, usando a mesma distribuição:

Figura 1.9: Correlação, *outliers* e pontos influentes



Fonte: Figueiredo Filho *et al.*(2014)

Dessa figura se conclui que a presença de um único *outlier* levou a que a correlação passasse de $R=0.800$ para $R=0.591$, ou seja a correlação foi subestimada. O mesmo acontece com os pontos influentes que pela sua presença levou a que a associação forte passasse para fraco. Figueiredo Filho *et al.* (2014) chega a seguinte conclusão:

Do ponto de vista puramente estatístico, tanto *outliers* quanto pontos influentes são sempre indesejáveis. No limite, eles podem tanto criar uma falsa correlação entre variáveis que são de

fato independentes quanto esconder uma associação entre variáveis que estão, na realidade, associadas.


(Figueiredo Filho *et al.*, 2014:78)

3.1.1. Como detetar outliers

Pelo uso da estatística descritiva, Figueiredo Filho *et al.* (2014) indica a observação da magnitude do desvio padrão em relação à média como um dos primeiros passos na identificação dos *outliers*. Também sugere que se a distribuição dos dados for muito heterogênea poderá ser um indício da presença de *outliers*. Ainda propõe a utilização do gráfico de dispersão e também do *boxplot* na busca de *outliers*. Com relação ao *boxplot*, caso for visualizado algum círculo acima ou abaixo dos limites das linhas superiores e inferiores podem ser considerados como potenciais *outliers*. Ainda refere à presença de pontos extremos que podem ser identificados quando aparecem acima ou abaixo dos *outliers*. Uma outra forma de visualizar os *outliers* passa pela utilização do histograma e também da variação do coeficiente de determinação (R^2) entre o ajuste dos modelos. Neste caso, pode-se verificar a diferença do R^2 no modelo com todos os casos e outro com a exclusão dos casos considerado *outliers*. “Quanto maior a diferença entre eles, maior é o impacto dos *outliers*” (Figueiredo Filho *et al.* 2014:84)

Em caso da Figura 1.10, pode-se verificar que os casos 95 e 255 são potenciais *outliers* e o caso 4 é tido como um ponto extremo.

Figura 1.10: Boxplot para três variáveis simuladas



Fonte: Figueiredo Filho *et al.* (2014)

Para além do uso de gráficos e do coeficiente de determinação, Figueiredo Filho *et al.* (2014) apresenta, também, alguns testes estatísticos que permite identificar os *outliers* em uma distribuição aproximadamente normal: O teste de Grubbs utilizado para testar a existência de apenas um *outlier*; O teste de Tietjen-Moore utilizado para testar a existência de pelo menos um *outlier*; O teste *generalized extreme studentized deviate* utilizado quando não se sabe a quantidade de *outliers* existente na base de dados; e a distância de Cook, considerado desejável para identificar *outliers*. Também “representa a importância de cada observação para os coeficientes de regressão quando um caso específico é retirado da análise” (Figueiredo Filho *et al.*, 2011, 2014:85).

Figueiredo Filho *et al.* (2014) ainda acrescenta alguns pacotes estatísticos existente no SPSS que fornecem estimativas para identificar e avaliar o impacto dos *outliers*. Por exemplo: DfBeta(s), Standardized DfBeta, DfFit, Standardized DfFit e Covariance ratio.

Uma outra forma de identificar possíveis *outliers* segundo Maroco (2011) é através dos valores centrados *Leverage* que estão classificados assim: (i) valores de *Leverage* inferiores a 0.2 são aceitáveis, (ii) valores entre 0.2 e 0.5 são arriscados, e (iii) valores superiores a 0.5 indicam a presença de um *outlier* multivariado. “Alternativamente para mais de $p > 6$ variáveis e $(n-p) > 12$ pode usar-se o valor $3p/n$ como limite acima do qual se classifica uma observação como *outlier*” (Maroco, 2011: 697).

Segundo Pestana e Gageiro (2008) o uso dos resíduos estandardizados, estudantizados e *estudentized deleted* é essencial para identificar os *outliers* levando em conta uma das três condições (ver tabela 1.4), segundo o nível de significância (erro tipo I):

Tabela 1.4: Condições para identificar *outliers* segundo o nível de significância

	Resíduos estandardizados	Resíduos estudantizados	Resíduos estudantizados deleted
Alpha= 0.01	$ ZRE_1 > 2.576$	$ SER_1 > 2.576$	$ SDR_1 > 2.576$
Alpha= 0.05	$ ZRE_1 > 1.96$	$ SER_1 > 1.96$	$ SDR_1 > 1.96$
Alpha= 0.10	$ ZRE_1 > 1.645$	$ SER_1 > 1.645$	$ SDR_1 > 1.645$

Fonte: adaptado de Pestana e Gageiro (2008)

Para distinguir um *outlier* Hill e Hill (2005) sugere que se verifique qualquer caso cujo resíduo estandardizado esteja fora da gama $\pm 3,00$.

Caso se verifique qualquer observação cujo resíduo é consideravelmente superior, em termos absolutos, aos resíduos das outras observações em, por exemplo, mais de dois desvios-padrão relativamente á média então é um *outlier* (Maroco, 2011).

Para Figueiredo Filho *et al.* (2014) não se pode simplesmente excluir um *outlier* da base de dados e sugere que em caso de dúvida sempre se pode consultar manuais aplicados e ou também solicitar apoio de investigadores mais experientes.

Pestana e Gageiro (2008) sugere que os *outliers* só deverão ser excluídos se houver evidência que não são membros válidos da população ou caso não haja justificação teórica para mantê-los.

Para Hill e Hill (2005) os *outliers* podem influenciar os resultados de uma regressão múltipla, mas não necessariamente. Entretanto, excluir os *outliers* da base de dados é algo aceitável, pelo que em seguida deverá ser feita uma nova análise dos dados.

Figueiredo Filho *et al.* (2014) sugere a utilização de diferentes métodos para identificar a existência de *outliers* e poder estimar o impacto que terão na consistência e eficiência das estimativas. Esses métodos são utilizados caso forem descartados erros na base de dados.

Qualquer que seja o método utilizado na identificação dos *outliers* é importante realizar duas análises multivariadas, ou seja, uma com todos os casos presentes na base de dados e outra com a exclusão dos casos identificados como *outliers*. Caso os resultados das estimativas das duas análises se mostrarem muito diferentes é sinal de que o *outlier* produz grande impacto. Do contrário o *outlier* terá um efeito menor sobre a consistência e eficiência das estimativas (Afifi & Clark, 1999 ; Figueiredo Filho *et al.*, 2014).

Segundo Maroco (2011) os efeitos dos *outliers* sobre a estimação dos coeficientes de regressão podem ser de dois tipos: (1) moderados, se estiverem no meio do domínio das observações e (2) extremos, se estiverem próximos dos limites do domínio das observações.

3.2. Observações influentes

Segundo Belsley, Kuh e Welsch (1980) as observações influentes “são aquelas que individualmente ou em conjunto com outras observações demonstram ter maior impacto, do que as restantes observações, no cálculo do valor dos vários estimadores (coeficientes, erros padrões, valores do teste t , valores previstos, resíduos e testes estatísticos)” (Belsley, Kuh & Welsch, 1980 ; Pestana & Gageiro, 2008: 585)

Pestana e Gageiro (2008) sugere seis medidas de diagnóstico na identificação das observações influentes: “

1. **Leverage** – (LEV_1), varia entre [0; 1]. Para uma dada observação i , um leverage elevado indica que essa observação se distancia do centro das observações, exercendo influencia no valor previsto \hat{Y}_i . Mas quanto maior for o leverage, menor é o valor dos resíduos (ℓ_i ou RES_1), pelo que uma observação com um elevado leverage só será influente se o seu resíduo não for pequeno. Assim, um elevado leverage implica apenas que essa observação poderá ser influente. Considera-se um leverage elevado quando:

$$LEV_1 > \frac{3 \times (k + 1)}{n}; \text{ para } n \leq 30 \quad (14)$$

$$LEV_1 > \frac{2 \times (k + 1)}{n}; \text{ para } n > 30 \quad (15)$$

Onde n é a dimensão da amostra e k o número de variáveis exógenas.

2. **SDFBETA** – ($SDFBO_1$; $SDFB1_1$) É uma medida estandardizada que corresponde à alteração nos coeficientes estimados $(\hat{\beta}_0; \hat{\beta}_1)$ quando se exclui a observação i .

Uma observação é **influyente** quando:

$$|SDFBETA| > 1.96; \text{ para } n \leq 30 \quad (16)$$

$$|SDFBETA| > \frac{2}{\sqrt{n}}; \text{ para } n > 30 \quad (17)$$

3. **SDFFIT** – É uma medida estandardizada que corresponde à alteração nos valores previstos \hat{Y}_i quando se exclui a observação i . Uma observação é **influyente** quando:

$$|SDF_1| > 2 \times \sqrt{\frac{k + 1}{n - k - 1}} \quad (18)$$

4. **Distancia de Cook** – (COO_1) Mede o impacto combinado da observação i nos coeficientes estimados $(\hat{\beta}_0; \hat{\beta}_1)$. Quanto maior for a distancia de Cook maior serão os resíduos (ℓ_i ou RES_1). Uma observação é **influyente** quando:

$$COO_1 > \frac{4}{n - k - 1} \quad (19)$$

5. **Rácio de covariância** – (*COV_1*) Mede a influencia da exclusão da observação *i* na variância estimada dos coeficientes estimados $(\hat{\beta}_0; \hat{\beta}_1)$. O rácio de covariância assume valores elevados quando (*LEV_1*) é elevado, e assume valores pequenos quando os resíduos *SDR_1* são elevados. Uma observação é **influyente** quando:

$$|COV_1 - 1| > \frac{3 \times (k + 1)}{n} \quad (20)$$

6. **Distancia de Mahalanobis** – (*MAH_1*) Mede a influencia de uma observação *i* em relação ao valor médio de todas as observações das variáveis exógenas e não o impacto nos valores previstos. Valores substancialmente maiores que os restantes indiciam observações influyentes.”

(Pestana & Gageiro, 2008: 586,587)

A **distancia DfFits**, dado por Myers (1986):

$$DfFits_j = \frac{\hat{y}_j - \hat{y}_{j,-j}}{\sqrt{QME_{-j} \times h_{jj}}} \quad (21)$$

onde $\hat{y}_{j,-j}$ é o valor estimado para o caso x_{ij} e *QME* é a estimativa da variância do modelo quando o ajustamento dos coeficientes é feito sem o caso *j*.

Segundo Maroco (2011), essa medida é a mais utilizada e valores superiores a 2, em termos absolutos, devem ser considerados com precaução. Entretanto Belsley, Kuh e Welsch (1980) sugerem que “o valor 2 deve ser usado apenas para amostras de dimensões moderada e que um valor de ‘decisão’ mais apropriado para classificar uma observação como influyente na análise é $2 \times \sqrt{p/n}$.” (Belsley, Kuh e Welsch, 1980 ; Maroco, 2011: 698)

Essas medidas são obtidas no SPSS através do subcomando **Salvar da Analise de Regressão Linear**.

4. **Autocorrelação**

O pressuposto de autocorrelação significa verificar a existência de independência das variáveis aleatórias residuais, ou seja, se a covariância é nula (Pestana & Gageiro, 2008).

Para testar a hipótese de que a covariância é nula Pestana e Gageiro (2008) sugere a utilização do teste Durbin-Watson, com a seguinte formulação das hipóteses:

$$\begin{cases} H_0 : \rho = 0 \\ H_1 : \rho \neq 0 \end{cases}, \text{ onde } \rho \text{ é a autocorrelação dos resíduos.}$$

Segundo Pestana e Gageiro (2008), para testar a não autocorrelação (ρ) dos resíduos é utilizado a tabela de Durbin-Watson que é composta por amostras cujo tamanho varia de $n = 6$ a $n = 200$ e com um número de variáveis exógenas variando entre $k = 1$ a $k = 10$, sendo d_L o valor crítico inferior e d_U o valor crítico superior.


Na Tabela 1.5 Maroco (2011) apresenta a tabela de Durbin-Watson para até 15 variáveis exógenas:

Tabela 1.5: Tabela de Durbin-Watson

ρ n		Valores críticos de d_L e d_U para $\alpha = 0.05$													
		1		2		3		4		5		10		15	
		d_L	d_U	d_L	d_U	d_L	d_U	d_L	d_U	d_L	d_U	d_L	d_U	d_L	d_U
6		0.61	1.40												
10		0.88	1.32	0.70	1.64	0.53	2.02	0.38	2.41	0.24	2.82				
20		1.20	1.41	1.10	1.54	1.00	1.68	0.89	1.83	0.79	1.99	0.34	2.89	0.06	3.68
30		1.35	1.49	1.28	1.57	1.21	1.65	1.14	1.74	1.07	1.83	0.71	2.36	0.39	2.94
40		1.44	1.54	1.39	1.60	1.34	1.66	1.29	1.72	1.23	1.70	0.95	2.15	0.68	2.56
50		1.50	1.59	1.46	1.63	1.42	1.67	1.38	1.72	1.34	1.77	1.11	2.05	0.88	2.35
60		1.55	1.62	1.51	1.65	1.48	1.69	1.44	1.73	1.41	1.77	1.22	1.98	1.03	2.28
70		1.58	1.64	1.55	1.67	1.53	1.70	1.49	1.74	1.46	1.77	1.31	1.95	1.14	2.15
80		1.61	1.66	1.59	1.69	1.56	1.72	1.53	1.74	1.51	1.77	1.37	1.93	1.22	2.09
90		1.64	1.68	1.61	1.70	1.59	1.73	1.57	1.75	1.54	1.78	1.42	1.91	1.29	2.06
100		1.65	1.69	1.63	1.72	1.61	1.74	1.59	1.76	1.57	1.78	1.46	1.90	1.35	2.03
200		1.76	1.78	1.75	1.79	1.74	1.80	1.73	1.81	1.72	1.82	1.67	1.87	1.61	1.93

Fonte: (Maroco, 2011:700)

O diagrama explicativo bem como as regras para a tomada de decisão é dado por Pestana e Gageiro (2008):



Região de Aceitação (RA) = $[d_U; 4 - d_U]$ \rightarrow autocorrelação nula, $\rho = 0$.

Região Crítica (RC) = $[0; d_L]$ → autocorrelação positiva.

Região Crítica (RC) = $[4 - d_L; 4]$ → autocorrelação negativa.

Uma outra regra de tomada de decisão também é apresentada por Pestana e Gageiro (2008):

- Se o valor de Durbin-Watson estiver próximo de 2, então a autocorrelação dos resíduos é nula;
- Quando o valor de Durbin-Watson for próximo de 0 significa uma autocorrelação positiva;
- Caso o valor de Durbin-Watson estiver próximo de 4, então existe uma autocorrelação negativa.

Segundo Maroco (2011), se o valor de Durbin-Watson for aproximadamente igual a 2 então a autocorrelação entre os resíduos é inexistente. Se for muito inferior a 2 estamos na presença de uma autocorrelação positiva aumentando assim o erro tipo I nos testes à significância dos coeficientes de regressão, por causa da subestimação dos erros-padrão desses coeficientes. Se for muito superior a 2 a autocorrelação é negativa, aumentando assim o erro tipo II por causa da sobrestimação dos erros-padrão dos coeficientes de regressão. Ainda desaconselha o uso do método dos mínimos quadrados tradicional e propõe o uso do método dos mínimos quadrados ponderados, quando existir um forte autocorrelação entre os resíduos.

O valor de Durbin-Watson pode ser localizado na tabela *Model Summary* produzido pelo SPSS.

5. Multicolinearidade

Segundo Hill e Hill (2005) na regressão múltipla assume-se que as variáveis preditoras não estão relacionadas umas com as outras e aponta a razão:

O coeficiente de regressão β_i da equação estimada associado a uma variável independente mede o efeito dessa variável na variável dependente. Isto significa que quando na variável independente (i) há um aumento de uma unidade, a variável dependente aumenta, em média, β_i unidades. Mas esta medida só está correta se esta variável independente não estiver

correlacionada com nenhuma das outras variáveis independentes usadas para explicar o comportamento da variável dependente. Caso contrário, o aumento de uma unidade na variável independente tem também repercussões nas outras variáveis independentes com ela correlacionadas, as quais, por sua vez, vão também influenciar o comportamento da variável dependente.

(Hill & Hill, 2005:239)

Segundo Hill e Hill (2005) caso a correlação entre as variáveis preditoras se verificar e for capaz de influenciar o comportamento da variável dependente é um sinal da existência de multicolinearidade, e, portanto, para Pestana e Gageiro (2008), maiores serão as modificações que ocorrerão nas estimativas dos coeficientes caso for introduzida variáveis no modelo.

Segundo Pestana e Gageiro (2008) quando houver muitos *valores próprios* próximos de zero significa que existe uma forte correlação entre as variáveis, levando a que pequenas variações nos dados possam conduzir a grandes variações nos coeficientes estimados.

Na regressão linear múltipla se pressupõe que as variáveis preditoras são linearmente independentes, ou seja, não existe multicolinearidade; significando que cada coeficiente é obtido à custa das observações de apenas uma variável, pelo que se for inserida ou excluída do modelo uma outra variável não se verificará alterações nas estimativas dos restantes parâmetros do modelo (Pestana e Gageiro, 2008).

Segundo Hill e Hill (2005) um pressuposto da análise de regressão é que todas as variáveis sejam métricas. Mas é possível aplicar a técnica quando uma variável independente é nominal ou categórica. A esta variável dá-se o nome de 'variável *dummy*'.

5.1. A multicolinearidade no SPSS Statistics

A multicolinearidade é analisada depois de aplicar os seguintes comandos:

Regression-→Linear-→Statistics-→Collinearity diagnostics.

Segundo Hill e Hill (2005) o SPSS apresenta, para cada variável independente, duas medidas de multicolinearidade: a *tolerância* e o *VIF (Variance Inflation Factor)*. As duas medidas são inversas uma da outra, ou seja, $VIF_i = 1/Tol_i$ (i = variável independente), sendo a tolerância

dada por Pestana e Gageiro (2008): Tolerância de $X_a = 1 - R_i^2$ onde X_a é uma variável explicativa e R_i^2 é o coeficiente de determinação entre X_a e as outras variáveis explicativas. A tolerância mede o grau em que uma dada variável preditora é explicada por todas as outras variáveis preditoras. O seu valor varia entre 0 e 1. Quanto mais próximo estiver de 0 (de 1) maior (menor) será a multicolinearidade entre a variável e as restantes variáveis preditoras. O valor usualmente considerado como limite abaixo (acima) do qual a multicolinearidade é inaceitável é 0.1 para a tolerância (10 para a estatística *VIF*). Variáveis com valores de tolerância muito reduzidos devem ser excluídas.

Pestana e Gageiro (2008) também coloca como limite para a qual existe a multicolinearidade o valor de 0.1, onde $R^2 = 0.9$ e $R = 0.95$. Também indica que “O SPSS define por defeito 0.0001 como o nível de tolerância mínimo abaixo do qual a variável independente é excluída do modelo por estar fortemente correlacionada com as outras variáveis independentes” (Pestana & Gageiro, 2008:603)

Segundo Hill e Hill (2005), um valor de *VIF* igual ou superior a 10,00 indica um grau inaceitável de multicolinearidade. Também caso as variáveis preditoras tiver um valor de *VIF* perto de 10,00 pode-se concluir que o problema de multicolinearidade não é muito grave.

Para analisar o efeito da multicolinearidade entre as variáveis preditoras, o SPSS apresenta o *condition index* e a matriz de *regression coefficient variance-decomposition* que avalia o efeito da multicolinearidade na equação de regressão estimada. Combinando estes dois conceitos procede-se do seguinte modo (Hill & Hill, 2005):

1. Identificam-se todos os *condition index* acima de um valor pré-definido, geralmente entre 15 e 30 (o mais usual é a utilização de 30);

Segundo Pestana e Gageiro (2005) “O *Condition index* fornece o tamanho relativo da matriz dos valores próprios através da raiz quadrada do quociente entre o maior valor próprio e cada um dos valores próprios” (Pestana & Gageiro, 2005:259). Caso o valor do *Condition index* for maior do que 15 é a indicação de um possível

problema de multicolinearidade e caso for maior do que 30 indica sérios problemas de multicolinearidade (Pestana & Gageiro, 2008).

2. Para todos os *condition index* que excedem o valor pré-definido, identificam-se os parâmetros com proporção de variância superior a 50%;

Segundo Pestana e Gageiro (2008) a proporção de variação indica a proporção de variância para cada um dos parâmetros estimados que é atribuída a cada valor próprio. “Os valores próprios medem a quantidade de variância contida na matriz de correlações [...]” (Pestana & Gageiro, 2005:258)

3. A multicolinearidade entre as variáveis preditoras tem influencia inaceitável na equação de regressão estimada quando um *condition index*, identificado no ponto 1, contribui numa proporção considerável de variância (90%, ou mais) para dois ou mais parâmetros.

Para Pestana e Gageiro (2008) a intensidade da multicolinearidade é elevada quando simultaneamente o *condition index* é maior que 30, e quando uma componente contribui substancialmente (em 90% ou mais) para a variância de duas ou de mais variáveis.

A intensidade de multicolinearidade, segundo Pestana e Gageiro (2008) é analisada através: (1) da correlação entre as variáveis preditoras; (2) do valor da tolerância; (3) do valor do *VIF*; (4) do *condition index* e (5) da *variance proportion*.

Caso as variâncias dos coeficientes, inicialmente, forem elevadas e depois de excluir uma ou mais variáveis do modelo, se os desvios padrões das restantes variáveis preditoras diminuïrem, então é um indicativo da existência de multicolinearidade. Mas se os valores dos desvios padrões se mostrarem semelhantes de um modelo para outro, é um indicativo de não multicolinearidade (Pestana & Gageiro, 2008).

Segundo Pestana e Gageiro (2008), quando os coeficientes de correlações parciais entre cada variável explicativa e a variável dependente forem baixas é um indicativo de que existe uma forte dependência linear entre as variáveis preditoras (*X*'s). Entretanto, se esses coeficientes, em termos absolutos, forem superiores a 0.9 é sinal da presença de

multicolinearidade. Mas garantir a não multicolinearidade pelo facto de não existirem elevados coeficientes de correlação entre as variáveis preditoras é insuficiente.

1.7. Inferência e escolha do modelo

Nesta parte deste capítulo abordaremos a análise de variância, a inferência aos coeficientes do modelo, o coeficiente de determinação e os métodos de seleção dos preditores.

1.7.1. Inferência sobre o modelo de regressão

Segundo Maroco (2011), depois de obter as estimativas b_0, \dots, b_p é necessário avaliar o quão as variáveis preditoras influenciam quantitativamente a variável dependente na amostra e cuidar de verificar três aspetos: (1) verificar se na população essa relação continua a existir; (2) verificar se pelo menos uma variável preditora influencia a variável dependente (Y); (3) em caso de haver variáveis influenciadoras, verificar em que percentagem o modelo ajustado explica a variação observada em Y .

1.7.2. Análise de variância

O que se pretende com a análise de variância é verificar se pelo menos um dos coeficientes do modelo seja diferente de zero na população ($\beta_i \neq 0$) de onde a amostra foi extraída. Para isso é feita a inferência, a partir de estimativas amostrais, para verificar se na população existe alguma variável independente que influencia a variável dependente, ou seja, se é ou não significativo o modelo ajustado (Maroco, 2011).

Essa hipótese é formulada da seguinte forma (Maroco, 2011):

$$\begin{cases} H_0: \beta_1 = \beta_2 = \dots = \beta_p = 0 \\ H_1: \exists i: \beta_i \neq 0 (i = 1, \dots, p) \end{cases}$$

(H_1 lê-se assim: *existe pelo menos um i tal que β_i é diferente de zero*)

Segundo Maroco (2011), essas hipóteses são testadas dividindo em duas componentes aditivas (SQR – Soma dos Quadrados dos Resíduos – que é explicada pelo modelo ajustado

e SQE – Soma dos Quadrados dos Erros – que é explicada pelos erros) a variabilidade total em Y (SQT – Soma dos Quadrados Totais dos desvios – que é expressa pela soma dos desvios de Y com relação a \bar{Y}), expressa matematicamente por:

$$\underbrace{\sum_{j=1}^n (Y_j - \bar{Y})^2}_{SQT} = \underbrace{\sum_{j=1}^n (\hat{Y}_j - \bar{Y})^2}_{SQR} + \underbrace{\sum_{j=1}^n (Y_j - \hat{Y}_j)^2}_{SQE} \quad (22)$$

Segundo Maroco (2011) o modelo ajustado é considerado significativo caso a fração da variância total em Y explicada pelo modelo de regressão for significativamente maior do que a proporção da variância total não explicada pelo modelo. Para estimar a variância explicada pela regressão divide-se a *SQR* pelo número de variáveis preditoras no modelo (g.l) e para estimar a variância dos erros divide-se a *SQE* pelos respetivos graus de liberdade ($p - n - 1$), sendo a estatística de teste dada por:

$$F = \frac{SQR/p}{SQE/(n-p-1)} = \frac{QMR}{QME} \quad (23)$$

onde *QMR* representa os quadrados médios da regressão, *QME* representa os quadrados médios dos erros, *F* é a estatística de teste com distribuição *F*-Snedecor com ($p - n - 1$) e *p* graus de liberdade.

No SPSS Statistics cada parte no cálculo da estatística de teste é resumido em uma tabela designada de ANOVA da regressão (tabela 1.6). Também é produzido o *p-value* que está associado à estatística de teste e caso o *p-value* $\leq \alpha$, não se aceita a hipótese nula, $H_0: \beta_1 = \beta_2 = \dots = \beta_p = 0$, querendo isto dizer que pelo menos um dos β_i é significativamente diferente de zero, ou seja, uma das variáveis preditoras possui um efeito significativo sobre a variação da variável dependente (Maroco, 2011).

Tabela 1.6: Anova de regressão

Fonte de Variação	SQ	g.l	QM	F
Regressão	$\sum_{j=1}^n (\hat{Y}_j - \bar{Y})^2$	p	SQR/p	QMR/QME
Erros	$\sum_{j=1}^n (Y_j - \hat{Y})^2$	$n - p - 1$	$SQE/(n - p - 1)$	
Total	$\sum_{j=1}^n (Y_j - \bar{Y})^2$	$n - 1$		

Fonte: Maroco, 2011

1.7.3. Testes aos coeficientes do modelo de regressão

A formulação de hipóteses na página anterior, segundo Maroco (2011) apenas nos leva a concluir que existe pelo menos um coeficiente que seja significativamente diferente de zero, mas é necessário identificar qual ou quais dos coeficientes é diferente de zero. Para tal deve ser feito múltiplos testes aos coeficientes do modelo, β_i .

As hipóteses estatísticas para cada coeficiente são:

$$\begin{cases} H_0: \beta_i = k \\ H_1: \beta_i \neq k (i = 1, \dots, p) \end{cases}$$

com $k=0$ e a estatística de teste é dada por (Maroco, 2011):

$$T_{\beta_i} = \frac{\hat{b}_i - k}{\sqrt{S_{y..x}^2 \times C_{ii}}} \quad (24)$$

onde \hat{b}_i é a estimativa de β_i , $S_{y..x}^2 = QME$ é a estimativa da variância do modelo e C_{ii} é o elemento i da diagonal da matriz $(\tilde{X}'\tilde{X})^{-1}$ correspondente a β_i .

O *SPSS Statistics* produz o *p-value* que permite rejeitar a hipótese nula caso *p-value* $\leq \alpha$.

Mas Maroco (2011) chama atenção para o seguinte:

Se bem que o teste *t-Student* apresentado seja válido para cada uma das variáveis, uma de cada vez, a extrapolação para qual ou quais das variáveis, influenciam em simultâneo a variável dependente não é válida. Note que a estatística de teste T_{β_i} é obtida para cada β_i assumindo que apenas a variável independente correspondente a β_i entra no modelo (*i.e.*, mantendo as

outras variáveis independentes constantes). Para testar a influencia de uma das variáveis independentes sobre a variável dependente não descartando a influencia que outra ou outras variáveis independentes teriam sobre a variável dependente é necessário considerar um nível de significância de α/p e não α .

(Maroco, 2011:683)

1.7.4. Coeficiente de determinação

O coeficiente de determinação (R^2), é dada pela expressão,

$$R^2 = \frac{SQR}{SQT}, \quad (25)$$

e segundo Maroco (2011), é utilizado para medir a “proporção da variabilidade total que é explicada pela regressão ($0 \leq R^2 \leq 1$) ou de modo equivalente a proporção da variabilidade total de Y que é atribuível à dependência do Y de todos os X_i , como definido pelo ajustamento do modelo de regressão aos dados” (Maroco, 2011:683).

Segundo Pestana e Gageiro (2008), o coeficiente de determinação indica a percentagem de variação de uma variável explicada pela outra e quanto mais perto de um (1) maior a percentagem da variação de uma variável que é explicada pela outra e quanto mais perto de zero (0) menor é essa percentagem da variação.

Maroco (2011), indica um $R^2 > 0.9$ como sendo um indicador de um bom ajustamento do modelo em caso das ciências exatas e em caso das ciências sociais indica um $R^2 > 0.5$ como um indicador de qualidade do ajustamento.

Para Pestana e Gageiro (2008) o coeficiente de determinação é “uma medida otimista da qualidade do ajustamento feito”, mas “tende a ser influenciado pela dimensão da amostra e pela dispersão existente nos dados” (Pestana & Gageiro, 2008:568).

O coeficiente de determinação (R^2) só pode ser usado para comparar modelos que diferem relativamente quanto ao número de variáveis preditoras presentes no modelo, pois a inserção de mais uma variável preditora tende a aumentar o coeficiente, independentemente de esta variável possuir influencia reduzida ou não sobre a variável dependente (Maroco, 2011).

Em alternativa ao coeficiente de determinação (R^2), Maroco (2011) indica o uso do coeficiente de determinação ajustado (R_a^2) podendo ser visto como sendo melhor estimador de qualidade do ajustamento do modelo e melhor estimador do coeficiente de determinação na população, para além de ser visto como uma medida capaz de generalizar o modelo para outras amostras oriundas da mesma população.

O coeficiente de determinação ajustado é utilizado com mais frequência quando os modelos têm pelo menos uma variável preditora (Pestana & Gageiro, 2008).

Uma outra diferença apontada por Maroco (2011) é que a inserção de uma nova variável preditora apenas faz aumentar o (R_a^2) caso essa variável levar a um melhor ajustamento do modelo, ou seja, se relativamente à variância total (QMT) a variância dos erros diminuir (QME).

A expressão matemática do (R_a^2) é dada por (Zar, 1999 ; Maroco, 2011:684):

$$R_a^2 = 1 - \frac{QME}{QMT} = 1 - \frac{n-1}{n-p-1} (1 - R^2) = R^2 - \frac{p(1 - R^2)}{n-p-1} \quad (25)$$

A inferência sobre o coeficiente de determinação na população (ρ^2) pode ser feita usando a estatística de teste dada por (Zar, 1999 ; Maroco, 2011:684):

$$F = \frac{R^2}{1 - R^2} \times \frac{n - p - 1}{p} \quad (26)$$

que segundo Maroco (2011) não passa de uma forma alternativa de

$$F = \frac{QMR}{QME} \quad (27)$$

A formulação da hipótese é apresentada de duas formas por serem equivalentes (Maroco, 2011):

$$\begin{cases} H_0: \rho^2 = 0 \\ H_1: \rho^2 \neq 0 \end{cases} \leftrightarrow \begin{cases} H_0: \beta_1 = \beta_2 = \dots = \beta_p = 0 \\ H_1: \exists i: \beta_i \neq 0 (i = 1, \dots, p) \end{cases}$$

1.7.5. Métodos de seleção de preditores

Segundo Maroco (2011), para escolher quais as variáveis preditoras que possam constar do modelo final da regressão, existe no SPSS, três métodos de seleção sequencial dessas variáveis: seleção *Forward*, seleção *Backward* e seleção *Stepwise*.

A utilização dos três métodos em simultâneo é um procedimento aconselhável para verificar quais as variáveis são melhores candidatas ao modelo final. Os modelos obtidos com estes métodos podem ser avaliados comparando os valores do R_a^2 e o *QME*. O modelo com maior R_a^2 e menor *QME* pode ser considerado o melhor (Maroco, 2011).

A diferença entre esses métodos é descrita a seguir:

Seleção *Forward*:

Este método parte da suposição de que não existe nenhuma variável preditora no modelo, apenas a constante (β_0). O procedimento é adicionar uma variável de cada vez, sendo a primeira (X_1) a inserir aquela com maior correlação com a variável resposta. Com essa variável adicionada ao modelo é calculado a estatística *F* para testar se ela é realmente significativa para o modelo. A variável entra no modelo se *F* for maior do que um valor crítico de entrada (F_{Entry}). Geralmente se usa $F_{Entry}=2$ e $\alpha=5\%$ ou 10% . Pressupondo que X_1 foi selecionado, o próximo passo é encontrar uma variável que, na presença da primeira, possui maior correlação com a variável resposta (Y). Esta é chamada de correlação parcial e é a correlação dos resíduos do modelo ajustado $\hat{y} = b_0 + b_1X_{1j}$ com os resíduos do modelo ajustado com outras variáveis $\hat{X}_{ij} = a_0 + a_1X_{1j}$. Supondo que a maior correlação parcial com Y seja X_2 , então um maior acréscimo da estatística *F* parcial é dado por:

$$F = \frac{QMR(X_2 | X_1)}{QME(X_1, X_2)} \quad (28)$$

Caso o novo $F > F_{Entry}$ ou possuir $p\text{-value} < \alpha$, a variável X_2 então é selecionada para o modelo. Assim, todas as variáveis cujo o valor $F > F_{Entry}$ serão inseridas no modelo até que não haja nenhuma que satisfaça essa condição (Maroco, 2011).

Seleção Backward:

Enquanto o método *Forward* começa sem nenhuma variável no modelo e com um determinado critério é adicionado variáveis, o método *Backward* faz o caminho oposto. Este método inicia-se com todas as variáveis preditoras e depois, por etapas, cada uma pode ser ou não excluída do modelo.

Para cada variável preditora é calculada a sua estatística F parcial, dada por:

$$F = \frac{QMR(X_k | X_1, K, X_{k-1})}{QME} \quad (29)$$

A variável com menor valor de F parcial (ou com maior $p\text{-value}$) é comparada com um valor crítico $F_{Removal}$ e caso $F < F_{Removal}$, essa variável é removida do modelo. No próximo passo ajusta-se novamente o modelo, agora com as $p - 1$ variáveis. As estatísticas F parciais são calculadas para esse modelo e o processo é repetido e termina até que todas as variáveis presentes no modelo tenham $F > F_{Removal}$ (Maroco, 2011).

Seleção Stepwise:

Este método é como uma junção dos métodos *Forward* e *Backward* em que na primeira etapa inicia-se com uma variável independente, mas o critério para se inserir cada variável no modelo é como no *Backward*.

O procedimento é iniciar com uma variável, aquela com maior correlação com a variável resposta. A cada passo (como o método *Forward*), depois de incluir uma variável, aplica-se o *Backward* para decidir sobre a exclusão de variáveis. O processo continua até que não haja nenhuma variável a ser incluída ou excluída.

Assim, o método *Stepwise* requer dois valores de corte: F_{Entry} e $F_{Removal}$ sendo $F_{Entry} = F_{Removal} = 4$, um valor usado com muita frequência. Também pode-se fazer o uso dos níveis

de significância, usando $\alpha = 0.05$ para o valor de F_{Entry} e $\alpha = 0.10$ para o valor de $F_{Removal}$. Este método é especialmente utilizado quando as correlações entre as variáveis exógenas existirem e forem significativas (Maroco, 2011).

Capítulo 2
Opções Metodológicas

2.1. Metodologia

Neste capítulo trataremos de expor a metodologia do trabalho, ou seja, explicar a forma como os dados foram recolhidos, trabalhados e analisados. Apresentaremos, também, todas as variáveis abreviadas, devidamente descritas e codificadas. Este capítulo está subdividido em quatro tópicos: recolha de dados, base de dados, uniformização da base de dados e análise dos dados.

2.2. Recolha de dados

Para este estudo utilizou-se uma base de dados gentilmente cedida pela Professora Doutora Maria Teresa Restivo em um ficheiro Excel de três folhas, uma para os dados das pregas cutâneas, outra para as restantes medições realizadas e informações recolhidas e outra com a descrição das variáveis (tabela 2.7). Tal ficheiro contém informações sobre o estado de saúde, capacidade cognitiva, estado nutricional, ingestão alimentar (etanol e cafeína), exercício físico, variáveis socio-demográficas e medições antropométricas peso, altura e as pregas cutâneas tricipital, subescapular, bicipital, iliocristal, supraespinal, abdominal, crural e geminal.

Definiram-se como critérios de exclusão a existência de pacemaker, a amputação *major*, lipodistrofia, paquidermia e terapias dialíticas, visto tratarem-se de situações que inviabilizam a realização do exame de BIA ou diminuem a sua validade, segundo Kyle *et al.*, (2004). A avaliação da composição corporal e de estado de hidratação foi efetuada por BIA tetrapolar (modelo Tanita Multi Frequency Body Corporation Analyser MC – 180 MA).

As medições das pregas foram realizadas em cento e oitenta pontos distribuídos pelo corpo e foram feitas com o sistema LipoTool. De forma a obter uma melhor caracterização da amostra procedeu-se, também, à avaliação da capacidade muscular por dinamometria.

Para a recolha dessas informações foi aplicado um questionário a 66 estudantes e funcionários da Universidade do Porto que forneceram o consentimento livre e informado para o presente trabalho. A entrevista e todos os procedimentos relacionados ao estudo teve lugar no Pavilhão da Faculdade de Ciências da Nutrição e Alimentação da Universidade

do Porto e foram conduzidos por uma Nutricionista treinada e membro da equipa de investigação do UISPA-IDMEC.

Os participantes foram devidamente informados sobre o objetivo e a metodologia do estudo, sobre os benefícios associados a participação e sobre a confidencialidade dos dados, através de um termo que foi assinado em duplicado tendo o participante ficado com um exemplar e o investigador com outro. Esses benefícios incluíram comunicar aos participantes os seus resultados pessoais das avaliações realizadas, nomeadamente sobre a composição corporal, bem como quaisquer desvios face à normalidade. O termo assinado entre os participantes e o investigador foi submetido e aprovado pela Comissão de Ética da Universidade do Porto (Parecer final nº14/CEUP/2015).

2.3. A base de dados

As variáveis que constam do ficheiro em Excel e que seguidamente exportados para o SPSS, estão listadas na Tabela 2.7, abreviadas, com suas respetivas descrições, codificação, tipo e medida:

Tabela 2.7: Descrição das variáveis da base de dados

Nome da Variável	Descrição e codificação	Tipo/Medida
NI	Nº identificação	Numérico/Escala
NI_Lipo (BI)	Nº identificação no Software LipoSoft	Numérico/Nominal
Data	Data em que foi realizada a avaliação	String/Nominal
Hora	Hora em que foi realizada a avaliação	Numérico/Escala
Sexo	Sexo. 0: mulher, 1: homen	Numérico/Nominal
Data_Nasc	Data de nascimento (dd/mm/aa)	String/Nominal
Idade	Idade	Numérico/Escala
Escol	Escolaridade. 1:4 anos, 2:12 anos, 3: 13 anos, 4:bacharelato, 5:licenciatura, 6:mestrado, 7:doutoramento	Numérico/Ordinal
Ocupacao	Ocupação. 0: não, 1: sim	Numérico/Nominal
Profissao	Qual? 1:professor, 2:estudante, 3:reformado, 4:desempregado, 5:bolseiro, 6:func.limpeza, 7:emp.comercial, 8:engenheiro, 9:secretariado, 10:investigador, 11:assistente social, 12:assistente comercial, 13:nutricionista, 14:cardiopneumologista	Numérico/Nominal
AF	Atividade Física. 0:não, 1:sim	Numérico/Nominal

AF_Qual	Qual modalidade. 1:ginástica, 2:dança, 3:cardio, 4:ginásio, 5:musculação, 6:caminhadas, 7:volei, 8:natação, 9:squash, 10:treino funcional, 11:ginástica localizada, 12:corrida, 13:ballet, 14:bicicleta	Numérico/Nominal
AF_h	Nº horas que pratica AF/semana	Numérico/Escala
AF_ultimas8h	Praticou AF nas últimas 8h. 0: não, 1: sim	Numérico/Nominal
E_Saude	Estado de saúde. 0: muito bom, 1: bom, 2: razoável, 3: mau, 4: muito mau	Numérico/Ordinal
D_Cronicas	Se tem doenças crônicas. 0: não, 1: sim	Numérico/Nominal
Qual_DC	Qual doença crônica. 1:diabete, 2:asma,	Numérico/Nominal
Anos_DC	Há quantos anos tem esta doença	Numérico/Escala
Med_12m	Tomou medicação para estas doenças nos últimos 12 meses. 0:não, 1:sim	Numérico/Nominal
N_Medico_3m	Quantas vezes consultou um médico nos últimos 3 meses	Numérico/Escala
Dialise	Faz diálise. 0:não, 1:sim	Numérico/Nominal
Dialise_h	Se sim, há qtas horas foi realizado o procedimento	Numérico/Escala
Est_Diur_HC	Toma esteróides, diuréticos ou hormona de crescimento. 0:não, 1:sim	Numérico/Nominal
Est_Diur_HC_h	Se sim, há quantas horas tomou esta medicação	Numérico/Escalar
Atrofia_Hemip	Tem atrofia ou hemiplegia. 0:não, 1:sim	Numérico/Nominal
Anom_T_Memb	Apresenta anomalia no tronco ou membros. 0:não, 1:sim	Numérico/Nominal
Amp	Tem algum membro amputado. 0:não, 1:sim	Numérico/Nominal
Amp_Od	Se sim, que membro	String/Nominal
Prot_Impl	Tem próteses ou implantes. 0:não, 1:sim	Numérico/Nominal
Prot_Impl_Od	Se sim, onde	String/Nominal
Período_M	Está com o período menstrual. 0:não, 1:sim	Numérico/Nominal
Ing_ultimas8h	Comeu nas últimas 8 horas. 0:não, 1:sim	Numérico/Nominal
Ing_Qtas_h	Se sim, há quantas horas comeu	Numérico/Escala
Café_Alcool_ultimas8h	Bebeu café ou álcool nas últimas 8 horas. 0:não, 1:sim	Numérico/Nominal
Café_Alcool_Qtas_h	Se sim, há quantas horas bebeu café/álcool	Numérico/Escala
Evacuacao	Evacou hoje. 0:não, 1:sim	Numérico/Nominal
Peso	Peso (kg)	Numérico/Escala
MLG_kg	Massa gorda (kg)	Numérico/Escala
MG%	Massa gorda (%)	Numérico/Escala
ACT (kg)	Água corporal total em kilogramas	Numérico/Escala
ACT (%)	Água corporal total em percentagem	Numérico/Escala
AC_Intracel (kg)	Água corporal intracelular em kilogramas	Numérico/Escala
AC_Extracel (%)	Água corporal extracelular em kilogramas	Numérico/Escala
AC_Extracel (kg)	Água corporal extracelular em percentagem	Numérico/Escala
BMI	Índice de massa corporal (kg/m2)	Numérico/Escala

Fonte: Base de dados da pesquisa em estudo

Mas antes de ser exportado o ficheiro em Excel para o SPSS foi alterada a disposição da matriz de dados referente a medição das pregas cutâneas, para que as duas folhas pudessem ser mescladas e assim constituir uma única base de dados com uma estrutura adequada para ser exportada para o SPSS.

Para que isso pudesse ser possível optou-se por resumir os valores dos pontos (dos 180 pontos) de cada prega por meio de algumas estatísticas, nomeadamente a média, a mediana e o desvio padrão (de todos os pontos, dos últimos 10 pontos, dos últimos 3 pontos, respetivamente) e a diferença entre o ponto máximo e o ponto mínimo e a diferença entre o primeiro ponto e o último ponto (ver Anexo IX e X) utilizando as próprias fórmulas do Excel. Ao todo onze medidas-resumo do tipo: numérico e medida: escala. Tal procedimento foi útil no sentido de fazer comparações entre essas formas de resumo (resumo dos dados por meio da média, da mediana, do desvio-padrão e da diferença) a ver qual seria mais adaptado aos dados, para as análises de regressão linear múltipla.

Depois de exportar a base de dados no Excel para o SPSS, deu-se início às técnicas e tratamento de uma base de dados bem como as análises necessárias para atender aos desafios proposto pelo estudo de hidratação e compressibilidade das pregas cutâneas.

2.4. Uniformização da base de dados

Antes de se avançar com as análises multivariadas, deu-se ao trabalho de limpar e preparar a base de dados, identificando valores ruidosos e valores ausentes.

As variáveis onde foram detetados dados ruidosos ou valores ausentes não foram eliminadas da base, mas foram recodificadas em novas variáveis criadas automaticamente pelo SPSS. Por exemplo E_saude → E_saude_1.

Para o tratamento dos dados omissos foi aplicado, nas variáveis quantitativas, o método de imputação pela média por ser uma medida de tendência central que melhor caracteriza os dados. Na verdade, nas variáveis quantitativas com dados omissos presentes, que não seguiam distribuição normal foi aplicado o método de imputação pela média, dado que o SPSS não dispõe do método de imputação pela mediana (*Séries Median*). Em alternativa foi escolhido o *Median of nearby points*, mas como os resultados com este método, para essas

variáveis em análise, deram o mesmo com o *Séries mean*, foi aplicado este. Para as variáveis categóricas foi aplicado o método de imputação pela moda.

2.5. Análise dos dados

Referente a análise de regressão, todas as análises realizadas foram feitas inicialmente para cada tipo de medida-resumo (média, mediana, desvio-padrão e diferença) para que se pudesse verificar qual ou quais seriam melhores para analisar os dados. A decisão na escolha, dentre os onze, de qual ou quais fariam parte da análise e discussão dos resultados, foi baseada na análise de fiabilidade através do Índice de Alpha de Cronbach. A escolha recaiu sobre as medidas-resumo que mais informação transmitia sobre a precisão do instrumento de medição das pregas cutâneas, apresentando um Alpha de Cronbach maior ou igual a 0.90, valor este considerado satisfatório nos casos de investigação aplicada. Nessa análise as medidas-resumo foram definidas como variáveis dependentes e as variáveis socio-demográficas como preditoras.

Depois de analisar todas as medidas-resumo escolhidas em cada prega, foi identificada a medida que mais contribuiu no aumento de qualidade do modelo de regressão, através de dois indicadores: o coeficiente de determinação ajustado (R_a^2) e do erro-padrão (Maroco, 2011). A medida cujo modelo proporcionou maior R_a^2 e menor erro-padrão foi elegida. Tal método foi utilizado tanto na verificação da relação das pregas cutâneas com as variáveis sócio-demográficas como na relação entre as pregas e o estado de hidratação. Também foi utilizado o teste *t para amostras emparelhadas* para verificar se havia diferença significativa entre os valores de R_a^2 e erro-padrão com a presença e com a exclusão do *outlier* e diferença quando os dados eram submetidos a uma medida-resumo e depois outra.

Mas para que o modelo final de cada prega, em cada medida-resumo, fosse construído foi necessário aplicar os métodos *Enter*, *Stepwise* e *Backward* para identificar as variáveis significativas. Assim, as variáveis significativas identificadas em cada um dos três métodos fizeram parte na composição do modelo final de cada prega, em cada medida-resumo. Para a escolha das variáveis significativas foi utilizado dois critérios: um de entrada de variáveis,

para um $\alpha = 5\%$, e outro para remover, para um $\alpha = 10\%$. A análise do modelo final foi realizada com o método *Enter*.

As variáveis que se mostraram ser colineares umas com as outras, através dos valores VIF, foram eliminadas baseada na correlação “Part” para aquelas que se mostraram menos importante em prever a variável resposta.

Dado a inúmeras análises realizadas e tendo em conta o número limitado de páginas sugerida para este trabalho, optou-se por escolher apenas uma medida-resumo para demonstrar todas as análises, servindo de exemplo de como as restantes medidas-resumo foram analisadas. Os resultados dessas análises não detalhadas foram devidamente ilustradas em tabelas. O resumir as análises em tabelas permitiu fazer uma análise comparativa e em simultâneo da eficiência do modelo de cada prega em todas as medidas-resumo.

Durante as análises multivariadas foram detetados *outliers* e pontos influentes. Para identifica-los foi feito o uso das fórmulas descritas na bibliografia, dos valores da tabela “Estatística de resíduos” e da visualização gráfica. Os casos influentes e os *outliers*, detetados, foram devidamente caracterizados por forma a poder perceber sobre a sua importância, ou não, na conclusão final sobre os resultados das análises.

As análises de regressão foram feitas sempre com a presença e com a exclusão dos *outliers* da base de dados para fins de análises comparativas sobre o seu impacto na qualidade do modelo. Essas análises estão descritas neste trabalho apenas para a média dos últimos 10 pontos, dado que foi considerado a medida-resumo que mais qualidade trás ao modelo de regressão das pregas analisadas conjuntamente com as variáveis sócio-demográficas e com o estado de hidratação.

Capitulo 3
Apresentação dos Resultados

3.1. Explorando e adequando a base de dados

Todas as variáveis foram, inicialmente, devidamente caracterizadas pelo nome, tipo, rótulo, valores de código, valores em falta, medida, largura, número de casas decimais, largura da coluna, e alinhamento.

3.1.1. Observação de dados ruidosos

Através da elaboração das tabelas de frequência de cada variável não se verificou erros de digitação dos dados. Mas através de uma análise cuidada, comparando variáveis, se identificou erros de digitalização na variável “Período_M”. Foram encontrados indivíduos do sexo masculino que responderam terem estado com período menstrual no momento da aplicação do inquérito. É claro que para os homens essa pergunta não se aplica, pelo que foi codificada essas respostas com o tipo *Não se aplica*.

3.1.2. Observação e tratamento dos valores ausentes

Através da elaboração de tabelas de frequência se verificou os valores ausentes nas seguintes variáveis:

Em variáveis quantitativas – “N_Medico_3m”, “Ing_Qtas_h”, “Café_Alcool_Qtas_h”,

Em variáveis qualitativas (categóricas) – “Escol”, “Ocupacao”, “E_Saude”, “Periodo_M”, “Ing_ultimas8h”, “Café_Alcool_ultimas8h”, “Evacuacao”, “AF_Qual” e “Med_12m”.

Tais valores foram observados e foram-lhes dado o devido tratamento, ou seja, para as variáveis não-categóricas foi verificado a normalidade dos dados (ver tabelas 3.8; 3.10 e gráficos 3.11; 3.13) afim de escolher o método de imputação.

Tabela 3.8. Estatísticas da variável “N_Medico_3m”

Quantas vezes consultou um médico nos últimos 3 meses “N_Medico_3m”

N	Válido	64
	Omisso	2
Média		,64
Mediana		,00
Desvio Padrão		,982
Assimetria		1,618
Erro padrão da assimetria		,299
Curtose		2,022
Erro Padrão da Curtose		,590

Figura 3.11 – Histograma da variável “N_Medico_3m”

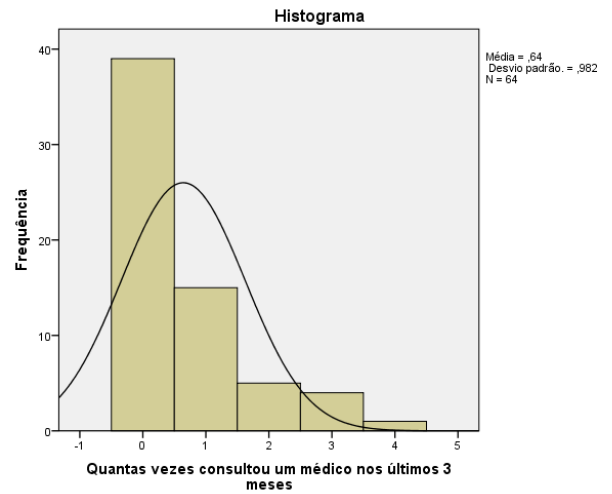


Tabela 3.9. Estatísticas da variável “Ing_Qtas_h”

Há quantas horas comeu

N	Válido	55
	Omisso	11
Média		2,54
Mediana		2,00
Desvio Padrão		1,490
Assimetria		,724
Erro padrão da assimetria		,322
Curtose		-,532
Erro Padrão da Curtose		,634

Figura 3.12 – Histograma da variável “Ing_Qtas_h”

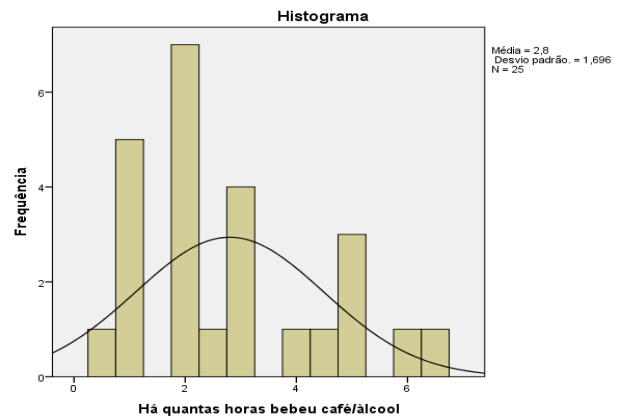



Tabela 3.10. Estatísticas da variável “Café_Alcool_Qtas_h”

Há quantas horas bebeu café/álcool

N	Válido	25
	Omisso	41
Média		2,80
Mediana		2,00
Desvio Padrão		1,696
Assimetria		,716
Erro padrão da assimetria		,464
Curtose		-,460
Erro Padrão da Curtose		,902

Figura 3.13 – Histograma da variável “Café_Alcool_Qtas_h”



Verifica-se pelas tabelas produzidas pelo *output*, que os valores brutos dos indicadores de assimetria (1.618; 0.724; 0.716) e curtose (2.022; -0.532; -0.460) das variáveis “N_Medico_3m”, “Ing_Qtas_h” e “Café_Alcool_Qtas_h”, respectivamente, estão afastados de zero, o que mostra uma tendência de não haver normalidade na distribuição das variáveis em análise. Mas, ao olhar para a medida de dispersão das variáveis “Ing_Qtas_h” e “Café_Alcool_Qtas_h” verifica-se que o desvio padrão é inferior à média, o que pressupõe uma aproximação à normalidade. Com relação à visualização dos histogramas, fica a ideia que não existe normalidade em nenhuma das variáveis. Para que não houvesse qualquer dúvida sobre a normalidade, por último recorreu-se aos Testes K-S e S-W na qual se confirma que as variáveis tendem em não seguir uma distribuição normal, já que em todas elas o *p-value* < 5%, com exceção da variável “Ing_Qtas_h” (tabela 3.11).

Feita todas essas análises preliminares recorreu-se ao método de imputação da mediana em detrimento da média para as variáveis que não seguiam uma distribuição normal. Entretanto, como o SPSS não dispõe do método (*Séries Median*), foi escolhido o *Median of nearby points*, mas os resultados com este método, para essas variáveis em análise, é o mesmo com o *Séries mean*, pelo que foi aplicado este.

Tabela 3.11: Testes de Normalidade para as variáveis “N_Medico_3m”, “Ing_Qtas_h” e “Café_Alcool_Qtas_h”

	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Estatística	gl	Sig.	Estatística	gl	Sig.
Quantas vezes consultou um médico nos últimos 3 meses “N_Medico_3m”	,468	23	,000	,543	23	,000
Há quantas horas comeu “Ing_Qtas_h”	,158	23	,143	,888	23	,015
Há quantas horas bebeu café/álcool “Café_Alcool_Qtas_h”	,190	23	,031	,906	23	,033

a. Correlação de Significância de Lilliefors

Para as variáveis categóricas escolheu-se como método de imputação a Moda.

Verificou-se que os dados faltantes seguem tanto o *padrão não resposta unidades* (B) como o *padrão de não resposta geral* (D). Referente ao padrão B, alguns entrevistados não deram respostas para as seguintes variáveis: “Ing_ultimas8h” – comeu nas ultimas 8 horas,

“Ing_Qtas_h” – há quantas horas comeu, “Café_Alcool_ultimas8h” – bebeu café ou álcool nas últimas 8h, “Café_Alcool_Qtas_h” – há quantas horas bebeu café ou álcool, “Evacuacao” – evacuou hoje, “Fuma_Atual” – fuma atualmente, “Fuma_Passado” – fumou no passado. Essas variáveis estão dispostas na base de dados de forma sequencial.

Dado haver mais do que um tipo de padrão, se pôde concluir que o mecanismo dos dados não observados indicam ser aleatórios (Mcknight *et al.*, 2007 ; Veroneze, 2011), sendo os mecanismos MAR e MCAR. Segundo Allison (2001) estes mecanismos são classificados como *ignoráveis* e não serão considerados no modelo.

No caso das variáveis “AF_Qual” e “Med_12m”, os dados omissos não derivaram da ausência de resposta, mas sim não aplicava ao contexto referido na própria variável e/ou na variável antecedente. Nesses casos considerou-se os dados em falta como tipo ignorável, pois não havia necessidade de modelar.

Na variável “Fuma_Atual” existem 39 valores ausentes, o que corresponde a 59.1% dos dados nesta variável. Na bibliografia encontrada diz que quando as não respostas atingem 20% dos dados ou um valor superior (que é o caso), deverão ser analisadas com cuidado. Entretanto não se sabe ao certo se tal recomendação está relacionada com um atributo, ou um conjunto de atributos ou com toda a base de dados, pelo que não se avançou com esta variável nas análises. De todo o modo, dado que é uma variável categórica, o método de tratamento seria aplicar a moda, mas pelo número elevadíssimo de dados faltantes contido nela, não seria conveniente aplicar tal tratamento.

Dado que este número de casos omissos acontece apenas na variável que se refere ao ato de fumar, foi verificada algumas características dos indivíduos que não responderam (uma hipótese) à questão: 81.6% são mulheres e 18.4% homens. A idade média dos não respondentes é de 22.97 anos (abaixo da média geral – 28.9 anos), sendo a idade mínima de 18 anos e máxima de 42 anos, com um desvio-padrão de 5.279. A maioria são estudantes (78.9%), sendo os restantes engenheiros, bolsiros, secretariado e assistente social. A nível de estado de saúde, 68.4% estão iguais ou superiores ao estado da maioria (\geq Bom).

Na Variável “E_Saude” e “D_Cronica”, alguns afirmaram ter um estado de saúde *Bom* a *Muito Bom*, mas, no entanto, tem algum tipo de doença crónica, o que parece ser um

contrassenso. Foi então identificado os tipos de doenças crônicas, sendo elas: Asma, diabetes, ulcera duodenal, hipotireoidismo e psoríase. A razão dos indivíduos alegar *Bom* e *Muito Bom* estado de saúde apesar de estarem a enfrentar uma determinada doença crônica, em média a 10.7 anos, é o fato de estas doenças, sendo bem controladas levar as pessoas a se sentirem bem e muito bem, pois afirmaram estar a tomar remédios para estas doenças.

3.2. Análise de Fiabilidade e inferência estatística sobre os dados de compressibilidade das pregas cutâneas

3.2.1. Análise das oito pregas (com a média de todos os pontos)

As correlações positivas entre as pregas (tabela 3.12) mostram que existe uma certa concordância nas suas medições e essa correlação é significativa entre todas as pregas ($p < 0.01$ e $p < 0.05$), com exceção dos pares de pregas Geminal-Abdominal e Abdominal-Crural, apresentando, ao mesmo tempo, correlação muito fraca e fraca. As correlações significativas indicam que, provavelmente, o coeficiente de correlação entre os pares de prega do Universo é diferente de zero, sendo que a probabilidade desta conclusão estar errada é menor que 0.05.

As correlações estão apresentadas da seguinte forma:

Bem fraca [0.00-0.19]- entre as pregas Geminal e Abdominal (0.178).

Fraca [0.20-0.39]- entre as pregas Abdominal e Tricipital (0.345), Geminal e Subescapular (0.375), Crural e Abdominal (0.216).

Moderada [0.40-0.69] - entre as pregas Subescapular e Tricipital (0.532), Iliocrystal e Tricipital (0.608), Supraespinal e Tricipital (0.665), Supraespinal e Subescapular (0.669), Abdominal e Subescapular (0.589), Iliocrystal e Bicipital (0.636), Abdominal e Bicipital (0.484), Crural e Bicipital (0.623), Geminal e Bicipital (0.543), Crural e Iliocrystal (0.500), Geminal e Iliocrystal (0.398), Crural e Supraespinal (0.567), Geminal e Supraespinal (0.574).

Forte [0.70-0.89] - entre as pregas Bicipital e Tricipital (0.777), Geminal e Tricipital (0.788), Supraespinal e Iliocristal (0.771), Abdominal e Supraespinal (0.710), Geminal e Crural (0.743), Crural e Tricipital (0.813).

A correlação mais baixa se refere às pregas Geminal e Abdominal (0.178) e a mais forte referente às pregas Crural e Tricipital (0.813).

Tabela 3.12: Matriz de Correlação entre as pregas cutâneas com a média de todos os pontos

		prega Tricipital	prega Subescapular	prega Bicipital	prega Iliocristal	prega Supraespinal	prega Abdominal	prega Crural	prega Geminal
prega Tricipital	Correlação de Pearson	1	,532**	,777**	,608**	,665**	,345**	,813**	,788**
	Sig. (2 extremidades)		,000	,000	,000	,000	,005	,000	,000
	N	66	66	66	66	66	66	66	66
prega Subescapular	Correlação de Pearson	,532**	1	,523**	,696**	,669**	,589**	,442**	,375**
	Sig. (2 extremidades)	,000		,000	,000	,000	,000	,000	,002
	N	66	66	66	66	66	66	66	66
prega Bicipital	Correlação de Pearson	,777**	,523**	1	,636**	,685**	,484**	,623**	,543**
	Sig. (2 extremidades)	,000	,000		,000	,000	,000	,000	,000
	N	66	66	66	66	66	66	66	66
prega Iliocristal	Correlação de Pearson	,608**	,696**	,636**	1	,771**	,692**	,500**	,398**
	Sig. (2 extremidades)	,000	,000	,000		,000	,000	,000	,001
	N	66	66	66	66	66	66	66	66
prega Supraespinal	Correlação de Pearson	,665**	,669**	,685**	,771**	1	,710**	,567**	,574**
	Sig. (2 extremidades)	,000	,000	,000	,000		,000	,000	,000
	N	66	66	66	66	66	66	66	66
prega Abdominal	Correlação de Pearson	,345**	,589**	,484**	,692**	,710**	1	,216	,178
	Sig. (2 extremidades)	,005	,000	,000	,000	,000		,081	,154
	N	66	66	66	66	66	66	66	66
prega Crural	Correlação de Pearson	,813**	,442**	,623**	,500**	,567**	,216	1	,743**
	Sig. (2 extremidades)	,000	,000	,000	,000	,000	,081		,000
	N	66	66	66	66	66	66	66	66
prega Geminal	Correlação de Pearson	,788**	,375**	,543**	,398**	,574**	,178	,743**	1
	Sig. (2 extremidades)	,000	,002	,000	,001	,000	,154	,000	
	N	66	66	66	66	66	66	66	66

****.** A correlação é significativa no nível 0,01 (2 extremidades).

A maioria das correlações são moderadas (0.398 a 0.669), o que significa que cada prega tem uma parte que é comum aos restantes, mas que também explica algo específico. Dá confiança de que as pregas representam aspetos diferentes da compressibilidade e todas elas não medem exatamente a mesma coisa, mas é razoável concluir que medem duas

coisas – alguma coisa que todas as outras pregas também medem e alguma coisa que as outras pregas não medem.

Na Tabela 3.13, na terceira coluna, temos o coeficiente de correlação *R* de *Pearson* de cada uma das pregas com as demais e verifica-se que a maior correlação é entre a prega Supraespinal e as restantes pregas (0.847). O valor das correlações apresentada nessa coluna indica que cada prega contribui mais ou menos de igual forma para a compressibilidade, o que é confirmado pelos valores da quarta coluna.

No geral existe uma associação linear forte entre as pregas, sendo que a prega Abdominal apresenta com uma correlação mais fraca com os demais (0.529).

Tabela 3.13: Estatísticas de item-total entre as pregas cutâneas com a média de todos os pontos

	Média de escala se o item for excluído	Variância de escala se o item for excluído	Correlação de item total corrigida	Correlação múltipla ao quadrado	Alpha de Cronbach se o item for excluído
prega Tricipital	107,9920416	939,588	,827	,840	,876
prega Subescapular	112,7797212	973,757	,677	,544	,889
prega Bicipital	116,1984983	1012,137	,770	,679	,885
prega Iliocrystal	108,9945393	967,193	,773	,711	,881
prega Supraespinal	113,8738752	993,423	,847	,781	,880
prega Abdominal	107,5503310	961,245	,529	,648	,907
prega Crural	103,0663395	862,141	,682	,699	,895
prega Geminal	110,5283068	983,614	,642	,707	,892

Pode ver-se também que a prega Tricipital é a que tem a maior percentagem de variabilidade explicada pelas outras pregas, ou seja, 84.0% da variabilidade observada na prega Tricipital é explicada pelas demais.

A Tabela 3.14 diz-nos que o valor médio da compressibilidade das pregas é 125,855. Este valor é a soma dos valores médios das oito pregas.

Tabela 3.14: Estatística de escala entre as pregas cutâneas com a média de todos os pontos

Média	Variância	Desvio Padrão	N de itens
125,85480758365155	1238,431	35,191345697322994	8

Tabela 3.15: Estatísticas de confiabilidade entre as pregas cutâneas com a média de todos os pontos

Alpha de Cronbach	Alpha de Cronbach com base em itens		N de itens
	padronizados		
,901	,916		8

Intervalo de confiança para o Alpha

Um intervalo de confiança exato para α a $(1 - \gamma) \times 100\%$ pode então ser estimado por:

$$\left[1 - (1 - \hat{\alpha}) \times f_{1-\gamma/2; (n-1), (n-1)(k-1)}; 1 - (1 - \hat{\alpha}) \times f_{\gamma/2; (n-1)(k-1)} \right]$$

Dado $\gamma = 5\%$, temos

$$\left[1 - (1 - 0.916) \times f_{0.975; (65, 520)}; 1 - (1 - 0.916) \times f_{0.025; (65, 520)} \right]$$

Consultando uma tabela de distribuição F , e sabendo que $f_{0.025; (65, 520)} = 1 / f_{0.975; (520, 65)}$ temos

$$\left[1 - (1 - 0.916) \times 1.27; 1 - (1 - 0.916) \times 0.763 \right]$$

Um intervalo de confiança a 95% para α é]0.8933; 0.9359[.

As mesmas análises foram feitas com as restantes medidas-resumo. A Tabela 3.16 trás um resumo das análises de fiabilidade e correlação das pregas em cada medida-resumo (média, mediana, desvio-padrão e diferenças) por forma a escolher as medidas que serão trabalhadas ao longo do estudo. As escolhidas foram aquelas que apresentaram um índice de Alpha de Cronbach e um índice de Alpha de Cronbach padronizado igual ou superior a 0.90, sendo este valor considerado satisfatório nos casos de investigação aplicada. Em todas essas medidas existe uma forte correlação (> 0.80) entre as pregas Crural e Tricipital

e uma fraca correlação (< 0.30) entre as pregas Geminal e Abdominal. Também em todas as medidas-resumo a maioria das correlações são moderadas. A média dos últimos 10 pontos é a medida-resumo que possui a maior percentagem de correlações moderadas (60.7%).

Tabela 3.16: Resumo da fiabilidade e correlações em cada medida-resumo

	Alpha de Cronbach	Alpha de Cronbach com base em itens padronizados	Média	Variância	Baixa correlação entre	Forte correlação entre	% das correlações moderadas
Média de todos os pontos	,901	,916	125,855	1238,431	Geminal e Abdominal (0.178)	Crural e Tricipital (0.813).	(46.4%) de (0.398 a 0.669).
Media dos últimos 10 pontos	,900	,917	122,299	1220,47	Geminal e Abdominal (0.182)	Crural e Tricipital (0.812).	(60.7%) de (0.396 a 0.693).
Media dos últimos 3 pontos	,897	,913	121,613	1227,49	Geminal e Abdominal (0.174)	Crural e Tricipital (0.814).	(64.3%) de (0.405 a 0.686).
Mediana de todos os pontos	,902	,917	124,188	1239,60	Geminal e Abdominal (0.190)	Crural e Tricipital (0.813)	(53.6%) de (0.450 a 0.686)
Mediana dos últimos 10 pontos	,901	,917	122,541	1219,04	Geminal e Abdominal (0.224)	Crural e Tricipital (0.810).	(57.1%) de (0.451 a 0.692).
Desvio padrão de todos os pontos	,862	,877	4,3373	14,198	Iliocristal e Bicipital (0.236)	Abdominal e Supraespinal (0.662).	(78.6%) de (0.402 a 0.662).
Desvio padrão dos últimos 10 pontos	,146	-,089					
Diferença entre ponto1 e ponto 180	,808	,832	19,8231	316,976	Iliocristal e Bicipital (0.170)	Crural e Tricipital (0.733).	(39.3%) de (0.402 a 0.627).
Diferença entre ponto min e ponto max	,809	,834	19,9505	319,790	Iliocristal e Bicipital (0.165)	Crural e Tricipital (0.733).	(39.3%) de (0.407 a 0.628).

Fonte: Elaboração própria

3.2.2. Análise das oito pregas (com a média dos últimos 10 pontos)

As correlações positivas entre as pregas mostraram que existe uma certa concordância nos resultados das suas medições e essa correlação é significativa entre todas as pregas ($p < 0.01$ e $p < 0.05$), com exceção dos pares de pregas Geminal-Abdominal e Abdominal-Crural, apresentando, ao mesmo tempo, correlação muito fraca e fraca. As correlações estão apresentadas da seguinte forma:

Bem fraca [0.00-0.19]- entre as pregas Geminal e Abdominal (0.182).

Fraca [0.20-0.39]– entre as pregas Abdominal e Tricipital (0.374), Geminal e Subescapular (0.380), Crural e Abdominal (0.223).

Moderada [0.40-0.69] - entre as pregas Subescapular e Tricipital (0.540), Iliocristal e Tricipital (0.616), Supraespinal e Tricipital (0.671), Supraespinal e Subescapular (0.667), Abdominal e Subescapular (0.594), Iliocristal e Bicipital (0.622), Abdominal e Bicipital (0.503), Crural e Bicipital (0.609), Geminal e Bicipital (0.532), Crural e Iliocristal (0.505), Geminal e Iliocristal (0.396), Crural e Supraespinal (0.574), Geminal e Supraespinal (0.569).

Forte [0.70-0.89] - entre as pregas Bicipital e Tricipital (0.777), Geminal e Tricipital (0.791), Supraespinal e Iliocristal (0.769), Abdominal e Supraespinal (0.716), Geminal e Crural (0.738), Crural e Tricipital (0.812).

A correlação mais baixa se refere às pregas Geminal e Abdominal (0.182) e a mais forte referente às pregas Crural e Tricipital (0.812). Pelo coeficiente de correlação R de *Pearson* de cada uma das pregas com as demais verifica-se que a maior correlação é entre a prega Supraespinal e as restantes pregas (0.849). O valor das correlações indica que cada prega contribui mais ou menos de igual forma para a compressibilidade. No geral existe uma associação linear forte entre as pregas, sendo que a prega Abdominal apresenta com uma correlação mais fraca com os demais (0.542). Verificou-se que a prega Tricipital é a que tem a maior percentagem de variabilidade explicada pelas outras pregas, ou seja, 85.1% da variabilidade observada na prega Tricipital é explicada pelas demais. Comparando a última coluna da tabela “Estatística de item-total” com a Tabela 3.17 vê-se que o Alpha (não padronizado) tende a aumentar para 0.906, caso for excluída a prega Abdominal.

Tabela 3.17: Estatísticas de confiabilidade entre as pregas cutâneas com a média dos últimos 10 pontos

Alpha de Cronbach	Alpha de Cronbach com base em itens	
	padronizados	N de itens
,900	,917	8

Intervalo de confiança para o Alpha

Um intervalo de confiança exato para α a $(1-\gamma)\times 100\%$ pode então ser estimado pela fórmula (7). Dado $\gamma = 5\%$, temos

$$\left[1 - (1 - 0.917) \times f_{0.975, (65, 520)}; 1 - (1 - 0.917) \times f_{0.025, (65, 520)} \right]$$

Consultando uma tabela de distribuição F , e sabendo que $f_{0.025, (65, 520)} = 1 / f_{0.975, (520, 65)}$ temos

$$\left[1 - (1 - 0.917) \times 1.27; 1 - (1 - 0.917) \times 0.763 \right]$$

Um intervalo de confiança a 95% para α é]0.8946; 0.9367[.

3.2.3. Análise das oito pregas (com a Mediana de todos os pontos)

As correlações positivas entre as pregas mostraram que existe uma certa concordância nos resultados das suas medições e essa correlação é significativa entre todas as pregas ($p < 0.01$ e $p < 0.05$), com exceção dos pares de pregas Geminal-Abdominal e Abdominal-Crural, apresentando, ao mesmo tempo, correlação muito fraca e fraca.

As correlações estão apresentadas da seguinte forma:

Bem fraca [0.00-0.19]- entre as pregas Geminal e Abdominal (0.190).

Fraca [0.20-0.39]- entre as pregas Abdominal e Tricipital (0.367), Geminal e Subescapular (0.382), Crural e Abdominal (0.224) e Geminal e Iliocristal (0.394).

Moderada [0.40-0.69] - entre as pregas Tricipital e Subescapular (0.539), Tricipital e Iliocristal (0.613), Tricipital e Supraespinal (0.668), Subescapular e Abdominal (0.600), Bicipital e Iliocristal (0.632), Bicipital e Supraespinal (0.686), Bicipital e Crural (0.616), Supraespinal e Crural (0.569), Supraespinal e Abdominal (0.574).

Forte [0.70-0.89] - entre as pregas Bicipital e Tricipital (0.779), Geminal e Tricipital (0.790), Supraespinal e Iliocristal (0.762), Abdominal e Supraespinal (0.717), Geminal e Crural (0.740), Crural e Tricipital (0.813), Subescapular e Iliocristal (0.696), Iliocristal e abdominal (0.700).

A correlação mais baixa se refere às pregas Geminal e Abdominal (0.190) e a mais forte referente às pregas Crural e Tricipital (0.813). Pelo coeficiente de correlação R de *Pearson* de cada uma das pregas com as demais verifica-se que a maior correlação é entre a prega Supraespinal e as restantes pregas (0.846). O valor das correlações indica que cada prega contribui mais ou menos de igual forma para a compressibilidade. No geral existe uma associação linear forte entre as pregas, sendo que a prega Abdominal apresenta com uma correlação mais fraca com os demais (0.543). Verificou-se que a prega Tricipital é a que tem a maior percentagem de variabilidade explicada pelas outras pregas, ou seja, 84.8% da variabilidade observada na prega Tricipital é explicada pelas demais. Comparando a última coluna da tabela “Estatística de item-total” com a Tabela 3.18 vê-se que o Alpha (não padronizado) tende a aumentar para 0.907, caso for excluída a prega Abdominal.

Tabela 3.18: Estatísticas de confiabilidade entre as pregas cutâneas com a mediana de todos os pontos

Alpha de Cronbach	Alpha de Cronbach com base em itens padronizados	N de itens
,902	,917	8

À semelhança da prega anterior analisada, foi usada a fórmula (7) e obtido o seguinte intervalo de confiança a 95% para α :]0.8946; 0.9367[.

3.2.4. Análise das oito pregas (com a mediana dos últimos 10 pontos)

As correlações positivas entre as pregas mostraram que existe uma certa concordância nos resultados das suas medições e essa correlação é significativa entre todas as pregas ($p < 0.01$ e $p < 0.05$), com exceção dos pares de pregas Geminal-Abdominal e Abdominal-Crural, apresentando, ao mesmo tempo, correlação muito fraca e fraca. As correlações estão apresentadas da seguinte forma:

Bem fraca [0.00-0.19]- entre as pregas Geminal e Abdominal (0.185).

Fraca [0.20-0.39]– entre as pregas Abdominal e Tricipital (0.375), Geminal e Subescapular (0.380), Crural e Abdominal (0.224) e Geminal e Iliocristal (0.391).

Moderada [0.40-0.69] - entre as pregas Tricipital e Subescapular (0.539), Tricipital e Iliocristal (0.616), Tricipital e Supraespinal (0.670), Subescapular e Bicipital (0.523), Subescapular e Iliocristal (0.692), Subescapular e Supraespinal (0.668), Subescapular e Abdominal (0.599), Subescapular e Crural (0.451), Bicipital e Iliocristal (0.627), Bicipital e Supraespinal (0.682), Bicipital e Abdominal (0.509), Bicipital e Crural (0.615), Bicipital e Geminal (0.535), Iliocristal e Crural (0.503), Supraespinal e Crural (0.571), Supraespinal e Geminal (0.573).

Forte [0.70-0.89] - entre as pregas Bicipital e Tricipital (0.779), Geminal e Tricipital (0.791), Supraespinal e Iliocristal (0.757), Abdominal e Supraespinal (0.716), Geminal e Crural (0.738), Crural e Tricipital (0.810), Iliocristal e abdominal (0.697).

A correlação mais baixa se refere às pregas Geminal e Abdominal (0.185) e a mais forte referente às pregas Crural e Tricipital (0.810). Pelo coeficiente de correlação R de *Pearson* de cada uma das pregas com as demais verifica-se que a maior correlação é entre a prega Supraespinal e as restantes pregas (0.845). O valor das correlações indica que cada prega contribui mais ou menos de igual forma para a compressibilidade. No geral existe uma associação linear forte entre as pregas, sendo que a prega Abdominal apresenta com uma correlação mais fraca com os demais (0.544). Verificou-se que a prega Tricipital é a que tem a maior percentagem de variabilidade explicada pelas outras pregas, ou seja, 84.9% da variabilidade observada na prega Tricipital é explicada pelas demais. Comparando a última coluna da tabela “Estatística de item-total” com a Tabela 3.19 vê-se que o Alpha (não padronizado) tende a aumentar para 0.906, caso for excluída a prega Abdominal.

Tabela 3.19: Estatísticas de confiabilidade entre as pregas cutâneas com a mediana dos últimos 10 pontos

Alpha de Cronbach	Alpha de Cronbach com base em itens padronizados	N de itens
,901	,917	8

À semelhança da prega anterior analisada, foi usada a fórmula (7) e obtido o seguinte intervalo de confiança a 95% para α :]0.8946; 0.9367[.

3.3. Análise de associação e regressão

Nesta parte de análise pretende-se verificar a existência de relação entre as variáveis sócio-demográficas das pessoas e a compressibilidade das pregas cutâneas usando as quatro medidas propostas (a média de todos os pontos, a média dos últimos 10 pontos, a mediana de todos os pontos e a mediana dos últimos 10 pontos).

A variável dependente (ou de resposta) é a compressibilidade das pregas cutâneas e as variáveis independentes (ou preditoras) são as variáveis sócio-demográficas. Sendo a variável dependente do tipo quantitativo e dado haver mais que uma variável independente foi utilizada a Regressão Linear múltipla.

Dado que não se conhecia previamente quais as variáveis que constituiriam o modelo, foi utilizado o método *Enter* para a seleção das variáveis.

3.3.1. Média de todos os pontos da prega Tricipital

As variáveis preditoras utilizadas são: idade, sexo, escolaridade, ocupação, peso, massa gorda, estado de saúde, doenças crónicas, índice de massa corporal e Nº de horas que pratica atividade física.

Verificou-se a normalidade da variável resposta, recorrendo ao teste K-S, na qual $p=0.200>5\%$, podendo concluir que existe normalidade.

Tabela 3.20: Testes de Normalidade da prega Tricipital para a média de todos os pontos

	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Estatística	gl	Sig.	Estatística	gl	Sig.
Média de todos os pontos (ponto1 - ponto 180) da prega Tricipital	,083	66	,200 [*]	,988	66	,772

*. Este é um limite inferior da significância verdadeira.

a. Correlação de Significância de Lilliefors

Tabela 3.21: Sumarização do modelo da prega Tricipital para a média de todos os pontos

Modelo	R	R quadrado	R quadrado ajustado	Erro padrão da estimativa
1	,864 ^a	,747	,637	3,337046624

a. Preditores: (Constante), Nº de horas que pratica atividade física/semana, Peso do individuo (em kg), Se tem doenças crônicas, Estado de saúde, Ocupação do individuo, Idade do individuo, Sexo do individuo, Escolaridade, Índice de massa corporal (kg/m2), Massa gorda (em kg)

Podemos verificar pela Tabela 3.21 que 63.7% da variabilidade total em Y (média de todos os pontos da prega tricipital) é explicada pelas variáveis predictoras do modelo ajustado. Quanto a significância do modelo ajustado, vemos na tabela ANOVA que a estatística de teste F=6.786 tem associado um p<0.001 (Sig.=0.000) o que permite concluir que o modelo é bastante significativo.

Tabela 3.22: ANOVA na prega Tricipital para a média de todos os pontos

Modelo	Soma dos Quadrados	gl	Quadrado Médio	F	Sig.
1 Regressão	755,697	10	75,570	6,786	,000
Resíduo	256,125	23	11,136		
Total	1011,823	33			

O modelo ajustado é pois:

Tricipital_MediaTodos = 6.030 – 5.028 Sexo + 0.030 Idade + 0.593 Escol – 0.100 Ocupacao – 0.100 Peso – 0.193 MLG(kg) + 2.124 E_Saude – 0.635 D_Crônicas + 1.119 BMI – 0.325 AF_h

Agora, quais as variáveis que afetam significativamente a variável dependente?

As variáveis “Estado de Saúde” e “Índice de massa corporal” apresentam as maiores contribuições relativas no comportamento da variável dependente. E para um nível de significância de 5% podemos concluir que apenas as variáveis “Estado de Saúde” e “Índice de massa corporal” afetam significativamente a variável dependente ($p < 0.05$).

Pressupondo que os *p-values* encontrados possam ser afetados pelo número de variáveis no modelo, quer pelas correlações entre estas, quer ainda pela dimensão da amostra, foi utilizado também a correção de Bonferroni (α / p). Assim usando esta correção, temos que $\alpha / p = 0.05 / 10 = 0.005$, indicando que com este critério as variáveis não são tidas como significativas no modelo.

Tabela 3.23: Coeficientes da prega Tricipital para a média de todos os pontos

Modelo	Coeficientes não padronizados		Coeficientes padronizados	t	Sig.	Correlações			Estatísticas de colinearidade	
	B	Erro Padrão				Beta	Ordem zero	Parcial	Parte	Tolerância
1 (Constante)	6,030	6,174		,977	,339					
Idade do individuo	,030	,082	,051	,365	,718	-,081	,076	,038	,556	1,799
Sexo do individuo	-5,028	2,836	-,440	-1,773	,090	-,550	-,347	-,186	,178	5,608
Escolaridade	,593	,563	,173	1,054	,303	-,103	,215	,111	,408	2,451
Ocupação do individuo	-,100	,221	-,060	-,453	,655	-,133	-,094	-,047	,624	1,603
Peso do individuo (em kg)	-,100	,194	-,233	-,516	,611	-,082	-,107	-,054	,054	18,478
Massa gorda (em kg)	-,193	,206	-,351	-,937	,359	-,413	-,192	-,098	,079	12,726
Estado de saúde	2,124	,889	,298	2,389	,026	,425	,446	,251	,709	1,411
Se tem doenças crónicas	-,635	1,628	-,049	-,390	,700	-,129	-,081	-,041	,687	1,456
Índice de massa corporal (kg/m2)	1,119	,445	,772	2,512	,019	,272	,464	,264	,116	8,585
Nº de horas que pratica atividade física/semana	-,325	,236	-,175	-1,379	,181	-,069	-,276	-,145	,680	1,470

Pressuposto do modelo através da análise de resíduos

Para verificar o pressuposto de independência dos resíduos consultaremos a tabela dos valores críticos (tabela 1.5) e compararemos com o teste d (de Durbin-Watson) na Tabela 3.24. Assim obtemos para $n=34$ e $p=10$, $d_L=0.95$ e $d_U=2.15$. Assim, sendo $d_L < d = 1.590 < d_U$ nada se pode concluir sobre se existe ou não autocorrelação entre os resíduos. Também, pelo fato do valor da estatística $d=1.590$ estar afastado do valor 2, mostra que os resíduos podem não ser independentes.

Tabela 3.24: Sumarização do modelo da prega Tricipital para a média de todos os pontos

Modelo	R	R quadrado	R quadrado ajustado	Erro padrão da estimativa	Durbin-Watson
1	,864	,747	,637	3,337046624	1,590

A Tabela 3.25 dá uma indicação de possível existência de Outliers e ou casos influentes. Um olhar atento aos diferentes tipos de resíduos, nessa tabela, é possível verificar que poderá existir pelo menos um *Outlier*. Igual conclusão se chega pela análise do valor centralizado de Alavancagem (0.638) que indica a presença de um *Outlier* multivariado.

Tabela 3.25: Estatísticas de resíduos da prega Tricipital para a média de todos os pontos


	Mínimo	Máximo	Média	Desvio Padrão	N
Valor predito	7,256975651	26,84436607	17,25040852	4,785386317	34
Valor Predito Padrão	-2,088	2,005	,000	1,000	34
Erro padrão do valor predito	1,211	2,726	1,851	,428	34
Valor predito ajustado	7,249367237	30,60957527	17,36172016	5,279645242	34
Resíduo	-4,79776144	5,844737530	,000000000000	2,785923730	34
Resíduo Padrão	-1,438	1,751	,000	,835	34
Resíduo studentizado	-1,777	2,082	-,012	1,024	34
Resíduo Excluído	-8,36694908	8,256289482	-,111311642	4,341799756	34
Resíduo Studentizado Excluído	-1,871	2,260	-,004	1,059	34
Mahal. Distância	3,372	21,046	9,706	4,985	34
Distância de Cook	,000	,333	,057	,083	34

Valor Centralizado de Alavancagem	,102	,638	,294	,151	34
-----------------------------------	------	------	------	------	----

Pressuposto da normalidade dos resíduos

Da Figura 3.14, podemos concluir que os resíduos apresentam, aproximadamente, distribuição normal, pois os pontos estão mais ou menos próximos da reta.

Figura 3.14: Análise da normalidade dos resíduos na prega tricipital para a média de todos os pontos



Já com o uso do teste K-S, concluímos que os resíduos cumprem com o pressuposto de normalidade pois o $p=0.200 > 5\%$.

Tabela 3.26: Testes de Normalidade dos resíduos standardizados na prega Tricipital para a média de todos os pontos

	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Estatística	gl	Sig.	Estatística	gl	Sig.
Standardized Residual	,078	34	,200*	,973	34	,542

*. Este é um limite inferior da significância verdadeira.

a. Correlação de Significância de Lilliefors

Pressuposto de homogeneidade de variância dos resíduos

Na Figura 3.15 verifica-se que os resíduos se distribuem de forma mais ou menos aleatória em torno de zero.

Figura 3.15: Distribuição dos resíduos em torno do zero da prega Tricipital para a média de todos os pontos de todos os pontos





Figura 3.16: Distribuição dos resíduos em torno do zero com *press* na prega Tricipital para a média de todos os pontos



Ao utilizar o teste K-S foi encontrado um $p(\text{exato}) = 0.975$, concluindo-se que os resíduos não-estandarizados RES_1 seguem uma distribuição normal.

Tabela 3.27: Teste de Kolmogorov-Smirnov de uma amostra na prega Tricipital para a média de todos os pontos

		Unstandardized Residual
N		34
Parâmetros normais	Média	,0000000
	Desvio Padrão	2,78592373
Diferenças Mais Extremas	Absoluto	,078
	Positivo	,078
	Negativo	-,054
Estatística do teste		,078
Significância Assint. (Bilateral)		,200
Sig exata (bilateral)		,975
Probabilidade de ponto		,000

Pressuposto de Multicolinearidade

Segundo o valor da correlação “Parte” da Tabela 3.23, acima, a variável mais importante para prever a variável resposta é o “Índice de Massa Corporal”, seguida pelo “Estado de Saúde”, depois o “Sexo”, “Nº de horas que pratica atividade física”, “Escolaridade” e assim por diante. Na mesma tabela vemos que as variáveis “Peso” e “Massa gorda (Kg)” tem valores *VIF* muito elevados (18.478 e 12.726 respectivamente), o que mostra que são colineares, pelo que uma delas foi eliminada da análise. Pela correlação “Parte” foi eliminada a variável “Peso” já que a “Massa gorda (Kg)” mostrou-se mais importante em prever a variável resposta.

Excluindo a variável “Peso” da análise

Foi retirada a variável “Peso” para realizar novas análises e ver o que acontecia com o modelo. Com a sua exclusão verificou-se que a variabilidade total em Y (média de todos os pontos da prega tricipital) explicada pelas variáveis preditoras do modelo ajustado aumentou de 63.7% para 64.8%. O modelo continua bastante significativo.

As variáveis “Estado de Saúde” e “Índice de massa corporal” continua a apresentar as maiores contribuições relativas no comportamento da variável dependente, ficando, agora, de fora a “Massa gorda (Kg)”. E para um nível de significância de 5% apenas as variáveis “Estado de Saúde” e “Índice de massa corporal” afetam significativamente a variável dependente ($p < 0.05$). Usando a correção de Bonferroni (α/p) temos que $\alpha/p = 0.05/9 = 0.006$, indicando que agora apenas a variável “BMI” (Índice de Massa Corporal) é tida como significativa no modelo.

Quanto às outras análises de nada se alteraram com a exclusão do “Peso”, sendo certo que deixou de existir o problema de multicolinearidade. Quanto a existência de Outliers agora a observação 44 pode ser considerada como tal, pois se manifesta, de forma mais nítida, afastada dos demais e acima do limite máximo (> 0.6).

Excluindo a variável “Peso” e substituindo a variável “Massa gorda (Kg)” por “Massa gorda (%)”

Foi retirada a variável “Peso” e “Massa gorda (kg)” e inserida a “Massa gorda (%)” para realizar novas análises e ver o que acontece com o modelo, já que a “Massa gorda (%)” é mais normalizado (tabela 3.28).

Tabela 3.28: Testes de Normalidade para as variáveis Massa gorda (kg e %)

	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Estatística	gl	Sig.	Estatística	gl	Sig.
Massa gorda (em kg)	,188	66	,000	,888	66	,000
Massa gorda (em %)	,092	66	,200*	,988	66	,758

*. Este é um limite inferior da significância verdadeira.

a. Correlação de Significância de Lilliefors

Verificou-se que a variabilidade total em Y (média de todos os pontos da prega tricripital) explicada pelas variáveis predictoras do modelo ajustado aumentou de 64.8% para 68.8%. O modelo continua sendo bastante significativo.

Com a substituição da variável “Massa gorda (Kg)” por “Massa gorda (%)” apenas esta influencia significativamente a variável dependente a um nível de 5%. Mas ao usar a

correção de Bonferroni (α / p) temos que $\alpha / p = 0.05 / 9 = 0.006$, indicando que com este critério nenhuma das variáveis é tida como significativa no modelo.

A observação 44 continua sendo um *Outlier* possível. Também, agora, parece, sim, existir, no modelo geral, pontos influentes, sendo eles as observações 1, 20 e 56. Ao verificar pontos influentes para cada coeficiente de regressão também se encontrou as mesmas observações (20 e 56) como sendo influentes na estimação de cada coeficiente de regressão. De resto não houve qualquer alteração na verificação dos outros pressupostos.

Mantendo a variável “Peso” e substituindo a variável “Massa gorda (Kg)” por “Massa gorda (%)”

Verificou-se que a variabilidade total em Y (média de todos os pontos da prega tricipital) explicada pelas variáveis preditoras do modelo ajustado atinge os 74.6%. O modelo continua sendo bastante significativo.

Com a substituição da variável “Massa gorda (Kg)” por “Massa gorda (%)” e mantendo a variável “Peso”, esta passa a ser, juntamente com a “Massa gorda (%)” e “BMI”, uma influencia significativa na variável dependente a um nível de 5%. Mas ao usar a correção de Bonferroni (α / p) temos que $\alpha / p = 0.05 / 10 = 0.005$, indicando que com este critério apenas a variável “Massa gorda (%)” é tida como significativa no modelo.

O problema de multicolinearidade se mantém na variável “Peso”, com $VIF=14.572 > 10$. A conclusão quanto aos restantes pressupostos se mantem inalterados. A presença de *Outliers* e pontos influentes continuam a existir.

Em todas as medidas analisadas com as restantes pregas, se verificou o problema de multicolinearidade com a variável “Peso”, pelo que as análises posteriores foram feitas sem essa variável. A Tabela 3.29 compara o efeito da variável “Peso” na qualidade do modelo quando analisada em conjunto com a variável “Massa gorda” (kg ou %):

Tabela 3.29: Efeito da variável “Peso” na qualidade do modelo na presença da variável “Massa Gorda”

Com “Peso” e com “Massa gorda (kg)	Com “Peso” e com “Massa gorda (%)	Sem “Peso” e com “Massa gorda (kg)	Sem “Peso” e com “Massa gorda (%)
$R_a^2=63.7\%$	$R_a^2=74.6\%$	$R_a^2=64.8\%$	$R_a^2=68.8\%$
Erro-padrão=3.3370	Erro-padrão=2.7894	Erro-padrão=3.2856	Erro-padrão=3.0905

Depois de aplicado o método *Enter* seguiu-se a outros dois métodos, o *Stepwise* e o *Backward* fazendo as análises com e sem a observação 44 considerada *Outlier*.

3.3.1.1. Aplicação do método *Stepwise*

A Tabela 3.30 indica o método de seleção usado (*Stepwise*) e os critérios para a entrada e saída de variáveis e qual a variável selecionada (Massa gorda (%)).

Com este método o modelo continua sendo bastante significativo e a estatística de Durbin-Watson, $d= 1.594$, (ver tabela 3.31), continua a tomar valores que não permite rejeitar a hipótese da autocorrelação dos resíduos.

Tabela 3.30: Variáveis inseridas/removidas do modelo na prega Tricipital para a média de todos os pontos

Modelo	Variáveis inseridas	Variáveis removidas	Método
1	Massa gorda (em %)		Stepwise (Critérios: Probabilidade de F a ser inserido \leq ,050, Probabilidade de F a ser removido \geq ,100).

Tabela 3.31: Sumarização do modelo na prega Tricipital para a média de todos os pontos

Modelo	R	R quadrado	R quadrado ajustado	Erro padrão da estimativa	Durbin-Watson
1	,844 ^a	,713	,704	3,01458039700	1,594

A Tabela 3.32 mostra os valores dos coeficientes de regressão e o VIF da variável independente “Massa gorda (%)” que se mostra altamente significativa.

A Tabela 3.33 mostra as variáveis excluídas da análise, os seus coeficientes e os *p-values* associados às hipóteses de que esses coeficientes não são significativamente diferentes de zero. De acordo com os valores do VIF, nenhum dos preditores removidos apresenta problemas de multicolinearidade.

Tabela 3.32: Coeficientes do modelo da prega tricípital para a média de todos os pontos com o método *stepwise*

Modelo	Coeficientes não padronizados		Coeficientes padronizados	t	Sig.	Correlações			Estatísticas de colinearidade	
	B	Erro	Beta			Ordem zero	Parcial	Parte	Tolerância	VIF
		Padrão								
1 (Constante)	1,636	1,828		,895	,377					
Massa gorda (em %)	,688	,077	,844	8,907	,000	,844	,844	,844	1,000	1,000

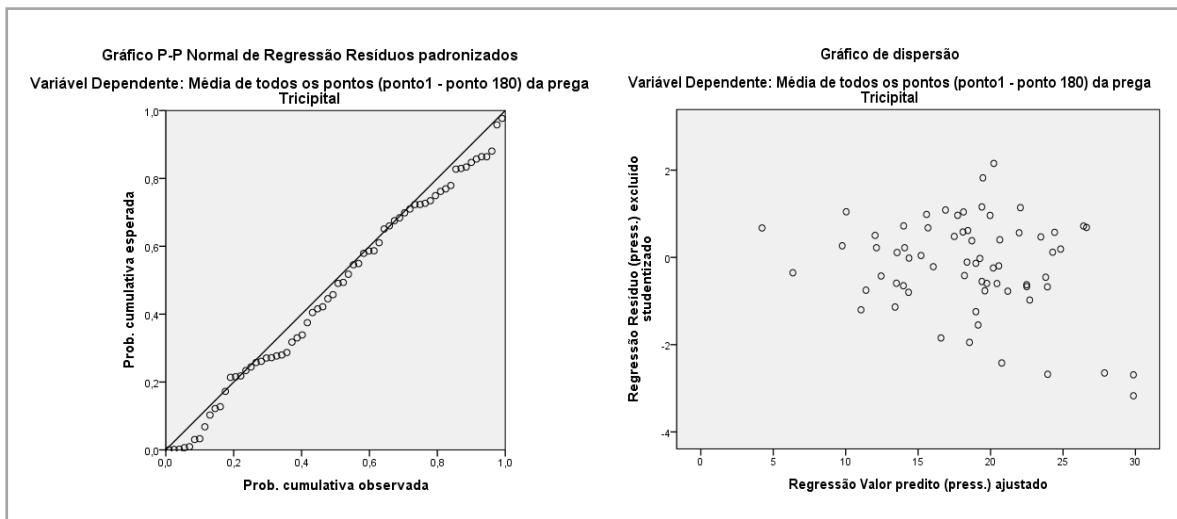
Tabela 3.33: Variáveis excluídas do modelo Tricípital para a média de todos os pontos com o método *Stepwise*

Modelo	Beta In	t	Sig.	Correlação parcial	Estatísticas de colinearidade		
					Tolerância	VIF	Tolerância mínima
1 Sexo do individuo	-,160 ^b	-1,482	,148	-,257	,738	1,354	,738
Idade do individuo	-,075 ^b	-,789	,436	-,140	1,000	1,000	1,000
Índice de massa corporal (kg/m2)	-,054 ^b	-,525	,603	-,094	,858	1,166	,858
Nº de horas que pratica atividade física/semana	,061 ^b	,628	,535	,112	,977	1,024	,977
Se tem doenças crónicas	-,018 ^b	-,187	,853	-,034	,983	1,018	,983
Escolaridade	-,094 ^b	-,996	,327	-,176	1,000	1,000	1,000
Ocupação do individuo	-,107 ^b	-1,133	,266	-,199	,999	1,001	,999
Estado de saúde	,149 ^b	1,499	,144	,260	,878	1,139	,878

A Figura 3.19 permite validar os pressupostos do modelo. Não há indícios de *outliers* e os dados apresentam distribuição normal.

Dado que nenhuma das variáveis presentes na análise apresenta *VIF* elevados, será usado o método *Backward*.

Figura 3.19: Análise de normalidade e dispersão dos dados da prega Tricipital com o método *Stepwise* para a média de todos os pontos



3.3.1.2. Aplicação do método *Backward*

Na Tabela 3.34 verifica-se que o modelo 7 é a melhor escolha pois apresenta um maior R_a^2 e um menor erro-padrão do que os restantes modelos, sendo todos os modelos significativos ($p < 0.001$).

Da Tabela 3.35, seguinte, foi suprido os restantes modelos, apresentando apenas o modelo 7 escolhido. Este quadro permite observar a importância relativa das variáveis predictoras neste modelo. Para um nível de significância de 5% apenas a variável "Massa gorda (%)" fará parte do modelo, mas para um nível de significância de 10% todas as variáveis se manteriam presentes no modelo.

Tabela 3.34: Sumarização do modelo da prega Tricipital com o método *Backward* para a média de todos os pontos

Modelo	R	R quadrado	R quadrado ajustado	Erro padrão da estimativa	Durbin-Watson
1	,879	,773	,688	3,09054162301	
2	,879	,773	,701	3,02979031291	
3	,879	,772	,711	2,97802026115	
4	,878	,771	,720	2,92958505519	
5	,877	,768	,727	2,89383197275	
6	,874	,764	,731	2,86939363580	
7	,871	,758	,734	2,85763021984	1,728

Tabela 3.35: Coeficientes do modelo da prega Tricipital com o método *Backward* para a média de todos os pontos

Modelo	Coeficientes não padronizados		Coeficientes padronizados	t	Sig.	Correlações			Estatísticas de colinearidade	
	B	Erro Padrão	Beta			Ordem zero	Parcial	Parte	Tolerância	VIF
7 (Constante)	3,999	2,236		1,788	,084					
Sexo do individuo	-2,161	1,207	-,189	-1,790	,084	-,550	-,311	-,161	,722	1,386
Massa gorda (em %)	,560	,092	,686	6,090	,000	,844	,744	,547	,636	1,573
Estado de saúde	1,248	,692	,175	1,804	,081	,425	,313	,162	,858	1,166

3.3.1.3. Modelo final da prega Tricipital

O modelo final é obtido selecionando todas as variáveis significativas registradas em cada um dos três métodos aplicados. Assim o modelo final será composto pelas três variáveis “Massa gorda (%)”, “Sexo” e “Estado de saúde”. Novamente será aplicado o método *Enter*, produzindo o seguinte *output* (ver tabelas 3.36 a 3.39):

Tabela 3.36: Variáveis inseridas/removidas do modelo final da prega Tricipital para a média de todos os pontos

Modelo	Variáveis inseridas	Variáveis removidas	Método
1	Estado de saúde, Sexo do indivíduo, Massa gorda (em %)	.	Inserir

Tabela 3.37: Sumarização do modelo final da prega Tricipital para a média de todos os pontos

Modelo	R	R quadrado	R quadrado ajustado	Erro padrão da estimativa	Durbin-Watson
1	,814	,662	,645	3,17596086095	1,946

Tabela 3.38: ANOVA no modelo final do modelo final da prega Tricipital para a média de todos os pontos

Modelo		Soma dos Quadrados	gl	Quadrado Médio	F	Sig.
1	Regressão	1223,936	3	407,979	40,447	,000
	Resíduo	625,377	62	10,087		
	Total	1849,313	65			

Tabela 3.39: Coeficientes do modelo final do modelo final da prega Tricipital para a média de todos os pontos

Modelo		Coeficientes não padronizados		Coeficientes padronizados	t	Sig.	Correlações			Estatísticas de colinearidade	
		B	Erro Padrão	Beta			Ordem zero	Parcial	Parte	Tolerância	VIF
1	(Constante)	5,374	1,567		3,430	,001					
	Sexo do indivíduo	-1,971	,972	-,163	-2,029	,047	-,442	-,249	-,150	,846	1,182
	Massa gorda (em %)	,505	,059	,710	8,485	,000	,797	,733	,627	,778	1,285
	Estado de saúde	,620	,590	,081	1,051	,297	,294	,132	,078	,913	1,095

Neste modelo final, dado que a variável “Estado de saúde” não é significativa ($p=0.297>0.05$), de novo foi selecionado o modelo final, agora, composto apenas pelas

variáveis “Massa gorda (%)” e “Sexo”, obtendo os seguintes resultados (ver tabelas 3.40 a 3.43):

Tabela 3.40: Variáveis inseridas/removidas do novo modelo final da prega Tricipital para a média de todos os pontos

Modelo	Variáveis inseridas	Variáveis removidas	Método
1	Massa gorda (em %), Sexo do individuo ^b	.	Inserir

Tabela 3.41: Sumarização do novo modelo final da prega Tricipital para a média de todos os pontos

Modelo	R	R quadrado	R quadrado ajustado	Erro padrão da estimativa	Durbin-Watson
1	,810	,656	,645	3,178600961665253	1,907

Tabela 3.42: ANOVA para o novo modelo final da prega Tricipital para a média de todos os pontos

Modelo		Soma dos Quadrados	gl	Quadrado Médio	F	Sig.
1	Regressão	1212,792	2	606,396	60,018	,000
	Resíduo	636,521	63	10,104		
	Total	1849,313	65			

Tabela 3.43: Coeficientes do novo modelo final da prega Tricipital para a média de todos os pontos

Modelo	Coeficientes não padronizados		Coeficientes padronizados		Sig.	Correlações			Estatísticas de colinearidade	
	B	Erro Padrão	Beta	t		Ordem zero	Parcial	Parte	Tolerância	VIF
1 (Constante)	5,570	1,557		3,577	,001					
Sexo do individuo	-1,902	,970	-,157	-1,960	,054	-,442	-,240	-,145	,850	1,176
Massa gorda (em %)	,523	,057	,736	9,180	,000	,797	,756	,679	,850	1,176

O modelo final é então:

$$\text{Tricipital_MediaTodos} = 5.570 - 1.902 \text{ Sexo} + 0.523 \text{ Massa gorda (\%)}$$

Todos os coeficientes de regressão são significativos (para $\alpha = 0.10$), e o modelo ajustado explica 64.5% ($p < 0.001$) da variação observada na variável “Tricipital_MediaTodos”. As variáveis preditoras não são colineares (VIF= 1.176 quer para o Sexo quer para a Massa gorda (%)) e de acordo com os gráficos dos resíduos produzidos conclui-se que os resíduos apresentam distribuição normal e variância constante. Usando os resíduos não estandardizados podemos afirmar, pelo teste de Kolmogorov-Smirnov com correção de Lilliefors, que os resíduos apresentam distribuição normal ($p = 0.200 > 0.05$).

Dos restantes *outputs* produzidos verificou-se os seguintes: A tabela “Estatísticas de resíduos” demonstra que não existem valores de *Leverage* ou de *Std. Deleted Residual* suficientemente extremos para indicar a presença de *outliers*. A estatística de Durbin-Watson é $d = 1.907$, e de acordo com a tabela dos valores críticos dessa estatística, para $n = 66$ e $p = 2$, temos $d_L = 1.55$ e $d_U = 1.67$ pelo que não se rejeita a hipótese nula de que os resíduos são independentes. A tabela do “Diagnóstico de colinearidade” apresenta um *índice de condição* abaixo do valor 15 indicando não haver qualquer problema de multicolinearidade.

As mesmas análises, ilustradas acima, foram feitas com todas as medidas-resumo em todas as restantes pregas e todos os pressupostos do modelo de regressão foram satisfeitas. Os quadros em anexo (Anexos I a VIII) resumem todas as análises feitas com a aplicação dos três métodos em cada medida-resumo para todas as pregas, com a presença e com a exclusão da observação 44 considerada *outlier*. Desses quadros deriva-se as seguintes análises possíveis:

- A observação nº 44, considerada *Outlier*, quando excluída da base de dados, tem, sim, influência sobre os resultados. Essa influência parece não ser significativa no R_a^2 e Erro padrão, mas a sua exclusão leva que apareça novas variáveis significativas no modelo final de quase todas as pregas e também exclui outras variáveis.

- Foi aplicado o teste t para amostras relacionadas, para averiguar se a diferença das médias dos R_a^2 e também dos Erros-padrão com a inclusão e exclusão do *Outlier* era nula. Foi verificado que apenas nas pregas Subescapular, Crural, Bicipital e Abdominal existe diferença entre as médias, mas essa diferença é significativa apenas na prega Crural e Bicipital; ou seja, a exclusão do *Outlier* (Observação nº 44) apenas produz alterações significativas no R_a^2 (na prega Crural) e no Erro padrão (na prega Bicipital).
- A variação das variáveis significativas no modelo final acontece em todas as pregas, com exceção da prega Bicipital e Supraespinal, independentemente de excluir ou não o *Outlier*. Nestas duas pregas, as variáveis significativas no modelo final com a inclusão do *Outlier* são as mesmas com a exclusão do *Outlier*.

Abaixo (tabelas 3.44 a 3.46), um exemplo do teste t para amostras emparelhadas efetuado (o mesmo foi feito com as outras pregas):

Tabela 3.44: Estatísticas de amostras emparelhadas para a prega Crural

		Média	N	Desvio Padrão	Erro Padrão da Média
Par 1	RC44_Crural	52,1250	4	,42720	,21360
	RS44_Crural	49,9250	4	,28723	,14361

Tabela 3.45: Correlações de amostras emparelhadas para a prega Crural

		N	Correlação	Sig.
Par 1	RC44_Crural & RS44_Crural	4	,998	,002

Tabela 3.46: Teste de amostras emparelhadas para a prega Crural

		Média	Desvio Padrão	Diferenças emparelhadas		t	gl	Sig. (bilateral)	
				Erro Padrão da Média	95% Intervalo de Confiança da Diferença Inferior Superior				
Par 1	RC44_Crural - RS44_Crural	2,20000	,14142	,07071	1,97497	2,42503	31,113	3	,000

RC44 = refere-se ao R^2 com a presença do *Outlier* (44) RS44 = refere-se ao R^2 sem a presença do *Outlier* (44)

Quanto à medida a utilizar (média de todos os pontos, média dos últimos 10 pontos, mediana de todos os pontos ou mediana dos últimos 10 pontos), poder-se-ia utilizar a média dos últimos 10 pontos (ponto 170 – 180), pois apresenta melhores resultados de R_a^2 e erro padrão em todas as pregas, independentemente de excluir ou não o *Outlier*. Mas seria relevante? Para verificar foi aplicado o teste *t* para amostras relacionadas.

Quando comparado a média dos últimos 10 pontos com as restantes medidas-resumo, para verificar se existe diferença entre as médias do R_a^2 e erro padrão obtidos em todas as pregas, vemos:

Com a exclusão do *Outlier*: não existe diferença entre as médias, tanto no R_a^2 como no Erro padrão (e é significativa); ou seja, a aplicação da média dos últimos 10 pontos é justificável. Essa mesma conclusão se verifica comparando a média dos últimos 10 com as outras medidas. A mesma análise foi feita com a inclusão da observação 44, considerada *outlier*:

Com a inclusão do *Outlier*: não existe diferença entre as médias no R_a^2 (e é significativa), mas existe diferença significativa entre as médias dos Erros padrão. Comparando a média dos últimos 10 com as restantes medidas verifica-se que não existe diferença.

3.3.1.4. Característica do *Outlier* (observação nº 44)

A observação ou o caso ou o individuo número 44 foi diagnosticado como sendo um *outlier* com um efeito considerado moderado, dado que está mais próxima do meio do que dos limites do domínio das observações. Dado que ao excluí-lo da base de dados mostrou-se ter alguma influencia na determinação das variáveis significativas, eis as suas características: sexo (Mulher = a maioria), Idade (22 anos – abaixo da média), Massa gorda (31.9% - acima da média), Índice de Massa Corporal (33.1 m/kg² – acima da média), Nº de horas de atividade física/semana (14 horas/semana – muito acima da média), Estado de saúde (Mau – muito abaixo da maioria), Ocupação (Estudante = a maioria) e Escolaridade (12 anos – abaixo da maioria).

O fato desta jovem praticar catorze horas por semana (duas horas por dia) de exercício físico (no ginásio) e alegar mau estado de saúde, sendo ela estudante, leva a pensar duas coisas: que pode ser um erro de digitalização de dados como pode não ser. A segunda opção é a mais plausível dado que ela tem uma doença crónica, a obesidade. Pelo valor do índice de massa corporal (33.1 m/kg²) não se coloca a hipótese da presença de obesidade mórbida ou severa, pois segundo Fonseca-Junior *et al.* (2013) “Indivíduos com índice de massa corporal (BMI) acima de 40 m/kg² são considerados obesos de grau 3, mórbidos ou severos” (Fonseca-Junior *et al.*, 2013: 67). Diante dessas informações pode-se colocar a hipótese de que o nº de horas de prática de exercício físico (duas horas por dia) parece que não tem vindo a ajudar na perda de peso. Não se sabe qual o tipo de exercício que a jovem pratica no ginásio. Caso o tipo de exercício no ginásio for aeróbico, Fonseca-Junior *et al.* (2013) recomenda que seja feita 250 minutos de exercícios aeróbicos por semana com intensidade moderada para prevenir o aumento de peso. Esse valor recomendado é, praticamente, o mesmo valor médio (3.91 horas/semana) de atividade física praticada semanalmente pelos indivíduos que constam do presente estudo. Caso for outro tipo de exercício feito no ginásio o problema da obesidade tende a permanecer, pois segundo Santos (2006) “O exercício, quer pelo aumento da massa gorda [...] quer pelo efeito deplector de energia, ajuda, mas não resolve o problema da obesidade” (Santos, 2006:162). Outra hipótese se coloca quanto a uma alimentação saudável e rigorosa, que poderá estar em falta, para não conseguir baixar de peso apesar de tantas horas de exercício semanal. Uma outra hipótese tem a ver com desvios genéticos ou hormonais (Santos, 2006:162). As duas últimas hipóteses não são verificáveis dado a não existência dessas informações por parte do entrevistado, na base de dados.

3.3.1.5. Característica dos pontos influentes

Das análises verificou-se que a média dos últimos 10 pontos é a medida-resumo que produz melhores resultados em termos da qualidade dos modelos de cada prega, devido ao seu maior R_a^2 e menor Erro-padrão, sendo por isso escolhida para analisar os pontos influentes.

A figura do anexo XI, mostra os pontos influentes em cada prega para cada coeficiente do modelo bem como para o modelo geral. Comparando com os modelos iniciais de cada prega, com ou sem a eliminação do *outlier*, verifica-se que o modelo sem os pontos influentes aumentam de qualidade em todas as pregas ($> R_a^2$ e $<$ Erro-padrão) com exceção das pregas Supraespinal e Subescapular (no R_a^2 - ocorre quando não se exclui o *outlier*). Os valores (não os sinais) dos coeficientes de regressão aumentam e diminuem ligeiramente com a eliminação dos pontos influentes. A eliminação dos pontos influentes faz aumentar o *Índice de Condição* em algumas pregas (Abdominal, Subescapular, Iliocristal e Crural), principalmente com a exclusão do *Outlier*, mas não implicando problemas de multicolinearidade.

Quanto ao efeito dos pontos influentes em cada coeficiente de cada prega, a análise feita com a presença do *outlier* (C/44) e com a sua eliminação (S/44) é a seguinte:

Na prega Iliocristal:

C/44: os casos influentes são Indivíduos homens. A percentagem de massa gorda é acima da média ($>24.5\%$).

S/44: indivíduos com a percentagem de massa gorda praticamente abaixo da média ($<24.34\%$), sendo apenas dois acima da média. Com BMI acima da média ($> 23.46\text{m/kg}^2$), sendo apenas um abaixo da média ($<23.46 \text{ m/kg}^2$).

Na prega Subescapular:

C/44: indivíduos com um nº de horas de atividade física abaixo da média (<3.91 horas) e um acima da média (cerca de 4 vezes acima). Com um BMI acima da média (>23.6) e com estado de saúde acima da maioria ($>$ Bom) e um abaixo ($<$ Bom). Verifica-se que o mesmo individuo com estado de saúde acima da maioria tem 31.3m/kg^2 de BMI. Outro individuo com um BMI de 33.1 m/kg^2 pratica 14 horas de exercício físico por semana. Um outro com 34.7 m/kg^2 de BMI pratica apenas 1 hora de exercício por semana.

S/44: o tipo de sexo é igual a da maioria (Mulher). Com um BMI acima da média (>23.46 m/kg²). Com um estado de saúde igual ou mais que a maioria (>= Bom), apenas um apresenta abaixo do Bom. Pode-se constatar que duas das mulheres diferem no BMI tendo em conta o estado de saúde. A que possui um estado de saúde igual a da maioria tem maior BMI do que a outra com um estado de saúde abaixo da maioria (< Bom).

Na prega Crural:

C/44: os indivíduos influentes são tanto homem como mulheres. Apresentam uma percentagem de massa gorda acima da média (> 24.5%), com uma única exceção (esta exceção é homem e com 23.5% de MG). As idades estão acima da média (> 28.9), com uma única exceção (23 anos). Possuem BMI acima da média (> 23.6 m/kg²), com uma única exceção (com 22.8 BMI).

S/44: a mesma análise.

Na prega Bicipital:

C/44: indivíduos com MG acima da média (> 24.5%).

S/44: mesma análise.

Na prega Tricipital:

C/44: indivíduos com MG acima da média (> 24.5%).

S/44: mesma análise.

Na prega Abdominal:

C/44: quanto ao nº de horas por semana de atividade física, dois dos indivíduos estão abaixo da média (<3.91 horas) e outros dois acima (cerca de duas a três mais acima da média). A ocupação dos indivíduos influentes é de secretariado e assistente social.

S/44: quanto ao nº de horas por semana de atividade física, estão acima da média (>3.6 h/s), quase duas vezes mais, e apenas um está abaixo. A ocupação dos indivíduos influentes é de secretariado e assistente social. Os indivíduos possuem um BMI acima da média

(>23.46 m/kg²) sendo apenas um abaixo. Quanto ao estado de saúde apenas um está abaixo da maioria (< Bom), ou seja, de saúde razoável.

Na prega Supraespinal:

C/44: o individuo apresenta com uma percentagem de massa gorda muito abaixo da média (<< 23.6%). Apresenta um estado de saúde igual a maioria (=Bom). O nº de horas de atividade física por semana, para um está abaixo da média (<3.91 h/s) enquanto para outro está muito acima da média (este individuo é o nosso outlier).

S/44: a percentagem de massa gorda está acima da média (>24.34%), sendo apenas um abaixo. O estado de saúde está abaixo da média (< Bom), sendo razoável e mau. O nº de horas de atividade física por semana está acima da média (> 3.6 h/s). Dois dos indivíduos influentes tem um nível de escolaridade igual e acima da maioria (>= licenciatura) e outros dois abaixo (com 12 anos de escolaridade).

Na prega Geminal:

C/44: a percentagem de massa gorda está acima da média (>24.5%). A idade muito acima da média (>28.9 anos).

S/44: dois dos influentes tem uma percentagem de massa gorda acima da média (>24.34%) e outro muito abaixo. A idade está acima da média (>28.97 anos).

3.4. Relação das pregas com o estado de hidratação

Inicialmente foi verificado se as variáveis dependentes: “Água corporal total”, “Água corporal intracelular” e “Água corporal extracelular” seguiam uma distribuição normal (Hill & Hill, 2005). Verificou-se que tal não se verificava, pois, $p=0.000<0.05$ (tabela 3.47). Assim, seguindo a sugestão do mesmo autor, foi feita uma transformação em cada uma. A “Água corporal total” e “Água corporal intracelular” apresentaram uma distribuição assimétrica positiva, portanto foi aplicado a transformação $\log X$. A “Água corporal extracelular” apresentou-se com uma distribuição assimétrica negativa e foi aplicado a transformação

\sqrt{X} . Mas continuaram não seguindo uma distribuição normal. Mas dado que as técnicas multivariadas são robustas, prosseguiram as análises sem o pressuposto da normalidade.

Tabela 3.47: Testes de Normalidade para os estados de hidratação

	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Estatística	gl	Sig.	Estatística	gl	Sig.
Água corporal total (em kg)	,208	66	,000	,872	66	,000
Água corporal intracelular (em kg)	,206	66	,000	,871	66	,000
Água corporal extracelular (em %)	,232	66	,000	,666	66	,000

a. Correlação de Significância de Lilliefors

Dos resultados obtidos (ver tabela 3.48) pode-se constatar que a média dos últimos 10 pontos é a medida-resumo que trás melhor qualidade ao modelo, pois apresenta maior R_a^2 e menor erro padrão. Entretanto a proporção explicada pelo modelo em cada estado de hidratação é muito baixa. A maior proporção explicada pelo modelo aparece relacionada com a “Água corporal total (%)” que se aproxima dos 39% e é o único que satisfaz os pressupostos para a aplicação do modelo de regressão. O estado de hidratação “Água corporal total (%)” apresenta um *Outlier* correspondente ao caso nº 17, com a seguinte característica: é um individuo do sexo masculino, de 30 anos de idade, com 34.7 m/kg² de BMI, com 36% de massa gorda, com 43.8% de água corporal total, com 27.1Kg de água corporal intracelular, com *Bom* estado de saúde e bolseiro. Quanto a “Água corporal extracelular (%)” o *Outlier* corresponde ao caso nº 12 caracterizado por ser um individuo do sexo feminino, de 55 anos de idade, com 34.2 m/kg² de BMI, com 41% de massa gorda, com 47.5% de água corporal extracelular, com *Bom* estado de saúde e reformada. A “Água corporal intracelular (kg)” não apresenta nenhum *outlier*. Tendo detetado os outliers, novas análises se fizeram, agora com a exclusão dos *outliers* identificados anteriormente, a fim de verificar o comportamento do modelo. As analises foram feitas apenas para a média dos últimos 10 pontos, dado ser a medida que melhor qualidade trás ao modelo:

Com relação a “Água corporal extracelular (%)”, sem o *outlier*, as pregas Subescapular e Iliocristal que antes eram significativas, deixaram de o ser. A qualidade do modelo se

manteve apesar do R_a^2 passar de 28.4% para 28.3% e ter sofrido um ligeiro aumento (não significativo) no erro-padrão, passando de 3.3642 para 3.3672. De resto nada se alterou. Quanto aos pontos influentes, no modelo geral, foi detetado os casos 7 e 12. Nos coeficientes da regressão foi detetado os casos 12 e 13 (na prega Bicipital) e os casos 6, 7 e 12 (na prega Geminal). Eliminando os pontos influentes do modelo geral, verificou-se que a qualidade do modelo melhorou, passando de $R_a^2=28.3\%$ para $R_a^2=38.2\%$, diminuindo muito o erro-padrão (1.9360). Todos os pressupostos do modelo foram satisfeitos com a eliminação dos pontos influentes, principalmente quanto à normalidade dos resíduos.

Com relação a “Água corporal total (%)”, sem o *outlier*, a qualidade do modelo diminuiu passando de $R_a^2=38.7\%$ para $R_a^2=37.9\%$, diminuindo também o erro-padrão. Quanto aos pontos influentes, no modelo geral, foi detetado os casos 8, 15, 37 e 39. Nos coeficientes de regressão foi detetado os casos 8, 12 e 37 (na prega Iliocristal) e os casos 7, 13, 15 e 55 (na prega Geminal). Ao eliminar esses pontos influentes, do modelo geral, verificou-se um melhoramento na qualidade do modelo, passando de $R_a^2=37.9\%$ para $R_a^2=44.0\%$, diminuindo ligeiramente o erro-padrão. Todos os pressupostos do modelo foram satisfeitos, com a eliminação dos pontos influentes, principalmente quanto à normalidade dos resíduos; mas, agora, não se consegue concluir sobre a autocorrelação dos resíduos ($d=1.190$).

Com relação a “Água corporal intracelular (kg)”, foi detetado, no modelo geral, os casos 6, 8, 9, 16, 17, 20, 24, 25, 26, 34 e 40. Nos coeficientes de regressão foi detetado os casos 6, 9, 16, 20, 24, 34 e 40 (na prega Tricipital) e os casos 6, 8, 16, 17 e 25 (na prega Iliocristal). Com o eliminar desses pontos influentes, do modelo geral, este aumentou de qualidade, passando de $R_a^2=26.3\%$ para $R_a^2=31.4\%$, diminuindo também o erro-padrão, de 3.9678 para 2.8286 e provocando pequenas alterações (não significativas) nos valores dos coeficientes de regressão. Mesmo com a eliminação dos outliers e dos pontos influentes, a proporção explicada pelo modelo, em cada estado de hidratação continua sendo muito baixa para a “Água corporal intracelular (kg)” e para a “Água corporal extracelular (%)”, mas passa a moderada na “Água corporal total (%)”.

Tabela 3.48: Relação das pregas com o estado de hidratação

	Estado de hidratação	Média de todos os pontos			Média dos últimos 10			Observação
		R_a^2	Erro padrão	Variáveis significativas (modelo final)	R_a^2	Erro padrão	Variáveis significativas (modelo final)	
1.	Água corporal total (%)	37.5%	5.4063	Iliocristal e Geminal	38.7%	5.3537	Iliocristal e Geminal	Problemas de normalidade dos resíduos.
2.	Água corporal intracelular (kg)	25.2%	3.9984	Tricipital e Iliocristal	26.3%	3.9678	Tricipital e Iliocristal	Não tem problemas de normalidade de resíduos e preenche todos os pressupostos
3.	Água corporal extracelular (%)	29.7%	3.3742	Subescapular, Bicipital, Iliocristal e Geminal	28.3%	3.3672	Bicipital e Geminal	Problemas de normalidade dos resíduos.
Observação		1. A_Corp_Total= 68.700 – 0.439Iliocristal – 0.518Geminal 2. A_Corp_Intra = 23.225 – 0.564Tricipital + 0.437Iliocristal 3. A_Corp_Extra = 35.712 + 0.200Subescapular + 0.252Bicipital – 0.222Iliocristal + 0.271Geminal			1. A_Corp_Total= 68.694 – 0.447Iliocristal – 0.536Geminal 2. A_Corp_Intra = 22.949 – 0.590Tricipital + 0.475Iliocristal 3. A_Corp_Extra = 34.845 + 0.204Bicipital + 0.291Geminal			A água corporal total (%) apresenta melhores resultados que a Água corporal total (Kg). Mas as variáveis do modelo final para a Água corporal total (kg) é Tricipital e Geminal.

	Estado de hidratação	Mediana de todos os pontos			Mediana dos últimos 10			Observação
		R_a^2	Erro padrão	Variáveis significativas (modelo final)	R_a^2	Erro padrão	Variáveis significativas (modelo final)	
1.	Água corporal total (%)	38.2%	5.3760	Iliocristal e Geminal	38.5%	5.3608	Iliocristal e Geminal	Problemas de normalidade dos resíduos.
2.	Água corporal intracelular (kg)	25.9%	3.9779	Tricipital e Iliocristal	26.3%	3.9678	Tricipital e Iliocristal	Não tem problemas de normalidade de resíduos e preenche todos os pressupostos
3.	Água extracelular (%)	29.6%	3.3761	Subescapular, Bicipital, Iliocristal e Geminal	29.6%	3.3769	Subescapular, Bicipital, Iliocristal e Geminal	Problemas de normalidade dos resíduos.
Observação		1. A_Corp_Total= 68.677 – 0.433Iliocristal – 0.536Geminal 2. A_Corp_Intra = 22.972 – 0.577Tricipital + 0.461Iliocristal 3. A_Corp_Extra = 35.856 + 0.194Subescapular + 0.249Bicipital – 0.220Iliocristal + 0.274Geminal			1. A_Corp_Total= 68.695 – 0.443Iliocristal – 0.540Geminal 2. A_Corp_Intra = 22.956 – 0.591Tricipital + 0.475Iliocristal 3. A_Corp_Extra = 35.891 + 0.197Subescapular + 0.255Bicipital – 0.222Iliocristal + 0.272Geminal			

Conclusão

Em todas as medidas-resumo escolhidas em análise neste estudo (média de todos os pontos, média dos últimos 10 pontos, mediana de todos os pontos e mediana dos últimos 10 pontos), a maioria das correlações se apresentaram de forma moderada, significando que cada prega cutânea tem algo em comum com as restantes pregas. A *média dos últimos 10 pontos* foi a medida-resumo que apresentou uma maior percentagem de correlações moderadas (60.7%).

A correlação entre as pregas Abdominal e Tricipital (em todas as medidas-resumo, excetuando a média de todos os pontos), Geminal e Subescapular (em todas as medidas), Geminal e Iliocristal (apenas nas medianas) mostraram-se fracas, todavia significativas. Isto poderá indicar ou a necessidade de haver mais dados ou apenas explica pouca variação.

Outro fato é que a prega Tricipital, em qualquer uma das medidas-resumo, é a que tem a maior percentagem de variabilidade explicada pelas outras pregas, sendo essa percentagem acima dos 84.0%.

Constatou-se que o índice de Alpha de Cronbach, em qualquer uma das medidas-resumo, sempre pode ser maior com a exclusão da prega Abdominal. Também se verificou que o Alpha diminuiria se retirada qualquer uma das pregas (caindo de Muito Boa para Boa consistência interna, excetuando no caso da prega Abdominal), concluindo daqui que a fiabilidade dos dados de compressibilidade depende da contribuição de cada uma das pregas, não sendo necessariamente dependente da prega Abdominal.

O valor do Alpha em todas as medidas-resumo escolhidas foi de 0.917, exceto a média de todos os pontos ($\alpha = 0.916$). Entretanto, a inferência sobre a estimativa do Alpha de Cronbach ($\hat{\alpha}$) foi calculada através do intervalo de confiança apresentado em Maroco e Garcia-Marques (2006) e qualquer que fosse a medida escolhida o Alpha situou-se no intervalo [0.893; 0.937]. Qualquer valor de Alpha neste intervalo é de uma fiabilidade moderada à elevada e, portanto, pode ser considerado aceitável e o instrumento de medição das pregas como sendo fiável.

A variável “Peso” provoca problemas de multicolinearidade, sempre que é analisada em conjunto com a variável “Massa gorda” (kg ou %). Entretanto esta mostrou-se contribuir mais para o modelo, pelo que a variável “Peso” foi excluída da análise.

A média dos últimos 10 pontos (ponto 170 a 180) mostrou ser a medida-resumo mais adequada na verificação da relação entre as pregas e as variáveis sócio-demográficas bem como na relação entre as pregas com o estado de hidratação, pois ao comparar o R_a^2 e o erro-padrão de todas as medidas-resumo, essa se mostrou melhor, dado que apresentou com maior R_a^2 e menor erro padrão.

Das análises realizadas tanto na presença como na ausência do outlier, verificou-se que a compressibilidade das pregas tende a ser caracterizada pelas variáveis Sexo, Índice de massa corporal, Massa gorda (%), Atividade física, Estado de saúde, Idade, Ocupação e Escolaridade; sendo esta última referente apenas à exclusão do *outlier*.

Na relação entre as pregas e o estado de hidratação, a qualidade do modelo se mostrou muito fraca, abaixo dos 39.0%. A proporção de água corporal total é a que se mostrou melhor, apesar da qualidade do modelo se manter muito fraca ($R_a^2=38.7\%$). Mesmo com a exclusão dos *outliers* e dos pontos influentes esse cenário se manteve, continuando a apresentar melhoria apenas na “Água corporal total” ($R_a^2=44.0\%$). Sendo assim, conclui-se que a percentagem da variabilidade total do estado de hidratação explicada pelas pregas cutâneas é muito baixa (podendo chegar a moderada), não alcançando o esperado que seria, segundo Maroco (2011) acima de 0.9 em caso das ciências exatas e acima de 0.5 em caso das ciências sociais; portanto, a medição das pregas (método fácil e não invasivo) pode, ainda, não ser vista como um estimador ou preditor do estado de hidratação de um indivíduo.

A exclusão dos *outliers* da base de dados influenciou, sim, os resultados da regressão múltipla assim como afirma Hill e Hill (2005). Em determinados momentos fez aumentar a qualidade e em outros fez diminuir a qualidade do modelo, consoante o tipo de variáveis em análise. Mas sempre fez diminuir o erro-padrão que é um indicador importante na ajuda da escolha do melhor modelo.

Os pontos influentes também influenciam, e muito, os resultados da regressão. Com a eliminação dos pontos influentes os modelos aumentaram de qualidade com ou sem a presença do *outlier*. Apenas nas pregas Supraespinal e Subescapular tal não se verifica devido a presença do *outlier*.

No processo de escolher quais os pontos influentes, chegou-se a duas, outras, possíveis conclusões: (1) a qualidade do modelo não é influenciada pela quantidade de dados influentes, mas sim pela escolha mais acertada dos mesmos e (2) caso o nível de qualidade do modelo se diminuir com a eliminação dos dados influentes, é caso de se por em causa a escolha desses dados como sendo influentes. A eliminação das observações influentes fez aumentar, em alguns casos, o valor do *condition index*, mas não criando grandes problemas de multicolinearidade.

Durante as análises dos *outliers* e pontos influentes, ficou evidente que as diferentes técnicas de detetar esses valores devem ser feitas em conjunto para que se possa chegar a uma conclusão mais plausível de quem seja os *outliers* e os pontos influentes. Muitas vezes surge uma certa “contradição” quanto aos valores apresentados na tabela “Estatística de resíduos” com a visualização gráfica e outras vezes esta com as fórmulas que permite detetar *outliers* e pontos influentes descritos em Pestana e Gageiro (2008).

A análise multivariada permite trazer à luz várias conclusões referentes a uma base de dados, pelo que muitas outras análises poderiam ser feitas para poder comparar e testar outras alternativas. Mas como é óbvio, dada a limitação de tempo e do número de páginas disponíveis para uma tese de dissertação, não foi possível dissecar todo o tipo de análises. Assim, como sugestão imediata para a continuidade do trabalho fica a aplicação da análise fatorial de componentes principais e da persistência no uso de Clusters, bem como desenvolver pacotes em R que permitam simular a estimativa da gordura corporal e da composição corporal. Ainda poderá ser pesquisado e trabalhado outros artefatos que possam existir para a compreensão do objeto de estudo e que poderão ter fugido do controlo no âmbito desta dissertação.

Bibliografia

Afifi, Abdelmonem A. and Clark, Virginia. 1999. Computer-Aided Multivariate Analysis, 2nd ed. London: Chapman and Hall Limited.

Allison, P. D. (2001). Missing Data (Quantitative Applications in the Social Sciences) (1ª ed.). Thousand Oaks, CA: SAGE Publications.

Baumgartner RN, Chumlea WC, Roche AF (1988). Bioelectric impedance phase angle and body composition. Am J Clin Nutr. 48:16-23.

Belsey, D.A, Kuh, E., Welsch, R. 1980, Regression diagnostics: identifying influential data and sources of collinearity, New York, Wiley.

Brozek J, Kinzey W (1960). Age changes in skinfold compressibility. J Gerontol. 15:45-51.

Brozek J, Grande F, Anderson JT et al., (1963). Densitometric analysis of body composition: revision of some quantitative assumptions. Ann N Y Acad Sci. 110:113-140.

Castro I. Queirós. *Uma aplicação de Métodos de Imputação no Estudo de Fatores Associados ao Baixo Peso ao Nascer*. Juis de Fora: [s.n], 2014. 78 f. Trabalho de Conclusão de Curso (graduação). <http://www.ufjf.br/cursoestatistica/files/2014/04/Monografia-Isabela-Queiros-Castro.pdf> [29 de maio de 2017]

Chandola, Varun; Banerjee, Arindam and Kumar, Vipin. 2007. "Anomaly Detection - A Survey", ACM Computing Surveys 41 (2007), 15.

Charter, R.A., Feldt, L.S. (1996). Testing the equality of two alpha coefficients. Perceptual and Motor Skills, 82, 763-768.

Chumlea WC, Shumei SS. Bioelectrical Impedance Analysis. In: Heymsfield SB, Lohman TG, Wang ZM, Going SB, editors. Human body composition. 2nd ed. Champaign, IL: Human Kinetics; 2005. p. 79-88.

Clarys JP, Martin AD, Drinkwater DT et al. (1987). The skinfold: myth and reality. J Sports Sci. 5:3-33.

Clarys JP, Provyn S, Marfell-Jones MJ (2005). Cadaver studies and their impact on the understanding of human adiposity. Ergonomics. 48:1445-1461.

Clasey JL, Kanaley JA et al. Validity of methods of body composition assessment in young and older men and women. Journal of Applied Physiology 1999 May; 86 (5): 1728-1738.

Clegg EJ, Kent C (1967). Skinfold compressibility in young adults. Hum Biol. 39:418-429.

Consolazio C, Johnson R, Pecora L. Physiological measurements of metabolic function in man. London: McGraw-Hill; 1963.

Corrêa R. Clorivaldo. *SITUAÇÕES INCÔMODAS NO TRABALHO: confiabilidade de uma escala de medida utilizando o Coeficiente Alfa Ordinal*. Juis de Fora: [s.n], 2012. 74 f. Dissertação de Mestrado.
<http://www.ufjf.br/pgsaudecoletiva/files/2013/03/Disserta%C3%A7%C3%A3o-final-para-impress%C3%A3o.pdf> [5 de abril de 2017]

Cortina, J.M. (1993). What is coeficiente alfa? Na examination of theory and application. *Journal of Applied Psychology*, 78, 98-104.

Cronbach, L., (1951). Coefficient alpha and the internal structure of tests. *Psychometrika*, 16, 297-37.

Duhacheck, A., Iacobucci, D. (2004). Alpha's Standart Error (ASE): An accurate and precise confidence interval estimate. *Journal of Applied Psychological*, 89(5), 792-808.

Durnin JV, Womersley J (1974). Body fat assessed from total body density and its estimation from skinfold thickness: measurements on 481 men and women aged from 16 to 72 years. *Br J Nutr*. 32:77-97.

Enders, C. K. (2010). *Applied missing data analysis*. New York.

Farhangfar A., Kurgan L., Pedrycz W. Experimental analysis of methods for imputation of missing values in databases. *Proceedings of SPIE, Orlando*, vol. 5421, pp. 172-182, 2004.

Figueiredo Filho, Dalson B.; Da Silva Junior, José A.; Da Rocha, Enivaldo C. 2011. What is R2 all about? *Leviathan-Cadernos de Pesquisa Politica*, v.3, p.60-68.

Figueiredo Filho, Dalson B.; Da Silva Junior, José A.; Da Rocha, Enivaldo C., et al. Desvendando os Mistérios do Coeficiente de Correlação de Pearson: O retorno. *Leviathan-Cadernos de Pesquisa Politica*. N.8, pp.66-95, 2014.

Fonseca-Junior, Jorge Sidney *et al.* Exercício físico e obesidade Mórbida_ Uma revisão sistemática. *ABCD Arq Bras Cir Dig* 2013; 26 (Suplemento 1): 67-73.
<http://www.scielo.br/pdf/abcd/v26s1/a15v26s1.pdf> [4 de junho de 2017]

Frisancho AR. *Anthropometric Standards. An Interactive Nutritional Reference of Body Size and Body Composition for Children and Adults*. 2nd ed. Ann Arbor, MI: University of Michigan Press; 2008.

Gudivaka R, Schoeller DA, Kushner RF *et al.* (1999). Single- and multifrequency models for bioelectrical impedance analysis of body water compartments. *J Appl Physiol* (1985). 87:1087-1096.

Hattori K, Okamoto W (1993). Skinfold compressibility in Japanese university students. *Okajimas Folia Anat Jpn.* 70:69-77.

Hawkins, Douglas. 1980. Identification of Outliers. Chapman and Hall, London.

Heymsfield SB, Lohman TG, Wong Z *et al.* Human Body Composition. 2nd ed. Champaign, IL: Human Kinetics; 2005.

Hill. M. Manuela; HILL, A. Investigação por Questionário. 2ª edição-2ª reimpressão. Edições silabo, lisboa 2005. ISBN: 972-618-273-5

Himes JH, Roche AF, Siervogel RM (1979). Compressibility of skinfolds and the measurement of subcutaneous fatness. *Am J Clin Nutr.* 32:1734-1740.

Jackson AS, Pollock ML (1978). Generalized equations for predicting body density of men. *Br J Nutr.* 40:497-504.

Jackson AS, Pollock ML, Ward A (1980). Generalized equations for predicting body density of women. *Med Sci Sports Exerc.* 12:175-181.

José Santos, R. A. Obesidade e Exercício. XI Congresso Ciências do Desporto e Educação Física dos países de língua portuguesa. Ver.bras. Educ. Fis.Esp., São Paulo, v.20, p.161-162, set.2006. Suplemento n.5.
http://citrus.uspnet.usp.br/eef/uploads/arquivo/44_Anais_p161.pdf [4 de junho de 2017]

World Cancer Research Fund / American Institute for Cancer Research. Policy and Action for Cancer Prevention. Food, Nutrition, and Physical Activity: a Global Perspective. Washington DC: AICR; 2009.

World Health Organization. Health topics, Obesity [cited 3 Nov 2014].

World Health Organization. Obesity and overweight, Fact sheet N°311, 2014 [cited 3 Nov 2014].

Wu C., Wun C., Chou H. Using association rules for completing missing data. Proceedings of the 4th International Conference On Hybrid Intelligent Systems, Taiwan, pp. 236-241, 2004.

Keskin, S. (2006). Comparison of Several Univariate Normality Tests Regarding Type I Error Rate and Power of the Test in Simulation Based Small Samples. *Journal of Applied Science Research* 2(5), pp. 296-300.

Kyle UG, Bosaeus I, De Lorenzo AD et al. (2004). Bioelectrical impedance analysis--part I: review of principles and methods. *Clin Nutr.* 23:1226-1243.

Kyle UG, Bosaeus I, De Lorenzo AD et al. (2004). Bioelectrical impedance analysis-part II: utilization in clinical practice. *Clin Nutr.* 23:1430-1453

Lilliefors, H.W. (1967). On the Kolmogorov-Smirnov test for normality with mean and variance unknown. *Journal of the American Statistical Association*, 64: 399-402.

Little R. J. A., Rubin D. B. *Statistical analysis with missing data*, 2. ed. Hoboken: John Wiley & Sons, 2002.

Lobiondo-Wood, Geri; Haber, Judith. *Pesquisa em enfermagem: Métodos, avaliação crítica e utilização*. 4a edição. Rio de Janeiro: Guanabara Koogan; 2001.

Lohman TG (1981). Skinfolts and body density and their relation to body fatness: a review. *Hum Biol.* 53:181-225.

Marfell-Jones M, Olds T, Stewart A *et al.* International standards for anthropometric assessment. South Africa, Potchefstroom: International Standards for Anthropometric Assessment; 2006.

Maroco, J. *Análise Estatística com Utilização do SPSS*. 2ª ed. Revista e corrigida. Lisboa, abril de 2003. ISBN: 972-618-331-6

Maroco, J.; Garcia-Marques, T. Qual a fiabilidade do Alpha de Cronbach? Questões antigas e soluções modernas? *Laboratório de Psicologia*, 4(1): 65-90 (2006), Instituto Superior de Psicologia Aplicada, Portugal. <http://publicacoes.ispa.pt/index.php/lp/article/viewFile/763/706> [27 de fevereiro de 2017]

Maroco, J. (2011). *Análise Estatística com o SPSS Statistics*, Edições Sílabo, Lisboa.

Martin AD, Ross WD, Drinkwater DT et al. (1985). Prediction of body fat by skinfold caliper: assumptions and cadaver evidence. *Int J Obes.* 9 Suppl 1:31-39.

Mcknight P. E., Mcknight K. M., Sidani S., Figueredo A. J. *Missing data: a gentle introduction*. New York: The Guilford Press, 2007.

Mendes, M.; Pala, A. (2003). Type I Error Rate and Power of Three Normality Tests. *Pakistan Journal of Information and Tecnology* 2(2), pp. 135-139.

Moore, David S. and McCabe, George P. 2003. Introduction to the Practice of Statistics, W.H. Freeman and Company.

Muller W, Horn M, Furhapter-Rieger A et al. (2013). Body composition in sport: a comparison of a novel ultrasound imaging technique to measure subcutaneous fat tissue compared with skinfold measurement. Br J Sports Med. 47:1028-1035.

Myrtveit I., Stensrud E., Olsson U. H. Analyzing data sets with missing data: an empirical evaluation of imputation methods and likelihood-based methods. IEEE Transactions On Software Engineering, vol. 27, no. 11, pp. 999-1013, 2001.

Nunes, L. N. (2007). Métodos de imputação de dados aplicados na área da saúde. Tese de Doutorado em Epidemiologia, UFRGS, Faculdade de Medicina, Porto Alegre.

Nunes, L. N., Klück, M. M., & Fachel, J. G. Uso da imputação múltipla de dados faltantes: uma simulação utilizando dados epidemiológicos. Caderno de Saúde Pública, p. 268-278; 2009.

National Institutes of Health (NIH), National Heart, Lung, and Blood Institute (NHLBI), NHLBI Obesity Education Initiative, North American Association for the Study of Obesity. The Practical Guide: Identification, Evaluation, and Treatment of Overweight and Obesity in Adults. NIH Publication; 2000.

Norton K, Marfell-Jones M, Whittingham N *et al.* Anthropometric assessment protocols. In: Gore C, editor. Physiological tests for elite athletes. Champaign, IL: Human Kinetics; 2000. p. 66-85.

Pestana, H. Maria; Gageiro, N. João. Descobrimos a Regressão com a Complementaridade do SPSS. Edições Sílabo. Lisboa 2005. ISBN: 972-618-394-4

Pestana, H. Maria; Gageiro, N. João. Análise de Dados para Ciências Sociais – A Complementaridade do SPSS. 5ª edição revista e corrigida. Edições Sílabo. Lisboa 2008. ISBN: 978-972-618-498-0

PEREIRA, Alexandre. Guia Prático de Utilização do SPSS – Análise de Dados para Ciências Sociais e Psicologia. 4ª Edição, Lisboa Março de 2003, ISBN: 972-618-296-4 Edições Sílabo

Peterson, M.J, Czerwinski, S.A, Siervogel, R.M (2003). Development and validation of skinfold-thickness prediction equations with a 4-compartment model. Am J Clin Nutr. 77:1186-1191.

Pilati, R.; Porto, B.J. Apostila para tratamento de dados via SPSS. UnB. https://social.stoa.usp.br/articles/0016/4637/apostila_SPSS_Porto_.pdf [21 de Outubro de 2015]

Razali, M.N.; Wah, B.Y. (2011). Power comparisons of Shapiro-Wilk, Kolmogorov-Smirnov, Lilliefors and Anderson-Darling tests. Journal of Statistical Modeling and Analytics, vol.2, Nº1, pp. 21-33. https://www.researchgate.net/profile/Bee_Yap/publication/267205556_Power_Comparisons_of_Shapiro-Wilk_Kolmogorov-Smirnov_Lilliefors_and_Anderson-Darling_Tests/links/5477245b0cf29afed61446e1/Power-Comparisons-of-Shapiro-Wilk-Kolmogorov-Smirnov-Lilliefors-and-Anderson-Darling-Tests.pdf [19 de Agosto de 2017]

Reis Elizabeth. Estatística Descritiva. 7ª edição, revista e corrigida, edições silabo, lisboa. ISBN: 978-972-618-476-8

Robert M. Groves, Floyd J. Fowler, Jr., Mick P. Couper, James M. Lepkowski, Eleanor Singer, & Roger Tourangeau. (2009). Survey Methodology (2ªed.). John Wiley & Sons.

Rodrigues, Adriano e Paulo, Edilson. 2007. "Introdução à análise multivariada". In. Corrar, Luiz J.; Paulo, Edilson; Dias-Filho, J. Maria (Coord.). Análise multivariada: para os cursos de administração, ciências contábeis e economia. São Paulo: Atlas, p. 1-72.

SAS, Institute Inc., 1999. Comparison of P-P Plots and Q-Q Plots. <https://v8doc.sas.com/sashtml/qc/chap8/sect9.htm> [20 de Agosto de 2017]

Siri, W.E. Body composition from fluid spaces and density: analyses of methods. Techniques for measuring body composition. Washington, DC: Natl Acad. Sci. National Res. Council; 1961. p. 223-244.

Slaughter MH, Lohman TG, Boileau RA et al. (1988). Skinfold equations for estimation of body fatness in children and youth. Hum Biol. 60:709-723.

Thompson, B. (Ed.). (2002). Contemporary thinking on reliability issues. Newbury Park, CA: Sage.

Torman, L.B. Vanessa; Coster, R.; Ribolti, J. Normalidade de variáveis: Métodos de verificação e comparação de alguns testes não-paramétricos por simulação. Revista HCPA, 2012; 32(2): 227-234. <http://www.seer.ufrgs.br/hcpa/article/viewFile/29874/19186> [19 de Agosto de 2017]

Veroneze, Rosana. Tratamento de Dados Faltantes Empregando Biclusterização com Imputação Múltipla. Dissertação de Mestrado apresentada à Faculdade de Engenharia Elétrica e de Computação. Campinas SP – Brasil, Junho de 2011. Pag. 26 ftp://ftp.dca.fee.unicamp.br/pub/docs/vonzuben/theses/dissertacao_Rosana_Veroneze.pdf [15 de maio de 2017]

Vieira, Marcel de Toledo. (2011). Material didático da disciplina de Amostragem I e II. Universidade Federal de Juiz de Fora, Departamento de Estatística, Juiz de Fora.

Visser M, van den Heuvel E, Deurenberg P (1994). Prediction equations for the estimation of body composition in the elderly using anthropometric data. Br J Nutr. 71:823-833.

<http://www.ebah.com.br/content/ABAAAAScQAG/probabilidade?part=11> [02 de junho de 2017]

Zar, J.H. Biostatistical analysis. Upper Saddle River, N.J.: Prentice Hall; 1999.

Anexos

Anexo I – Resumo da prega Tricipital com a presença e ausência do *Outlier*

		Tricipital											
		Com Outlier (44)					Sem Outlier (44)						
Medidas		Enter	Stepwise	Backward	Modelo final			Enter	Stepwise	Backward	Modelo final		
		Variáveis significativas	Variáveis significativas	Variáveis significativas	R_a^2	Erro padrão	Variáveis significativas	Variáveis significativas	Variáveis significativas	Variáveis significativas	R_a^2	Erro padrão	Variáveis significativas
1	Média de todos os pontos	Massa gorda(%)	Massa gorda(%)	Massa gorda(%), sexo, estado saúde.	64.5%	3.18	Massa gorda(%), sexo	Massa gorda(%)	Massa gorda(%)	Massa gorda(%), sexo, estado saúde.	63.9%	3.18	Massa gorda(%), sexo
2	Média dos últimos 10	Massa gorda(%)	Massa gorda(%)	Massa gorda(%)	64.1%	3.12	Massa gorda(%)	Massa gorda(%)	Massa gorda(%)	Massa gorda(%), estado saúde.	63.8%	3.14	Massa gorda(%)
2	Mediana de todos os pontos	Massa gorda(%)	Massa gorda(%)	Massa gorda(%)	63.6%	3.19	Massa gorda(%)	Massa gorda(%)	Massa gorda(%)	Massa gorda(%), sexo, estado saúde.	64.2%	3.16	Massa gorda(%), sexo
4	Mediana dos últimos 10	Massa gorda(%)	Massa gorda(%)	Massa gorda(%)	63.7%	3.13	Massa gorda(%)	Massa gorda(%)	Massa gorda(%)	Massa gorda(%)	63.4%	3.16	Massa gorda(%)
Observação		Modelo final: 1. Media_Todos = 5.570 – 1.902Sexo + 0.523Massa gorda (%) 2. Media_Ultimos10 = 3.726 + 0.557Massa gorda (%) 3. Mediana_Todos = 3.816 + 0.564Massa gorda (%) 4. Mediana_Ultimos10 = 3.794 + 0.556Massa gorda (%)					Modelo final: 1. Media_Todos = 5.648 – 1.879Sexo + 0.518Massa gorda (%) 2. Media_Ultimos10 = 3.716 + 0.558Massa gorda (%) 3. Mediana_Todos = 5.172 – 1.636Sexo + 0.525Massa gorda (%) 4. Mediana_Ultimos10 = 3.783 + 0.556Massa gorda (%)						

Anexo II – Resumo da pregra Crural com e sem a presença do *Outlier*

		Crural											
		Com Outlier (44)					Sem Outlier (44)						
Medidas		Enter	Stepwise	Backward	Modelo final			Enter	Stepwise	Backward	Modelo final		
		Variáveis significativas	Variáveis significativas	Variáveis significativas	R_a^2	Erro padrão	Variáveis significativas	Variáveis significativas	Variáveis significativas	Variáveis significativas	R_a^2	Erro padrão	Variáveis significativas
1	Média de todos os pontos	Sexo, idade, estado saude	Massa gorda(%), idade, estado saude	Sexo, idade, BMI, escolaridade, estado saúde	52.7%	5.40	Sexo, idade, massa gorda(%), BMI	Sexo, idade, estado saude	Massa gorda(%), idade	Sexo, idade, BMI, estado saúde	50.3%	5.44	Sexo, idade, massa gorda(%), BMI
2	Média dos últimos 10	Sexo, idade, estado saude	Massa gorda(%), idade, estado saude	Sexo, idade, BMI, escolaridade, estado saúde	51.8%	5.41	Sexo, idade, massa gorda(%), BMI	Sexo, idade, estado saude	Massa gorda(%), idade	Sexo, idade, BMI, escolaridade, estado saúde	49.7%	5.45	Sexo, idade, massa gorda(%), BMI
3	Mediana de todos os pontos	Sexo, idade, estado saude	Massa gorda(%), idade, estado saude	Sexo, idade, BMI, escolaridade, estado saúde	52.2%	5.41	Sexo, idade, massa gorda(%), BMI	Sexo, idade, estado saude	Massa gorda(%), idade	Sexo, idade, BMI, escolaridade, estado saúde	50.0%	5.46	Sexo, idade, massa gorda(%), BMI
4	Mediana dos últimos 10	Sexo, idade, estado saude	Massa gorda(%), idade, estado saude	Sexo, idade, BMI, escolaridade, estado saúde	51.8%	5.41	Sexo, idade, massa gorda(%), BMI	Sexo, idade, estado saude	Massa gorda(%), idade	Sexo, idade, BMI, escolaridade, estado saúde	49.7%	5.45	Sexo, idade, massa gorda(%), BMI
Observação		Modelo final: 1. $Media_Todos = 2.528 - 5.577Sexo + 0.416Massa\ gorda\ (\%) - 0.196Idade + 0.728BMI(kg/m2)$ 2. $Media_Ultimos10 = 1.850 - 5.028Sexo + 0.433Massa\ gorda\ (\%) - 0.184Idade + 0.698BMI(kg/m2)$ 3. $Mediana_Todos = 2.141 - 5.227Sexo + 0.431Massa\ gorda\ (\%) - 0.190Idade + 0.708BMI(kg/m2)$ 4. $Mediana_Ultimos10 = 1.847 - 5.029Sexo + 0.433Massa\ gorda\ (\%) - 0.184Idade + 0.698BMI(kg/m2)$					Modelo final: 1. $Media_Todos = 2.867 - 5.394Sexo + 0.428Massa\ gorda\ (\%) - 0.194Idade + 0.696BMI(kg/m2)$ 2. $Media_Ultimos10 = 1.936 - 4.981Sexo + 0.436Massa\ gorda\ (\%) - 0.184Idade + 0.690BMI(kg/m2)$ 3. $Mediana_Todos = 2.382 - 5.096Sexo + 0.439Massa\ gorda\ (\%) - 0.188Idade + 0.685BMI(kg/m2)$ 4. $Mediana_Ultimos10 = 1.931 - 4.983Sexo + 0.436Massa\ gorda\ (\%) - 0.184Idade + 0.690BMI(kg/m2)$						

Anexo III – Resumo da prega Geminal com e sem a presença do *Outlier*

		Geminal											
		Com Outlier (44)						Sem Outlier (44)					
Medidas		Enter	Stepwise	Backward	Modelo final			Enter	Stepwise	Backward	Modelo final		
		Variáveis significativas	Variáveis significativas	Variáveis significativas	R_a^2	Erro padrão	Variáveis significativas	Variáveis significativas	Variáveis significativas	Variáveis significativas	R_a^2	Erro padrão	Variáveis significativas
1	Média de todos os pontos	Massa gorda(%)	Massa gorda(%), sexo	Massa gorda(%), sexo, idade	63.2%	3.37	Massa gorda(%), idade	Massa gorda(%)	Massa gorda(%), sexo	Massa gorda(%), sexo	56.5%	3.68	Massa gorda(%), sexo
2	Média dos últimos 10	Massa gorda(%)	Massa gorda(%), sexo	Massa gorda(%), sexo, idade	63.1%	3.35	Massa gorda(%), idade	Massa gorda(%)	Massa gorda(%), sexo	Massa gorda(%), sexo, idade	63.1%	3.360	Massa gorda(%), idade
3	Mediana de todos os pontos	Massa gorda(%)	Massa gorda(%), sexo	Massa gorda(%), sexo, idade	63.4%	3.36	Massa gorda(%), idade	Massa gorda(%)	Massa gorda(%), sexo	Massa gorda(%), sexo	57.4%	3.64	Massa gorda(%), sexo
4	Mediana dos últimos 10	Massa gorda(%)	Massa gorda(%), sexo	Massa gorda(%), sexo, idade	57.2%	3.60	Massa gorda(%), sexo	Massa gorda(%)	Massa gorda(%), sexo	Massa gorda(%), sexo, idade	63.1%	3.361	Massa gorda(%), idade
Observação		Modelo final: 1. Media_Todos = 3.538 – 0.135Idade + 0.642Massa gorda (%) 2. Media_Ultimos10 = 2.943 – 0.124Idade + 0.635Massa gorda (%) 3. Mediana_Todos = 3.066 – 0.127Idade + 0.642Massa gorda (%) 4. Mediana_Ultimos10 = 2.900 – 1.873Sexo + 0.510Massa gorda (%)						Modelo final: 1. Media_Todos = 3.616 – 2.223Sexo + 0.503Massa gorda (%) 2. Media_Ultimos10 = 2.898 – 0.127Idade + 0.642Massa gorda (%) 3. Mediana_Todos = 3.054 – 2.002Sexo + 0.514Massa gorda (%) 4. Mediana_Ultimos10 = 2.902 – 0.127Idade + 0.642Massa gorda (%)					

Anexo IV – Resumo da prega Iliocristal com e sem a presença do *Outlier*

		Iliocristal											
		Com Outlier (44)					Sem Outlier (44)						
Medidas		Enter	Stepwise	Backward	Modelo final			Enter	Stepwise	Backward	Modelo final		
		Variáveis significativas	Variáveis significativas	Variáveis significativas	R_a^2	Erro padrão	Variáveis significativas	Variáveis significativas	Variáveis significativas	Variáveis significativas	R_a^2	Erro padrão	Variáveis significativas
1	Média de todos os pontos	-----	Massa gorda(%), sexo	Massa gorda(%), sexo	48.3%	3.67	Massa gorda(%), sexo	-----	Massa gorda(%), BMI	Massa gorda(%), BMI, estado saude	42.4%	3.90	Massa gorda(%), BMI
2	Média dos últimos 10	-----	Massa gorda(%), sexo	Massa gorda(%), sexo, estado saude	50.0%	3.54	Massa gorda(%), sexo	Estado saude	Massa gorda(%), BMI, estado saude	Massa gorda(%), BMI, estado saude	43.9%	3.78	Massa gorda(%), BMI
3	Mediana de todos os pontos	-----	Massa gorda(%), sexo	Massa gorda(%), BMI, estado saúde, Nº horas atividade física	33.2%	4.12	Massa gorda(%)	-----	Massa gorda(%), BMI	Massa gorda(%), BMI, estado saude	42.9%	3.84	Massa gorda(%), BMI
4	Mediana dos últimos 10	-----	Massa gorda(%), sexo	Massa gorda(%), sexo, estado saude	49.5%	3.56	Massa gorda(%), sexo	-----	Massa gorda(%), BMI	Massa gorda(%), BMI, estado saude	43.3%	3.80	Massa gorda(%), BMI
Observação		Modelo final: 1. Media_Todos = 3.102 + 4.850Sexo + 0.512Massa gorda (%) 2. Media_Ultimos10 = 2.724 + 5.072Sexo + 0.508Massa gorda (%) 3. Mediana_Todos = 7.085 + 0.393Massa gorda (%) 4. Mediana_Ultimos10 = 2.844 + 5.057Sexo + 0.505Massa gorda (%)						Modelo final: 1. Media_Todos = - 0.070 + 0.471BMI(kg/m2) + 0.240Massa gorda (%) 2. Media_Ultimos10 = - 0.754 + 0.503BMI(kg/m2) + 0.221Massa gorda (%) 3. Mediana_Todos = - 0.390 + 0.495BMI(kg/m2) + 0.224Massa gorda (%) 4. Mediana_Ultimos10 = - 0.602 + 0.500BMI(kg/m2) + 0.219Massa gorda (%)					

Anexo V – Resumo da prega Subescapular com e sem a presença do *Outlier*

		Subescapular											
		Com Outlier (44)					Sem Outlier (44)						
Medidas		Enter	Stepwise	Backward	Modelo final			Enter	Stepwise	Backward	Modelo final		
		Variáveis significativas	Variáveis significativas	Variáveis significativas	R_a^2	Erro padrão	Variáveis significativas	Variáveis significativas	Variáveis significativas	Variáveis significativas	R_a^2	Erro padrão	Variáveis significativas
1	Média de todos os pontos	BMI, estado saude	BMI, estado saúde, Nº horas atividade física	BMI, estado saúde, Nº horas atividade física, escolaridade	72.6%	2.52	BMI, estado saúde, Nº horas atividade física	BMI, estado saude	BMI, estado saude	BMI, estado saúde, sexo	62.7%	3.37	BMI, estado saúde, sexo
2	Média dos últimos 10	BMI, estado saúde, Nº horas atividade física	BMI, estado saúde, Nº horas atividade física	BMI, estado saúde, Nº horas atividade física	74.0%	2.46	BMI, estado saúde, Nº horas atividade física	BMI, estado saude	BMI, estado saude	BMI, estado saúde, sexo	63.3%	3.34	BMI, estado saúde, sexo
3	Mediana de todos os pontos	BMI, estado saude	BMI, estado saúde, Nº horas atividade física	BMI, estado saúde, Nº horas atividade física	73.3%	2.51	BMI, estado saúde, Nº horas atividade física	BMI, estado saude	BMI, estado saude	BMI, estado saúde, sexo	63.3%	3.35	BMI, estado saúde, sexo
4	Mediana dos últimos 10	BMI, estado saúde, Nº horas atividade física	BMI, estado saúde, Nº horas atividade física	BMI, estado saúde, Nº horas atividade física	73.3%	2.48	BMI, estado saúde, Nº horas atividade física	BMI, estado saude	BMI, estado saude	BMI, estado saúde, sexo	63.2%	3.34	BMI, estado saúde, sexo
Observação		Modelo final: 1. Media_Todos = - 9.305 – 0.396Nº_h_AF + 2.289Est_Saude + 0.883BMI(kg/m2) 2. Media_Ultimos10 = - 9.556 – 0.444Nº_h_AF + 2.301Est_Saude + 0.889BMI(kg/m2) 3. Mediana_Todos = - 9.574 – 0.423Nº_h_AF + 2.325Est_Saude + 0.891BMI(kg/m2) 4. Mediana_Ultimos10 = - 9.389 – 0.432Nº_h_AF + 2.296Est_Saude + 0.881BMI(kg/m2)					Modelo final: 1. Media_Todos = - 12.321 – 2.010Sexo + 1.191Est_Saude + 1.048BMI(kg/m2) 2. Media_Ultimos10 = - 12.679 – 1.926Sexo + 1.161Est_Saude + 1.052BMI(kg/m2) 3. Mediana_Todos = - 12.635 – 1.967Sexo + 1.192Est_Saude + 1.055BMI(kg/m2) 4. Mediana_Ultimos10 = - 12.597 – 1.934Sexo + 1.164Est_Saude + 1.049BMI(kg/m2)						

Anexo VI – Resumo da prega Supraespinal com e sem a presença do *Outlier*

		Supraespinal											
		Com Outlier (44)						Sem Outlier (44)					
Medidas		Enter	Stepwise	Backward	Modelo final			Enter	Stepwise	Backward	Modelo final		
		Variáveis significativas	Variáveis significativas	Variáveis significativas	R_a^2	Erro padrão	Variáveis significativas	Variáveis significativas	Variáveis significativas	Variáveis significativas	R_a^2	Erro padrão	Variáveis significativas
1	Média de todos os pontos	Estado saúde, Nº horas atividade física	Massa gorda(%), sexo	Massa gorda(%), Nº horas atividade física, escolaridade, estado saúde	51.5%	2.72	Massa gorda(%), Nº horas atividade física, estado saúde	Estado saúde	Massa gorda(%), escolaridade, estado saúde	Massa gorda(%), estado saúde	49.0%	3.06	Massa gorda(%), escolaridade, estado saúde
2	Média dos últimos 10	Estado saúde, Nº horas atividade física	Massa gorda(%), sexo	Massa gorda(%), Nº horas atividade física, estado saúde	52.1%	2.69	Massa gorda(%), Nº horas atividade física, estado saúde	Estado saúde	Massa gorda(%), escolaridade, estado saúde	Massa gorda(%), Nº horas atividade física, estado saúde	56.8%	2.60	Massa gorda(%), escolaridade, estado saúde, Nº horas atividade física
3	Mediana de todos os pontos	Estado saúde, Nº horas atividade física	Massa gorda(%), sexo	Massa gorda(%), Nº horas atividade física, estado saúde	51.6%	2.71	Massa gorda(%), Nº horas atividade física, estado saúde	Estado saúde	Massa gorda(%), escolaridade, estado saúde	Massa gorda(%), Nº horas atividade física, estado saúde	56.1%	2.62	Massa gorda(%), escolaridade, estado saúde, Nº horas atividade física
4	Mediana dos últimos 10	Estado saúde, Nº horas atividade física	Massa gorda(%), sexo	Massa gorda(%), Nº horas atividade física, estado saúde	52.0%	2.68	Massa gorda(%), Nº horas atividade física, estado saúde	Estado saúde	Massa gorda(%), escolaridade, estado saúde	Massa gorda(%), Nº horas atividade física, estado saúde	56.6%	2.59	Massa gorda(%), escolaridade, estado saúde, Nº horas atividade física
		Modelo final:						Modelo final:					

Observação	1. $Media_Todos = 5.880 + 2.109Est_Saude - 0.496N^{\circ}_h_AF + 0.232Massa\ gorda\ (\%)$ 2. $Media_Ultimos10 = 5.956 + 2.058Est_Saude - 0.540N^{\circ}_h_AF + 0.226Massa\ gorda\ (\%)$ 3. $Mediana_Todos = 6.032 + 2.071Est_Saude - 0.526N^{\circ}_h_AF + 0.227Massa\ gorda\ (\%)$ 4. $Mediana_Ultimos10 = 6.075 + 2.076Est_Saude - 0.542N^{\circ}_h_AF + 0.220Massa\ gorda\ (\%)$	1. $Media_Todos = - 0.217 + 1.570Est_Saude + 0.560Escol + 0.344Massa\ gorda\ (\%)$ 2. $Media_Ultimos10 = 2.337 + 2.367Est_Saude + 0.597Escol - 0.385N^{\circ}_h_AF + 0.238Massa\ gorda\ (\%)$ 3. $Mediana_Todos = 2.464 + 2.376Est_Saude + 0.588Escol - 0.373N^{\circ}_h_AF + 0.239Massa\ gorda\ (\%)$ 4. $Mediana_Ultimos10 = 2.496 + 2.381Est_Saude + 0.592Escol - 0.389N^{\circ}_h_AF + 0.232Massa\ gorda\ (\%)$
-------------------	--	--

Anexo VII – Resumo da prega Abdominal com a presença e ausência do *Outlier*

		Abdominal											
		Com Outlier (44)						Sem Outlier (44)					
Medidas		Enter	Stepwise	Backward	Modelo final			Enter	Stepwise	Backward	Modelo final		
		Variáveis significativas	Variáveis significativas	Variáveis significativas	R_a^2	Erro padrão	Variáveis significativas	Variáveis significativas	Variáveis significativas	Variáveis significativas	R_a^2	Erro padrão	Variáveis significativas
1	Média de todos os pontos	Nº horas atividade física	Nº horas atividade física, BMI, ocupação	Nº horas atividade física, ocupação, sexo, massa gorda(%)	29.1%	5.72	Nº horas atividade física, ocupação	-----	Nº horas atividade física, BMI, ocupação, estado saude	Nº horas atividade física, BMI, estado saude	45.7%	5.03	Nº horas atividade física, BMI, ocupação, estado saude
2	Média dos últimos 10	Nº horas atividade física	Nº horas atividade física, BMI, ocupação	Nº horas atividade física, ocupação, sexo, massa gorda(%)	31.4%	5.710	Nº horas atividade física, ocupação	-----	Nº horas atividade física, BMI, ocupação	Nº horas atividade física, BMI, ocupação, estado saude	47.5%	5.010	Nº horas atividade física, BMI, ocupação, estado saude
3	Mediana de todos os pontos	Nº horas atividade física	Nº horas atividade física, BMI, ocupação, estado saude	Nº horas atividade física, ocupação, sexo, massa gorda(%)	30.2%	5.74	Nº horas atividade física, ocupação	-----	Nº horas atividade física, BMI, ocupação, estado saude	Nº horas atividade física, BMI, ocupação, estado saude	47.4%	5.006	Nº horas atividade física, BMI, ocupação, estado saude
4	Mediana dos	Nº horas atividade física	Nº horas atividade	Nº horas atividade física,	31.4%	5.709	Nº horas atividade	-----	Nº horas atividade	Nº horas atividade física, BMI,	47.5%	5.009	Nº horas atividade física, BMI,

últimos 10		física, BMI, ocupação	ocupação, sexo, massa gorda(%)			física, ocupação		física, BMI, ocupação	ocupação, estado saude			ocupação, estado saude
Observação	Modelo final: 1. $Media_Todos = 17.623 - 0.865N^{\circ}_h_AF + 0.775Ocupação$ 2. $Media_Ultimos10 = 17.055 - 0.899N^{\circ}_h_AF + 0.814Ocupação$ 3. $Mediana_Todos = 17.289 - 0.875N^{\circ}_h_AF + 0.804Ocupação$ 4. $Mediana_Ultimos10 = 17.056 - 0.899N^{\circ}_h_AF + 0.814Ocupação$						Modelo final: 1. $Media_Todos = 2.750 - 1.022N^{\circ}_h_AF + 0.687Ocupação + 2.689Est_Saude + 0.564BMI(kg/m2)$ 2. $Media_Ultimos10 = 1.626 - 1.046N^{\circ}_h_AF + 0.717Ocupação + 2.592Est_Saude + 0.593BMI(kg/m2)$ 3. $Mediana_Todos = 2.027 - 1.045N^{\circ}_h_AF + 0.712Ocupação + 2.680Est_Saude + 0.584BMI(kg/m2)$ 4. $Mediana_Ultimos10 = 1.617 - 1.046N^{\circ}_h_AF + 0.717Ocupação + 2.593Est_Saude + 0.593BMI(kg/m2)$					

Anexo VIII – Resumo da prega Bicipital com a presença e ausência do *Outlier*

		Bicipital											
		Com Outlier (44)					Sem Outlier (44)						
Medidas		Enter	Stepwise	Backward	Modelo final			Enter	Stepwise	Backward	Modelo final		
		Variáveis significativas	Variáveis significativas	Variáveis significativas	R_a^2	Erro padrão	Variáveis significativas	Variáveis significativas	Variáveis significativas	Variáveis significativas	R_a^2	Erro padrão	Variáveis significativas
1	Média de todos os pontos	Massa gorda(%)	Massa gorda(%)	Massa gorda(%)	42.2%	3.233	Massa gorda(%)	Massa gorda(%)	Massa gorda(%)	Massa gorda(%)	42.7%	3.24	Massa gorda(%)
2	Média dos últimos 10	Massa gorda(%)	Massa gorda(%)	Massa gorda(%)	42.1%	3.175	Massa gorda(%)	Massa gorda(%)	Massa gorda(%)	Massa gorda(%)	42.7%	3.182	Massa gorda(%)
3	Mediana de todos os pontos	Massa gorda(%)	Massa gorda(%)	Massa gorda(%)	42.1%	3.226	Massa gorda(%)	Massa gorda(%)	Massa gorda(%)	Massa gorda(%)	42.7%	3.23	Massa gorda(%)
4	Mediana dos últimos 10	Massa gorda(%)	Massa gorda(%)	Massa gorda(%)	42.1%	3.173	Massa gorda(%)	Massa gorda(%)	Massa gorda(%)	Massa gorda(%)	42.7%	3.180	Massa gorda(%)

Observação	Modelo final: 1. $Media_Todos = 0.567 + 0.372 \text{Massa gorda (\%)}$ 2. $Media_Ultimos10 = 0.297 + 0.364 \text{Massa gorda (\%)}$ 3. $Mediana_Todos = 0.330 + 0.370 \text{Massa gorda (\%)}$ 4. $Mediana_Ultimos10 = 0.315 + 0.364 \text{Massa gorda (\%)}$	Modelo final: 1. $Media_Todos = 0.482 + 0.377 \text{Massa gorda (\%)}$ 2. $Media_Ultimos10 = 0.204 + 0.370 \text{Massa gorda (\%)}$ 3. $Mediana_Todos = 0.238 + 0.376 \text{Massa gorda (\%)}$ 4. $Mediana_Ultimos10 = 0.221 + 0.369 \text{Massa gorda (\%)}$
-------------------	--	--

Anexo IX: Disposição inicial da medição dos pontos em cada prega cutânea

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S	T	U	V
1	NI	NI_Lip	PregaPc	ConsultaID	TipoPregaNome	Ponto1	Ponto2	Ponto3	Ponto4	Ponto5	Ponto6	Ponto7	Ponto8	Ponto9	Ponto10	Ponto11	Ponto12	Ponto13	Ponto14	Ponto15	Ponto16	Ponto17
2	1	2E+05	62	26	Tricipital	20,03205	20,01291	20,01291	19,99378	19,99378	19,97465	19,97465	19,95552	19,95552	19,95552	19,93638	19,93638	19,93638	19,91725	19,91725	19,89812	19,89812
3	1	2E+05	63	26	Subescapular	7,948297	7,948297	7,948297	7,948297	7,948297	7,948297	7,948297	7,948297	7,948297	7,948297	7,948297	7,948297	7,948297	7,948297	7,948297	7,948297	7,948297
4	1	2E+05	66	26	Bicipital	8,823977	8,805325	8,786674	8,768023	8,749374	8,749374	8,749374	8,730725	8,730725	8,712078	8,712078	8,712078	8,712078	8,712078	8,712078	8,712078	8,712078
5	1	2E+05	67	26	Iliocristal	16,44809	16,4291	16,41011	16,41011	16,39112	16,39112	16,39112	16,39112	16,39112	16,39112	16,39112	16,37213	16,37213	16,37213	16,37213	16,37213	16,37213
6	1	2E+05	68	26	Supraespinal	13,2689	13,2689	13,2689	13,2689	13,2689	13,2689	13,2689	13,2689	13,2689	13,2689	13,2689	13,25005	13,25005	13,25005	13,25005	13,23119	13,23119
7	1	2E+05	69	26	Abdominal	15,65116	15,55638	15,55638	15,48057	15,42373	15,42373	15,34794	15,29111	15,27217	15,27217	15,27217	15,27217	15,27217	15,27217	15,23429	15,19641	15,15853
8	1	2E+05	70	26	Crural	19,55391	19,55391	19,55391	19,55391	19,55391	19,55391	19,55391	19,55391	19,55391	19,55391	19,55391	19,55391	19,55391	19,55391	19,55391	19,55391	19,55391
9	1	2E+05	71	26	Geminal	20,58727	20,58727	20,58727	20,58727	20,58727	20,58727	20,58727	20,58727	20,58727	20,58727	20,58727	20,58727	20,58727	20,58727	20,58727	20,58727	20,58727
10	2	2E+07	72	28	Tricipital	13,81605	13,81605	13,74054	13,70279	13,66504	13,6273	13,6273	13,58956	13,55182	13,51409	13,51409	13,45749	13,41977	13,41977	13,40091	13,38205	13,38205
11	2	2E+07	73	28	Bicipital	5,388686	5,388686	5,351718	5,333236	5,259316	5,277795	5,277795	5,240839	5,203887	5,203887	5,185412	5,185412	5,148465	5,129993	5,11522	5,11522	5,11522
12	2	2E+07	75	28	Subescapular	8,954564	8,898593	8,898593	8,842629	8,805325	8,786674	8,786674	8,786674	8,786674	8,749374	8,749374	8,749374	8,749374	8,749374	8,749374	8,749374	8,749374
13	2	2E+07	76	28	Iliocristal	12,25193	12,25193	12,25193	12,25193	12,17669	12,17669	12,17669	12,17669	12,17669	12,17669	12,17669	12,17669	12,17669	12,17669	12,17669	12,17669	12,17669
14	2	2E+07	77	28	Supraespinal	9,1972	9,085196	8,973224	8,917249	8,917249	8,842629	8,749374	8,674786	8,600212	8,56293	8,56293	8,544291	8,544291	8,544291	8,544291	8,544291	8,544291
15	2	2E+07	78	28	Abdominal	14,09933	14,08044	14,08044	14,00488	13,96711	13,89157	13,83493	13,83493	13,79717	13,79717	13,77829	13,70279	13,64617	13,58956	13,55182	13,49522	
16	2	2E+07	81	28	Crural	22,81429	22,81429	22,69886	22,69886	22,54499	22,35273	22,21819	22,10289	21,98762	21,98762	21,89159	21,73796	21,71876	21,71876	21,69956	21,62278	21,62278
17	2	2E+07	82	28	Geminal	8,842629	8,693432	8,693432	8,600212	8,525652	8,432472	8,357944	8,357944	8,302058	8,264805	8,264805	8,264805	8,264805	8,227555	8,171688	8,153067	8,153067
18	3	2E+06	83	29	Tricipital	14,02377	14,02377	14,02377	14,02377	14,02377	14,02377	14,02377	14,02377	14,02377	14,02377	14,02377	14,02377	14,02377	14,02377	14,02377	14,02377	14,02377
19	3	2E+06	84	29	Subescapular	7,66924	7,66924	7,66924	7,66924	7,66924	7,66924	7,66924	7,66924	7,66924	7,66924	7,66924	7,66924	7,66924	7,66924	7,66924	7,66924	7,66924
20	3	2E+06	85	29	Bicipital	8,600212	8,600212	8,600212	8,600212	8,600212	8,600212	8,600212	8,600212	8,600212	8,600212	8,600212	8,600212	8,600212	8,600212	8,600212	8,600212	8,600212
21	3	2E+06	86	29	Iliocristal	10,35642	10,35642	10,35642	10,3377	10,3377	10,3377	10,3377	10,31898	10,31898	10,31898	10,31898	10,30025	10,30025	10,30025	10,30025	10,30025	10,30025
22	3	2E+06	87	29	Supraespinal	7,59486	7,59486	7,59486	7,59486	7,59486	7,59486	7,59486	7,59486	7,576267	7,576267	7,576267	7,576267	7,576267	7,576267	7,576267	7,576267	7,576267
23	3	2E+06	88	29	Abdominal	12,68478	12,68478	12,68478	12,68478	12,66596	12,66596	12,66596	12,66596	12,66596	12,66596	12,66596	12,66596	12,66596	12,66596	12,66596	12,66596	12,66596
24	3	2E+06	89	29	Crural	24,64524	24,64524	24,64524	24,64524	24,64524	24,64524	24,64524	24,64524	24,64524	24,64524	24,64524	24,64524	24,64524	24,64524	24,64524	24,64524	24,64524
25	3	2E+06	90	29	Geminal	12,60947	12,60947	12,60947	12,60947	12,60947	12,60947	12,60947	12,60947	12,60947	12,60947	12,60947	12,60947	12,60947	12,60947	12,60947	12,60947	12,60947
26	4	9E+05	91	30	Tricipital	20,22343	20,22343	20,22343	20,20429	20,20429	20,20429	20,20429	20,20429	20,20429	20,20429	20,20429	20,20429	20,20429	20,20429	20,20429	20,20429	20,20429
27	4	9E+05	92	30	Subescapular	13,89157	13,89157	13,89157	13,89157	13,89157	13,89157	13,89157	13,89157	13,89157	13,89157	13,89157	13,89157	13,89157	13,89157	13,89157	13,89157	13,89157
28	4	9E+05	93	30	Bicipital	12,92964	12,92964	12,92964	12,87312	12,85428	12,85428	12,83545	12,83545	12,81661	12,76011	12,76011	12,74128	12,74128	12,70362	12,66596	12,6283	12,6283
29	4	9E+05	94	30	Iliocristal	20,3766	20,3766	20,3383	20,3383	20,31915	20,31915	20,31915	20,31915	20,31915	20,31915	20,31915	20,31915	20,31915	20,31915	20,31915	20,31915	20,31915
30	4	9E+05	95	30	Supraespinal	12,77894	12,76011	12,76011	12,70362	12,68478	12,68478	12,68478	12,66596	12,64713	12,60947	12,59065	12,59065	12,59065	12,59065	12,57182	12,57182	12,553

Fonte: Elaboração própria

Anexo X: Resumo dos valores dos pontos de cada prega

Base_Dados_ComprPregas_22Julho16 final [Modo de Compatibilidade] - Excel

CMSAL / Gilberto Alves Neves Partilhar

	AU	AV	AW	AX	AY	AZ	BA	BB	BC	BD	BE	BF	BG	BH	BI	BJ	BK	BL	BM	BN
	Tricipital_MediaTodos	Tricipital_MediaUlt10	Tricipital_MediaUlt3	Tricipital_MedianaTodos	Tricipital_MedianaUlt10	Tricipital_DPTodos	Tricipital_DPUlt10	Tricipital_Dif_p1_p180	Tricipital_Dif_MinMax	Subescapular_MediaTodos	Subescapular_MediaUlt10	Subescapular_MediaUlt3	Subescapular_MedianaTodos	Subescapular_MedianaUlt10	Subescapular_PTodos	Subescapular_PUIlt10	Subescapular_f_p1_p180	Subescapular_f_MinMax	Bicipital_MediaTodos	Bicipital_MediaUlt10
1	19,64654853	19,49136	19,47745	19,59215	19,49657	0,14271	0,008931	0,5546	0,554599762	7,896812296	7,87386	7,87386	7,87386	7,87386	0,02831	0	0,07444	0,07444	8,449062596	8,273271
2	12,82427211	12,51535	12,51535	12,71304	12,51535	0,329111	0	1,300699	1,300699234	8,495539676	8,41384	8,41384	8,43247	8,41384	0,119	0	0,54072	0,54072	4,938262725	4,889942
3	13,89010802	13,81605	13,81605	13,89157	13,81605	0,055115	0	0,207721	0,207720757	7,520910925	7,48331	7,48331	7,48331	7,48331	0,06158	0	0,18593	0,18593	8,403701152	8,320686
4	19,97040764	19,85987	19,85987	19,91725	19,85987	0,107585	0	0,36356	0,363559723	13,72209712	13,6084	13,6084	13,6839	13,6084	0,10442	0	0,28314	0,30203	12,3116563	12,10831
5	26,2398516	25,95787	25,95318	26,15318	25,95963	0,308978	0,005834	1,317429	1,317428589	19,86359719	19,726	19,726	19,8407	19,726	0,11387	0	0,49744	0,49744	18,0366791	17,93176
6	13,30923857	13,23633	13,23119	13,2689	13,23119	0,075905	0,008809	0,30177	0,30177021	17,32168482	17,1738	17,183	17,2654	17,1703	0,16634	0,00769	0,49482	0,51384	9,807054461	9,70161
7	10,60397087	10,56244	10,56244	10,58117	10,56244	0,057687	0	0,24361	0,243610382	10,95385709	10,7873	10,7873	10,956	10,7873	0,0957	0	0,33753	0,33753	4,300645124	4,299722
8	20,51630809	20,3766	20,3766	20,47235	20,3766	0,130305	0	0,4981	0,498100281	28,05654943	27,8293	27,8205	28,0535	27,8205	0,15044	0,01014	0,60218	0,60218	12,84771829	12,60092
9	25,43770363	25,26339	25,26339	25,41803	25,26339	0,138426	0	0,425371	0,42537117	12,82760643	12,7413	12,7413	12,7978	12,7413	0,07701	0	0,28257	0,28257	11,65168562	11,5753
10	17,25498993	17,00434	16,99916	17,22738	16,99916	0,165532	0,008879	0,68499	0,684989929	11,21895952	11,1623	11,1623	11,1999	11,1623	0,072	0	0,31907	0,31907	11,12556874	11,1014
11	18,57392953	18,48458	18,48458	18,56089	18,48458	0,093896	0	0,419811	0,419811249	9,23983665	9,1972	9,1972	9,21587	9,1972	0,0603	0	0,28015	0,28015	14,44940164	14,28829
12	20,78920554	20,65345	20,64474	20,77887	20,64474	0,096885	0,010007	0,383322	0,383321762	36,46217844	36,3132	36,3042	36,4026	36,3042	0,19058	0,01027	0,74795	0,74795	10,71374182	10,45005
13	19,16983076	19,0884	19,07624	19,15264	19,09534	0,048795	0,012877	0,19101	0,191009521	15,92234666	15,8597	15,8597	15,9166	15,8597	0,06981	0	0,30356	0,30356	7,417667291	7,31606
14	19,1669131	18,92348	18,92348	19,13354	18,92348	0,238748	0	0,85988	0,85988059845	23,83411963	23,5652	23,5652	23,7386	23,5652	0,31318	0	1,23453	1,23453	17,90773559	17,30521
15	9,015941827	8,973224	8,973224	8,973224	8,973224	0,072609	0	0,317337	0,317337036	6,243045158	6,22143	6,22143	6,22143	6,22143	0,04715	0	0,18531	0,22236	7,282211736	7,223172
16	12,82302394	12,58209	12,57182	12,77894	12,57182	0,154592	0,012944	0,52742	0,527420044	13,49807173	13,3632	13,3632	13,4575	13,3632	0,12597	0	0,43398	0,43398	3,830390526	3,802475
17	28,73686057	28,55872	28,55872	28,69481	28,55872	0,175178	0	0,739161	0,739160538	24,08994764	23,9629	23,9507	24,0664	23,9507	0,10583	0,0156	0,36647	0,36647	15,85970146	15,61325
18	10,92644845	10,89978	10,89978	10,91853	10,89978	0,033283	0	0,15002	0,150019646	11,18623482	11,0873	11,0873	11,1717	11,0873	0,09353	0	0,33777	0,35655	5,821397625	5,684557
19	20,20536545	20,10859	20,10859	20,14687	20,10859	0,109154	0	0,36376	0,363759995	13,47479146	13,3975	13,3883	13,4764	13,4009	0,06217	0,00763	0,24525	0,24525	10,30631595	10,16922
20	6,588122869	6,536505	6,536505	6,536505	6,536505	0,071069	0	0,241119	0,241118908	6,536711539	6,51796	6,51796	6,53651	6,51796	0,02111	0	0,12981	0,12981	2,414497928	2,369891
21	20,68254087	20,56812	20,56812	20,6639	20,56812	0,106298	0	0,421591	0,421590805	16,38259144	16,2064	16,2013	16,3152	16,2013	0,13411	0,00887	0,49377	0,49377	9,068132957	8,140513
22	17,77440559	17,72224	17,72224	17,74128	17,72224	0,075506	0	0,30479	0,304790497	14,65835869	14,5255	14,5151	14,6475	14,534	0,08565	0,00988	0,3405	0,3405	8,425857994	8,307139
23	21,77138621	21,51983	21,50761	21,75716	21,52681	0,190775	0,009687	0,86434	0,864339828	12,28401312	12,2194	12,2143	12,2895	12,2143	0,03803	0,00879	0,20694	0,20694	13,36352932	13,23119
24	28,8436979	28,67537	28,67537	28,88929	28,67537	0,10671	0	0,42791	0,427909851	14,56295714	14,0822	14,0804	14,5151	14,0804	0,32455	0,0057	1,24856	1,24856	19,96755546	19,66862
25	16,9038893	16,82806	16,82806	16,92311	16,82806	0,055434	0	0,209129	0,209129333	10,3214756	10,2815	10,2815	10,2909	10,2815	0,06473	0	0,26218	0,29962	4,819442667	4,631602
26	22,93007037	22,81429	22,81429	22,81429	22,81429	0,116953	0,00778	0,519732	0,519731522	18,36826167	18,1743	18,1604	18,3511	18,1795	0,11123	0,0089	0,51492	0,51492	17,406549	17,34153

Fonte: Elaboração própria

Anexo XI – Identificação de pontos influentes nos modelos de cada prega

ILIOCRISTAL					
Com Outlier			Sem Outlier		
Variável	Ponto influente	Descrição	Variável	Ponto influente	Descrição
Sexo	8	Homem	IMC	8	34.7
	17	Homem		13	32.4
				14	32.2
				17	34.7
				20	21.6
Massa gorda (%)	8	30.1%	Massa gorda (%)	7	11.8
	13	41%		8	30.1
	17	36%		13	41
				20	4.6
				43	13.2
Geral	8		Geral	8	
	13			13	
	17			14	
				17	
	47			20	

SUBESCAPULAR					
Com Outlier			Sem Outlier		
Variável	Ponto influente	Descrição	Variável	Ponto influente	Descrição
N_h_A_Fisica	8	1 hora	Sexo	12	Mulher
	44	14 horas		13	Mulher
				24	Mulher
IMC	8	34.7	IMC	12	34.2
	16	31.3		13	32.4
	44	33.1		24	32
Saúde	16	Mbom	Saúde	12	Bom
	42	Mau		13	Razoável
	55	Mbom		16	Mbom
Geral	8		Geral	12	
	16			13	
	42			16	
	44			24	
	55			62	

BICIPITAL					
Com Outlier			Sem Outlier		
Variável	Ponto influente	Descrição	Variável	Ponto influente	Descrição
Massa gorda (%)	12	41%	Massa gorda (%)	12	41%
	13	41%		13	41%
	24	36.3%		24	36.3%
	63	32.9%			
Geral	12		Geral	12	
	13			13	

TRICIPITAL					
Com Outlier			Sem Outlier		
Variável	Ponto influente	Descrição	Variável	Ponto influente	Descrição
Massa gorda (%)	12	41%	Massa gorda (%)	12	41%
	13	41%		13	41%
	14	38.1%		14	38.1%
Geral	12		Geral	12	
	13			13	
	14			14	

CRURAL					
Com Outlier			Sem Outlier		
Variável	Ponto influente	Descrição	Variável	Ponto influente	Descrição
Sexo	12	Mulher	Sexo	12	Mulher
	17	Homem		17	Homem
	21	Homem		21	Homem
Massa gorda (%)	17	36%	Massa gorda (%)	17	36%
	21	23.5%		21	23.5%
	36	31.5%		36	31.5%
Idade	6	65	Idade	6	65
	9	59		9	59
	13	83		13	83
	17	30		17	30
	21	23		21	23
IMC	12	34.2	IMC	12	34.2
	16	31.3		16	31.3
	21	25.7		17	34.7
	24	32		21	25.7
	36	22.8		24	32
Geral	12		Geral	12	
	16			16	
	17			17	
	21			21	

ABDOMINAL					
Com Outlier			Sem Outlier		
Variável	Ponto influente	Descrição	Variável	Ponto influente	Descrição
N_h_A_Fisica	8	1 hora	N_h_A_Fisica	15	8 horas
	25	8 horas		25	8 horas
	26	1 hora		26	1 horas
	44	14 horas			
Ocupação	19	Secretaria do Assistente social	Ocupação	19	Secretariado
	25			25	Assistente social
Geral	25		Geral	19	
	26			25	
	44			26	

SUPRAESPINAL					
Com Outlier			Sem Outlier		
Variável	Ponto influente	Descrição	Variável	Ponto influente	Descrição
Massa gorda (%)	56	6.5%	Massa gorda (%)	20	4.6%
				36	31.5%
				55	26.2%
Est_Saúde	8	Bom	Saúde	8	Razoável
				42	Mau
N_h_A_Fisica	8	1 hora	N_h_A_Fisica	25	8 horas
	44	14 hora			
Geral	8		Geral	8	Mestrado
				32	12 anos
				39	12 anos
				50	Licenciatura

GEMINAL					
Com Outlier			Sem Outlier		
Variável	Ponto influente	Descrição	Variável	Ponto influente	Descrição
Massa gorda (%)	12	41%	Massa gorda (%)	12	41%
	17	36%		17	36%
				20	4.6%
Idade	6	65	Idade	6	65
	13	83		13	83
Geral	6		Geral	6	
	12			12	
	13			13	
	17			17	