

António Manuel Correia Martinho Lopes

SISTEMAS INTELIGENTES PARA MEDIÇÃO DA PRESSÃO INTRA-ABDOMINAL

Tese de Doutoramento em Engenharia Biomédica, orientada por
Professor Doutor António Dourado Pereira Correia e Professora Doutora Maria Manuela Grave Rodeia Espada Niza e apresentada ao
Departamento de Física da Faculdade de Ciências e Tecnologia da Universidade de Coimbra

Agosto 2017



UNIVERSIDADE DE COIMBRA



Universidade Coimbra
Programa Doutoral em Engenharia Biomédica

Tese de Doutoramento
Sistemas Inteligentes para Medição de Pressão Intra-abdominal

ANTÓNIO MANUEL CORREIA MARTINHO LOPES

ORIENTADOR

PROFESSOR DOUTOR ANTÓNIO
DOURADO PEREIRA CORREIA

CO-ORIENTADOR

PROFESSORA DOUTORA MARIA
MANUELA GRAVE RODEIA ESPADA
NIZA

2017

COIMBRA

Abstract

Intra-abdominal pressure (IAP) is a pressure state of the abdominal cavity, which is determined by body mass index, posture, wall muscular activity and breath. IAP is directly influenced by several factors such as the volume of organs, bones, abdominal area contents and the degree of distension of the abdominal wall. These structures by direct volume alteration, or liquid, or gas accumulation, are likely to change IAP acutely, subacute or chronic. Increased IAP is a well-documented phenomenon, being directly associated with pathophysiological changes in all organ systems, increasing morbidity and mortality. The gold standard for its determination is the transurethral method (TM), which continues today surrounded in controversy.

The purpose of this study was building an intelligent model for measuring the IAP by a computational system based on multi-parameter monitoring. The first part of the study was focused in the characterization of the dog's abdominal cavity (area and volume). In this phase, it was also performed one biophysical study of IAP to explain the methods of mensuration and the variables that affect it, in order to support the intelligent measurement model. The second part consisted of the collection of dog's vital signs and IAP to build a database for the construction of the smart metering system.

Methods: The characterization of the abdominal area and biophysical study of the IAP and its variables was performed using retrospective studies of CT's series cases and study in a non-living model of the abdominal cavity. The measurement of the abdominal areas and volumes was carried out by processing the CT's digital images to construct 3D models of the abdominal cavity. These models allowed the determination of an abdominal surface area formula based on morphometric parameters. The biophysical study of IAP, methods and variables that affect it was carried out in a non-live model of the abdominal cavity. This type of model, allowed the elimination of the variables described to alter IAP maintaining a greater experimental control. In this part of the study it was determined all the physical components, that generate the IAP on the anatomical model, and the determination of IAP was performed by various methods in order to compare the different values.

The last step of the study was the development of a smart system, making it possible to determine IAP, using physiological and morphological parameters used in multi-parameter monitoring. It was carried out a retrospective study of multi-parameter monitoring database of dogs. Data collection was performed according to the rules of the Board of Ethics and Animal Welfare and with the authorization of the owners. The database studied collected consisted on the physiological, morphological and IAP values. Using this database was created a computational intelligence model based on 18 inputs (physiological and morphological parameters) and a system output (IAP). The parameters used were defined based on the system characteristics and variables with the biggest influence on IAP.

Results: The volume (mean \pm standard deviation) of the abdominal cavity of dogs was $0.0039 \pm 0.00206 \text{ m}^3$ and the abdominal surface area of $0.1519 \pm 0.05950 \text{ m}^2$. The mathematical formula allows the calculation of abdominal area and doesn't present statistically significant differences ($P = 0.988$) when compared to the individual determination. Areas and strength determination of the anatomical structures in the animal model body, allowed the replacement values in biophysical formulation and calculation of IAP. These determinations compared with direct readings per sensor, not presented statistically significant differences ($P < 0.05$).

The comparison of the three methods used for determining IAP evidenced that TM and intra-gastric manometry are both reliable methods for indirect determination of IAP with a 95% confidence interval in the lateral, prone and supine position. In these anatomical positions TM demonstrated better correlation indexes. The direct determination of IAP in the various anatomical positions revealed no statistically significant differences. Indirect methods revealed statistically significant differences between measurements in the various positions. The position of Trendelenburg and reverse Trendelenburg affects the measurement of IAP by indirect methods.

Of the 18 input parameters studied who had a higher correlation with the PIA were: weight (cc 0.48), abdominal surface area (cc 0.46), perimeter (cc 0.34), diastolic blood pressure (cc 0.25), QRS duration (cc 0.20), mean arterial pressure (cc 0.17) and the amplitude of the R-wave (cc 0.12). There were

created 162 artificial neural networks (ANN) and the best performances obtained showed a regression index of about 0.97. It was also used a reduced model, using only the entries with the highest correlation with the output, obtaining identical performance results. The best adaptive networking model based on fuzzy interference systems (ANFIS) created had a 0.29 training error and a testing error of 0.33.

Conclusion: The determined values of the abdominal cavity surface area provide non-existent anatomical information and contribute to the study of diseases affecting this surface. The determination of this area allows its application in the calculation of IAP because the physics definition of pressure is the result of the quotient between the forces (F) applied per unit area (A). The same methodology can be employed in humans for determination and calculation of the area of the abdominal cavity. The TM is the most accurate indirect method to measure the PIA in lateral, ventral and dorsal recumbency. If indirect methods are used to measure IAP on the Trendelenburg or reverse Trendelenburg position results can be over or under estimated. The biophysical principles demonstrate the veracity of the theoretical definition of IAP, prove the veracity of TM and explain the variables that affect it increasing the success of the measurements made in intensive care units.

The intelligent measurement method based on neural networks, never used before to determine IAP, allows their measurement by non-invasive means and continuously. The ANN and ANFIS created, allowed to predict IAP with low error. This type of solution may be included in the multi-parameter monitors on health units facilitating the monitoring of IAP in animals and humans.

Keywords: Intra-abdominal pressure, biophysics, artificial neural networks, indirect measurement, transurethral method

Resumo

A pressão intra-abdominal (PIA) é um estado de pressão dentro da cavidade abdominal, o qual é determinada pelo índice de massa corporal, postura, atividade muscular da parede e respiração. A PIA é influenciada diretamente por vários fatores tais como o volume dos órgãos, os ossos, o conteúdo do espaço abdominal e o grau de distensibilidade da parede abdominal. Estas estruturas, por variarem diretamente de volume, devido à acumulação de líquido ou gás, são passíveis de alterar a PIA de forma aguda, subaguda ou crónica. O aumento da PIA é um fenómeno bem documentado, estando diretamente associado a alterações fisiopatológicas em vários sistemas orgânicos, aumentando a morbidade e mortalidade. O *Gold standard* para sua determinação é o método transvesical (MT), que ainda hoje é alvo de controvérsia.

O objetivo deste estudo incidiu na construção de um modelo inteligente para medição da PIA através de um sistema computacional apoiado na monitorização multiparamétrica. A primeira parte deste trabalho consistiu na caracterização, em cães, da cavidade abdominal (área e volume). Tendo sido também realizado o estudo biofísico da PIA, bem como dos métodos e as variáveis que a afetam, de forma a fundamentar o modelo inteligente de medição. A segunda parte, compreendeu na recolha dos parâmetros vitais e da PIA numa população de cães, de forma a elaborar uma base de dados para elaboração do sistema inteligente de medição.

Material e métodos: A caracterização da área abdominal de cães e o estudo biofísico da PIA e suas variáveis foi realizado através do estudo retrospectivo de uma série de casos de exames tomográficos (TACs) e do estudo de um modelo não vivo da cavidade abdominal. A medição das áreas e volumes abdominais foi efetuada através das TACs com construção de modelos 3D da cavidade abdominal. Estes modelos conduziram à delineação de uma fórmula de cálculo que permitiu a determinação da área de superfície abdominal, tendo como base os parâmetros morfométricos dos indivíduos. O estudo biofísico da PIA assim como, dos métodos e das variáveis que a afetam foi realizado em modelo

anatômico não vivo da cavidade abdominal. Este tipo de modelo permitiu a erradicação das variáveis fisiológicas suscetíveis de alterar a PIA, o que conduziu a um maior controlo experimental. Neste ponto foram determinadas todas as componentes físicas que geram a PIA no modelo anatômico e foi realizada a sua determinação através de diferentes métodos, de forma a comparar os diversos valores obtidos.

A última fase consistiu no desenvolvimento de uma estrutura informática de inteligência computacional, com o objetivo de determinar a PIA através do uso de parâmetros fisiológicos e morfológicos utilizados na monitorização multiparamétrica de indivíduos. Foi então realizado o estudo retrospectivo de uma base de dados de monitorização multiparamétrica de cães. A recolha de dados foi realizada segundo as normas do Conselho de Ética e Bem-estar Animal e com a respetiva autorização dos proprietários. A base de dados estudada era constituída pelos parâmetros fisiológicos, morfológicos e valores de PIA. Através desta base de dados foi criado um modelo de inteligência computacional, baseado em 18 entradas (parâmetros fisiológicos e morfológicos) e uma saída de sistema (PIA). Os parâmetros utilizados foram definidos tendo como base as características do sistema e as variáveis com a maior influência na PIA.

Resultados: O volume (média \pm desvio padrão) da cavidade abdominal de cães foi de 0.0039 ± 0.00206 m³ e a área de superfície abdominal de 0.1519 ± 0.05950 m². A fórmula matemática encontrada permite calcular a área sem diferenças estatisticamente significativas ($P=0.988$) quando comparada com a determinação individual.

A determinação das áreas e da força das estruturas anatómicas no modelo em cadáver animal permitiu a substituição de valores na formulação biofísica e cálculo da PIA. Estes valores comparados com as leituras diretas por sensor não apresentaram diferenças estatisticamente significativas ($P<0.05$).

A comparação dos três métodos mais utilizados para determinação da PIA demonstrou que o MT e a manometria intra-gástrica são ambos métodos indiretos fiáveis, com um intervalo de confiança de 95 % no decúbito lateral, ventral e dorsal. Nestas posições anatómicas, o MT demonstrou melhores

índices de correlação. A determinação da PIA pelo método direto nas várias posições anatómicas não revelou diferenças estatisticamente significativas. Os métodos indiretos revelaram diferenças estatisticamente significativas entre as medições nas várias posições. A posição de Trendelenburg e Trendelenburg reversa afetou a medição da PIA pelos métodos indiretos.

Dos 18 parâmetros de entrada estudados, os que apresentaram uma maior correlação com a PIA foram: peso (cc 0.48), área de superfície abdominal (cc 0.46), perímetro (cc 0.34), a pressão arterial diastólica (cc 0.25), a duração do QRS (cc0.20), a pressão arterial média (cc 0.17) e a amplitude da onda R (cc 0.12). Das 162 redes neuronais artificiais (RNA) criadas, os melhores desempenhos obtidos apresentaram um índice de regressão linear de 0.97. Foi também utilizado um modelo simplificado, apenas das entradas com maior correlação com a saída, tendo sido obtidos resultados de desempenho idênticos. O melhor modelo de sistema de rede adaptativo baseado em sistemas de inferência difusa (ANFIS) criado, apresentou um erro de treino de 0.29 e um erro de teste de 0.33.

Conclusão: os valores obtidos da área de superfície da cavidade abdominal, providenciam informação não existente em termos anatómicos e contribuem para o estudo de doenças que afetam esta superfície. A determinação desta área possibilita a sua aplicação no cálculo e determinação da PIA, tal como a sua melhor compreensão. A mesma metodologia pode ser empregue em humanos para determinação e cálculo da área da cavidade abdominal. O MT é o método indireto mais preciso para medir a PIA no decúbito lateral, ventral e dorsal. Se os métodos indiretos forem utilizados para medir a PIA na posição de Trendelenburg ou Trendelenburg reversa, os resultados podem ser sobre ou sob estimados. Os princípios biofísicos demonstram a veracidade da definição teórica de PIA e provam a veracidade do MT, explicando as variáveis que o afetam, aumentando assim o sucesso das medições efetuadas nas unidades de cuidados intensivos.

O método de medição inteligente baseado em redes neuronais, nunca antes utilizado para determinação da PIA, permite a sua medição por meios não invasivos e de forma contínua. As RNA e as ANFIS criadas permitiram prever a PIA com baixo erro. Este tipo de solução poderá assim ser incluído nos

monitores multiparamétricos das unidades de saúde, facilitando a monitorização da PIA tanto em animais como em humanos.

Palavras-chave: Pressão intra-abdominal, biofísica, redes neuronais artificiais, medição indireta, método transvesical.

Agradecimentos

No Sudoeste da Europa, Portugal surge como um País onde o apoio à investigação, tecnologia e inovação em todas as áreas do conhecimento continua a apresentar grandes deficiências. A ausência de fundos privados e públicos continua a marcar a atualidade e leva a uma fuga concertada de investigadores. Contudo, a maior riqueza do nosso País é constituída pelas pessoas e pelos seus costumes. Assim, gostaria de agradecer às pessoas e instituições que possibilitaram este trabalho, pois sem elas teria sido impossível desenvolver o mesmo. Toda esta investigação foi desenvolvida com fundos próprios e num ritmo de trabalho incessante.

Numa primeira instância gostaria de agradecer aos meus orientadores, Professor António Dourado e Professora Maria Manuela Rodeia, toda a ajuda disponibilizada e sábio aconselhamento no percurso deste projeto. Ao Professor António Ferreira, Diretor do Hospital Escolar, gostaria de demonstrar a minha gratidão por ter autorizado e possibilitado o acesso à base de dados de exames tomográficos da Faculdade de Medicina Veterinária da Universidade de Lisboa. Unicamente com o acesso a estes exames, e a ajuda de dois colegas e amigos de trabalho, Rui Onça e Hugo Pereira, foi possível desenvolver e finalizar a primeira parte do trabalho.

Gostaria também de apresentar um agradecimento formal à comercialização de dispositivos médicos da Johnson & Johnson Portugal, por ter facultado gratuitamente três microsensores da Codman. Sem estes dispositivos nunca teria sido possível ter um sensor de referência que medisse as pressões intra-abdominais.

A todos aqueles que sempre me apoiaram e que com pequenas frases marcaram o meu percurso. No rosto marcado pelo tempo, e nas ânsias e correrias do desespero, fica o conselho sábio de quem me criou:

“Com o tempo tudo passa”

Índice

| | |
|--|--------------|
| FOLHA DE ROSTO..... | I |
| ABSTRACT..... | II |
| RESUMO..... | V |
| AGRADECIMENTOS | IX |
| ÍNDICE | X |
| ÍNDICE DE TABELAS..... | XII |
| ÍNDICE DE FIGURAS..... | XIII |
| ÍNDICE DE EQUAÇÕES..... | XVI |
| ÍNDICE DE ABREVIATURAS..... | XVIII |
| CAPÍTULO 1 – INTRODUÇÃO..... | 1 |
| 1.1 - Motivações e objetivo | 2 |
| 1.2- Organização da tese..... | 2 |
| 1.3- Publicações | 4 |
| 1.4- Introdução Geral..... | 5 |
| 1.4.1- Fisiopatologia da pressão intra-abdominal | 8 |
| 1.4.2- Terapêutica na hipertensão abdominal..... | 12 |
| 1.4.3- Medição da pressão..... | 14 |
| 1.4.4- Monitorização | 25 |
| CAPÍTULO 2 - ÁREA DE SUPERFÍCIE DA CAVIDADE ABDOMINAL | 27 |
| 2.1 – Introdução | 28 |
| 2.1.1- Cavidade Abdominal | 28 |
| 2.1.2- Volume e área abdominal | 30 |
| 2.2 - Material e métodos | 31 |
| 2.2.1- Avaliação das TAC's..... | 31 |
| 2.2.2- Segmentação manual | 32 |
| 2.2.3- Modelação 3D..... | 35 |
| 2.2.4- Cálculo dos parâmetros morfométricos | 36 |
| 2.3 – Resultados..... | 37 |
| 2.3.1- Valores determinados da cavidade abdominal..... | 37 |
| 2.3.1- Correlação matemática da cavidade abdominal de cães | 38 |

| | |
|------------------------------|-----------|
| 2.4 - Discussão | 38 |
|------------------------------|-----------|

CAPÍTULO 3 – VALIDAÇÃO DA PRESSÃO INTRA-ABDOMINAL42

| | |
|--|-----------|
| 3.1- Introdução | 43 |
| 3.1.1- Conceitos físicos de Pressão | 43 |
| 3.1.2- Métodos diretos de medição da PIA | 45 |
| 3.1.3- Métodos indiretos de medição da Pressão intra-abdominal | 46 |
| 3.2 - Material e Métodos..... | 55 |
| 3.2.1- Medição direta da PIA | 57 |
| 3.2.2- Medição indireta da PIA | 57 |
| 3.2.3- Determinações morfométricas | 58 |
| 3.2.4- Área do estômago e bexiga | 59 |
| 3.2.5 - Área de superfície corporal e do abdômen..... | 61 |
| 3.2.6 - Mecânica de Fluidos | 61 |
| 3.3 – Resultados | 63 |
| 3.3.1 - Sobreposição de princípios biofísicos..... | 63 |
| 3.3.2- Valores da Pressão Intra-abdominal | 66 |
| 3.3.3- Valor das Variáveis para cálculo da PIA | 68 |
| 3.3.4- Cálculo da PIA pela sobreposição de princípios físicos | 69 |
| 3.3.4- Comparação de valores obtidos pela sobreposição de princípios físicos | 70 |
| 3.3.6- Variáveis que influenciam a medição da PIA | 71 |
| 3.4 - Discussão | 83 |

CAPÍTULO 4 – MEDIÇÃO DA PIA COM MÉTODOS DE INTELIGÊNCIA COMPUTACIONAL94

| | |
|---|------------|
| 4.1 - Introdução | 95 |
| 4.1.1 - Redes Neurais | 96 |
| 4.1.2 - Sistemas difusos..... | 101 |
| 4.1.3 – Clustering para a aprendizagem de Sistemas Difusos..... | 103 |
| 4.1.4 - Sistemas de redes adaptativas baseadas em sistemas de inferência difusa | 105 |
| 4.2 - Material e Métodos..... | 107 |
| 4.2.1- População..... | 108 |
| 4.2.2- Parâmetros fisiológicos e morfológicos..... | 108 |
| 4.2.3- Análise Estatística..... | 110 |
| 4.2.4- Modelo da PIA usando inteligência computacional..... | 110 |
| 4.2.4.1- Redes Neurais Artificiais | 111 |
| 4.2.4.2- Redes adaptativas baseadas em sistemas de inferência Difusa | 112 |
| 4.3 - Resultados | 115 |
| 4.3.1 - População Saudável | 115 |
| 4.3.2- População Doente | 116 |
| 4.3.3- Redução do número de características: correlação estatística entre as variáveis de entrada | 117 |
| 4.3.4- Correlação estatística entre as variáveis de entrada e de saída | 119 |
| 4.3.5- Redes Neurais Artificiais | 120 |
| 4.3.6- Agrupamento por mapas auto-organizados..... | 131 |
| 4.3.7- Redes adaptativas baseadas em sistemas de inferência difusa | 133 |
| 4.4- Discussão | 151 |

| | |
|---|------------|
| CAPÍTULO 5 – CONCLUSÃO FINAL | 164 |
|---|------------|

| | |
|----------------------------|------------|
| BIBLIOGRAFIA: | 169 |
|----------------------------|------------|

| | |
|--------------------|------------|
| ANEXOS..... | 190 |
|--------------------|------------|

| | |
|--|-----|
| Autorização da Comissão de Ética e Bem-Estar Animal da Universidade Lusófona | 190 |
| Dados Totais de Redes Neurais Artificiais obtidos..... | 191 |
| Dados Totais dos ANFIS obtidos..... | 200 |

Índice de tabelas

| | |
|--|-----|
| TABELA 1-1- CLASSIFICAÇÃO DA HA EM GRAUS NO HOMEM, DE ACORDO COM A SOCIEDADE MUNDIAL DE SÍNDROME DE COMPARTIMENTALIZAÇÃO ABDOMINAL [1,27]. | 7 |
| TABELA 1-2 - EFEITOS DO AUMENTO DA PIA. ADAPTADO DE ANDRADE JI, 1989 [32] | 9 |
| TABELA 2-1- VALORES DAS DETERMINAÇÕES MORFOMÉTRICAS: PESO CORPORAL, PERÍMETRO ABDOMINAL, ÁREA DE SUPERFÍCIE CORPORAL, ÁREA DE SUPERFÍCIE DA CAVIDADE ABDOMINAL E VOLUMA DA CAVIDADE ABDOMINAL. | 37 |
| TABELA 3-1- VALORES MÉDIOS DA PIA EM MMHG OBTIDOS POR MEDIÇÃO DIRETA..... | 66 |
| TABELA 3-2 - VALORES MÉDIOS DA PIA EM MMHG OBTIDOS PELO MÉTODO TRANSVESICAL..... | 67 |
| TABELA 3-3 - VALORES MÉDIOS DA PIA EM MMHG OBTIDOS POR MANOMETRIA INTRA-GÁSTRICA. | 67 |
| TABELA 3-4- VARIÁVEIS DE CÁLCULO, LIMITE INFERIOR E SUPERIOR, MÉDIA E DESVIO PADRÃO. | 68 |
| TABELA 3-5- VARIÁVEIS DE CÁLCULO, LIMITE INFERIOR E SUPERIOR, MÉDIA E DESVIO PADRÃO EM PASCAL. | 70 |
| TABELA 4-1 – ESTATÍSTICA DESCRITIVA DAS 19 VARIÁVEIS OBTIDOS NA POPULAÇÃO TOTAL | 115 |
| TABELA 4-2- ESTATÍSTICA DESCRITIVA DAS 19 VARIÁVEIS OBTIDOS NA POPULAÇÃO SAUDÁVEL.... | 115 |
| TABELA 4-3- ESTATÍSTICA DESCRITIVA DAS 19 VARIÁVEIS OBTIDOS NA POPULAÇÃO DOENTE. | 116 |
| TABELA 4-4- VALORES DE CORRELAÇÃO ENTRE AS 18 VARIÁVEIS DE ENTRADA. | 118 |
| TABELA 4-5- CORRELAÇÃO ESTATÍSTICA, COEFICIENTE DE CORRELAÇÃO DE PEARSON, ENTRE AS VARIÁVEIS DE ENTRADA E A VARIÁVEL DE SAÍDA. | 119 |
| TABELA 4-6- RESUMO DOS MELHORES RESULTADOS OBTIDOS NAS RNA, O R REPRESENTA O COEFICIENTE DE REGRESSÃO LINEAR ENTRE AS SAÍDAS E O ALVO..... | 120 |
| TABELA 4-7- RESULTADOS DOS ANFIS INICIALIZANDO O SISTEMA DIFUSO COM A FUNÇÃO GENFIS3 COM 18 E 7 VARIÁVEIS DE ENTRADA COM O ERRO DE TESTE, DE TREINO E DE VALIDAÇÃO OBTIDOS COM A DIVISÃO DOS DADOS 50% PARA TREINO, 25% PARA TESTE E 25% PARA VALIDAÇÃO. OS RESULTADOS FIS SÃO DO TIPO SUGENO DE ORDEM 1. O ERRO REPRESENTA O RMSE, A MÉDIA DO QUADRADO DOS ERROS OBTIDO EM CADA PONTO. NOS SISTEMAS COM 11 E 46 REGRAS, QUANDO UTILIZAMOS A FUNÇÃO AUTOMÁTICA ESTE UTILIZA O MÉTODO SUBTRATIVO E O MÉTODO FCM QUANDO ESTIPULAMOS O NÚMERO DE REGRAS. | 134 |
| TABELA 4-8- RESULTADOS DOS ANFIS OBTIDOS COM A FUNÇÃO GENFIS2 COM 18 E 7 VARIÁVEIS DE ENTRADA COM O ERRO DE TESTE, DE TREINO E DE VALIDAÇÃO OBTIDOS COM A DIVISÃO DOS DADOS 50% PARA TREINO, 25% PARA TESTE E 25% PARA VALIDAÇÃO. | 139 |
| TABELA 4-9- RESULTADOS DOS ANFIS OBTIDOS, COM A FUNÇÃO GENFIS3, PARA O MODELO REDUZIDO COM O RMSE DE TESTE E DE TREINO, COM A DIVISÃO DOS DADOS 77% PARA TREINO E 23% PARA TESTE. O ERRO REPRESENTA O RMSE, A MÉDIA DO QUADRADO DOS ERROS OBTIDO EM CADA PONTO. | 139 |
| TABELA 4-10- RESULTADOS DOS ANFIS OBTIDOS, COM A FUNÇÃO GENFIS3, PARA O MODELO REDUZIDO COM O RMSE DE TESTE E DE TREINO, COM A DIVISÃO DOS DADOS 67,4% PARA TREINO E 32,6 % PARA TESTE. O ERRO REPRESENTA O RMSE, A MÉDIA DO QUADRADO DOS ERROS OBTIDO EM CADA PONTO. | 140 |

Índice de Figuras

| | |
|--|----|
| FIGURA 1-1- PRINCIPAIS REPERCUSSÕES INDUZIDAS PELO AUMENTO DA PIA TRADUZIDO E ADAPTADO DE CHEATHAM, 2009 [2]. | 8 |
| FIGURA 1-2- SÍNDROME DE COMPARTIMENTALIZAÇÃO NO HOMEM. DESCOMPRESSÃO ABDOMINAL NUM PACIENTE COM SCA RECORRENDO A MATERIAIS PROTÉSICOS EM PERRY & PHILIPS, 2003 [47]. | 14 |
| FIGURA 1-3- TUBO DE BOURDON TRADUZIDO E ADAPTADO DE WHITE, 2009 [48]. | 16 |
| FIGURA 1-4- DESENHO TÍPICO DE CIRCUITO DE WHEATSTONE COM SENSOR STRAIN GAUGE TRADUZIDO E ADAPTADO DE CHEVALIER, CHAMBERLIN, 2011 [51]. | 18 |
| FIGURA 1-5- HIERARQUIA DE MODELAÇÃO MULTIESCALA TRADUZIDO E ADAPTADO DE GODDARD ET AL, 2001 [59]. | 22 |
| FIGURA 1-6- SENSOR COM CAMADA INTERMÉDIA DE POLIDIMETILSILOXANO ESQUEMA ILUSTRATIVO DE SENSOR DE PRESSÃO, COM CAMADA INTERMÉDIA DE POLIDIMETILSILOXANO TRADUZIDO E ADAPTADO DE ZHOU E WANG, 2013 [60]. | 24 |
| FIGURA 2-1- FIGURA ILUSTRATIVA DA CAVIDADE ABDOMINAL DE CÃO TRADUZIDO E ADAPTADO DE DONE GOODY & EVANS, 1996 [81]. | 28 |
| FIGURA 2-2- IMAGEM ILUSTRATIVA DOS LIMITES DA CAVIDADE ABDOMINAL NUM PLANO TRANSVERSO DE CÃO EVIDENCIANDO A CAVIDADE TORÁCICA, ABDOMINAL E PÉLVICA, TRADUZIDO E ADAPTADO DE ASPINALL, 2004 [84]. | 29 |
| FIGURA 2-3- IMAGEM TOMOGRÁFICA DA CAVIDADE ABDOMINAL EM VÁRIAS ORIENTAÇÕES, COM A SEGMENTAÇÃO MANUAL DE CADA CORTE, CORRESPONDENTE À ÁREA DE SUPERFÍCIE DA CAVIDADE ABDOMINAL. | 32 |
| FIGURA 2-4- IMAGEM TOMOGRÁFICA DA CAVIDADE ABDOMINAL NO PLANO TRANSVERSAL COM DELIMITAÇÃO DA ÁREA DE INTERESSE. | 33 |
| FIGURA 2-5- REGIÃO DE INTERESSE DA CAVIDADE ABDOMINAL EM CORTE TRANSVERSAL APÓS CORREÇÃO DOS VALORES DE PIXEL POR SEGMENTAÇÃO INDIVIDUAL DE CADA CORTE. | 34 |
| FIGURA 2-6- IMAGEM TRIDIMENSIONAL DA CAVIDADE ABDOMINAL EM OSIRIX. MODELO FINAL QUE PERMITE EXPORTAÇÃO DE FICHEIRO STEREO LITHOGRAPHY PARA SER MODELADO EM SOFTWARE CAD. | 34 |
| FIGURA 2-7- IMAGEM TRIDIMENSIONAL DA CAVIDADE ABDOMINAL EM SOLID WORKS. FICHEIRO STL. DA SUPERFÍCIE DE ÁREA DA CAVIDADE ABDOMINAL ABERTO EM SOFTWARE CAD. | 35 |
| FIGURA 2-8- MODELO TRIDIMENSIONAL FINAL DA CAVIDADE ABDOMINAL QUE PERMITE A OBTENÇÃO DOS VALORES DE ÁREA DE SUPERFÍCIE E DO VOLUME. | 36 |
| FIGURA 2-9- GRÁFICO DOS VALORES DE ÁREA DE SUPERFÍCIE ABDOMINAL MEDIDOS POR TAC E VALORES CALCULADOS PELO POLINÓMIO DE PRIMEIRO GRAU. | 40 |
| FIGURA 3-1- IMAGEM ILUSTRATIVA DO MÉTODO TRANSVESICAL EM HUMANOS, TRADUZIDO E ADAPTADO DE ASENSIO, CEBALLOS, FORNO & SAVA, 2002 [31]. | 48 |
| FIGURA 3-2- IMAGEM ILUSTRATIVA DE MANOMETRIA INTRA-GÁSTRICA VIA TUBO NASOGÁSTRICO NO HOMEM, TRADUZIDO E ADAPTADO DE ASENSIO, CEBALLOS, FORNO & SAVA, 2002 [31]. | 52 |
| FIGURA 3-3- REPRESENTAÇÃO ESQUEMÁTICA DA MEDIÇÃO DA PIA POR MÉTODOS DIRETOS E PELOS MÉTODOS INDIRETOS (MÉTODO TRANSVESICAL E INTRAGÁSTRICO). | 57 |
| FIGURA 3-4- FOTOGRAFIA DA DIÉRESE SAGITAL DA BEXIGA DE FORMA A OBTER UMA SUPERFÍCIE PLANA. | 59 |
| FIGURA 3-5 - IMAGEM DIGITAL (BIPMAP) DO CORTE SAGITAL DA BEXIGA E DO ESTÔMAGO E DO QUADRADO DE ESCALA DE 1 CENTÍMETRO | 60 |
| FIGURA 3-6- IMAGEM DIGITAL DA BEXIGA, ESTÔMAGO E ESCALA APÓS PROCESSAMENTO DE IMAGEM NO MATLAB COM OS VALORES DE ÁREA DE SUPERFÍCIE DA BEXIGA E DO ESTÔMAGO. | 61 |
| FIGURA 3-7- REPRESENTAÇÃO ESQUEMÁTICA DAS FORÇAS ENVOLVIDAS NO MÉTODO TRANSVESICAL. P_0 REPRESENTA A PRESSÃO ATMOSFÉRICA, P_1 O PONTO DE PRESSÃO NO CENTRO DA BEXIGA, P_2 A PRESSÃO DA COLUNA DE ÁGUA, H_1 A ALTURA DO FLUIDO NA BEXIGA, H_2 A ALTURA DO FLUIDO NA COLUNA DE ÁGUA, P REFERE-SE À DENSIDADE, G A ACELERAÇÃO GRAVÍTICA, P_M A PRESSÃO EXERCIDA PELOS MÚSCULOS, P_C A PRESSÃO EXERCIDA PELO CONTEÚDO PERITONEAL E P_B A PRESSÃO EXERCIDA PELOS OSSOS. | 65 |
| FIGURA 3-8- REPRESENTAÇÃO ESQUEMÁTICA DAS FORÇAS ENVOLVIDAS NO MÉTODO TRANSVESICAL QUANDO EXISTE AUMENTO DO PESO. P_0 REPRESENTA A PRESSÃO ATMOSFÉRICA, P_1 PONTO DE PRESSÃO NO CENTRO DA BEXIGA, P_2 A PRESSÃO DA COLUNA DE ÁGUA, H_1 ALTURA DO FLUIDO | |

| | |
|---|-----|
| NA BEXIGA, H_2 A ALTURA DO FLUIDO NA COLUNA DE ÁGUA, P A DENSIDADE, G A ACELERAÇÃO GRAVÍTICA; A LETRA F REPRESENTA OS VETORES DE FORÇA SENDO F_M A FORÇA DOS MÚSCULOS, F_C A FORÇA DO CONTEÚDO VISCERAL E F_B A FORÇA EXERCIDA PELOS OSSOS; A LETRA P REFERE-SE AOS ESTADOS DE PRESSÃO SENDO P_M A PRESSÃO EXERCIDA PELOS MÚSCULOS, P_C A PRESSÃO EXERCIDA PELO CONTEÚDO PERITONEAL E P_B A PRESSÃO EXERCIDA PELOS OSSOS. A LETRA A REPRESENTA A ÁREA ONDE SÃO APLICADAS AS FORÇAS, SENDO A ASCA A ÁREA DE SUPERFÍCIE DA CAVIDADE ABDOMINAL..... | 73 |
| FIGURA 3-9 - REPRESENTAÇÃO ESQUEMÁTICA DAS FORÇAS ENVOLVIDAS NO MÉTODO TRANSVESICAL QUANDO EXISTE CONTRAÇÃO MUSCULAR. P_0 REPRESENTA A PRESSÃO ATMOSFÉRICA, P_1 O PONTO DE PRESSÃO NO CENTRO DA BEXIGA, P_2 A PRESSÃO NA COLUNA DE ÁGUA, H_1 A ALTURA DO FLUIDO NA BEXIGA, H_2 A ALTURA DO FLUIDO NA COLUNA DE ÁGUA, P DENSIDADE, G A ACELERAÇÃO GRAVÍTICA, SENDO F_M A FORÇA DOS MÚSCULOS; A LETRA P REFERE-SE AOS ESTADOS DE PRESSÃO SENDO P_M A PRESSÃO EXERCIDA PELOS MÚSCULOS, P_C A PRESSÃO EXERCIDA PELO CONTEÚDO PERITONEAL E P_B A PRESSÃO EXERCIDA PELOS OSSOS E A ASCA REPRESENTA A ÁREA DE SUPERFÍCIE DA CAVIDADE ABDOMINAL..... | 74 |
| FIGURA 3-10- REPRESENTAÇÃO ESQUEMÁTICA DAS FORÇAS ENVOLVIDAS NO MÉTODO TRANSVESICAL NOS DOIS MOMENTOS DISTINTOS DA RESPIRAÇÃO, INSPIRAÇÃO E EXPIRAÇÃO. AS SETAS COLOCADAS NA CAVIDADE TORÁCICA REPRESENTAM A DIMINUIÇÃO DA CAVIDADE TORÁCICA O QUE PROVOCA UMA DIMINUIÇÃO DE ÁREA. P_0 REPRESENTA A PRESSÃO ATMOSFÉRICA, P_1 O PONTO DE PRESSÃO NO CENTRO DA BEXIGA, P_2 A PRESSÃO DA COLUNA DE ÁGUA, H_1 A ALTURA DO FLUIDO NA BEXIGA, H_2 A ALTURA DO FLUIDO NA COLUNA DE ÁGUA, P A DENSIDADE, G A ACELERAÇÃO GRAVÍTICA, SENDO F_M A FORÇA DOS MÚSCULOS; A LETRA P REFERE-SE AOS ESTADOS DE PRESSÃO SENDO P_M A PRESSÃO EXERCIDA PELOS MÚSCULOS, P_C A PRESSÃO EXERCIDA PELO CONTEÚDO PERITONEAL E P_B A PRESSÃO EXERCIDA PELOS OSSOS E A ASCA A REPRESENTA A ÁREA DE SUPERFÍCIE DA CAVIDADE ABDOMINAL..... | 75 |
| FIGURA 3-11- REPRESENTAÇÃO ESQUEMÁTICA DAS FORÇAS ENVOLVIDAS NO MÉTODO TRANSVESICAL APÓS ALTERAÇÃO DA POSIÇÃO. P_0 REPRESENTA A PRESSÃO ATMOSFÉRICA, P_1 O PONTO DE PRESSÃO NO CENTRO DA BEXIGA, P_2 A PRESSÃO DA COLUNA DE ÁGUA, H_1 A ALTURA DO FLUIDO NA BEXIGA, H_2 A ALTURA DO FLUIDO NA COLUNA DE ÁGUA, H_3 A PORÇÃO DA ALTURA DO PLANO INCLINADO, L CORRESPONDE AO SEGMENTO DA COLUNA; θ O ÂNGULO DE INCLINAÇÃO; P A DENSIDADE, G A ACELERAÇÃO GRAVÍTICA, SENDO F_M A FORÇA DOS MÚSCULOS; A LETRA P REFERE-SE AOS ESTADOS DE PRESSÃO SENDO P_M A PRESSÃO EXERCIDA PELOS MÚSCULOS, P_C A PRESSÃO EXERCIDA PELO CONTEÚDO PERITONEAL E P_B A PRESSÃO EXERCIDA PELOS OSSOS..... | 79 |
| FIGURA 3-12- REPRESENTAÇÃO ESQUEMÁTICA DAS FORÇAS ENVOLVIDAS NO MÉTODO TRANSVESICAL VARIANDO A POSIÇÃO DO MANÓMETRO DE ÁGUA. P_0 REPRESENTA A PRESSÃO ATMOSFÉRICA, P_1 O PONTO DE PRESSÃO NO CENTRO DA BEXIGA, P_2 A PRESSÃO DA COLUNA DE ÁGUA, H_1 A ALTURA DO FLUIDO NA BEXIGA, H_2 A ALTURA DO FLUIDO NA COLUNA DE ÁGUA, H_3 A PORÇÃO DA ALTURA DO PLANO INCLINADO, L CORRESPONDE AO SEGMENTO DA COLUNA; θ O ÂNGULO DE INCLINAÇÃO; P A DENSIDADE, G A ACELERAÇÃO GRAVÍTICA, SENDO F_M A FORÇA DOS MÚSCULOS; A LETRA P REFERE-SE AOS ESTADOS DE PRESSÃO SENDO P_M A PRESSÃO EXERCIDA PELOS MÚSCULOS, P_C A PRESSÃO EXERCIDA PELO CONTEÚDO PERITONEAL E P_B A PRESSÃO EXERCIDA PELOS OSSOS..... | 80 |
| FIGURA 3-13- REPRESENTAÇÃO ESQUEMÁTICA DAS FORÇAS ENVOLVIDAS NO MÉTODO TRANSVESICAL COM INSTILAÇÃO DE GRANDE VOLUME RESIDUAL. P_0 REPRESENTA A PRESSÃO ATMOSFÉRICA, P_1 O PONTO DE PRESSÃO NO CENTRO DA BEXIGA, P_2 A PRESSÃO DA COLUNA DE ÁGUA, H_1 A ALTURA DO FLUIDO NA BEXIGA, H_2 A ALTURA DO FLUIDO NA COLUNA DE ÁGUA; P A DENSIDADE, G A ACELERAÇÃO GRAVÍTICA, SENDO F_U A FORÇA EXERCIDA PELO FLUIDO CONTIDO NA BEXIGA E F_2 A FORÇA EXERCIDA PELA COLUNA DE FLUIDO NO MANÓMETRO; A LETRA P REFERE-SE AOS ESTADOS DE PRESSÃO SENDO P_U A PRESSÃO HIDROSTÁTICA DO FLUIDO NA BEXIGA, P_M A PRESSÃO EXERCIDA PELOS MÚSCULOS, P_C A PRESSÃO EXERCIDA PELO CONTEÚDO PERITONEAL E P_B A PRESSÃO EXERCIDA PELOS OSSOS; A LETRA M REPRESENTA A MASSA, SENDO M_U A MASSA DO FLUIDO CONTIDA NA BEXIGA E M_2 A MASSA DE FLUIDO CONTIDA NO MANÓMETRO; A LETRA V REPRESENTA O VOLUME SENDO V_U O VOLUME CONTIDO NA BEXIGA E V_2 O VOLUME CONTIDO NO MANÓMETRO; A LETRA A REPRESENTA AS ÁREAS SENDO A_U A ÁREA DA BEXIGA E A_2 A ÁREA DE SECCÃO DO MANÓMETRO..... | 82 |
| FIGURA 4-1- APRESENTAÇÃO ESQUEMÁTICA DAS PRINCIPAIS APLICAÇÕES DAS REDES NEURONAIS ARTIFICIAIS NA MEDICINA; TRADUZIDO E ADAPTADO DE PATEL ET AL 2007 [160]. | 97 |
| FIGURA 4-2- FUNÇÃO DE TRANSFERÊNCIA LOG-SIGMOID [174]. | 99 |
| FIGURA 4-3- FUNÇÃO DE TRANSFERÊNCIA TAN-SIGMOID [175]. | 100 |

| | |
|---|-----|
| FIGURA 4-4- FUNÇÃO DE TRANSFERÊNCIA LINEAR [175]..... | 100 |
| FIGURA 4-5- DESCRIÇÃO GERAL DE UM SISTEMA FUZZY; ADAPTADO DE MATLAB FUZZY TOOLBOX [193]...... | 105 |
| FIGURA 4-6- DIAGRAMA DE FUNCIONAMENTO DO SISTEMA DE INFERÊNCIA SUGENO (FUZZY LOGIC TOOLBOX DO MATLAB), [193]. | 106 |
| FIGURA 4-7- MODELO DE INTELIGÊNCIA COMPUTACIONAL COM 18 ENTRADAS E 1 SAÍDA..... | 111 |
| FIGURA 4-8-ÍNDICES DE CORRELAÇÃO ENTRE AS ENTRADAS E SAÍDAS DO SISTEMA | 119 |
| FIGURA 4-9- COMPARAÇÃO DO ÍNDICE DE REGRESSÃO LINEAR DE TREINO, ENTRE AS SAÍDAS E OS ALVOS, DAS VÁRIAS ARQUITETURAS DE RNA TESTADAS, NA POPULAÇÃO TOTAL USANDO O MODELO REDUZIDO. NO EIXO HORIZONTAL ESTÃO REPRESENTADOS O NÚMERO DE NEURÓNIOS POR CADA CAMADA. | 121 |
| FIGURA 4-10- COMPARAÇÃO DO ÍNDICE DE REGRESSÃO LINEAR TOTAL (TREINO E TESTE), ENTRE AS SAÍDAS E OS ALVOS, DAS VÁRIAS ARQUITETURAS DE RNA TESTADAS, NA POPULAÇÃO TOTAL USANDO O MODELO REDUZIDO. NO EIXO HORIZONTAL ESTÃO REPRESENTADOS O NÚMERO DE NEURÓNIOS POR CADA CAMADA. | 122 |
| FIGURA 4-11- HISTOGRAMA DE ERRO DA MELHOR RNA UTILIZANDO OS 18 PARÂMETROS DE ENTRADA. A BARRA AZUL REPRESENTA OS DADOS DE TREINO E A BARRA A VERMELHO OS DADOS DE TESTE. | 123 |
| FIGURA 4-12 – ARQUITETURA DA MELHOR RNA UTILIZANDO OS 7 PARÂMETROS DE ENTRADA PARA A POPULAÇÃO TOTAL (FIGURA CRIADA PELO MATLAB)..... | 123 |
| FIGURA 4-13 -GRÁFICOS DE REGRESSÃO DO TREINO DA REDE, DE TESTE, E TOTAL, UTILIZANDO 7 PARÂMETROS DE ENTRADA NA POPULAÇÃO TOTAL. | 124 |
| FIGURA 4-14. HISTOGRAMA DE ERRO DA MELHOR RNA UTILIZANDO OS 7 PARÂMETROS DE ENTRADA. A BARRA AZUL REPRESENTA OS DADOS DE TREINO E A BARRA A VERMELHO OS DADOS DE TESTE. | 125 |
| FIGURA 4-15- GRÁFICO DE COMPARAÇÃO DOS VALORES REAIS DE PIA OBTIDOS POR SENSOR DIRETO (PONTOS AZUIS) COM OS VALORES DETERMINADOS PELA MELHOR RNA DO MODELO REDUZIDO COM 7 ENTRADAS DE SISTEMA (VALORES A VERMELHO). | 126 |
| FIGURA 4-16- GRÁFICOS DE REGRESSÃO DO TREINO DA REDE DE TESTE E TOTAL, UTILIZANDO OS 18 PARÂMETROS DE ENTRADA NA POPULAÇÃO SAUDÁVEL..... | 127 |
| FIGURA 4-17- GRÁFICO DE PERFORMANCE DA RNA UTILIZANDO OS 18 PARÂMETROS DE ENTRADA NA POPULAÇÃO SAUDÁVEL. | 128 |
| FIGURA 4-18- HISTOGRAMA DE ERRO DA MELHOR RNA UTILIZANDO OS 18 PARÂMETROS DE ENTRADA NA POPULAÇÃO SAUDÁVEL. A BARRA AZUL REPRESENTA OS DADOS DE TREINO E A BARRA A VERMELHO OS DADOS DE TESTE..... | 128 |
| FIGURA 4-19- GRÁFICO DE PERFORMANCE DA RNA UTILIZANDO OS 7 PARÂMETROS DE ENTRADA NA POPULAÇÃO SAUDÁVEL. MSE – ERRO QUADRADO MÉDIO..... | 129 |
| FIGURA 4-20- HISTOGRAMA DE ERRO DA MELHOR RNA UTILIZANDO OS 7 PARÂMETROS DE ENTRADA NA POPULAÇÃO SAUDÁVEL. A BARRA AZUL REPRESENTA OS DADOS DE TREINO E A BARRA A VERMELHO OS DADOS DE TESTE..... | 129 |
| FIGURA 4-21- HISTOGRAMA DE ERRO DA MELHOR RNA UTILIZANDO OS 18 PARÂMETROS DE ENTRADA NA POPULAÇÃO DOENTE. A BARRA AZUL REPRESENTA OS DADOS DE TREINO E A BARRA A VERMELHO OS DADOS DE TESTE..... | 130 |
| FIGURA 4-22- HISTOGRAMA DE ERRO DA MELHOR RNA UTILIZANDO OS 7 PARÂMETROS DE ENTRADA NA POPULAÇÃO DOENTE. A BARRA AZUL REPRESENTA OS DADOS DE TREINO E A BARRA A VERMELHO OS DADOS DE TESTE..... | 131 |
| FIGURA 4-23- ARQUITETURA DE REDE, NEURAL CLUSTERING (NCTOOL) DA TOTALIDADE DOS DADOS. OS DADOS TOTAIS FORAM AGRUPADOS EM 4 GRUPOS..... | 131 |
| FIGURA 4-24- REPRESENTAÇÃO COMPACTA A DUAS DIMENSÕES DO SOM, ONDE SE PODE VER NO CANTO SUPERIOR ESQUERDO OS PESOS DAS DISTÂNCIAS ENTRE NEURÓNIOS VIZINHOS. NO CANTO INFERIOR ESQUERDO AS CAMADAS DO SOM, ONDE CADA NEURÓNIO MOSTRA O NÚMERO DE VETORES DE ENTRADA QUE CLASSIFICOU. DO LADO DIREITO O GRÁFICO DEMONSTRA O PESO DAS POSIÇÕES DO SOM, COM OS VALORES DOS PONTOS AZUL CINZA. | 132 |
| FIGURA 4-25- VISUALIZADOR DE REGRAS PARA O ANFIS DO MODELO COM 18 ENTRADAS. REPRESENTAÇÃO GRÁFICA DAS FUNÇÕES DE PERTENÇA GAUSSIANAS DAS ENTRADAS, COM O LIMITE MÁXIMO E MÍNIMO PARA CADA UMA DELAS E NA ÚLTIMA COLUNA A SAÍDA DO SISTEMA (PIA). VARIÁVEIS DE ENTRADA NORMALIZADAS EM [-1 1]. | 135 |
| FIGURA 4-26- ESTRUTURA DA ANFIS COM 7 ENTRADAS E UM CONJUNTO DE 4 REGRAS. | 137 |

| | |
|---|-----|
| FIGURA 4-27- VISUALIZADOR DE REGRAS PARA O ANFIS DO MODELO REDUZIDO COM REPRESENTAÇÃO GRÁFICA DAS GAUSSIANAS DAS ENTRADAS, COM O LIMITE MÁXIMO E MÍNIMO PARA CADA UMA DELAS E NA ÚLTIMA COLUNA A SAÍDA DO SISTEMA (PIA)..... | 138 |
| FIGURA 4-28- GRÁFICO DE COMPARAÇÃO DA INFLUÊNCIA DA DIVISÃO DE DADOS NOS RESULTADOS DE TREINO DOS ANFIS. NO EIXO DOS X ESTÁ REPRESENTADO AS ANFIS COM VÁRIOS NÚMEROS DE REGRAS E NO EIXO DOS Y O RMSE OBTIDO EM CADA DIVISÃO DE DADOS. | 141 |
| FIGURA 4-29- GRÁFICO DE COMPARAÇÃO DA INFLUÊNCIA DA DIVISÃO DE DADOS NOS RESULTADOS DE TESTE DOS ANFIS. NO EIXO DOS X ESTÁ REPRESENTADO AS ANFIS COM VÁRIOS NÚMEROS DE REGRAS E NO EIXO DOS Y O RMSE OBTIDO EM CADA DIVISÃO DE DADOS. | 141 |
| FIGURA 4-30- GRÁFICO DA INFLUÊNCIA DO SISTEMA DE INFERÊNCIA SUGENO DE ORDEM 0 OU 1 NO RMSE DE TREINO DA ANFIS NA MELHOR DIVISÃO DE DADOS CONSEGUIDA, 67.4% (250 PONTOS) PARA TREINO E 32.6 (121 PONTOS) PARA TESTE..... | 142 |
| FIGURA 4-31- GRÁFICO DA INFLUÊNCIA DO SISTEMA DE INFERÊNCIA SUGENO DE ORDEM 0 OU 1 NO RMSE DE TESTE DO ANFIS NA MELHOR DIVISÃO DE DADOS CONSEGUIDA, 67.4% (250 PONTOS) PARA TREINO E 32.6 (121 PONTOS) PARA TESTE..... | 143 |
| FIGURA 4-32- GRÁFICO DE DISPERSÃO DOS PONTOS DE TREINO DE UMA ANFIS SUGENO DE ORDEM 1 COM 46 REGRAS. OS CÍRCULOS ABERTOS AZUIS SÃO OS DADOS DE TREINO E OS ASTERISCOS VERMELHOS OS DADOS DE SAÍDA DA FIS, RMSE DE 0.04..... | 144 |
| FIGURA 4-33- GRÁFICO DE DISPERSÃO DOS PONTOS DE TESTE DE UMA ANFIS SUGENO DE ORDEM 1 COM 46 REGRAS. OS PONTOS AZUIS SÃO OS DADOS DE TESTE E OS ASTERISCOS VERMELHOS OS DADOS DE SAÍDA DA FIS, RMSE DE 4.51. | 144 |
| FIGURA 4-34- DESENHO DA LÓGICA DO SISTEMA DIFUSO DO TIPO SUGENO DE ORDEM 0 DE 11 REGRAS NO MODELO REDUZIDO (7 ENTRADAS), UTILIZANDO 67.4% DOS DADOS (250 PONTOS) PARA TREINO E 32.6 % (121 PONTOS) PARA TESTE. | 145 |
| FIGURA 4-35- MODELO DA ESTRUTURA DO ANFIS DO TIPO SUGENO DE ORDEM 0 COM 11 REGRAS NO MODELO REDUZIDO (7 ENTRADAS), UTILIZANDO 67.4% DOS DADOS (250 PONTOS) PARA TREINO E 32.6 % (121 PONTOS) PARA TESTE. | 146 |
| FIGURA 4-36- GRÁFICO DE DISPERSÃO DOS PONTOS DE TREINO, SUGENO DE ORDEM 0 COM 11 REGRAS NO MODELO REDUZIDO (7 ENTRADAS), UTILIZANDO 67.4% DOS DADOS (250 PONTOS) PARA TREINO E 32.6 % (121 PONTOS) PARA TESTE. OS CÍRCULOS ABERTOS AZUIS SÃO OS DADOS DE TREINO E OS ASTERISCOS VERMELHOS CORRESPONDEM AOS DADOS DE SAÍDA DA FIS, MRSE DE 0.29..... | 147 |
| FIGURA 4-37- GRÁFICO DE DISPERSÃO DOS PONTOS DE TESTE, SUGENO DE ORDEM 0 COM 11 REGRAS NO MODELO REDUZIDO (7 ENTRADAS), UTILIZANDO 67.4% DOS DADOS (250 PONTOS) PARA TREINO E 32.6 % (121 PONTOS) PARA TESTE. OS PONTOS AZUIS SÃO OS DADOS DE TESTE E OS ASTERISCOS VERMELHOS CORRESPONDEM AOS DADOS DE SAÍDA DA FIS, MRSE DE 0.33. | 147 |
| FIGURA 4-38- FUNÇÕES DE PERTENÇA NO ANFIS SUGENO DE ORDEM 0 COM 11 REGRAS NO MODELO REDUZIDO (7 ENTRADAS), UTILIZANDO 67.4% DOS DADOS (250 PONTOS) PARA TREINO E 32.6 % (121 PONTOS) PARA TESTE. | 148 |
| FIGURA 4-39- EDITOR DAS 11 REGRAS DO SISTEMA ANFIS SUGENO DE ORDEM 0, NO MODELO REDUZIDO (7 ENTRADAS), UTILIZANDO 67.4% DOS DADOS (250 PONTOS) PARA TREINO E 32.6 % (121 PONTOS) PARA TESTE. | 148 |
| FIGURA 4-40- VISUALIZADOR DAS REGRAS DO ANFIS SUGENO DE ORDEM 0, NO MODELO REDUZIDO (7 ENTRADAS), UTILIZANDO 67.4% DOS DADOS (250 PONTOS) PARA TREINO E 32.6 % (121 PONTOS) PARA TESTE. | 149 |
| FIGURA 4-41- VISUALIZADOR DE SUPERFÍCIE DAS ENTRADAS COM MAIOR CORRELAÇÃO COM A SAÍDA, NO EIXO DOS X O PESO, NO EIXO DOS Y A ASCA, E NO EIXO DO Z A SAÍDA (PIA). | 150 |

Índice de Equações

| | |
|--|----|
| (2.1) FÓRMULA DE CÁLCULO DA ÁREA DE SUPERFICIE CORPORAL EM CÃES..... | 36 |
| (2.2) FÓRMULA DE DETERMINAÇÃO DA ÁREA DE SUPERFICIE DA CAVIDADE ABDOMINAL..... | 38 |
| (3.1) DEFINIÇÃO MATEMÁTICA DE PRESSÃO..... | 43 |
| (3.2) LEI FUNDAMENTAL DA HIDROSTÁTICA | 44 |
| (3.3) REPRESENTAÇÃO MATEMÁTICA DA PRESSÃO INTRA-ABDOMINAL | 63 |
| (3.4) EQUILÍBRIO DE PRESSÕES ENTRE PIA E MT | 63 |

| | |
|--|-----|
| (3.5) REPRESENTAÇÃO MATEMÁTICA DA PRESSÃO EM P1 (PONTO NO CENTRO DA BEXIGA)..... | 64 |
| (3.6) REPRESENTAÇÃO MATEMÁTICA DA PRESSÃO EM P2 (PONTO NA COLUNA DE FLUIDOS) | 64 |
| (3.7) EQUAÇÃO 3.4 REESCRITA COM A EQUAÇÃO (3.5) E (3.6)..... | 64 |
| (3.8) SIMPLIFICAÇÃO MATEMÁTICA DA EQUAÇÃO (3.7)..... | 64 |
| (3.9) IGUALDADE A VALIDAR POR COMPARAÇÃO DA MEDIÇÃO DIRECTA DA PIA POR SENSOR COM AS PRESSÕES CALCULADAS NOS 2 PONTOS DISTINTOS..... | 65 |
| (3.10) EQUAÇÃO (3.7) REESCRITA COM A DEFINIÇÃO DE PRESSÃO, COCIENTE DAS FORÇAS POR UNIDADE DE ÁREA | 72 |
| (3.11) EQUAÇÃO (3.10) REESCRITA COM A SEGUNDA LEI DE NEWTON | 72 |
| (3.12) SIMPLIFICAÇÃO MATEMÁTICA DA EQUAÇÃO (3.11)..... | 72 |
| (3.13) EQUAÇÃO (3.12) REESCRITA..... | 72 |
| (3.14) EQUAÇÃO (3.10) REESCRITA COM A DENSIDADE E A ACELARAÇÃO GRAVITICA EM EVIDÊNCIA .. | 76 |
| (3.15)TRADUÇÃO DO EQUILIBRIO ENTRE P1 E P2 NA POSIÇÃO DE TRENDELENBURG | 78 |
| (3.16)EQUAÇÃO (3.15) REESCRITA COM A DETERMINAÇÃO DA COMPONENTE H3 POR CÁLCULO TRIGNOMÉTRICO..... | 78 |
| (3.17) TRADUÇÃO DO EQUILIBRIO ENTRE P1 E P2 REESCRITA COM A DEFINIÇÃO DE PRESSÃO NA COMPONENTE DO FLUIDO | 81 |
| (3.18)EQUAÇÃO 3.17 REESCRITA COM A 2.ª LEI DE NEWTON NA FORÇA EXERCIDA PELO FLUIDO | 81 |
| (3.19).SIMPLIFICAÇÃO MATEMÁTICA DA EQUAÇÃO (3.18) | 82 |
| (3.20)EQUAÇÃO 3.20 REESCRITA COM A DEFINIÇÃO DE DENSIDADE DE FORMA A OBTER O VOLUME..... | 82 |
| (4.1) MODELO FUZZY DE SUGENO DE ORDEM ZERO..... | 129 |
| (4.2) MODELO FUZZY DE SUGENO DE ORDEM UM..... | 129 |

Índice de Abreviaturas

A

ASP- Área de superfície peritoneal

ASCA- Área de superfície da cavidade abdominal

ANFIS- Adaptive neuro fuzzy inference system

B

BSA- área de superfície corporal

C

Cm de H₂O- Centímetros de água

D

DICOM- Digital imaging and communications in media

F

F- Força

FEA- Análise finita de elementos

FIS- Sistema de inferência difuso

FCM- método das c-médias difusas

H

HA- Hipertensão abdominal

Ht- Hematócrito

I

ICD- Insuficiência cardíaca direita

IC- Inteligência Computacional

L

LFH- Lei fundamental da hidrostática

LL- Decúbito Laterolateral

M

MD- Dinâmica molecular

MH- Medicina Humana

mmHg- Milímetros de mercúrio

MT- Método transvesical

MI- Manometria Intra-gástrica

N

N- Newton

P

PDMS- Polidimetilsiloxano

P₀- Pressão atmosférica

Pa- Pascal

PAD- Pressão arterial diastólica

PAM- Pressão arterial média

PAS- Pressão arterial sistólica

PAP- Pressão artéria pulmonar

Pb- Pressão exercida pelos ossos

Pc- Pressão exercida pelo conteúdo peritoneal

PIA- Pressão intra-abdominal

PIC- Pressão intracraniana

PIV- Pressão Vesical

Pm- Pressão exercida pelos músculos

PPA- Pressão de perfusão abdominal

Pu- Pressão na bexiga

PVCC- Pressão da veia cava caudal

R

RNA- rede neuronal artificial

RVP- Resistência vascular periférica

RMSE- Erro quadrático médio

S

SCA- Síndrome de compartimentalização abdominal

T

TAC- Tomografia axial computadorizada

V

VCI- Veia cava Inferior

V- Volume

Vu- Volume bexiga

VP- Veia porta

VD- Decúbito Ventrodorsal

Capítulo 1 – Introdução

1.1 - Motivações e objetivo

O objetivo principal do presente projeto de doutoramento centrou-se na criação de um método complementar de medição da pressão intra-abdominal (PIA) não invasivo, baseado nos parâmetros fisiológicos e morfológicos do doente. Para atingir esse objetivo, o estudo foi realizado num modelo animal que permitiu obter algum grau de paralelismo com a espécie humana.

Este trabalho foi efetuado de forma a alcançar inicialmente uma melhor compreensão da PIA, variáveis que a influenciam e avaliar as metodologias disponíveis para medição da mesma.

Uma das principais motivações deste estudo foi o de contribuir para um maior conhecimento sobre a PIA e simultaneamente desenvolver formas mais fáceis e menos invasivas para a sua avaliação.

1.2- Organização da tese

A organização da tese foi estabelecida de forma a atingir o objetivo principal do trabalho, tendo por isso sido dividido em três partes distintas.

A primeira fase do trabalho consistiu em caracterizar fisicamente a área de superfície e volume da cavidade abdominal da espécie modelo em estudo. Na revisão bibliográfica realizada, não foram encontrados valores da área de superfície da cavidade abdominal em nenhuma espécie. Em humanos e ratos está descrita a área de superfície peritoneal, mas não a da cavidade abdominal. Assim, o objetivo desta primeira fase foi, através de modelação tridimensional (3D), determinar a área de superfície da cavidade abdominal (ASCA) em cães e, através de cálculo computacional, gerar uma fórmula para o seu cálculo. A determinação deste valor irá ajudar na determinação e compreensão da PIA, visto que a pressão é o cociente das forças aplicadas por unidade de área.

A segunda fase do trabalho residiu na formulação matemática de um modelo biofísico, baseado nos princípios da hidrostática, de forma a explicar o método transvesical (principal método utilizado para

medir a PIA) e as variáveis que influenciam a PIA. Nesta fase foi criado um modelo experimental, que mimetizou as condições *in vivo*, de forma a consolidar a formulação de princípios.

As duas primeiras fases tiveram um papel crucial na caracterização e investigação da PIA. A identificação, das principais variáveis que a afetam, tornou possível a escolha dos parâmetros a recolher de forma a construir o sistema de inteligência computacional (IC). A seleção das características é fundamental para a eficácia dos sistemas biomédicos, de diagnóstico ou de determinação de parâmetros médicos, baseados em sistemas de IC. A seleção dos parâmetros ou características médicas que não estejam diretamente relacionadas com o problema a solucionar irá influenciar o funcionamento dos sistemas computacionais.

A terceira fase consistiu assim na recolha de dados numa população de cães vivos, onde foram registados os valores da PIA e os parâmetros fisiológicos e morfológicos de cada indivíduo por monitorização multiparamétrica. O conjunto de dados recolhido foi utilizado para o treino do modelo computacional e formulação do sistema inteligente de medição da PIA. Assim, nesta fase, foram realizadas a integração e análise dos dados recolhidos através da criação de um sistema de IC. Neste sistema, os parâmetros fisiológicos e morfológicos irão funcionar como entrada do sistema sendo a saída de sistema representada pela PIA. O objetivo desta fase foi, através da análise da base de dados de parâmetros vitais e fisiológicos construída, construir uma rede neuronal artificial e um sistema de rede adaptativo baseado em sistemas de inferência difusa (ANFIS), passíveis de determinar a PIA de forma não invasiva.

1.3- Publicações

O trabalho realizado no âmbito desta tese de doutoramento resultou nas publicações listadas em baixo.

Revistas internacionais com arbitragem (artigos aceites)

Lopes AM, Nunes A, Niza MMRE, Dourado A. “Intra-abdominal Pressure is Influenced by Body Position?” *American Journal of Clinical Medicine Research*, vol. 4, no. 1 (2016): 11-18. doi: 10.12691/ajcmr-4-1-3.

Lopes AM, Pereira H, Niza MMRE, Onça R, Dourado A. “3D Modelling of Abdominal Surface Area in Cats.” *J Veterinary Sci Techno* 2015, 6:6 <http://dx.doi.org/10.4172/2157-7579.1000269>

Lopes AM, Morgado M, Niza MMRE, França N, Mestrinho L, Félix N, Dourado A. “Biophysical validation of intra-abdominal pressure and transurethral method.” *Vet Sci Med Diagn.* 2016, 5:3 <http://dx.doi.org/10.4172/2325-9590.1000196>

Revistas internacionais com arbitragem (artigos submetidos)

Lopes AM, Castro M, Niza MMRE, Onça R, Dourado A. “3D Modelling of Abdominal Surface Area in Dogs.” Submetido em *BMC Veterinary Research*

Apresentações em poster

Lopes AM, França N, Niza MMRE, Mestrinho L, Morgado M, Félix N, Dourado A. “Classic Physics for validation of intra-abdominal pressure and transurethral method.” Nas III Jornadas de Engenharia Física do Instituto Superior Técnico no dia 2 e 3 de março de 2016

Lopes AM, Niza MMRE, Dourado A. “System for indirect measurement of Intra-abdominal pressure.” Encontro com a Ciência e Tecnologia em Portugal 2017, Fundação para a Ciência e Tecnologia, Lisboa, Portugal – Centro de Congressos de 3 a 5 de julho de 2017.

Apresentações orais em congresso:

Lopes AM, Dourado A, Niza MMRE. “Pressão intra-abdominal novas descobertas.” XIII Hospital Veterinário de Montenegro, Santa Maria da Feira, Portugal – 18 e 19 fevereiro de 2017

Lopes AM, Niza MMRE, Dourado A. “Non-invasive system for measuring intra-abdominal pressure” in *Proceedings of the 3rd World Congress on Electrical Engineering and Computer Systems and Science (EECSS'17), Rome, Italy – June 5 – 6, 2017*, 4th International Conference on Biomedical Engineering and Systems (ICBES'17).

1.4- Introdução Geral

O interesse pela medição da pressão intra-abdominal (PIA) surgiu em pleno século XIX [1,2]. A síndrome de compartimentalização com localização nos membros foi inicialmente descrita por Richard Volkmann no ano de 1811, falando o autor numa condição derivada do aumento da pressão dentro da fáscia muscular, provocando diminuição da perfusão sanguínea e contractura muscular [3]. Em 1863, Etienne-Jules Marey associa pela primeira vez o aumento da PIA com a função respiratória no livro intitulado “*Physiologie médicale de la circulation du sang*” [4]. A primeira referência do mesmo fenómeno, mas na cavidade abdominal, foi realizada em 1984 por Kron, Harman e Nolan, que descreveram pela primeira vez a síndrome de compartimentalização abdominal (SCA), tendo associado a hipertensão abdominal (HA) à diminuição do débito urinário em pacientes humanos em cuidados médico-cirúrgicos [5]. Desde então, o interesse em determinar a PIA tem sido crescente, na medida em que as suas alterações colocam em perigo a função de vários órgãos em pacientes críticos [2,6].

O aumento da PIA é um fenómeno que atualmente se encontra bem documentado em medicina humana, estando diretamente associado a alterações fisiopatológicas a nível hemodinâmico, renal, respiratório, do sistema nervoso central, gastrointestinal e a nível hormonal. Estas alterações, quando verificadas, levam ao aumento da morbidade e mortalidade [7]. A PIA corresponde ao valor de pressão gerada dentro da cavidade abdominal, que é determinada pelo índice de massa corporal, postura, atividade muscular da parede abdominal e respiração [1,8], sendo influenciada diretamente por vários fatores, tais como o volume dos órgãos, os ossos, o conteúdo do espaço abdominal e o grau de distensibilidade da parede abdominal. Estas estruturas, por variarem diretamente de volume causado pela acumulação de líquido ou gás, são passíveis de alterar a PIA de forma aguda, subaguda ou crónica [8].

Embora a PIA venha a ser estudada quase há dois séculos, continua a ser alvo de alguma controvérsia tanto em medicina humana como em medicina veterinária, devido aos diferentes valores obtidos, bem como as metodologias usadas para sua avaliação [7,9–16].

Os valores da PIA considerados normais para a espécie humana situam-se entre 0.2-12.2 mmHg (0.27 a 16.6 cm de H₂O) [17]. No ano de 2013, devido aos diferentes valores utilizadas por autores, a Sociedade Mundial da Síndrome de Compartimentalização Abdominal (WSACS) definiu as normas para esta síndrome, considerando que existe hipertensão abdominal quando os valores se situam acima dos 12 mmHg [1].

No cão, os valores de PIA foram descritos pela primeira vez por Conzemius e colaboradores, encontrando-se estes entre 0-3.75 mmHg (0-5 cm de H₂O) [15]. Neste mesmo estudo, os investigadores descreveram que cadelas submetidas a ovariectomia, nas primeiras 24 horas após cirurgia (medições em 8 momentos temporais), podiam apresentar valores superiores, podendo estes atingir os 11.25 mmHg (15 cm de H₂O) sem que fosse observada sintomatologia de HA. Recentemente, Way e colaboradores (2014) descreveram valores médios de PIA superiores aos já descritos para cães, utilizando a mesma metodologia que Conzemius (5.9 ± 1.0 mmHg), e concluíram que a PIA não era afetada pela cirurgia abdominal, tendo como base uma única medição realizada pós-cirurgicamente [16]. Em humanos está claramente demonstrado que a cirurgia abdominal é um dos fatores que pode levar ao aumento da PIA [18,19]. Fenómeno idêntico foi observado num estudo similar em gatos [15,20]. Em felinos, os estudos são mais consensuais, situando-se os valores de PIA normais entre 2.15- 6.15 mmHg (2.90 a 8.40 cm H₂O) [21,22].

A HA é então uma medida de pressão abdominal elevada, com causa multifatorial em pacientes médico-cirúrgicos em estado crítico. Tal como já foi referido, embora ainda exista alguma controvérsia relativa aos valores que correspondem a HA em humanos, a generalidade dos autores considera que valores superiores a 12 mmHg (16 cm de H₂O), obtidos em 3 medições espaçadas por um intervalo de 4 a 6 horas e com uma pressão de perfusão abdominal (PPA) inferior a 60 mmHg, são diagnóstico de

HA [23]. A PPA condiciona a presença de um fluxo sanguíneo adequado aos vasos esplâncnicos e a sua determinação é realizada pela subtração dos valores da PIA aos da pressão arterial média (PAM) [24–26].

Em medicina veterinária, devido aos escassos estudos realizados, não existem valores pré-estabelecidos que caracterizem a HA. Em humanos, a HA subdivide-se em vários graus, conforme mostra a Tabela 1-1 [1,27].

Tabela 1-1- Classificação da HA em graus no Homem, de acordo com a Sociedade Mundial de Síndrome de Compartimentalização Abdominal [1,27].

| Grau | PIA (mmHg) | PIA (cm de H ₂ O) | Procedimentos a efetuar |
|------|------------|------------------------------|--|
| I | 12 a 15 | 16 a 21 | Assegurar volume vascular adequado ao paciente |
| II | 16 a 20 | 22 a 27 | Fluidoterapia com volume de ressuscitação pode ser necessário. Identificar causa e descompressão deve ser considerada |
| III | 21 a 25 | 28 a 34 | Fluidoterapia com volume de ressuscitação pode ser necessário. Identificar causa e descompressão deve ser considerada |
| IV | > 25 | > 34 | Realizar descompressão por paracentese ou exploração cirúrgica. |

Uma PIA elevada e prolongada ao longo do tempo leva a alterações graduais em vários sistemas orgânicos conduzindo à SCA. Esta poderá ser: primária, quando associado a um traumatismo, doença abdominal-pélvica ou após cirurgia abdominal; ou secundária, caso se desenvolva na sequência de uma causa extra-abdominal. Pode ainda ser recorrente, no tratamento médico ou cirúrgico da SCA primário ou secundário. A maioria dos autores considera que valores da PIA acima dos 20 cm de H₂O conduzem ao aparecimento de sintomas da SCA [1,8].

As principais causas que podem levar ao aumento do volume intraperitoneal, e consequentemente da PIA, são as seguintes: hemorragia intra-abdominal; aneurisma da aorta abdominal; necrose ou ruptura intestinais; ascite; organomegália provocado por traumatismo pélvico/abdominal ou outras etiologias; pancreatite; trombose venosa mesentérica; peritonite; tumores abdominais; cirurgia abdominal; aplicação de MAST (military anti-shock trousers); e por último obesidade [17].

1.4.1- Fisiopatologia da pressão intra-abdominal

A HA e a SCA são alterações raras. No entanto, apesar da baixa incidência (0.9 a 12 %) apresenta uma mortalidade bastante elevada com valores entre 50 a 80%, dependendo da população estudada [1,28,29]. O aumento da pressão persistente dá origem a uma SCA, cujas manifestações clínicas se repercutem em diferentes sistemas orgânicos.

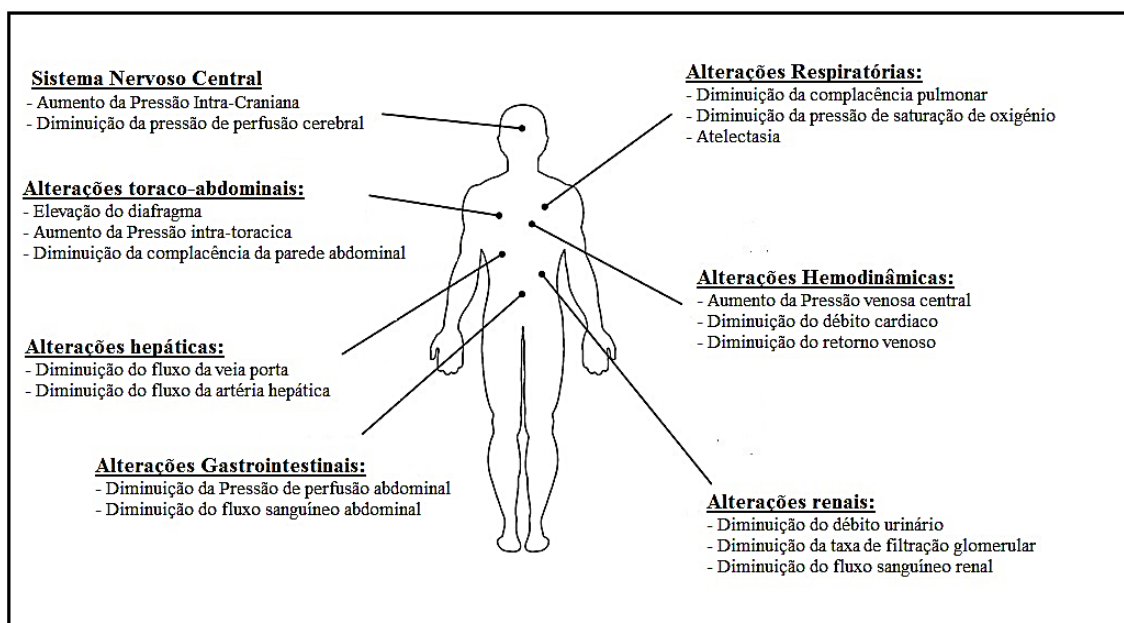


Figura 1-1- Principais repercussões induzidas pelo aumento da PIA traduzido e adaptado de Cheatham, 2009 [2].

Alterações Hemodinâmicas

Os parâmetros hemodinâmicos, como a frequência cardíaca (FC), a pressão arterial no átrio direito, a pressão na artéria pulmonar, a pressão arterial média (PAM), a resistência vascular periférica e o hematócrito, aumentam significativamente quando os valores de PIA se encontram acima de 40 mmHg e voltando a níveis fisiológicos quando se procede à descompressão abdominal [30].

Quando existe HA surge uma diminuição do fluxo sanguíneo absoluto em todos os órgãos intra e extra-abdominais, exceto na glândula adrenal [23]. Pensa-se que estas alterações sejam devidas à diminuição

do retorno venoso, o qual é secundário à compressão da veia cava inferior (VCI) e à compressão da veia porta (VP) [31]. Assim, a HA leva a uma diminuição da pré-carga cardíaca (compressão VCI) e a um aumento da pós-carga por compressão dos órgãos e vasos abdominais, com conseqüente redução do débito cardíaco [8]. Foi demonstrado em humanos que a descompressão abdominal melhora a oxigenação, o débito cardíaco e a pressão arterial em cerca de quinze minutos [23]. Os principais efeitos provocados pelo aumento da PIA encontram-se na Tabela 1-2.

Tabela 1-2 - Efeitos do aumento da PIA. Adaptado de Andrade JI, 1989 [32].

| Parâmetro | Aumentado | Diminuído | Sem alteração |
|----------------------------------|-----------|-----------|---------------|
| Pressão arterial média | - | - | + |
| Frequência cardíaca | + | - | - |
| Pressão capilar pulmonar | + | - | - |
| Pico de pressão nas vias aéreas | + | - | - |
| Pressão venosa central | + | - | - |
| Pressão pleural | + | - | - |
| Pressão veia cava inferior | + | - | - |
| Pressão veia renal | + | - | - |
| Resistência vascular sistêmica | + | - | - |
| Débito cardíaco | - | + | - |
| Retorno venoso | - | + | - |
| Fluxo sanguíneo visceral | - | + | - |
| Fluxo sanguíneo renal | - | + | - |
| Taxa de filtração glomerular | - | + | - |
| Pressão intracraniana | + | - | - |
| Pressão de perfusão cerebral | - | + | - |
| Complacência da parede abdominal | - | + | - |

Alterações Renais

Uma das alterações que surge associada ao aumento da PIA é a insuficiência renal aguda, que é rapidamente reversível com a descompressão abdominal. Com efeito, a filtração glomerular e o débito urinário encontram-se reduzidos em animais com valores de PIA entre 10 a 20 cm de H₂O, surgindo oligúria ou anúria quando os valores de PIA \geq 25 cm de H₂O [33]. Alguns estudos experimentais sugerem que estas alterações ocorrem devido ao efeito sinérgico da diminuição do débito cardíaco, com a compressão dos vasos, do parênquima renal e dos ureteres [23,33]. Assim, o aumento da PIA

leva a uma azotemia de origem multifatorial: pré-renal por diminuição do débito cardíaco e compressão vascular e pós-renal por compressão a nível dos ureteres [26,33,34]. Nesta situação existe ainda a estimulação do sistema renina-angiotensina-aldosterona, com conseqüente retenção de água e sódio. Devido à retenção de sódio, os níveis da hormona antidiurética aumentam ocorrendo a expansão isotónica do fluido extracelular [23,26,33].

Alterações Respiratórias

A elasticidade e a expansão pulmonar estão diminuídas na presença de uma PIA aumentada. A HA provoca um deslocamento cranial do diafragma diminuindo a sua contração, o que leva ao desenvolvimento de uma pressão intratorácica subatmosférica insuficiente [35]. Além destas alterações, existe ainda um aumento da pressão intratorácica, da diminuição da distensibilidade pulmonar e uma redução da perfusão pulmonar por diminuição do espaço da cavidade torácica [26,36,37]. Estas alterações, no seu conjunto, produzem hipoxia, hipercapnia e acidose. A descompressão habitualmente normaliza estes parâmetros [35]. Cleve e colaboradores, 2014, correlacionaram clinicamente a PIA e os volumes pulmonares após cirurgia abdominal superior e inferior. Estes concluíram que a cirurgia abdominal apresenta um risco acrescido de desenvolvimento de complicações respiratórias no período pós-cirúrgico, levando a hipoventilação. Este facto prende-se essencialmente com a redução do volume expiratório e da disfunção dos músculos respiratórios, verificada predominantemente em doentes submetidos a cirurgia abdominal cranial [19].

Alterações do Sistema Nervoso Central

A pressão intracraniana encontra-se aumentada em pacientes com HA, devido a vários fatores [38]. Por um lado, o aumento da pressão intracraniana está diretamente associado com o aumento da pressão

intratorácica, o que provoca uma diminuição do retorno venoso a nível da veia jugular. Por outro lado, existe também uma diminuição da perfusão cerebral, o que agrava a sintomatologia. Os sintomas incluem alterações dos reflexos cranianos, vômito, convulsões, entre outros [39].

Alterações Hepáticas e Gastrointestinais

A nível hepático, intestinal e gástrico existe uma diminuição do volume sanguíneo, com ocorrência de acidose tecidual [23]. As repercussões gastrointestinais podem ser graves na medida que valores de PIA de 10 mmHg provocam uma diminuição do fluxo venoso portal e da artéria hepática. Estas alterações hemodinâmicas induzem alterações na síntese hepática de proteínas e de imunoglobulinas [23,40].

Quando a PIA atinge os 20 mmHg, o fluxo sanguíneo mesentérico e a microcirculação intestinal ficam comprometidos, levando a isquemia da mucosa, com conseqüente acidose local, libertação de radicais livres de oxigénio, aumento da permeabilidade vascular e translocação bacteriana [41–43], podendo conduzir a choque séptico [8]. A mucosa gástrica é um dos primeiros tecidos a ser afetada pela hipoperfusão e a isquemia gástrica constitui a primeira repercussão clínica objetiva da HA. A diminuição da perfusão da mucosa e o aumento do metabolismo regional vão provocar um desequilíbrio entre a quantidade de CO₂ eliminada e a quantidade produzida. Esta alteração fisiopatológica tem relevância clínica, uma vez que a determinação de pH tecidual da mucosa gástrica permite detetar a presença de isquemia do tubo digestivo de forma precoce. Com efeito, valores de pH ácido encontram-se associados a um prognóstico mais reservado e conseqüentemente a uma maior mortalidade [8]. Os valores crescentes de PIA parecem estar correlacionados com um aumento de translocação bacteriana. Com efeito, estudos em ratos demonstraram que a partir de 14 mmHg observa-se a presença de translocação e de sobrecrescimento bacteriano no lúmen intestinal. Estes tornam-se clinicamente significativos acima de 20 mmHg [41]. O aumento da permeabilidade intestinal e a

translocação bacteriana são considerados a base patofisiológica para o desenvolvimento da endotoxemia enterogênica secundária à HA e consequente disfunção multiorgânica verificada frequentemente em doentes com SCA [44].

Alterações Sistema Endócrino

Várias alterações hormonais foram associadas ao aumento da PIA. Uma dessas alterações é o aumento da hormona antidiurética. Com efeito foi observado o seu aumento em cães sujeitos a pressões abdominais de 108 cm de H₂O, por compressão externa [41]. Em suínos foi também demonstrado um aumento da renina plasmática quando submetidos a pressões de 34 cm de H₂O. Estas alterações eram completamente revertidas por descompressão [45]. Já Drellich, 2000 [17], demonstrou a existência de um aumento das concentrações de epinefrina e norepinefrina em suínos quando sujeitos a uma PIA de 27.2 cm de H₂O [17,23].

1.4.2- Terapêutica na hipertensão abdominal

O tratamento dos casos de HA/SCA depende em muito do estado clínico do paciente. Só após avaliação do paciente e correlação com a PIA são tomadas decisões terapêuticas. Segundo Schachtrupp e colaboradores, 2006 [27], está indicado controlar a PIA nas seguintes situações [1,27]:

- 1- No pós-operatório de cirurgia abdominal
- 2- Traumatismos abdominais e/ou pélvicos graves
- 3- Infecções abdominais, peritonite e pancreatite
- 4- Quadros clínicos com acumulação de líquido intra-abdominal
- 5- Íleo paralítico, ou outras obstruções intestinais
- 6- Distensão abdominal e sintomatologia da SCA

7- Ventilação mecânica

8- Pneumoperitoneu e hemorragias retroperitoneais.

O princípio básico do tratamento da HA e a SCA é a descompressão da cavidade abdominal, de modo a diminuir a PIA. Como em qualquer outra doença deve ser investigada a causa etiológica para que a terapêutica possa ter sucesso. O grau de HA vai condicionar a estratégia terapêutica. Sempre que a PIA for superior a 21 cm de H₂O deve ser administrada fluidoterapia e considerada a descompressão. Para valores mais baixos está unicamente indicado assegurar volume vascular apropriado ao paciente [1,27].

Sempre que exista sintomatologia da SCA devem ser realizadas manobras de descompressão. Estas podem incluir a paracentese, laparotomia exploratória ou exérese de massas. Em humanos está descrito que a descompressão cirúrgica do abdómen é o tratamento que apresenta melhores probabilidades de sucesso [8]. Durante o procedimento cirúrgico de descompressão pode ocorrer hipotensão arterial de carácter transitório, quando se procede à abertura da cavidade abdominal. Para prevenir esta ocorrência, e antes de se proceder à celiotomia, deve ser restaurado o volume circulante, maximizar a oxigenação, corrigir as alterações de coagulação e prevenir a hipotermia. A assistolia após descompressão pode ocorrer, tendo já sido descrita em humanos [46].

No tratamento da SCA em seres humanos está descrito que o abdómen deverá permanecer aberto até a PIA regularizar, existindo para o efeito diferentes técnicas de proteção da parede e dos órgãos abdominais. Estas técnicas compreendem a utilização de materiais protésicos (Figura 1-2) e o encerramento da cavidade abdominal com técnicas de vácuo [8,47].



Figura 1-2- Síndrome de compartimentalização no homem. Descompressão abdominal num paciente com SCA recorrendo a materiais protésicos em Perry & Philips, 2003 [47].

1.4.3- Medição da pressão

A pressão é uma propriedade física que corresponde à força exercida sobre a unidade de área e que pode ser obtida segundo vários métodos. Na medição de pressões relacionadas com a mecânica de fluidos, a grande parte dos instrumentos infere sobre as mesmas, por calibração por um dispositivo primário. Existe uma grande variedade destes instrumentos, quer para fluidos em repouso quer em movimento, podendo estes ser agrupados em quatro categorias [48].

Independentemente da metodologia e do dispositivo, estes são instrumentos que respondem a um estímulo físico/químico de forma específica e mensurável, com determinação dos valores de forma analógica. Todas as tecnologias usadas na transdução de pressão têm o propósito de transformarem a pressão aplicada num sinal elétrico proporcional à mesma. As pressões obtidas podem ser relativas, medições efetuadas em relação à pressão atmosférica, podendo ter valores positivos ou negativos; ou pressões absolutas, que correspondem à soma da pressão atmosférica e da pressão relativa. A maior parte dos instrumentos de medição de pressão, são relativos à pressão absoluta e a generalidade é

calibrada com um instrumento primário, como um pistão de peso-morto de teste [48]. Os sensores para obtenção de pressões, podem ser agrupados da seguinte forma segundo White, 2009 [48]:

- Baseados na força gravítica: barómetros, manómetros e pistão de peso-morto.
- Deformação elástica: tubo de Bourdon (metal e quartzo), diafragma, fole, tensométricos e deslocamento do feixe ótico.
- Comportamento do gás: compressão gasosa (manómetro de Macleod), condutância térmica (manómetro de Pirani), impacto molecular (manómetro de Knudsen), ionização, condutividade térmica e pistão de ar.
- Saída elétrica: resistência (manómetro de fio Bridgman), *strain gage* difusa, capacitivo, piezoelétrico, indutância magnética, relutância magnética, transformador diferencial variável linear (LVDT) e frequência de ressonância.

1.4.3.1- Sensores baseados na força gravítica

Este tipo de sensores engloba os manómetros baseados no comportamento gasoso, que são especialmente utilizados para determinadas experiências científicas. Dentro deste grupo encontra-se também o pistão de peso morto, que geralmente é utilizado para aferir a calibração de instrumentos de pressão, sendo o instrumento usado pelo *United States National Institute*. A aplicação prática mais simples dos instrumentos deste grupo baseia-se na fórmula hidrostática e é denominada de barómetro, utilizado para medir a pressão atmosférica. Um tubo é cheio com mercúrio e invertido, enquanto submerso num reservatório, o que provoca um vácuo próximo da extremidade superior fechada, devido ao mercúrio ter uma pressão de vapor muito pequena à temperatura ambiente (0.16 Pa a 20 ° C). Uma vez que a pressão atmosférica força a coluna de mercúrio a subir uma distância h dentro do tubo, a superfície superior de mercúrio corresponde ao zero de pressão, podendo este mecanismo ser assim utilizado para a determinação da pressão [48].

A aplicação dos conceitos hidrostáticos pode também ser utilizada para obter valores de pressão, utilizando uma coluna estática de um ou mais fluidos e realizando a diferença de pressão entre dois pontos. Estes dispositivos são chamados de manómetros baseiam-se nos princípios da hidrostática e apresentam baixo custo. As medições através do manómetro não devem perturbar o fluido e, no caso de haver múltiplos fluidos, deverá ter-se em atenção as densidades dos mesmos. Uma pressão de fluxo oscilante pode também causar um maior erro devido à resposta dinâmica do tubo. São exemplos deste tipo de manómetros o tubo em U, a coluna reta vertical e o manómetro do tipo coluna inclinada [48]. Este tipo de manómetro é constituído por um tubo de vidro com área seccional uniforme, preenchido por um líquido onde parte se encontra dividido metricamente. O valor de pressão medida é obtido pela leitura da altura de coluna do líquido deslocado, em função da intensidade da pressão aplicada. Os líquidos mais utilizados são: água (normalmente com um corante) e mercúrio [48].

1.4.3.2- Sensores de deformação elástica

Neste tipo de sensores de deformação elástica está inserido o tubo de Bourdon. Este é utilizado frequentemente, sendo um dos sensores mais usados devido a apresentar um baixo custo e de apresentar elevada precisão. A sua representação esquemática é apresentada na figura 1-3 [48].




Figura 1-3- Tubo de Bourdon traduzido e adaptado de White, 2009 [48].

Este tipo de dispositivo é constituído por um tubo curvo de secção achatada que, quando sujeito a uma pressão interna, irá deflectir para o exterior. A deflexão provocada pode ser medida por uma ligação a um ponteiro calibrado ou ligado diretamente a uma saída elétrica. Similarmente, a membrana ou diafragma vai deflectir com baixas pressões, podendo ser medida diretamente.

Uma variação interessante é o tubo de Bourdon *forced-balanced-fused-quartz*, onde a deflexão é sentida opticamente e volta ao zero de referência, devido a um mecanismo magnético, sendo a saída proporcional à pressão do fluido. Este tipo de mecanismo é reportado como um dos sensores mais precisos, apresentando um grau de incerteza na ordem de $\pm 0.003 \%$ [48].

1.4.3.3 - Sensores de saída elétrica

Esta categoria de sensores é bastante importante na engenharia porque os dados podem ser armazenados, manipulados e analisados em computadores. Como já foi referido anteriormente, este tipo de sensores engloba sensores: de resistência (manómetro de fio Bridgman); de *strain gage* difusos; capacitivos, piezoelétricos, de indutância magnética, de relutância magnética, de transformador diferencial variável linear (LVDT) e de frequência de ressonância [48].

Os sensores do tipo capacitivo são dispositivos com maior fiabilidade e que já foram utilizados nas aplicações mais diversas. Baseados em transdutores, sendo a pressão aplicada em diafragmas, fazem com que exista uma variação de capacitância entre diafragmas. A pressão diferencial deflete o diafragma de silicone, alterando a capacitância do líquido na cavidade. O transdutor capacitivo de pressão mede a deformação das placas do condensador [48]. Este tipo de sensores capacitivos apresenta uma elevada estabilidade à temperatura, repetibilidade e um baixíssimo consumo de energia [49]. Contudo, este tipo de sensores necessita do desenvolvimento de cavidades seladas, incorporando um par de condutores isolados, o que dificulta a sua utilização em alguns aspetos [50].

Os sensores *strain gage* são difusos ou conectados a um chip que responde à pressão aplicada [48]. Este tipo de sensores de medição de pressão foi inventado por Simmons e Ruge em 1938. O tipo mais comum de *strain gage* consiste num suporte flexível isolado, suportado por um padrão de folha metálica. O medidor é ligado ao objeto por um adesivo adequado, como o cianoacrilato. Quando o objeto é deformado, a folha é também deformada, provocando uma alteração na sua resistência elétrica. Esta alteração é normalmente medida usando uma ponte de Wheatstone, que quando relacionada com a tensão é conhecida como o fator *gauge* [51].

O sensor *strain gage* baseia-se na propriedade física da condutância elétrica e sua dependência geométrica do condutor (Figura 1-4). Quando o condutor elétrico é esticado até ao limite da sua elasticidade, para que não se quebre ou que se deforme permanentemente, este irá tornar-se mais estreito e longo, modificações que aumentam a sua resistência elétrica de ponta-a-ponta. Por outro lado, quando o inverso acontece, isto é o condutor fica comprimido, a sua resistência elétrica diminui. A partir da resistência elétrica medida do calibre de tensão, a quantidade de tensão aplicada pode ser inferida e correlacionada com a pressão [51].

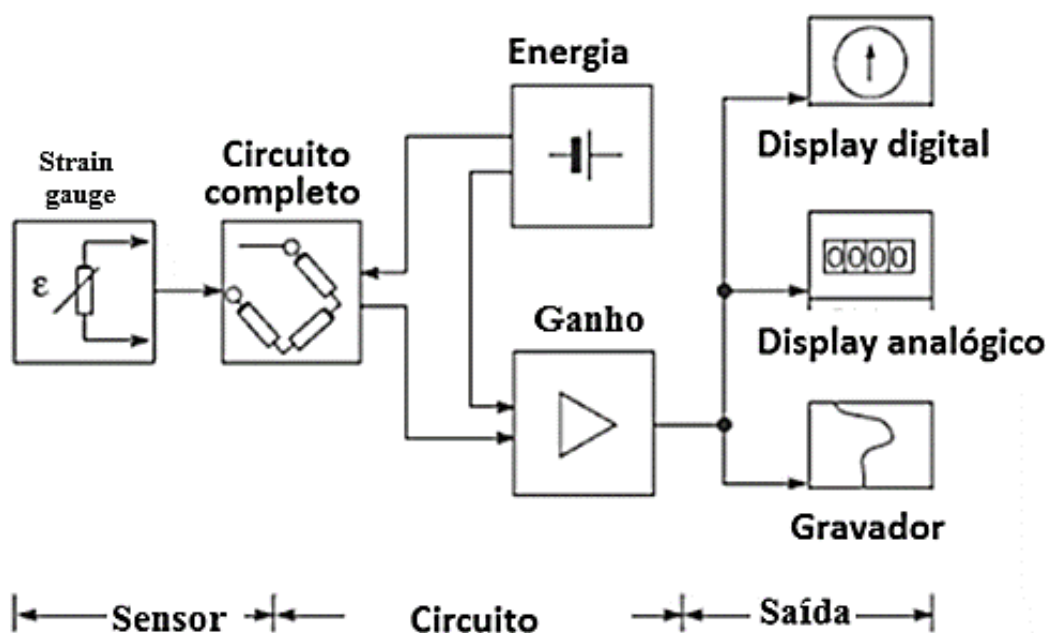


Figura 1-4- Desenho típico de circuito de Wheatstone com sensor *strain gage* traduzido e adaptado de Chevalier, Chamberlin, 2011 [51].

A tecnologia *strain gage* é utilizada nos mais diversos dispositivos médicos, desde aplicações críticas a não críticas, com presença em mecanismos de cirurgia robótica de alta precisão, sistemas de mamografia e até nos sistemas mais simples de bombas infusoras [51]. Um dos exemplos de utilização médica dos sensores *strain gage* piezoelétricos de alta precisão é o microsensor da Codman (Codman Microsensor Kit, Johnson & Johnson) [52]. Este tipo de sensor é utilizado para a medição invasiva da pressão intracraniana, diretamente no espaço subdural, parênquima ou intraventricular. Consiste num sensor *strain gage* miniatura colocado numa caixa de titânio, na ponta de um tubo de *nylon* flexível de 100 cm e unicamente com 1 mm de diâmetro. A informação é transmitida eletronicamente através de fibra ótica para o monitor de pressão intracraniana (PIC). As monitorizações de PIC, obtidas por este método, são estáveis ao longo do tempo pelo que é considerado um método padrão para as suas medições [53]. Este sensor também já foi utilizado para obter pressões noutras localizações anatómicas, como a PIA [54].

Dentro deste grupo de sensores, estão também incluídos os sensores piezoelétricos, constituídos por um cristal (como o quartzo, a turmalina ou titanato), que acumulam cargas elétricas em certas áreas da estrutura cristalina quando sofrem uma deformação física, por ação de uma pressão. Este tipo de sensores integrados baseados no efeito da piezoresistência tem sido aplicado em várias áreas, como a engenharia automóvel, aeroespacial e biomédica [50]. Este tipo de sensores é muito utilizado porque não precisa de cavidades seladas no seu interior para funcionar. Comparativamente aos métodos que utilizam os diafragmas elásticos de silicone, são pequenos e de construção robusta e a resposta é linear com a variação de pressão. Contudo, um dos maiores problemas deste tipo de sensores está relacionado com o facto de poderem ser influenciados pela temperatura, sendo o coeficiente de piezoresistência dependente da mesma [50].

Os sensores de frequência de ressonância são sensores de silício microcontrolados, construídos de forma a deformarem-se quando sujeitos a pressão, sendo a deformação proporcional à sua frequência

de vibração natural. A frequência de vibração é então captada por um oxilador, que converte o sinal em unidades de pressão apropriadas [48].

O sensor consiste de uma cápsula de silício colocada estrategicamente num diafragma, utilizando o diferencial de pressão para vibrar em maior ou menor intensidade, sendo a frequência proporcional à pressão aplicada. Este tipo de sensores baseados na ressonância tem sido largamente utilizado na indústria devido a possuir um tamanho compacto, boa estabilidade, baixo custo e a capacidade para trabalhar passivamente e por via wireless, tal como a habilidade para a realização de medições em ambientes extremos. A grande generalidade destes sensores tem um intervalo de medição alargado e uma sensibilidade relativa baixa, tornando a sua utilização comum para medir altas pressões, como acontece em máquinas de trabalho [55].

Recentemente tem sido atribuída muita atenção a sensores térmicos e de pressão, que prestam um importante papel em várias medições e que são parte integrante de microssistemas. No passado, vários tipos de sensores foram desenvolvidos, tendo em atenção a sua aplicação, as suas características, o ambiente exterior (físico e elétrico), a forma como a energia é conferida, entre outros. Contudo, a função exercida por este tipo de sensores era muitas vezes incompatível e limitante em determinadas aplicações de engenharia. A integração entre um ou mais transdutores monolíticos, em conjunto com um circuito de interface num chip único, permitiu a realização de sensores inteligentes integrados, tal como requerimentos importantes, como o tamanho diminuto, baixo custo, baixo consumo energético e estabilidade a longo termo [56]. Desde então têm sido desenvolvidos sistemas micro eletromecânicos (MEMS) que solucionam alguns problemas e aumentam o campo da sua aplicabilidade. Estes tipos de sistemas são construídos geralmente utilizando silício policristalino de alta qualidade (poly-Si). Contudo, para otimizar o material estrutural destes sistemas atribuindo-lhe as propriedades mecânicas desejadas, tem também sido utilizado o silício-germânio (poly-SiGe), o que possibilita o desenvolvimento de sensores capacitivos e piezoelétricos [57], como por exemplo a série de sensores asdx da Honeywell. Os sensores desta série consistem em quatro piezoresistências num diafragma de

silício ligados quimicamente. Qualquer alteração de pressão provoca um diferencial na tensão do diafragma, deformando-o e levando a que as piezoresistências também se deformem. Os valores apresentados pelos piezoresistências são proporcionais à pressão aplicada que, por sua vez, provoca uma saída elétrica [58].

1.4.3.4- Sensores e Biopolímeros

O tipo de material com que este tipo de sensores tem sido construído tem sofrido grandes alterações ao longo dos anos, surgindo nos dias de hoje novos compostos e biomateriais com novas propriedades e características.

De forma a desenvolver novos tipos de materiais e compostos, com novas propriedades, é essencial que essas propriedades sejam previstas antes da preparação, experimentação e caracterização. Apesar dos tremendos avanços feitos na modelação estrutural, térmica, mecânica e na capacidade de transporte dos materiais ao nível macroscópico (análise da estrutura finita dos elementos) continua a existir uma incerteza tremenda de como prever muitos dos problemas críticos relacionados com a performance [59].

O problema fundamental é que estas propriedades dependem das interações a nível atómico e químico (construção e destruição de pontes químicas). Contudo, estas interações acontecem a nível eletrónico e atómico e à escala dos nanómetros ou pico metros. O designer de compostos necessita de respostas da modelação macroscópica (paradigma dos elementos finitos) dos componentes, tendo escalas nos centímetros e nos milissegundos ou mais. As dificuldades são demonstradas na figura 1-5, onde observamos o vasto comprimento e escala temporal que separa a mecânica quântica (MQ) do mundo macroscópico do desenho da engenharia [59].

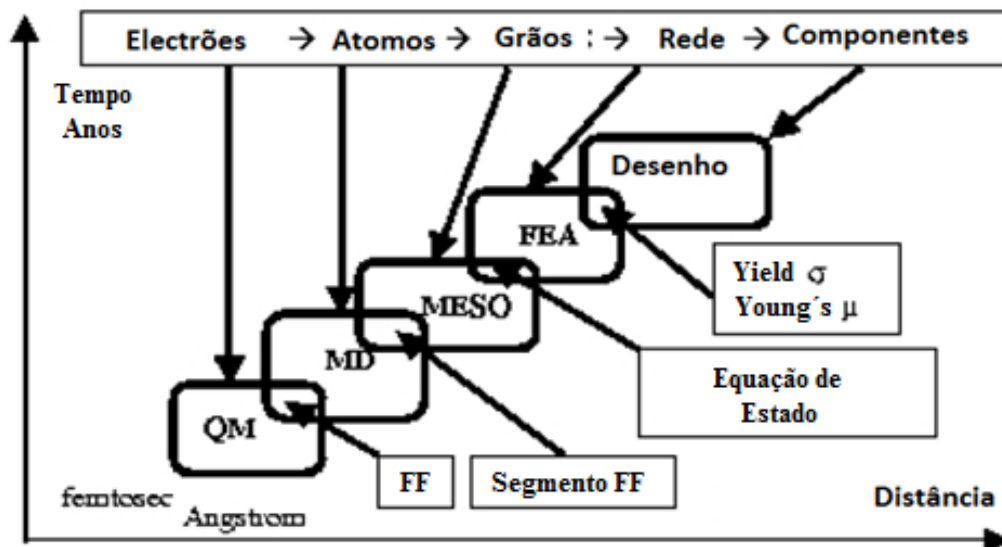


Figura 1-5- Hierarquia de modelação multiescala traduzido e adaptado de Goddard et al, 2001 [59].

A estratégia proposta na imagem, para atingir um objetivo, consiste numa aproximação por etapas de técnicas de modelação. Os parâmetros descritos são baseados nos cálculos de mecânica quântica, levando à descrição dos campos das forças (FF) que incluem cargas, constantes das forças, polarização, forças de Vander Waals. Com os FF estabelecidos, a dinâmica é descrita pelas equações de Newton, dinâmica molecular (MD), em vez de ser utilizada a equação de Schrodinger. Esta dinâmica molecular permite prever a estrutura e propriedades para o sistema, permitindo simulações de propriedades. Após a dinâmica molecular têm que ser desenvolvidos métodos de tratamento na mesoescala, entre o comprimento atômico e escala temporal da DM e o comprimento macroscópico e escala temporal da análise finita de elementos (FEA). Unicamente através do estabelecimento das conexões entre a microescala até à mesoescala é possível construir os primeiros princípios de métodos para descrever as propriedades de novos materiais e compostos [59].

Muitos dos novos compostos e biomateriais desenvolvidos na área de sensores de pressão estão relacionados com a criação de pele artificial. A pele artificial é um dos componentes mais importantes para as próximas gerações de robots e dispositivos médicos, de forma a detetar e quantificar o contacto dos aparelhos com o ambiente [60]. Os sensores utilizados para este fim têm que possuir características muito particulares, como escalabilidade, flexibilidade e elasticidade. Muitos trabalhos têm sido

descritos nesta área. Bao e colaboradores [61] descreveram dois tipos de peles eletrônicas altamente sensíveis e flexíveis formadas por sensores capacitivos microestruturados. Contudo, este tipo de pele apresentava limitações devido à falta de elasticidade, isto por causa da utilização de compostos à base de Ouro (Au) ou índio-óxido de estanho nos elétrodos [62]. Noutro estudo desenvolveram um tipo de pele com sensor de pressão baseado em nanotubos elásticos de carbono transparentes utilizando polidimetilsiloxano (PDMS) como substrato. A pressão aplicada é medida através das alterações de capacitância entre a rede de condensadores formados pelas linhas perpendiculares de nanotubos de carbono [63]. Num estudo similar utilizaram nanofios de prata (AgNWs) numa matriz de poliuretano para fabricar o sensor capacitivo transparente capaz de detetar pressões de 1 a 100 KPa [64]. Ramuz e colaboradores, 2012 [61], desenharam um sensor de pressão ótico com propriedades elásticas de substrato de PDMS integrado com um polímero orgânico de díodos emissores de luz (OLEDs) e um polímero usado na deteção de fotões. Este tipo de sensor apresentou uma sensibilidade elevada contudo poderia levar a determinações incorretas de pressão se captasse simultaneamente a luz de dois ângulos perpendiculares [61].

Someya e colaboradores, 2005 [65], demonstraram uma aplicação em que um transistor de rede ativa orgânica elástica ligado a uma matriz de sensores de pressão foi construído utilizando a integração dos transístores de efeito de campo orgânicos (FET) com sensores de pressão de borracha [65].

Tee e colaboradores, 2007 [66], desenvolveram uma pele eletrônica, com um composto de autorregeneração com propriedades sensíveis à pressão e à flexão. Embora o compósito, constituído por uma rede supramolecular de um polímero de pontes de hidrogénio e partículas de níquel, possa ser utilizado como material de deteção para o sensor de flexão e os elétrodos de autorregeneração para o sensor táctil, pode deixar de servir como elétrodos de sensores tácteis flexíveis, porque eles exigem a resistência dos elétrodos e as interligações estáveis durante a deformação sensor [66].

Considerando todas as vantagens dos sensores resistivos, como a diminuição de material eletrónico, facilidade de construção e integração a menor suscetibilidade ao ruído, este tipo de sensores tornam-

no uma das grandes escolhas para a utilização em polímeros de forma a tentar construir pele artificial. A utilização dos princípios piezoresistivos é muito usada na tecnologia de sensores de hoje em dia, nomeadamente neste campo. O desafio está em realizar a integração destes sensores nos elementos com interconexões elásticas. Os elastómeros condutivos sensíveis à pressão são os materiais mais usados no desenho de sensores tácteis resistivos. Estes elastómeros são misturas de borracha com fibras condutivas como o carbono preto, nanotubos, nanoplacas e iões metálicos [60]. A Figura 1-6 apresenta um esquema de sensor de pressão, onde as tiras condutoras de AgNWs/PDMS são utilizadas como interconexões elásticas e eléctrodos sensitivos. O elastómero condutivo é baseado em PDMS com iões metálicos, que é usado com o elemento piezoresistivo. A camada de deteção é colocada entre duas camadas finas de PDMS, cada uma das quais contém linhas paralelas de AgNWs / PDMS, tiras condutoras em contacto com os elementos piezoresistivos.




Figura 1-6- Sensor com camada intermédia de polidimetilsiloxano. Esquema ilustrativo de sensor de pressão, com camada intermédia de polidimetilsiloxano traduzido e adaptado de Zhou e Wang, 2013 [60].

Foi construído um sensor de pressão do mesmo género, só que utilizando material de ácido poliamínico que exhibe propriedades piezoelétricas. Este tipo de polímero apresenta matrizes de memória

ferroelétricas que utilizam os poliaminoácidos ferroelétricos como a camada ferroelétrica do transistor [67].

No campo da engenharia biomédica têm sido desenvolvidos sensores de pressão com efeitos de diagnóstico. Tan e colaboradores, 2013 [68], desenvolveram um cateter para avaliar pressões, construindo um modelo de análise que descreve a deformação de um tubo cheio de fluido, sendo parte dele exposto a uma pressão e a parte restante não exposta. O sensor, ao ser submetido a uma pressão, vai provocar uma alteração no volume interno do fluido eletrolítico, que altera a sua resistência elétrica. Esta alteração na resistência elétrica do fluido eletrolítico permite determinar a pressão e é a base do princípio deste sensor. Este tipo de sensor utiliza um eletrólito aquoso biocompatível para detectar as alterações na resistência do fluido quando submetido a diferentes pressões [68].

1.4.4- Monitorização

A monitorização multiparamétrica em pacientes cirúrgicos e em unidades de cuidados intensivos é um procedimento usual em todas as unidades hospitalares [69]. Segundo a Sociedade Americana de Anestesiologistas, os parâmetros mínimos de avaliação podem variar tal como a metodologia, mas geralmente consiste: na avaliação da oxigenação (pulsoximetria); na avaliação da ventilação (expiração de dióxido de carbono); na avaliação da circulação (frequência cardíaca, pulso e medição da pressão arterial); e na avaliação da temperatura corporal [70]. Geralmente, nas unidades de cuidados intensivos, o número de parâmetros avaliados é superior devido ao estado do paciente [69,71,72]. A PIA e a pressão de perfusão abdominal são dois parâmetros que são monitorizados sempre que exista alguma condição suscetível de os alterar, devendo ser monitorizada no paciente crítico [1,27].

Ao longo dos tempos são vários os métodos que têm vindo a ser utilizados para determinar a PIA, havendo métodos diretos e indiretos para a realizar [9]. Os métodos diretos são usados como referência para os indiretos [73,74]. Contudo, devido às desvantagens da monitorização direta da PIA e devido

ao procedimento invasivo em si, as técnicas indiretas continuam a ser as mais utilizadas. De todas as técnicas indiretas, a mais utilizada mundialmente é o MT, sendo o método de eleição para avaliação da hipertensão abdominal [9,75–77]. Contudo, este método continua a gerar controvérsia devido às várias variáveis que influenciam o método e sua medição, colocando em causa a sua reprodutibilidade [9,11–13,78]. Dentro dos métodos indiretos, os mais utilizados, como o MT e a MI, já foram clinicamente validados [74,76,79,80].

Capítulo 2 - Área de Superfície da Cavidade Abdominal

Este capítulo levou à publicação do artigo:

Lopes AM, Pereira H, Niza MMRE, Onça R, Dourado A. “3D Modeling of Abdominal Surface Area in Cats.” J Veterinar Sci Technol 2015, 6:6 <http://dx.doi.org/10.4172/2157-7579.1000269> . O artigo:

Lopes AM, Castro M, Niza MMRE, Onça R, Dourado A. “3D Modeling of Abdominal Surface Area in Dogs.” encontra-se submetido na revista BMC Veterinary Research

2.1 – Introdução

2.1.1- Cavidade Abdominal

A cavidade abdominal é a maior cavidade do corpo, estando separada da cavidade torácica pelo diafragma ligando-se caudalmente com a cavidade pélvica. Em cães apresenta um formato ovoide e é comprimida lateralmente. É delimitada dorsalmente pelas vértebras lombares, músculos lombares e diafragma. As paredes laterais são formadas pelos músculos abdominais oblíquos e transversos, peritoneu, costelas caudais, asas ilíacas e seus músculos. A parede ventral é constituída pelos músculos: reto abdominal, transverso, oblíquo e peritoneu. A parede cranial é formada pelo diafragma, profundamente côncavo, aumentando assim a cavidade abdominal (figura 2.1).

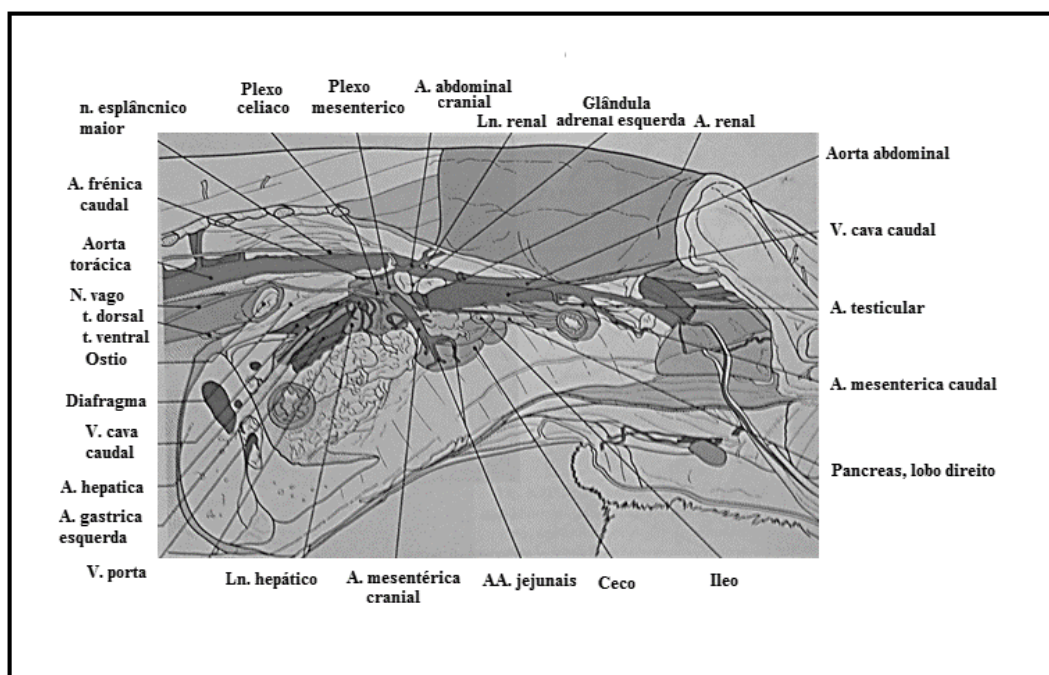


Figura 2-1- Figura ilustrativa da cavidade abdominal de cão traduzido e adaptado de Done Goody & Evans, 1996 [81].

O abdómen contém a maior parte dos órgãos digestivos e urinários, vasos sanguíneos, vasos e nódulos linfáticos, baço e glândulas adrenais [82,83].

A linha de demarcação entre a cavidade abdominal e retroperitoneal é denominada linha terminal, sendo formada dorsalmente pela base do sacro, lateralmente pelas linhas iliopectíneas e ventralmente pelos bordos craniais dos ossos púbicos (figura 2-2). A cavidade retroperitoneal contém o reto, parte dos órgãos genitais internos e urinários [82,83].

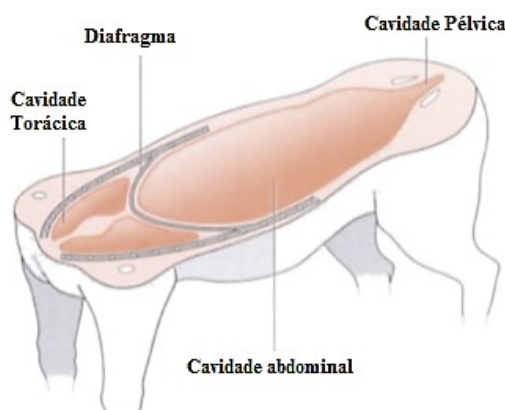


Figura 2-2– Imagem ilustrativa dos limites da cavidade abdominal num plano transversal de cão evidenciando a cavidade torácica, abdominal e pélvica, traduzido e adaptado de Aspinall, 2004 [84].

A cavidade abdominal é um espaço anatómico que está contido numa parede de distensibilidade limitada. Esta depende da rigidez do peritôneo, dos elementos que a compõem e da relação dinâmica entre o volume e a pressão. A cavidade abdominal e retroperitoneal atua como um compartimento estanque, razão pela qual qualquer alteração do seu volume ou do seu conteúdo conduz à elevação da PIA [1,8].

A cavidade abdominal é então um compartimento de distensibilidade limitada, sendo a sua pressão interna influenciada pelos órgãos internos nela contidos, pela tensão exercida pelas suas paredes musculares e por todas as forças que atuam externamente, tal como a pressão atmosférica ou qualquer pressão submetida no abdômen.

Na revisão bibliográfica realizada não foi encontrado nenhum estudo morfométrico que determinasse a área de superfície da cavidade abdominal (ASCA) quer em humanos quer em outra espécie. Em humanos e ratos está sim descrita a área de superfície peritoneal (ASP) por vários métodos, devido à sua importância como barreira direta de trocas na terapia intraperitoneal [85,86].

A determinação da ASCA é importante como parâmetro morfométrico de quantificação da superfície corporal, conduzindo a um aumento da informação anatômica básica não existente, o que vai permitir uma melhor compreensão de processos fisiológicos e patológicos que afetem a cavidade abdominal.

A utilização deste parâmetro pode tomar particular importância na determinação da PIA e na compreensão da SCA. A ASCA é uma variável que influencia diretamente a PIA, uma vez que a pressão é uma grandeza escalar que representa a ação de uma ou mais forças sobre uma determinada área, neste caso a ASCA [87].

2.1.2- Volume e área abdominal

A determinação física das dimensões de estruturas e de cavidades orgânicas, como o volume e a área de superfície, é muitas vezes um desafio nos vários campos da medicina [86,88–92]. Desde 1970, a tomografia axial computadorizada (TAC) revolucionou o diagnóstico radiológico e foi a primeira técnica tomográfica a ser combinada com cálculo computacional [93]. Desde essa altura houve um grande desenvolvimento tecnológico, que permitiu o uso destas técnicas para determinar e calcular com rigor parâmetros anatômicos de vários órgãos, quando comparados com modelos reais [94–98]. A construção tridimensional (3D) de modelos anatômicos tornou-se possível através da segmentação, com delimitação de cada região de interesse (ROI) e construção da nuvem de pontos representativa da estrutura. Recorrendo a um software computer-aided design (CAD), como o SolidWorks (Dassault Systèmes SolidWorks Corporation, USA), possibilita a modelação da estrutura e cálculo de propriedades de massa como o volume, densidade, área de superfície e centro de massa da ASCA [95,99].

Utilizando o cálculo computacional através da identificação de sistemas, consegue-se a construção de modelos matemáticos que permitem o interface entre aplicações do mundo real e o mundo matemático

[100]. Através destas técnicas é possível encontrar soluções matemáticas de fácil aplicação, que através dos parâmetros morfométricos permitam a determinação da ASCA.

2.2 - Material e métodos

Nesta primeira fase do estudo, de forma a criar uma fórmula de cálculo da ASCA, semelhante às que existem para calcular a área de superfície corporal [101,102], foi realizado um estudo retrospectivo de série de casos de TACs realizados em cães. Desta forma recorreremos à base de dados de exames tomográficos da Faculdade de Medicina Veterinária da Universidade de Lisboa e a uma base de dados particular, de forma a aumentar o número de exames. Da população total estudada (132 cães) foi selecionada uma amostra de 25 animais. Como critério de inclusão foram selecionados todos os exames de cães que permitissem a visualização da totalidade da cavidade abdominal e não demonstrassem doença que afetasse esta cavidade ou os seus órgãos. Das 25 TACs selecionadas, 12 eram de fêmeas e 13 de machos, com uma idade média de 10.04 ± 4.80 anos e com um peso médio de 25.20 ± 13.07 kg (Adam CPW Plus 150, USA). A população em estudo foi representativa de várias raças, inclusive raças de pequeno e grande porte. Todas as características individuais dos indivíduos, como o peso, perímetro abdominal e área de superfície corporal, são apresentadas na Tabela 2-1.

2.2.1- Avaliação das TAC's

Os exames foram realizados utilizando um *scanner* General Electric CT HiSpeed LX/i, apresentando uma espessura constante de corte, entre 1 e 3 milímetros. Os exames foram avaliados relativamente aos limites anatómicos do abdómen e à não existência de alterações anatómicas ou doença abdominal. O limite cranial foi estabelecido pelo diafragma e caudalmente pela cavidade pélvica. Dorsalmente a

delimitação foi realizada pelas vértebras lombares, músculos e parte lombar do diafragma. Os limites laterais foram estabelecidos pela parede abdominal, peritoneu, costelas caudais, asas ílicas e seus músculos. A porção ventral foi delimitada essencialmente pelos músculos abdominais e peritoneu [82,83].

2.2.2- Segmentação manual

Cada TAC foi trabalhada em formato *digital imaging and communications in media* (DICOM), utilizando um *software* de dados de imagem médica Osirix® (Pixmeo Sarl, Swiss), que permite a visualização de TACs. Este tipo de *software* permite ao utilizador ver imagens simultâneas nos três planos anatómicos (axial, sagital e coronal), facilitando a visualização e delimitação das estruturas anatómicas, figura 2-3.

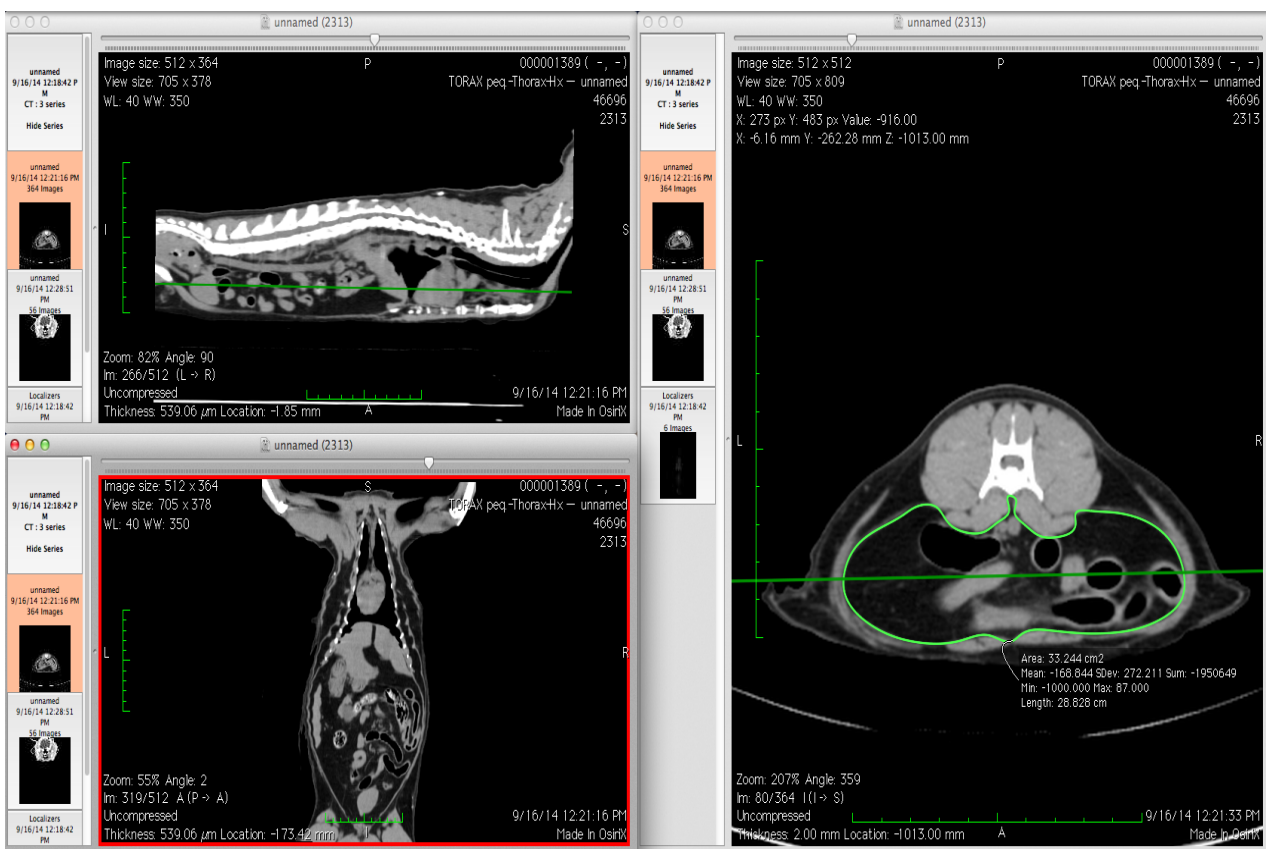


Figura 2-3- Imagem tomográfica da cavidade abdominal em várias orientações, com a segmentação manual de cada corte, correspondente à área de superfície da cavidade abdominal.

Com a ferramenta para delimitação de estruturas do programa, *Closed Polygon*, o utilizador pode delimitar em cada corte axial a estrutura anatómica de interesse. Com esta ferramenta é também possível determinar o perímetro abdominal a nível da quarta vertebra lombar [103]. O objetivo da segmentação manual é definir a ROI, devendo ser efetuada em todos os cortes de forma a diminuir o erro, figura 2-4.



Figura 2-4- Imagem tomográfica da cavidade abdominal no plano transversal com delimitação da área de interesse.

O passo seguinte é transformar os dados obtidos através do DICOM, apagando toda a informação exterior à ROI, sendo que todos os dados fora dos limites devem ser considerados ruído de fundo. Com o objetivo de efetuar este procedimento, selecionamos todos as ROI e utilizamos a função *Set Pixel Values*, que irá funcionar como ferramenta de segmentação. Nesta função alteramos os valores de *Outside ROI* para -1500 e os valores de *Inside ROI* para 300. Este último valor é de detalhe crucial, uma vez que o volume do abdómen criado deverá ser um sólido compacto (figura 2-5).




Figura 2-5- Região de interesse da cavidade abdominal em corte transversal após correção dos valores de pixel por segmentação individual de cada corte.

Para criação do modelo 3D é desejável a eliminação dos dados dentro e fora dos limites de forma a simplificar a construção do modelo no *software* CAD. O modelo final da cavidade abdominal é realizado com a função *3D Surface rendering* (figura 2-6), que possibilita a exportação dos dados da estrutura criada, numa extensão de ficheiro *stereolithography* (.stl) que permite a modelação no *software* CAD (figura 2-7) [104].




Figura 2-6- Imagem tridimensional da cavidade abdominal em Osirix. Modelo final que permite exportação de ficheiro *stereolithography* para ser modelado em *software* CAD.

2.2.3- Modelação 3D

A modelação 3D da cavidade abdominal foi realizada através do *software* SolidWorks. Este tipo de programa é fácil de trabalhar e possibilita a determinação do volume e da superfície de área em poucos passos. O ficheiro, que foi exportado do Osirix na extensão .stl, foi agora importado/aberto como *Mesh File*. A nuvem de pontos (*mesh*) resultante, tem um aspeto semelhante ao exportado do programa de visualização (figura 2-7).




Figura 2-7- Imagem tridimensional da cavidade abdominal em Solid Works. Ficheiro .stl da superfície de área da cavidade abdominal aberto em software CAD.

Utilizando a função *Mesh Prep Wizard*, esta irá preparar a nuvem de pontos, eliminando os erros de forma a criar um modelo sólido. A nuvem fica então preparada para a criação do modelo 3D através da função *Solid/Surface Creation*, sendo aconselhada a função automática. O modelo final está

preparado e permite a obtenção dos valores morfométricos do modelo através da ferramenta *Mass Properties* (figura 2-8).




Figura 2-8- Modelo tridimensional final da cavidade abdominal que permite a obtenção dos valores de área de superfície e do volume.

2.2.4- Cálculo dos parâmetros morfométricos

O cálculo dos parâmetros morfométricos e a determinação matemática da correlação entre estes e a ASCA foram realizados com o programa Matlab. Este é um software de alto nível de linguagem computacional e desenvolvimento de algoritmos [105]. A determinação da área de superfície corporal (BSA) foi calculada utilizando a equação seguinte, sendo a constante (K) para cães 10,1 [101,102]:

$$BSA (m^2) = K \times \text{Peso corporal (gramas)}^{2/3} \times 10^{-4} \quad (2.1)$$

Utilizamos então o peso, o perímetro abdominal e a área de superfície corporal para, através da interpolação e ajuste de curvas, tentar determinar uma fórmula que permitisse determinar a ASCA. Através de processos de interpolação linear, utilizando o método dos mínimos quadráticos e aplicando a função *polyfit* foi possível aproximar o conjunto de pontos por um polinômio de qualquer ordem [105]. Finalmente comparou-se os valores da ASCA, obtidos pelas várias funções polinomiais em função dos parâmetros morfométricos, com os valores da ASCA reais obtidos por TAC.

2.3 – Resultados

2.3.1- Valores determinados da cavidade abdominal

Os modelos 3D da cavidade abdominal criados permitiram determinar o volume médio da cavidade abdominal de cães, $3.90 \times 10^{-3} \pm 2.06 \times 10^{-3} \text{ m}^3$, sendo o limite mínimo de $3,65 \times 10^{-4}$ e o máximo de $7,67 \times 10^{-3} \text{ m}^3$. Estes modelos também permitiram calcular a área de superfície da cavidade abdominal, sendo o valor médio de $1.51 \times 10^{-1} \pm 5.95 \times 10^{-2} \text{ m}^2$, o limite mínimo de 3.20×10^{-2} e o máximo de $2.58 \times 10^{-1} \text{ m}^2$ (Tabela 2-1).

Tabela 2-1- Valores das determinações morfométricas: peso corporal, perímetro abdominal, área de superfície corporal, área de superfície da cavidade abdominal e volume da cavidade abdominal.

| Parâmetro | Limite Inferior | Limite Superior | Média | Desvio Padrão |
|--|-----------------------|-----------------------|-----------------------|-----------------------|
| Peso corporal | 1.95 | 52.20 | 25.20 | 13.07 |
| Perímetro Abdominal (m) | 2.70×10^{-1} | 8.40×10^{-1} | 5.88×10^{-1} | 1.52×10^{-1} |
| BSA (m ²) | 1.58×10^{-1} | 1.41 | 8.35×10^{-1} | 3.27×10^{-1} |
| Área de superfície da cavidade abdominal (m ²) | 3.20×10^{-2} | 2.58×10^{-1} | 1.51×10^{-1} | 5.95×10^{-2} |
| Volume da cavidade abdominal (m ³) | $3,65 \times 10^{-4}$ | $7,67 \times 10^{-3}$ | 3.90×10^{-3} | 2.06×10^{-3} |

2.3.1- Correlação matemática da cavidade abdominal de cães

Utilizando processos de interpolação linear criámos funções matemáticas que correlacionassem o peso, o perímetro abdominal ou a BSA com a ASCA, de forma a possibilitar a sua determinação sem executar exames imagiológicos. De todas as fórmulas criadas, a que permitiu o cálculo da ASCA com melhores resultados foi baseada no peso vivo, sendo o valor apresentado em m²:

$$\text{ASCA} = 0.0044 \text{ Peso vivo (Kg)} + 0.0413 \quad (2.2)$$

Esta fórmula não apresenta diferenças estatisticamente significativas (P=0.988) quando comparada com as áreas reais determinadas por TAC. Realizou-se também o cálculo do coeficiente de Pearson para averiguar a força entre a associação de variáveis elevada, tendo sido obtido um coeficiente de 0.965.

2.4 - *Discussão*

A primeira fase do trabalho consistiu em encontrar um método que permitisse determinar e quantificar a área de superfície abdominal.

O aumento patológico da PIA é um fenómeno que atualmente se encontra bem documentado, estando diretamente associado a alterações fisiopatológicas graves. Estas alterações, quando são verificadas, levam ao aumento da morbidade e mortalidade dos doentes, provocando a SCA [7,27]. Segundo a revisão bibliográfica realizada pelos autores, não foi encontrada a determinação prévia da área de superfície abdominal em nenhuma espécie. Esta determinação, além de dar o contributo de informação

anatômica básica não existente, toma também particular importância porque a PIA é resultado das forças exercidas nesta área de superfície.

A medição da PIA é geralmente realizada utilizando o MT, sendo este considerado o *Gold standard* para sua avaliação [9]. No entanto, as medições realizadas através do MT estão ainda hoje sujeitas a alguma controvérsia e discute-se se a PIA deve ser medida através de métodos mais sensíveis, reprodutíveis e de confiança [9,10]. A determinação da ASCA pode trazer novos dados na compreensão da PIA e na tentativa de reproduzir métodos mais reprodutíveis, visto ser uma das variáveis que afeta diretamente este parâmetro.

A determinação da ASCA é de difícil obtenção, visto ser um parâmetro que só pode ser conseguido com ajuda de exames imagiológicos ou pós morte. As últimas duas décadas levaram a grandes avanços nos sistemas médicos de aquisição de imagem e sua manipulação [95]. Através da aquisição de imagem por TAC e modelação 3D conseguiu-se realizar a determinação da ASCA num modelo canino, podendo este ser adaptado e extrapolado para a medicina humana.

As técnicas de segmentação de órgãos ou, neste caso, da cavidade abdominal apresentam a desvantagem de ser muito morosas, pois é necessário efetuar em cada corte axial a delimitação da região de interesse, de forma a diminuir o erro. Os softwares médicos de hoje em dia têm ferramentas disponíveis que permitem não fazer a delimitação em cada corte, completando as ROI automaticamente. Contudo, este procedimento está associado a um aumento do erro [106]. Para além do facto da delimitação ser morosa, a modelação do ficheiro .stl da estrutura de interesse, em software CAD, apresenta também alguns problemas. Um deles é o facto de estes sistemas precisarem de um grande espaço de armazenamento, tornando a modelação difícil quando os ficheiros são de grande dimensão [95]. Porém, estas técnicas permitem um grande avanço visto ser muito difícil medir cavidades internas com métodos exatos. As técnicas descritas de modelação 3D de estruturas anatómicas apresentam algum erro associado quando comparadas com as estruturas reais, estando descrito na literatura erros entre 2.9 % e 4.95 %, o que é considerado um erro baixo [94,95,98].

O modelo anatómico 3D da cavidade abdominal de cães encontra-se de acordo com o descrito na literatura anatómica, apresentando unicamente alterações conformacionais relacionadas com a raça e peso do cão [82,83], o que deu origem a modelos mais comprimidos dorso-ventralmente e outros lateralmente.

As técnicas de identificação de sistemas possibilitaram também otimizar soluções matemáticas, que permitiram determinar uma solução para cálculo da ASCA baseada em parâmetros morfométricos. Através destes sistemas tentámos criar soluções que permitissem o cálculo da ASCA a partir do peso, do perímetro abdominal ou da BSA, de forma a facilitar a sua determinação. Neste caso, o parâmetro que permitiu criar uma aproximação matemática de forma mais correta foi o peso vivo. A fórmula criada (2.2) demonstra boa capacidade de aproximação com os valores reais determinados, sendo um polinómio de 1.º grau. A representação gráfica da dispersão dos pontos calculados pode ser visualizada na Figura 2-9, não havendo diferenças estatisticamente significativas com a determinação realizada por TAC ($P= 0.988$) apresentando um índice de correlação elevado ($cc 0.965$).




Figura 2-9- Gráfico dos valores de área de superfície abdominal medidos por TAC e valores calculados pelo polinómio de primeiro grau.

Este tipo de técnicas tem vindo a ser cada vez mais usado, possibilitando a criação de algoritmos para várias estruturas anatómicas [107].

O tipo de metodologia utilizado num modelo canino, segmentação e modelação 3D da cavidade abdominal e determinação de fórmulas de cálculo da ASCA, pode ser utilizado e extrapolado para humanos. Como as bases de dados de TACs de medicina humana são muito maiores, os dados obtidos vão apresentar um maior nível de significância e fórmulas matemáticas mais precisas. A determinação deste valor irá ajudar na determinação e compreensão da PIA.

Capítulo 3 – Validação da Pressão intra-abdominal

Este capítulo levou à publicação dos artigos:

Lopes AM, Nunes A, Niza MMRE, Dourado A. “Intra-abdominal Pressure is Influenced by Body Position?” *American Journal of Clinical Medicine Research*, vol. 4, no. 1 (2016): 11-18. doi: 10.12691/ajcmr-4-1-3.

Lopes AM, Morgado M, Niza MMRE, França N, Mestrinho L, Félix N, Dourado A. “Biophysical validation of intra-abdominal pressure and transurethral method.” *Vet Sci Med Diagn*. 2016, 5:3 <http://dx.doi.org/10.4172/2325-9590.1000196>

3.1- Introdução

3.1.1 - Conceitos físicos de Pressão

O termo pressão é utilizado em diversas áreas da ciência como uma grandeza escalar que mensura a ação de uma ou mais forças sobre um determinado espaço, por ação de líquidos, gases ou mesmo de sólidos [48,108,109]. A PIA é um conceito médico que se refere à pressão no interior da cavidade abdominal, mas numa primeira instância continua a ser um dado físico, uma pressão.

A pressão média (P) exercida numa superfície é, por definição, igual ao quociente da intensidade da força da pressão (F) pela área da superfície (A) (3.1) [48].

$$P = \frac{dF}{dA} \quad (3.1)$$

A pressão deriva de a grandeza escalar força que, por sua vez, deriva da segunda lei de Newton, onde a força é igual ao produto da massa com a aceleração. A aceleração, por sua vez, deriva do quociente entre a variação da velocidade com o tempo, sendo a velocidade representada pela distância por unidade de tempo [48,108,109].

As unidades do sistema internacional de pressão são o Pascal (Pa), definido como um Newton por metro quadrado [110].

A aplicação destes conceitos em gases e líquidos é caracterizado na Mecânica de fluidos. Designa-se por fluido uma substância ou mistura de substâncias que se escoam, ou seja, flui, com maior ou menor facilidade. Consideram-se como fluidos todos os líquidos e gases [48,111]. A hidrostática representa o estudo dos fluidos em repouso e a hidrodinâmica o estudo dos fluidos em movimento.

Considera-se que um fluido está em equilíbrio hidrostático quando este permanece em repouso relativamente ao recipiente onde está contido, ou seja, quando a sua velocidade de escoamento é nula e quando as forças que o fluido exerce sobre as paredes do recipiente são perpendiculares a este [48]. A lei fundamental da hidrostática ou lei de Stevin (LFH) caracteriza as pressões que se fazem sentir num fluido em condições de equilíbrio hidrostático, traduzindo-se pela seguinte expressão:

$$P_b = P_a + \rho gh \quad (3.2)$$

Em que P_b corresponde à pressão hidrostática no ponto b, P_a à pressão hidrostática no ponto a, ρ corresponde à densidade do fluido, g ao valor da aceleração gravítica e h à diferença entre as alturas dos pontos a e b (3.2). Esta lei refere que, num dado local, o aumento da pressão de um fluido em equilíbrio hidrostático, quando se passa de um ponto para outro situado a maior profundidade, depende da sua densidade e é proporcional ao desnível entre os pontos referidos [48,111].

A diferença de pressão entre dois pontos com profundidades distintas, no interior de um líquido em equilíbrio hidrostático, é igual ao valor do peso de uma coluna de líquido, de área de base unitária e com altura igual à diferença de nível entre os dois pontos [48,112].

Quando a LFH se verifica demonstram-se os seguintes postulados num líquido em equilíbrio hidrostático:

- A pressão no seu interior aumenta com a profundidade;
- A superfície livre é plana e horizontal;
- No mesmo plano de profundidade, todos os pontos que se encontrem à mesma profundidade estão à mesma pressão;
- Dois pontos que se encontrem ao mesmo nível no interior de um líquido, contido num sistema de vasos comunicantes, em equilíbrio hidrostático, estão à mesma pressão;

- Dois líquidos imiscíveis num sistema de vasos comunicantes, as alturas dos líquidos medidas a partir da superfície de separação, são inversamente proporcionais às suas massas volúmicas.

Estes postulados levam à conclusão que a pressão num fluido estático uniforme, distribuído continuamente, varia apenas com a distância vertical e é independente da forma do recipiente. A pressão é a mesma em todos os pontos sobre um dado plano horizontal no fluido e aumenta com a profundidade do fluido [48].

3.1.2 - Métodos diretos de medição da PIA

Os métodos diretos para medição da PIA consistem em várias metodologias, que permitem a medição direta da pressão que se faz sentir no interior do abdómen. Estas medições são geralmente realizadas através de procedimentos laparoscópicos ou por cateteres de diálise peritoneal [80]. A técnica laparoscópica tem início com a colocação de uma agulha de Verres, através da qual se realiza a insuflação da cavidade abdominal em procedimentos laparoscópicos ou na colocação de cateteres intra-abdominais. A medição da PIA é realizada por monitores de pressão, diretamente ligados à agulha de Verres, permitindo monitorizar a PIA durante o procedimento de laparoscopia. As medições realizadas por este método podem apresentar alguns erros, devido ao bloqueio da agulha por tecido ou fluido, levando a uma sobre ou subestimação de valores.

Os cateteres de diálise peritoneal permitem também o contacto direto com a cavidade abdominal, permitindo a medição da PIA. Este tipo de cateteres pode ser conectado a um transdutor de pressão refletindo a pressão que se faz sentir no abdómen. Além destes cateteres, têm também sido usados alguns sistemas com sensores piezoelétricos na ponta para fazer a medição da PIA. Um estudo clínico comparou o uso de um Coach®-system (CPRM, MIPM, Mammendorf, Germany), geralmente usado para determinar a pressão intramuscular, conectado a um dispositivo manual de transdução de pressão, com um Accurate++®-probe (APRM, MIPM, Mammendorf, Germany), geralmente utilizado para

determinar a pressão intracraniana. As leituras obtidas nestes estudos estavam de acordo com as obtidas pelo MT [54,113,114].

Atualmente existem também alguns dispositivos que visam a utilização prática e medição direta da PIA: *Intra-Compartmental Pressure Monitor System* (Stryker Surgical, USA). Tendo sido inicialmente desenvolvidos para medir a pressão nas fáscias musculares e para a síndrome de compartimentalização muscular, este tipo de dispositivo pode também ser utilizado na cavidade abdominal [115,116]. Este tipo de equipamento apresenta um tamanho reduzido e um sensor de pressão acoplado a uma seringa preenchida com solução fisiológica padronizada, que depois é acoplado a uma agulha posicionada intra-abdominalmente. No estudo de Boody e colaboradores, 2005, foram comparados três sistemas de medição de pressão de compartimentalização muscular, tendo este dispositivo de Stryker obtido bons resultados. Contudo, dentro do estudo, foi o que apresentou piores resultados devido à utilização de uma agulha recta [117].

As desvantagens das técnicas diretas de medição da PIA estão diretamente ligadas com o grau de invasão, custo elevado e com o facto de não poderem ser utilizadas para a medição rotineira da PIA. A monitorização direta da PIA é essencialmente utilizada em unidades de cuidados intensivos, onde a utilização dos outros métodos de medição pode estar desaconselhada [9,54].

3.1.3 - Métodos indiretos de medição da Pressão intra-abdominal

3.1.3.1 - Medição da PIA pelo perímetro abdominal

A medição do perímetro abdominal foi anteriormente utilizada para aferir a PIA. Contudo, esta técnica caiu em desuso por não poder refletir a pressão que se faz sentir no abdómen. O perímetro abdominal não reflete a PIA, tendo sido encontrada uma correlação baixa entre a PIA e o perímetro abdominal. Clinicamente pode existir HA sem existir distensão abdominal [9,118]. Tal como a medição do

perímetro abdominal, a palpação do abdómen por digitoclasia, como método para determinar a PIA, só revela uma sensibilidade de 40%, não servindo para a aferição da mesma [118].

3.1.3.2 - Medição da PIA pelo Método Transvesical

A determinação da PIA utilizando o MT foi originalmente proposta por Kron e colegas em 1984 [5]. O método é baseado nas leis da Hidrostática e no Princípio de Pascal. Desde que Kron e colegas descreveram a técnica, esta tem sido sujeita a diversas evoluções com algumas diferenças entre elas. Contudo, o princípio é sempre o mesmo: permitir o contacto entre o fluido contido na bexiga e o fluido contido numa coluna de água até se atingir o equilíbrio, podendo este ser lido num transdutor [9].

a) - Sistema original aberto, para medição única (Kron et al, 1984):

Neste método é colocado um cateter estéril na bexiga, idealmente um cateter de Foley, que está conectado a um sistema de recolha de urina. Após remoção da urina, o sistema é desconectado e são instilados na bexiga 50 a 100 ml de solução fisiológica. Depois da conexão, é colocado um clamp distalmente ao sistema de aspiração e é colocada uma agulha de 16 G para permitir uma conexão em Y. Esta agulha está ligada ao manómetro de água revelando o menisco o valor da PIA [5].

b) - Sistema fechado, para medição única (Iberti et al, 1989):

Neste sistema, descrito por Iberti, os princípios são os mesmos, porém utiliza um sistema fechado de drenagem. Este sistema permite uma conexão ao cateter de Foley de forma a introduzir 250 ml de solução fisiológica, sem que haja a necessidade de desconectar o sistema. É então utilizada uma agulha de 20 G na porta de aspiração que está em contacto com o manómetro de água, marcando o menisco de fluido no transdutor o valor da PIA [80].

c) - Sistema fechado, para várias medições (Cheatham ML, Safcsak, 1998):

Este sistema tem algumas vantagens em relação aos descritos anteriormente, visto que não é necessário desconectar o cateter de Foley e permite realizar várias medições. O cateter de Foley está então conectado através de duas torneiras de três vias a: um sistema de infusão com solução salina; uma seringa com dispositivo *Luer-lock*; um transdutor de pressão e um sistema de drenagem. O transdutor de pressão pode ser um manómetro de água ou um transdutor estandardizado de pressão ligado a um monitor [6].

O método basicamente consiste na conexão do cateter uretral a uma válvula de três vias, que por sua vez está conectada a uma coluna de água, dividida em cm de H₂O, e totalmente preenchida com solução salina. Posiciona-se a algália e um sistema de três vias a nível da asa ilíaca, de modo a que o zero da coluna de água se encontre a este nível. Realiza-se a remoção da totalidade da urina pré-existente na bexiga, seguido da instilação de um volume predeterminado de solução fisiológica. A instilação de solução fisiológica é necessária para padronizar o volume intravesical em cada indivíduo. A leitura da PIA tem início quando se permite que o fluido contido na bexiga entre em contacto com o existente na coluna de água. Quando o fluido se encontra em equilíbrio, a PIA pode ser lida no ponto onde se encontra o menisco de água no manómetro (figura 3-1) [6,9].




Figura 3-1- Imagem ilustrativa do método transvesical em humanos, traduzido e adaptado de Asencio, Ceballos, Forno & Sava, 2002 [31].

Esta técnica minimiza o risco de infeções do trato urinário e a probabilidade de haver septicemia, ao contrário do que acontece na técnica original proposta por Kron. Além deste facto permite a medição repetida da PIA para além de apresentar custos reduzidos [9].

Existem várias variáveis que podem alterar a aferição da PIA, sendo este um dos motivos pelo qual o MT continua a ser alvo de alguma controvérsia [9–11,13,78,119]. As variáveis identificadas em vários estudos clínicos e protocolos experimentais são:

- Variáveis dependentes do operador: Um dos erros comuns na aferição da PIA por este método consiste na presença de bolhas de ar no manómetro de água e mau posicionamento do mesmo, levando a erros de aferição [9]. Variações de -6 a +30 mmHg foram reportadas em estudos prévios [78], revelando alguns deles um coeficiente de variação de reprodutibilidade entre 25 a 66% [120]. O nivelamento do manómetro de água a nível da sínfise púbica está também descrito poder alterar a medição da PIA [11].
- Posição do doente: A posição em que se realiza a medição da PIA é diferente segundo a espécie em estudo. No Homem é utilizado o decúbito dorsal enquanto que no cão e gato é geralmente utilizado o decúbito lateral (esta diferença é devida à diferente posição anatómica do pénis e vulva nestas espécies). No Homem, a PIA pode ser alterada pela modificação da posição do doente, quando se realizam medições na posição de Trendelenburg e Trendelenburg reversa [121]. O posicionamento do paciente pode levar a sobre ou subestimação da PIA. Yi M e colaboradores (2012) demonstraram que a elevação da cabeça em 30 a 45° em pacientes em estado crítico aumenta os valores de PIA [12]. Em medicina veterinária está também descrito que a posição pode afetar a mensuração quando utilizado o decúbito ventral em comparação com o lateral [22], não tendo sido observadas diferenças entre o decúbito dorsal e lateral [21].
- Condicionantes da coluna de fluidos: Todos os sistemas de coluna de água ligados a um transdutor de pressão possuem uma resposta dinâmica, que pode causar distorção e artefactos

na medição da PIA. O volume residual instilado na bexiga para realizar a medição da PIA é também uma variável que pode afetar a medição. No Homem, os volumes usados não são uniformes estando descrito a utilização de volumes de 50 a 250 ml de solução salina. A instilação de mais de 50 ml numa bexiga sem urina e com a elasticidade diminuída vai aumentar a pressão intravesical e sobrestimar a PIA [13]. Com a determinação da PIV, através da construção de curvas de volume, chegou-se à conclusão que a utilização de volumes entre os 50 a 100 ml não iria afetar a medição [122]. Em medicina veterinária, os volumes utilizados são inferiores aos usados no Homem. O volume instilado a nível vesical, descrito para canídeos, é de 0.5 a 1 ml/kg de solução fisiológica, adotando-se usualmente o valor de 1 ml/kg [16,17]. Em felídeos, os volumes utilizados variam entre 0.1 e 1 ml/Kg, sendo geralmente usado 0.5 ml/Kg de solução fisiológica [21,22].

- Características fisiológicas e morfológicas do indivíduo: O peso do paciente pode fazer variar o valor da PIA. Em humanos, o peso foi descrito como um dos fatores que pode levar ao aumento da PIA [22,123]. Similarmente em medicina veterinária observaram-se valores mais altos em animais com um peso mais elevado [21]. Este estudo refere também que os valores de PIA são superiores em machos. Contudo, referem que esta diferença, entre machos e fêmeas, poderá ser devido ao dimorfismo sexual [21].

A contração dos músculos abdominais é outro dos fatores identificados que pode elevar o valor da PIA, uma vez que funciona como uma força externa exercida sobre o abdómen [124,125].

A coactivação do diafragma e dos músculos abdominais nos movimentos respiratórios é outra das variáveis que também pode afetar a PIA [126,127], que sofre um aumento durante a inspiração proporcional à sua profundidade [126,128].

- Cirurgia: A cirurgia abdominal pode levar a aumento da PIA. Em humanos está descrito que a distensão abdominal aguda, após cirurgia abdominal complexa, pode resultar em dilatação gástrica levando a oligúria e aumento das pressões respiratórias [18,129]. Conzemius e

colaboradores, 1995, identificaram um aumento da PIA pós-cirúrgico em cadelas submetidas a ovariectomia, após terem efetuado 8 medições nas primeiras 24 horas [15]. Facto idêntico foi observado em gatas submetidas ao mesmo procedimento [20]. Contudo, esta variável continua a gerar alguma controvérsia tendo Way e colaboradores (2014) concluído no seu estudo que a PIA em cães saudáveis não era influenciada pela cirurgia abdominal [16].

3.1.3.3 - Medição da PIA por manometria intra-gástrica

Outro dos métodos indiretos para medição da PIA consiste na utilização de um tubo de gastrotomia ou tubo nasogástrico, colocado no estômago. Este método é geralmente utilizado quando não existe cateterização vesical ou em caso de traumas peritoneais que tenham afetado o sistema urinário que impeça o uso do MT [79].

a) - Técnica clássica para medições intermitentes:

A técnica clássica de medição da PIA por manometria intra-gástrica (MI) é muito semelhante ao MT. Assenta também nos princípios fundamentais da hidrostática, contudo com uma localização diferente. Neste método é colocado um tubo nasogástrico ou de gastrotomia dentro do estômago em conexão com uma coluna de água dividida metricamente (Figura 3-2), o que permite a obtenção do equilíbrio dinâmico entre o fluido contido no estômago com o da coluna de água. Quando se atinge o equilíbrio o valor lido na coluna de água corresponde à PIA [9,31].

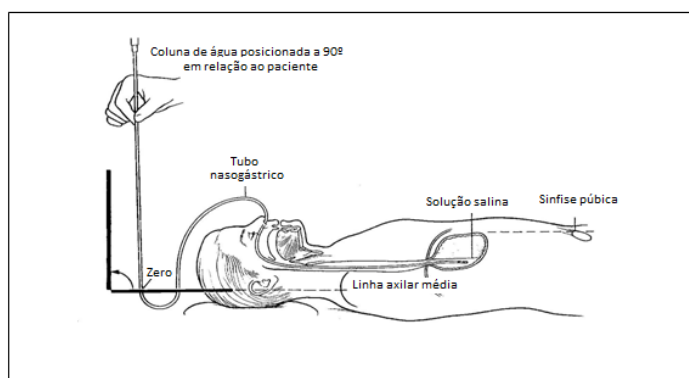


Figura 3-2- Imagem ilustrativa de manometria intra-gástrica via tubo nasogástrico no Homem, traduzido e adaptado de Asencio, Ceballos, Forno & Sava, 2002 [31].

Esta técnica apresenta parte das desvantagens do MT, devido ao sistema de coluna de água utilizado. Além disto, uma das desvantagens é inerente às pressões gástricas poderem interferir com a medição. Outro dos inconvenientes é a necessidade de remover todo o ar do estômago bem como o conteúdo gástrico antes de realizar a medição, o que por vezes pode ser difícil [9].

b) - Técnica Semi-contínua

Este tipo de técnica foi desenvolvido por Sugrue e colaboradores, utilizando um balão de um tonómetro gástrico durante procedimentos laparoscópicos de colecistectomia [130]. Os resultados demonstraram uma boa correlação com os valores obtidos pelo MT sem as desvantagens da técnica clássica e do MT. Este método limita assim os riscos de infeção e não interfere com a produção de urina. Como o sistema de colunas é repleto de ar, e não de solução salina, elimina algumas das desvantagens inerente à coluna de fluidos, não sendo necessário nivelar o zero do manómetro de água, nem sendo a leitura perturbada pela presença de bolhas que possam estar dentro do sistema. Uma possível desvantagem deste método é a migração do dispositivo gástrico [130].

c) - Técnica Semi-contínua revista

Esta técnica é muito semelhante à anterior, porém é introduzido um cateter esofágico de balão no estômago por via nasogástrica. Este é então conectado a uma torneira de três vias que está ligada a um transdutor de pressão e, conseqüentemente, a um monitor. Todo o ar é então removido do sistema com ajuda de uma seringa ligada à torneira de três vias e é introduzido 1-2 ml de ar no balão. O transdutor é nivelado com o zero na pressão atmosférica, sendo a PIA lida no final da expiração. Uma das desvantagens é o sistema necessitar de recalibrações sucessivas, uma vez que para realizar as leituras é necessário retirar todo o gás do sistema e introduzir uma quantidade padrão. Quando o sistema perde

o ar no balão o transdutor perde a capacidade de determinar a PIA. Esta técnica é ideal para monitorizações prolongadas da PIA, porque não interfere com a produção de urina e permite a repetição de leituras [9].

d) - Técnica contínua automatizada

Esta técnica utiliza um monitor específico para a monitorização da PIA, CiMON - *Intra-abdominal Pressure Monitor* (Pulsion Medical Systems, Munich, Germany). O cateter para a aferição da PIA apresenta um lúmen que conecta o monitor com o balão localizado na extremidade do cateter. O transdutor de pressão, o *hardware* eletrónico e o dispositivo para insuflar o balão na extremidade do cateter estão integrados no monitor da PIA. A cada hora o monitor equaliza o sistema ao valor da pressão atmosférica e insufla a quantidade de ar necessária no balão para a medição contínua da PIA. As medições obtidas por este método revelam boas correlações com os outros existentes [76]. Este tipo de monitor apresenta vantagens evidentes, possibilitando uma monitorização durante 24 horas. Porém é dificilmente utilizada na medição rotineira da PIA porque a entubação gástrica não é frequentemente realizada [9,76].

3.1.3.4 - Medição da PIA através do reto

A pressão rectal é utilizada rotineiramente para estimar a PIA durante os estudos urodinâmicos, para calcular a pressão transmural do músculo detrusor [131]. As pressões rectais são obtidas por meio de cateteres rectais abertos com irrigação contínua de fluidos a uma taxa de 1ml/min ou por cateteres com balão. As principais desvantagens estão relacionadas com os cateteres rectais serem abertos o que conduz à sua obstrução por massas fecaloides, podendo levar a uma sobrestimação da PIA. Outra das desvantagens está relacionada com a presença de doenças gastrointestinais que podem impossibilitar

a sua utilização. Como esta técnica utiliza um sistema de fluidos associado a uma coluna hidrostática tem os mesmos inconvenientes que o MT [9].

3.1.3.5 - Medição da PIA através do útero

A medição da PIA pelo útero é realizada utilizando os mesmos cateteres que são utilizados na aferição pela via rectal. Esta técnica é geralmente utilizada por ginecologistas durante a gravidez e trabalho de parto ou quando está contra-indicado a utilização do MT. As desvantagens são idênticas às apresentadas anteriormente para a medição por via rectal. É uma técnica mais difícil de realizar, implica uma maior manipulação, as medições são intermitentes e não pode ser utilizada em pacientes com metrorragias ou infeções concomitantes. Como a técnica se baseia nos princípios da hidrostática, apresenta todos os problemas anteriormente relatados. Acresce ainda que esta técnica não foi validada em unidades de cuidados intensivos [9].

3.1.3.6 - Medição da PIA pela Veia Cava Caudal

A pressão da veia cava caudal (PVCC) foi sugerida para realizar a medição da PIA. A descrição da técnica é idêntica às anteriores com a diferença do cateter ser posicionado na veia cava caudal (VCC). Um cateter venoso é inserido na VCC, através de acesso pela veia femoral direita ou esquerda. A confirmação da posição do cateter é realizada por RX e por um aumento da pressão abdominal externa, que vai provocar um aumento da PVCC. O sistema de conexão da coluna de água é idêntico ao descrito anteriormente. Uma das extremidades da torneira de três vias fica conectada diretamente ao lúmen do vaso, outra ao transdutor de pressão e a última a um sistema de venoclise de solução salina padrão. O sistema de transdução é nivelado a zero, a nível da linha média axilar, com o paciente na posição supino, sendo a medição da PIA realizada após final da expiração [9].

A sua maior desvantagem é o risco de infeções a nível vascular e choque séptico. A colocação inicial do cateter é também mais demorada e também esta técnica apresenta os problemas ligados ao facto da medição ser realizada com uma coluna de água. Uma das grandes vantagens é possibilitar a monitorização contínua da PIA, não interferir com a produção urinária e poder ser utilizada em pacientes com trauma vesical. Também, esta técnica não foi validada em pacientes de unidades de cuidados intensivos [9]. Num estudo comparativo dos vários métodos de aferição da PIA, realizado em coelhos, foi observada uma boa correlação entre o MT, a PVCC e as medições diretas na cavidade abdominal [132]. A mesma correlação foi observada num noutro estudo realizado em suínos sujeitos a laparoscopia e com monitorização da PIA pelos vários métodos [133].

3.1.3.7 - Cateteres com transdutores de ponta

Nos dias de hoje existem vários tipos de cateteres, que dispõem de um microchip com transdutor de pressão na extremidade. Estes podem ser colocados por várias vias, como a rectal, uterina, vesical ou gástrica. Estes cateteres estão então ligados a um monitor realizando a medição. Este tipo de cateteres permite a obtenção de uma calibração exata do valor zero de medição. A sua maior desvantagem é o custo económico inerente, tendo os cateteres um valor aproximado entre os 1000 e os 1500 € [9]. Estes são mais utilizados em estudos urodinâmicos e uma das suas maiores vantagens é permitirem uma monitorização contínua. Também neste caso, a utilização deste tipo de cateteres ainda não foi validada em pacientes em unidades de cuidados intensivos.

3.2 - *Material e Métodos*

A medição da PIA foi realizada numa população de 29 cães que deram entrada no departamento de Patologia da Faculdade de Medicina Veterinária para realização de necropsia. Dentro da população

estudada, 14 eram machos e 15 fêmeas, com um peso médio de 12.04 ± 5.67 quilogramas (kg) (Adam CPW Plus 150, USA).

A metodologia utilizada para efetuar o estudo biofísico da PIA, métodos de medição e as variáveis que a afetam foi escolhida por causa da dificuldade de eliminar algumas das variáveis que a influenciam. Além deste facto, a dificuldade em estudar isoladamente as variáveis e as condicionantes éticas ligadas à experimentação de animais vivos foram o suporte para a utilização deste tipo de modelo.

Utilizando uma aproximação analítica a problemas, optou-se por seleccionar uma metodologia que permitisse decompor o problema em vários mais pequenos. Desta forma, o estudo foi realizado num modelo anatómico não vivo da cavidade abdominal de cão. Este tipo de modelo permitiu a erradicação das variáveis fisiológicas que podem alterar a PIA como a contração gástrica e dos músculos abdominais, o reflexo da micção e a respiração [10,22,125,127,134–137].

As medições da PIA foram realizadas por três métodos diferentes, um método direto e dois indiretos: MT e MI. As medições com os três métodos foram realizadas em cinco posições anatómicas diferentes: lateral, ventral, dorsal, Trendelenburg e Trendelenburg reversa (ângulo de 45 graus).

No final das medições da PIA, todos os animais foram submetidos a necropsia o que permitiu confirmar a posição de todos os cateteres e validar as leituras. Todas as medições anatómicas e morfométricas de órgãos foram realizadas no âmbito do procedimento normal de necropsia.

Os critérios de inclusão deste estudo consistiram na ausência de doença que afetasse a cavidade abdominal e os seus órgãos, confirmado por necropsia. Todos os cães que demonstraram doença que afetasse a cavidade e seus órgãos foram excluídos do estudo. De forma a evitar alterações na tensão e elasticidade dos tecidos, o trabalho teve lugar imediatamente após a entrada do cadáver no serviço de anatomia patológica. Todos os cadáveres em que se verificaram alterações marcadas de tensão ou elasticidade de tecidos foram também eliminados do estudo.

3.2.1- Medição direta da PIA

A medição da PIA pelo método direto foi realizada através de um cateter intra-peritoneal, utilizando um sensor CODMAN (Codman, Johnson & Johnson). O sensor inicialmente foi ligado ao transdutor e a referência foi ajustada no zero tendo como referência a pressão atmosférica. Em seguida, o sensor foi inserido dentro do cateter e este empurrado para o interior da cavidade abdominal. Aguardou-se um minuto para estabilizar a pressão e iniciaram-se as leituras e o respectivo registo [54,113].

3.2.2- Medição indireta da PIA

Os métodos indiretos que existem para medir a PIA são quase todos dependentes de uma coluna de fluidos, geralmente solução fisiológica, dividida metricamente em centímetros de água. As duas técnicas usadas de medição indireta permitiram determinar o valor da PIA após a permissão do equilíbrio dinâmico entre a coluna de água e o fluido contido na bexiga ou no estômago (Figura 3-3).




Figura 3-3- Representação esquemática da medição da PIA por métodos diretos e pelos métodos indiretos (método transvesical e intragástrico).

No nosso estudo utilizou-se a técnica fechada, proposta por Cheatman [6] para medir a PIA pelo MT. Esta foi medida através de um cateter vesical transuretral, conectado através de dois sistemas de três vias, a um sistema de drenagem de urina, a uma coluna métrica e a um sistema de solução fisiológica. A bexiga é então esvaziada e um volume padrão de solução salina estéril, de 0.5 a 1 ml / kg de solução salina a 0.9% foi instilada na bexiga de forma a obter uma distensão fisiológica (muito solução salina na bexiga pode incorretamente elevar a medição de PIA) [16,17,138]. Uma vez instalada a solução salina na bexiga, permite-se o equilíbrio dinâmico entre o líquido contido na bexiga e o líquido contido na coluna de água dividida metricamente. O ponto zero da escala métrica da coluna de água deve estar nivelado a nível da sínfise púbica do paciente. Depois de se atingir o equilíbrio entre as duas colunas de fluido, o valor de PIA corresponde ao menisco da solução salina na escala métrica [17].

A técnica de medição da PIA pela MI é semelhante ao descrito para o MT, contudo em vez de utilizar a bexiga utiliza o estômago. A obtenção dos valores de pressão é obtida entre o equilíbrio dinâmico de pressões entre a coluna dividida metricamente e o fluido contido no estômago. É colocada uma sonda nasogástrica padrão posicionada a nível do estômago e removido todo o fluido existente. De seguida é colocada uma quantidade padrão de solução fisiológica, 50 ml por animal, de forma a obter uma distensão fisiológica do estômago. A pressão é obtida após permitir o equilíbrio entre a coluna métrica de fluido e o fluido gástrico [9].

As medições foram realizadas consecutivamente nas várias posições e todos os valores foram registados numa base de dados.

3.2.3- Determinações morfométricas

Durante o âmbito do procedimento de necropsia foram pesados todos os órgãos abdominais de forma a obter os valores para inserir na formulação biofísica. Assim, foram pesadas a totalidade das vísceras abdominais e a parede lateral do abdómen (pele e músculos). As pesagens foram realizadas

isoladamente com uma balança calibrada previamente. A força foi calculada de acordo com a segunda lei de Newton, que é o resultado do produto da massa do corpo pela aceleração gravítica [139]. O volume dos órgãos foi estabelecido através do princípio de Arquimedes da deslocação de fluidos [140].

3.2.4- Área do estômago e bexiga

Para determinação das áreas de superfície da bexiga e do estômago foi realizada a diérese sagital dos órgãos cavitários de forma a obter uma superfície plana (Figura 3-4).



Figura 3-4- Fotografia da diérese sagital da bexiga de forma a obter uma superfície plana.

Os órgãos foram então estendidos e colocados num tabuleiro branco ao lado de um quadrado de cor negra de escala de 1 centímetro de lado, foi tirada uma fotografia digital englobando toda a superfície de área do órgão e da escala. Através do tratamento digital das imagens e com a utilização de algoritmos de análise de pixels foi possível determinar a sua área de superfície [141]. Este tipo de metodologia é utilizado para a medição da superfície de área de lesões cutâneas em feridas crónicas [141]. A análise digital da imagem e cálculo da área de superfície foram realizadas recorrendo ao programa Matlab (Mathworks, Inc, USA). Este tipo de programa possui funções que permitem o tratamento digital da imagem com as ferramentas de processamento (*Image processing toolbox*). Utilizando a função *imshow* podemos representar a imagem numa forma binária (*bitmap*) unicamente

com duas cores, branco e preto, com disposição por pixels (valor 0: cor preta e valor 1: cor branca). Através da função *regionprops*, que mede e delimita regiões da imagem, e recorrendo às funções para determinação de áreas do Matlab consegue-se determinar a área da imagem digital a preto (Figura 3-5).




Figura 3-5 – Imagem digital (bimap) do corte sagital da bexiga e do estômago e do quadrado de escala de 1 centímetro

O código utilizado na área de trabalho do Matlab para obter as áreas de superfície da bexiga e estômago através da imagem digital foi o seguinte:

```

photo = imread('photo.jpg');
imshow(photo);
I = rgb2gray(photo);
threshold = graythresh(I);
bw = im2bw(I,threshold);
[B,L] = bwboundaries(bw);
imshow(label2rgb(L, @jet, [.5 .5 .5]));
hold on
for k = 1:length(B)
    boundary = B{k};
    plot(boundary(:,2), boundary(:,1), 'black', 'LineWidth', 2)
end
stats = regionprops(L,'Area');
for k = 1:length(B)
    boundary = B{k};
    area = stats(k).Area;
    area_string = sprintf('%0f',area);
    text(boundary(1,2)+5,boundary(1,1)+13,area_string,...
        'Color','white',...
        'FontSize',8,...
        'FontWeight','bold',...
        'BackgroundColor','black',...
        'FontName','Times');

```


A imagem final representa as áreas das superfícies e do quadrado de 1 centímetro de lado de escala utilizada, permitindo assim a determinação da área da bexiga e do estômago (Figura 3-6).




Figura 3-6- Imagem digital da bexiga, estômago e escala após processamento de imagem no Matlab com os valores de área de superfície da bexiga e do estômago.

3.2.5 - Área de superfície corporal e do abdômen

A determinação da área de superfície corporal (BSA) foi calculada, como anteriormente, utilizando a fórmula (2.1): $BSA (m^2) = K \times \text{Peso corporal (gramas)}^{2/3} \times 10^{-4}$, sendo a constante (K) para cães 10.1 [101,102]. Para a determinação da ASCA recorreu-se à fórmula matemática (2.2) baseada no peso vivo determinada na primeira fase do trabalho, $ASCA = 0.0044 \text{ Peso vivo (Kg)} + 0.0413$ sendo o valor apresentado em m^2 .

3.2.6 - Mecânica de Fluidos

O MT utiliza um sistema de vasos comunicantes que permite a comunicação entre a bexiga e uma coluna de água, metricamente dividida em centímetros de água [9]. O fluido contido na bexiga está

sobre a influência do princípio físico de Pascal, que estabelece que qualquer alteração de pressão num fluido em equilíbrio transmite-se integralmente a todos os pontos do líquido e às paredes do recipiente [9,48,109]. Logo, qualquer alteração de pressão que exista na cavidade abdominal é transmitida ao fluido contido na bexiga e de igual forma ao sistema de vasos que estabelece a comunicação com a coluna de água. Assim, sempre que é realizada uma leitura, existe um ponto de equilíbrio, em que a pressão do fluido na bexiga é igual à pressão existente na coluna de água. Neste momento verificam-se os princípios da hidrostática pois o número de partículas por unidade de volume é constante; não existe velocidade relativa das partículas do fluido; e as forças de ação do fluido sobre as paredes dos vasos que as contêm são perpendiculares [48,109]. Desta forma com base nos princípios da hidrostática, bem como da definição física de pressão e da aplicação das leis de Newton e de conceitos de trigonometria, foi criada uma sobreposição de princípios que explicasse o método e que pudesse explicar as várias variáveis que o afetam. Para determinar os valores de pressão total foi utilizado a pressão atmosférica ao nível do mar, 101325 Pascal (Pa) e um valor constante da aceleração gravítica de 9.80665 m/s^2 [48,109,139].

Todos os dados foram submetidos a análise de variância (ANOVA, *general linear model*) através do *software* SPSS (*Statistical Package for the Social Sciences, 2010*) para averiguar se havia diferenças estatisticamente significativas entre eles. Os valores são expressos como média \pm desvio padrão e nos testes estatísticos de comparações de médias, as diferenças são consideradas estatisticamente significativas quando $P < 0.05$. O coeficiente de correlação de Pearson foi utilizado para verificar a força da associação de variáveis. A correlação entre as variáveis é tanto maior quanto mais próximo estiver de 1 o coeficiente de correlação. Para avaliar se o peso influencia a PIA foi utilizado o teste de regressão linear, sendo considerado que o modelo de regressão prediz a variável se $P < 0.05$. Foi também calculado o coeficiente de regressão linear para comparar as medições entre o método direto e os métodos indiretos (MT e MI).

3.3 – Resultados

3.3.1 - Sobreposição de princípios biofísicos

Com base nos princípios da mecânica de fluidos e nas aplicações da hidrostática, escrevemos a seguinte sobreposição de princípios físicos de forma a tentar explicar a PIA e a sua medição pelo MT (Figura 3-7):

1. Segundo a definição teórica da PIA, esta é a pressão que se faz sentir dentro da cavidade abdominal [48,109]: Como este estudo foi realizado num modelo animal não vivo, tanto a respiração como a contração muscular estão ausentes. Assim, a PIA resulta do somatório da pressão exercida pelos músculos (P_m), da pressão de todo o conteúdo peritoneal (P_c) e da pressão exercida pelas estruturas ósseas (P_b) na área de superfície da cavidade abdominal (ASCA), obtendo-se a seguinte equação:

$$\text{Pressão intra - abdominal (PIA)} = P_m + P_c + P_b \quad (3.3)$$

2. A representação esquemática das pressões envolvidas na PIA e no MT estão representadas na Figura 3-7. A pressão no interior da bexiga é representada por P_1 e representa a pressão do fluido neste ponto. Este está conectado com o sistema métrico da coluna de água sendo P_2 a pressão na coluna de água. De acordo com o princípio de Pascal, a pressão exercida num ponto do fluido é transmitida a todo o fluido [48,109]. De acordo com este princípio escreve-se a seguinte equação que representa o equilíbrio do fluido.

$$P_1(\text{Pressão no centro da bexiga}) = P_2(\text{Pressão na coluna de fluidos}) \quad (3.4)$$

3. Segundo a lei fundamental da Hidrostática, quando existe equilíbrio hidrostático, a pressão de um líquido é igual à pressão atmosférica, mais o produto da densidade com a aceleração gravítica (g) e a altura do líquido (h) [48,111]. Contudo, no caso específico do MT, a bexiga não pode ser entendida como um recipiente estático uma vez que se encontra sujeita à pressão dos músculos (P_m), pressão de todo o conteúdo peritoneal (P_c) e à pressão exercida pelos próprios ossos (P_b) (Figura 3-7). Assim, o equilíbrio representa-se da seguinte maneira para P_1 e P_2 :

$$P_1 = (P_0 + \rho gh_1) + P_m + P_c + P_b \quad (3.5)$$

$$P_2 = P_0 + \rho gh_2 \quad (3.6)$$

Reescrevendo a equação (3.4) utilizando a equação (3.5) e (3.6) originamos a equação (3.7).

$$P_1 = P_2 \quad (3.4)$$

$$(P_0 + \rho gh_1) + P_m + P_c + P_b = P_0 + \rho gh_2 \quad (3.7)$$

A equação (3.7) reescrita com a eliminação de P_0 e colocando em evidência a densidade e a aceleração gravítica origina a equação (3.8).

$$P_m + P_c + P_b = \rho g (h_2 - h_1) \quad (3.8)$$

Em suma, pelo teorema de vasos comunicantes que tem como base a lei de Stevin, a pressão exercida pelos músculos e por todo o conteúdo peritoneal na parede vesical é proporcional à

diferença de alturas entre as colunas de água, visto que a densidade do líquido e a gravidade são constantes.

- O valor da medição direta da PIA e o valor da pressão no centro da bexiga (P_1) deve ser igual à pressão na coluna de fluido do manómetro (P_2) (Figura 3-7). Através da sobreposição de princípios biofísicos tentámos verificar a igualdade:

$$\begin{aligned} \text{Medição directa da PIA} &= P_1 (\text{Pressão no centro da bexiga}) \\ &= P_2 (\text{Pressão na coluna de fluido do manómetro}) \end{aligned} \quad (3.9)$$

De forma a comprovar a veracidade da sobreposição de princípios criada, foi efetuada a determinação de todas as variáveis necessárias para o cálculo da PIA no modelo de cadáver de cão e a medição da PIA por métodos diretos e indiretos.




Figura 3-7- Representação esquemática das forças envolvidas no método transvesical. P_0 representa a pressão atmosférica, P_1 o ponto de pressão no centro da bexiga, P_2 a pressão da coluna de água, h_1 a altura do fluido na bexiga, h_2 a altura do

fluido na coluna de água, ρ refere-se à densidade, g a aceleração gravítica, P_m a pressão exercida pelos músculos, P_c a pressão exercida pelo conteúdo peritoneal e P_b a pressão exercida pelos ossos.

3.3.2 - Valores da Pressão Intra-abdominal

A PIA foi obtida por 3 métodos, 1 direto e 2 indiretos em várias posições corporais, decúbito lateral, ventral, dorsal, Trendelemburg e Trendelenburg reversa.

a) - Método Direto

As medições de pressão por sensor direto na cavidade abdominal deram leituras muito constantes em todas as posições. No decúbito lateral as pressões médias foram de 3.07 ± 3.04 mmHg, no ventral de 2.31 ± 3.38 mmHg, no dorsal de 1.93 ± 3.44 mmHg, na posição Trendelemburg 2.35 ± 3.22 mmHg e por último na posição Trendelenburg reversa 2.24 ± 3.29 mmHg (Tabela 3-1).

Tabela 3-1- Valores médios da PIA em mmHg obtidos por medição direta.

| Posição corporal | Limite inferior | Limite superior | Média \pm Desvio padrão |
|-----------------------|-----------------|-----------------|---------------------------|
| Lateral | 0.00 | 13.00 | 3.07 ± 3.04 |
| Ventral | - 2.00 | 13.00 | 3.31 ± 3.38 |
| Dorsal | 0.00 | 14.00 | 1.93 ± 3.44 |
| Trendelemburg | -2.00 | 13.00 | 2.34 ± 3.22 |
| Trendelenburg reversa | -3.00 | 13.00 | 2.24 ± 3.52 |

A comparação dos valores diretos da PIA nas várias posições não evidenciou diferenças estatisticamente significativas entre eles ($P=0.765$).

A comparação das medições diretas com as medições do método transvesical, na posição lateral, através do modelo de regressão linear revelou um coeficiente de regressão de 0.76. A comparação do método direto com a manometria intra-gástrica revelou um coeficiente de 0.08.

b) - Método Transvesical

As medições de pressão pelo MT deram leituras variáveis sobretudo nas posições com um ângulo de inclinação. No decúbito lateral as pressões médias foram de 4.52 ± 3.12 mmHg, no ventral de 3.59 ± 2.94 mmHg, no dorsal de 3.40 ± 3.43 mmHg, na posição Trendelemburg 2.57 ± 3.14 mmHg e por último na posição Trendelenburg reversa 4.55 ± 2.98 mmHg (Tabela 3-2).

Tabela 3-2 - Valores médios da PIA em mmHg obtidos pelo método transvesical.

| Posição corporal | Limite inferior | Limite Superior | Média ± Desvio padrão |
|------------------------------|------------------------|------------------------|------------------------------|
| Lateral | 0.29 | 13.99 | 4.52±3.12 |
| Ventral | 0.00 | 11.55 | 3.59±2.94 |
| Dorsal | 0.00 | 12.65 | 3.40±3.43 |
| Trendelemburg | 0.00 | 11.25 | 2.57±3.14 |
| Trendelenburg reversa | 0.00 | 11.18 | 4.55 ± 2.98 |

As comparações dos valores da PIA nas várias posições não evidenciaram diferenças estatisticamente significativas entre elas ($P=0.091$) no decúbito lateral, ventral e dorsal. A posição de Trendelenburg e Trendelenburg reversa demonstrou diferenças estatisticamente significativas com o decúbito lateral ($P<0.05$).

c) - Método Manometria intra-gástrica

Nas medições de pressão pelo MI registaram-se leituras muito inconstantes, sobretudo nos planos inclinados. No decúbito lateral, as pressões médias foram de 4.73 ± 2.16 mmHg, no ventral de 3.04 ± 1.55 mmHg, no dorsal de 2.59 ± 1.99 mmHg, na posição Trendelemburg 7.14 ± 2.72 mmHg e por último na posição Trendelenburg reversa 0.11 ± 0.28 mmHg (Tabela 3-3).

Tabela 3-3 - Valores médios da PIA em mmHg obtidos por manometria Intra-gástrica.

| Posição corporal | Limite inferior | Limite superior | Média ± Desvio padrão |
|------------------------------|------------------------|------------------------|------------------------------|
| Lateral | 1.47 | 10.67 | 4.73±2.16 |
| Ventral | 0.00 | 5.37 | 3.04±1.55 |
| Dorsal | 0.00 | 9.19 | 2.59±1.99 |
| Trendelemburg | 0.96 | 12.00 | 7.14±2.72 |
| Trendelenburg reversa | 0.00 | 0.88 | 0.11 ± 0.28 |

As comparações dos valores da PIA nas várias posições evidenciaram diferenças estatisticamente significativas entre eles (P=0.0001).

3.3.3 - Valor das Variáveis para cálculo da PIA

Após a necropsia foram determinadas todas as variáveis necessárias para o cálculo da PIA, sendo os valores médios apresentados na Tabela 3-4. O peso médio das vísceras foi de 1.53 ± 0.77 Kg, que representa uma força média de 14.95 ± 7.57 Newton (N), o peso médio dos músculos abdominais e pele foi de 0.27 ± 0.16 Kg que representa uma força de 2.59 ± 1.52 N.

Os valores da área de superfície da bexiga, foram calculados através do programa de cálculo computacional Matlab, sendo os valores médios de $6.17 \times 10^{-3} \pm 5.05 \times 10^{-3}$ m². Os volumes médios da bexiga foram de $1.08 \times 10^{-4} \pm 1.21 \times 10^{-4}$ m³. Relativamente aos valores morfométricos do estômago verificaram-se valores médios de área de superfície de $3.55 \times 10^{-2} \pm 1.65 \times 10^{-2}$ m² e um volume médio de $1.16 \times 10^{-3} \pm 1.01 \times 10^{-3}$ m³.

Os valores calculados da área de superfície corporal foram de 0.52 ± 0.17 m² e os valores da área de superfície da cavidade abdominal de $9.69 \times 10^{-2} \pm 2.93 \times 10^{-2}$ m². A cavidade abdominal apresentou um volume médio de $2.15 \times 10^{-3} \pm 1.17 \times 10^{-3}$ m³ (Tabela 3-4).

Tabela 3-4- Variáveis de cálculo, limite inferior e superior, média e desvio padrão.

| Parâmetro | Limite inferior | Limite superior | Média \pm Desvio padrão |
|--|-----------------------|-----------------------|---|
| Peso (Kg) | 4.00 | 25.00 | 12.04 \pm 5.67 |
| Peso da pele e músculos (Kg) | 0.09 | 0.73 | 0.27 \pm 0.16 |
| Peso das vísceras (Kg) | 0.47 | 3.34 | 1.53 \pm 0.77 |
| Força da pele e dos músculos (N) | 0.88 | 7.15 | 2.59 \pm 1.52 |
| Força das vísceras (N) | 4.60 | 32.70 | 14.95 \pm 7.57 |
| Volume da bexiga (m ³) | 1.00×10^{-5} | 6.00×10^{-5} | $1.08 \times 10^{-4} \pm 1.21 \times 10^{-4}$ |
| Área de superfície da bexiga (m ²) | 1.30×10^{-3} | 2.73×10^{-2} | $6.17 \times 10^{-3} \pm 5.05 \times 10^{-3}$ |
| Área de superfície da cavidade abdominal (m ²) | 0.05 | 0.16 | $9.69 \times 10^{-2} \pm 2.93 \times 10^{-2}$ |
| Volume abdominal | 1.00×10^{-3} | 6.00×10^{-3} | $2.15 \times 10^{-3} \pm 1.17 \times 10^{-3}$ |
| Área de superfície do estômago (m ²) | 9.40×10^{-3} | 8.52×10^{-2} | $3.55 \times 10^{-2} \pm 1.65 \times 10^{-2}$ |
| Volume do estômago (m ³) | 1.00×10^{-5} | 3.70×10^{-3} | $1.16 \times 10^{-3} \pm 1.01 \times 10^{-3}$ |
| Área de superfície corporal (m ²) | 0.25 | 0.86 | 0.52 \pm 0.17 |

3.3.4 - Cálculo da PIA pela sobreposição de princípios físicos

Com a determinação de todas as variáveis efetuada em cada indivíduo, os valores foram substituídos na sobreposição de princípios para determinar a premissa inicial, de acordo com a equação (3.9). O cálculo da PIA segundo a sobreposição de princípios foi efetuado utilizando os valores obtidos na posição de decúbito lateral.

Cálculo da pressão em P_1

A pressão em P_1 foi calculada no ponto central da bexiga (Figura 3-7), sendo uma pressão com várias componentes: a pressão hidrostática do fluido, a pressão exercida pela pele e músculos (P_m), a pressão exercida pelas vísceras (P_c) e a pressão exercida pela componente óssea (P_b). O somatório destas pressões é exercido na área de superfície abdominal. Assim a pressão em P_1 é dada pela equação (3.5):

$$P_1 = (P_0 + \rho g h_1) + P_m + P_c + P_b \quad (3.5)$$

No caso específico do decúbito lateral, a pressão exercida pelos músculos e pele, é calculada pela força exercida pelos mesmos por unidade de área, neste caso da cavidade abdominal (ASCA). A pressão exercida pelas vísceras (P_c) é igual à força exercida pelo peso das vísceras sobre a área (ASCA) e a pressão exercida pelos ossos (P_b) é igual a zero porque o vetor do peso está apoiado na mesa. Os resultados médios calculados de P_1 foram de 101694.83 ± 300.78 Pascal (Pa) (Tabela 3-5).

Cálculo da pressão em P_2

O cálculo da pressão total em P_2 foi calculado pela lei fundamental da hidrostática, sendo a pressão na coluna de fluido igual ao somatório da pressão atmosférica mais o produto da densidade do líquido,

da aceleração gravítica e da altura da coluna de fluido. Assim o valor da pressão em P_2 é dado pela equação (3.6):

$$P_2 = P_0 + \rho gh_2 \quad (3.6)$$

Os resultados médios calculados de P_2 foram de 101926.84 ± 415.44 Pa (Tabela 3-5).

Tabela 3-5- Variáveis de cálculo, limite inferior e superior, média e desvio padrão em Pascal.

| Parâmetro | Limite inferior | Limite superior | Média ± Desvio padrão |
|--|------------------------|------------------------|------------------------------|
| P₁ (Pascal) | 101580.42 | 101809.24 | 101694.83±300.78 |
| P₂ (Pascal) | 101716.66 | 102021.03 | 101838.67±400.08 |
| PIA direta obtida por sensor + P₀ (Pascal) | 101588.39 | 101898.32 | 101766.34±407.39 |

3.3.4 - Comparação de valores obtidos pela sobreposição de princípios físicos

Se compararmos os valores calculados de P_1 e P_2 observamos que os valores não apresentam diferenças estatisticamente significativas entre si ($P=0.07$). Comparando os valores calculados de P_1 com P_2 e as medições diretas do sensor da PIA (Equação (3.9)) verificou-se que estes também não apresentaram diferenças estatisticamente significativas entre si ($P=0.192$), o que indica que os valores diretos de PIA são idênticos aos valores calculados para P_1 (ponto dentro da bexiga) e para P_2 (ponto na coluna de água). O coeficiente de correlação de Pearson foi utilizado para verificar a força da associação de variáveis tendo resultado uma correlação alta entre a variável P_1 e P_2 (cc, 0.737), uma correlação média entre P_2 e a PIA medida diretamente por sensor (cc, 0.342) e uma correlação mais baixa entre a P_1 e a PIA medida diretamente (cc, 0.02). Os níveis de correlação são significativos bilateralmente para o nível 0.01.

3.3.6 - Variáveis que influenciam a medição da PIA

Existem diversas variáveis que podem influenciar a medição da PIA aumentando ou diminuindo a mesma. De todas as variáveis descritas na literatura, tentamos explicar a sua influência utilizando a sobreposição de princípios físicos construída e validada nos pontos anteriores:

a) - Características fisiológicas e morfológicas do individuo

O peso é uma das variáveis que leva ao aumento da PIA, verificando-se valores mais altos em pacientes obesos [22,123]. No nosso estudo verificou-se que a PIA e o peso estavam associados estatisticamente apresentando, contudo, um grau de correlação baixo ($cc=0.23$).

Aplicando a sobreposição de princípios físicos criada, de forma a testar a variável, esta demonstra como o peso afeta a PIA. Considere-se a Figura 3-7 e nela as pressões P_1 e P_2 traduzidas pela equação (3.4):

$$P_1(\text{Pressão no centro da bexiga}) = P_2(\text{Pressão na coluna de fluidos}) \quad (3.4)$$

Considerando todas as pressões aplicadas em P_1 e P_2 , a partir da equação (3.4) obtém-se a equação (3.7) como anteriormente demonstrado.

$$(P_0 + \rho gh_1) + P_m + P_c + P_b = P_0 + \rho gh_2 \quad (3.7)$$

Segundo a definição de pressão, a pressão média exercida numa superfície é, por definição, igual ao quociente da intensidade da força de pressão pela área da superfície (3.1) [48,109]. A força segundo a segunda lei de Newton corresponde à multiplicação da massa pela aceleração gravítica [109,139]. Se

o peso vivo do animal aumenta, a massa de todos os tecidos aumenta, havendo um aumento proporcional da massa do conteúdo visceral (M_c), dos músculos abdominais (M_m) e da massa de osso (M_b). Este aumento leva a que a força exercida por cada um dos componentes F_c , F_m , e F_b , (resultantes de M_c , M_m , e M_b , respetivamente), por unidade de área abdominal seja maior. Reescrevendo a equação (3.7) com a formulação de pressão, cociente da força por unidade de área, obtém-se a equação (3.10)

$$(P_0 + \rho g h_1) + \frac{F_c}{ASCA} + \frac{F_m}{ASCA} + \frac{F_b}{ASCA} = P_0 + \rho g h_2 \quad (3.10)$$

Introduzindo agora na equação (3.10) a segunda lei de Newton, obtém-se a equação (3.11):

$$(P_0 + \rho g h_1) + \frac{\uparrow M_c g}{ASCA} + \frac{\uparrow M_m g}{ASCA} + \frac{\uparrow M_b g}{ASCA} = P_0 + \rho g h_2 \quad (3.11)$$

Eliminando a pressão atmosférica (P_0) de ambos os lados da igualdade e colocando em evidência a densidade e a aceleração gravítica ficamos com a equação (3.12):

$$\frac{\uparrow M_c g}{ASCA} + \frac{\uparrow M_m g}{ASCA} + \frac{\uparrow M_b g}{ASCA} = \rho g (h_2 - h_1) \quad (3.12)$$

Se todos os parâmetros dependentes da massa sobem, e como a densidade (ρ) e a aceleração gravítica (g) são contantes, obrigatoriamente o diferencial de alturas da coluna de fluidos vai ser superior (Figura 3-8) o que pode reescrever-se pela seguinte equação (3.13):

$$\uparrow P_m + \uparrow P_c + \uparrow P_b = \uparrow (h_2 - h_1) \quad (3.13)$$

Assim, o valor aumentado de P_1 e P_2 leva necessariamente a um aumento da PIA por causa da equação (3.9).




Figura 3-8- Representação esquemática das forças envolvidas no método transvesical quando existe aumento do peso. P_0 representa a pressão atmosférica, P_1 ponto de pressão no centro da bexiga, P_2 a pressão da coluna de água, h_1 altura do fluido na bexiga, h_2 a altura do fluido na coluna de água, ρ a densidade, g a aceleração gravítica; a letra F representa os vetores de força sendo F_m a força dos músculos, F_c a força do conteúdo visceral e F_b a força exercida pelos ossos; a letra P refere-se aos estados de Pressão sendo P_m a pressão exercida pelos músculos, P_c a pressão exercida pelo conteúdo peritoneal e P_b a pressão exercida pelos ossos. A letra A representa a área onde são aplicadas as forças, sendo a ASCA a área de superfície da cavidade abdominal.

Outra das variáveis fisiológicas descritas na literatura que pode levar à alteração da PIA é a contração dos músculos abdominais. Esta funciona como uma força externa exercida no abdómen elevando a PIA [124,125]. Quando utilizamos a sobreposição de princípios para calcular a PIA, mimetizando uma força de contração abdominal de 10 Kg efetuada por pressão, obtemos resultados médios de 102830.25 ± 476.09 Pa (Figura 3-9). Apresentando estes valores diferenças estatisticamente significativas ($P=0.0005$) com os valores normais.




Figura 3-9 - Representação esquemática das forças envolvidas no método transvesical quando existe contração muscular. P_0 representa a pressão atmosférica, P_1 o ponto de pressão no centro da bexiga, P_2 a pressão na coluna de água, h_1 a altura do fluido na bexiga, h_2 a altura do fluido na coluna de água, ρ densidade, g a aceleração gravítica, sendo F_m a força dos músculos; a letra P refere-se aos estados de Pressão sendo P_m a pressão exercida pelos músculos, P_c a pressão exercida pelo conteúdo peritoneal e P_b a pressão exercida pelos ossos e a ASCA representa a área de superfície da cavidade abdominal.

Fisicamente, o aumento da PIA é conseguido pelo aumento da força exercida pelos músculos quando a área se mantém praticamente igual elevando assim a pressão dos músculos. Pela equação (3.3), se existe o aumento de um dos componentes que forma a PIA, este irá provocar um aumento da mesma pois são diretamente proporcionais.

A co-activação do diafragma e dos músculos abdominais nos movimentos respiratórios é outra das variáveis que também pode afetar a PIA [124,126]. De forma a comprovar a influência da respiração na PIA foi realizada uma pressão intermitente positiva na cavidade torácica do nosso modelo até atingir uma pressão de 10 mm Hg, de forma a mimetizar o momento de inspiração. As medições da PIA mimetizando uma pressão torácica de inspiração apresentaram valores médios de 102019.19 ± 568.30 Pa. Se compararmos estes valores com os valores de PIA obtidos por método direto no decúbito lateral (101743.36 ± 407.39 Pa), estes apresentam diferenças estatisticamente significativas ($P=0.038$).

Os movimentos inspiratórios, fisiologicamente, provocam alterações de volume da cavidade abdominal e torácica. O diafragma delimita a cavidade torácica da abdominal e o seu movimento provoca uma alteração de área na inspiração e expiração (Figura 3-10).

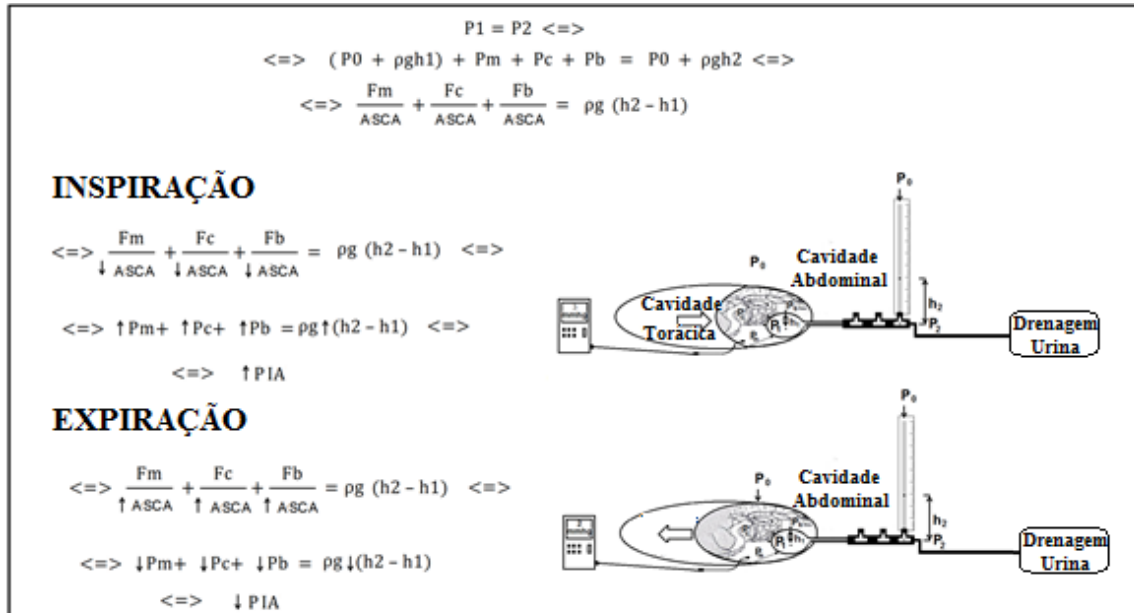


Figura 3-10- Representação esquemática das forças envolvidas no método transvesical nos dois momentos distintos da respiração, inspiração e expiração. As setas colocadas na cavidade torácica representam a diminuição da cavidade torácica o que provoca uma diminuição de área. P_0 representa a pressão atmosférica, P_1 o ponto de pressão no centro da bexiga, P_2 a pressão da coluna de água, h_1 a altura do fluido na bexiga, h_2 a altura do fluido na coluna de água, ρ a densidade, g a aceleração gravítica, sendo F_m a força dos músculos; a letra P refere-se aos estados de pressão sendo P_m a pressão exercida pelos músculos, P_c a pressão exercida pelo conteúdo peritoneal e P_b a pressão exercida pelos ossos e a $ASCA$ a representa a área de superfície da cavidade abdominal.

Na inspiração, os pulmões aumentam de volume, sendo o diafragma deslocado caudalmente provocando a diminuição, por instantes, da área da cavidade abdominal. Assim, segundo a formulação de princípios anteriormente explicada, se utilizarmos a equação (3.7), que resulta da equação (3.4) reescrita:

$$P_1 (\text{Pressão no centro da bexiga}) = P_2 (\text{Pressão na coluna de fluidos}) \quad (3.4)$$

$$\Leftrightarrow (P_0 + \rho gh_1) + P_m + P_c + P_b = P_0 + \rho gh_2 \Leftrightarrow \quad (3.7)$$

Se reescrevermos a equação (3.7) conjugando a definição matemática de pressão iremos obter a equação (3.10). Ao eliminar P_0 e colocando em evidência a densidade e a aceleração gravítica irá originar a equação (3.14):

$$\frac{F_m}{ASCA} + \frac{F_c}{ASCA} + \frac{F_b}{ASCA} = \rho g (h_2 - h_1) \quad (3.14)$$

Se existe uma diminuição da área abdominal (ASCA) irá haver um aumento da pressão exercida por cada uma das componentes da PIA.

$$\frac{F_m}{\downarrow ASCA} + \frac{F_c}{\downarrow ASCA} + \frac{F_b}{\downarrow ASCA} = \rho g \uparrow (h_2 - h_1) \quad (3.14)$$

Como a densidade e aceleração gravítica permanecem constantes a equação (3.8) mimetiza o aumento.

$$\uparrow P_m + \uparrow P_c + \uparrow P_b = \rho g \uparrow (h_2 - h_1) \quad (3.8)$$

O aumento de cada um dos lados da equação irá levar ao aumento do valor de P_1 e P_2 pela equação (3.4) o que leva necessariamente a um aumento da PIA pela equação (3.9).

Na expiração acontece o inverso, sendo o diafragma deslocado cranialmente provocando um aumento da área abdominal. Ao utilizarmos a equação (3.14):

$$\frac{F_m}{ASCA} + \frac{F_c}{ASCA} + \frac{F_b}{ASCA} = \rho g (h_2 - h_1) \quad (3.14)$$

E como a pressão e a área são inversamente proporcionais, se houver um aumento da área (ASCA) irá levar a uma diminuição momentânea da pressão de cada componente da PIA:

$$\frac{F_m}{\uparrow ASCA} + \frac{F_c}{\uparrow ASCA} + \frac{F_b}{\uparrow ASCA} = \rho g \downarrow (h_2 - h_1) \quad (3.14)$$

$$\downarrow P_m + \downarrow P_c + \downarrow P_b = \rho g \downarrow (h_2 - h_1) \quad (3.8)$$

A diminuição de cada componente pode ser observada na equação (3.8) traduzindo-se numa diminuição do valor de P_1 e P_2 pela equação (3.4) o que leva necessariamente a uma diminuição da PIA pela equação (3.9).

b- Posição corporal de medição

Neste estudo, a comparação dos valores da PIA obtidos pelos métodos diretos nas várias posições, não evidenciaram diferenças estatisticamente significativas entre eles ($P=0.765$). Este facto leva a concluir que não existe alteração da PIA quando se muda de posição. Contudo a comparação da PIA medida pelos métodos indiretos revelou que o TM e o MI apresentavam diferenças estatisticamente significativas nas posições de Trendelemburg e Trendelemburg reversa ($P<0.05$) quando comparados com as leituras obtidas na posição padrão de medição, decúbito lateral.

Achamos que este facto está diretamente relacionado com os princípios da hidrostática e com o movimento do fluido nas colunas. Segundo a sobreposição de princípios formulada, se a medição da PIA for realizada em decúbito ventral, o equilíbrio de pressão traduz-se da forma já anteriormente referida na Figura 3-7. Ao inclinarmos cranialmente o corpo (posição de Trendelemburg) ou inclinarmos caudalmente o corpo (posição de Trendelemburg reversa) irá ser criado um novo equilíbrio de pressões. O novo equilíbrio de pressões, acontece porque ao criarmos um ângulo de inclinação (ângulo Θ), as forças submetidas nos fluidos vão alterar-se. Utilizando a sobreposição de princípios físicos anteriormente utilizada e partindo do pressuposto da equação (3.4) que aqui se rescreve:

$$P_1(\text{Pressão no centro da bexiga}) = P_2 (\text{Pressão na coluna de fluidos}) \quad (3.4)$$

Contudo se colocarmos o corpo numa posição de Trendelemburg, alteramos o ângulo da coluna de fluidos tendo que entrar com esta nova condição de equilíbrio. Ao aumentarmos o ângulo Θ (Figura 3-11) para passar para a posição de Trendelemburg alterou-se automaticamente o equilíbrio hidrostático do manómetro de água. Neste novo equilíbrio, passamos a ter uma nova situação onde temos que entrar com o ângulo de inclinação da coluna de água. Assim, ao aumentarmos o ângulo, aumentamos a altura da coluna de fluido em P_2 , apresentando esta duas componentes. Assim temos a pressão exercida pela coluna de fluido ao longo da coluna L e a componente de pressão exercida pelo fluido contido no manómetro de água, o que pode ser traduzido pela equação (3.15)

$$(P_0 + \rho gh_1) + P_m + P_c + P_b = P_0 + \rho gh_3 + \rho gh_2 \quad (3.15)$$

Estas duas componentes levam a um aumento da pressão hidrostática e a um movimento de fluido no sentido da bexiga. Para realizar o cálculo da componente da altura h_3 (Figura 3-11) temos que recorrer a cálculo trigonométrico ficando com a seguinte sobreposição:

$$(P_0 + \rho gh_1) + P_m + P_c + P_b = P_0 + (\rho gL \sin \theta) + \rho gh_2 \quad (3.16)$$

Nesta nova situação de equilíbrio, a pressão exercida pelo conteúdo peritoneal na bexiga, também diminui, pois, a força do peso está a ser aplicada no diafragma. Assim estas condicionantes levam a um deslocamento do fluido para a bexiga levando a uma subvalorização da pressão lida no manómetro de água. Nas medições efetuadas no modelo não vivo da cavidade abdominal as leituras apresentaram

resultados médios de 2.57 ± 3.14 mmHg. Valores estes consideravelmente, mais baixos do que as leituras realizadas no decúbito lateral, ventral e dorsal.

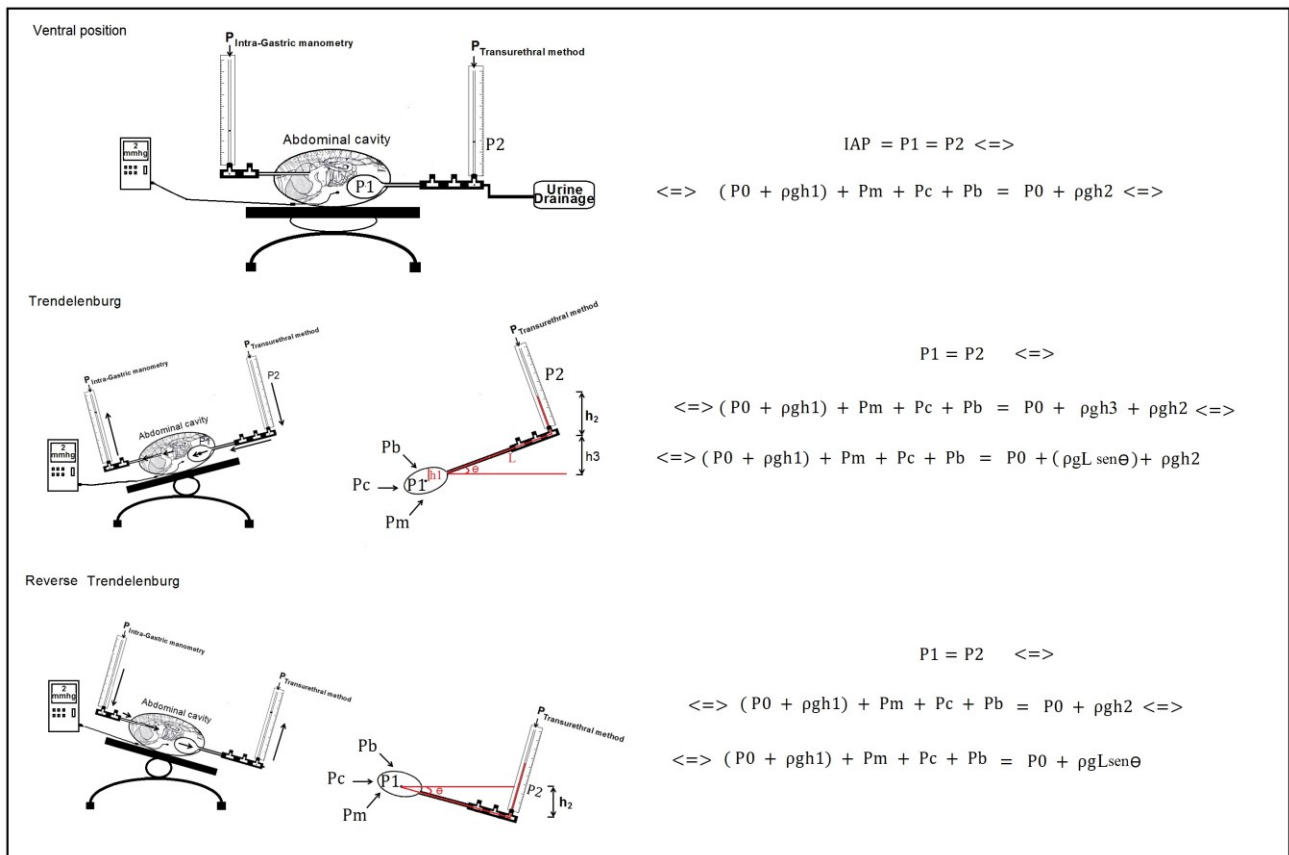


Figura 3-11- Representação esquemática das forças envolvidas no método transvesical após alteração da posição. P_0 representa a pressão atmosférica, P_1 o ponto de pressão no centro da bexiga, P_2 a pressão da coluna de água, h_1 a altura do fluido na bexiga, h_2 a altura do fluido na coluna de água, h_3 a porção da altura do plano inclinado, L corresponde ao segmento da coluna; θ o ângulo de inclinação; ρ a densidade, g a aceleração gravítica, sendo F_m a força dos músculos; a letra P refere-se aos estados de Pressão sendo P_m a pressão exercida pelos músculos, P_c a pressão exercida pelo conteúdo peritoneal e P_b a pressão exercida pelos ossos.

Na posição de Trendelenburg reversa acontece o contrário. Nesta nova condição de equilíbrio, o fluido contido na bexiga e o fluido contido na coluna L aumentam a sua altura, levando a um aumento da pressão hidrostática na coluna de fluidos. Este aumento traduz-se num deslocamento do fluido no mesmo sentido do manómetro de água. O aumento das forças exercidas pela coluna de líquido, tal como o aumento das forças exercidas pelo conteúdo visceral na superfície cranial da bexiga, levam a um aumento da P_2 para valores médios de 4.55 ± 2.98 mmHg.

c) Variáveis dependentes do operador

Está descrito que o nivelamento do manómetro de água no MT a nível da sínfise púbica pode alterar a medição da PIA [11]. A formulação biofísica que explica o fenómeno é muito idêntica ao que acontece quando mudamos a posição para Trendelemburg ou Trendelemburg reversa. Assim, se aumentarmos a altura do manómetro de água em relação à crista ilíaca, o valor de PIA é subestimado. Este facto acontece porque ao aumentarmos a altura da coluna de água, levamos a um aumento da pressão hidrostática levando a um movimento de fluido no sentido da bexiga. Se baixarmos o manómetro de água em relação à crista ilíaca estamos a diminuir a altura da coluna de fluido e, nomeadamente, da pressão na coluna. Assim, a pressão na bexiga vai ser superior e vai desencadear um movimento de fluido no sentido da coluna de água provocando uma sobrestimação de PIA (Figura 3-12).

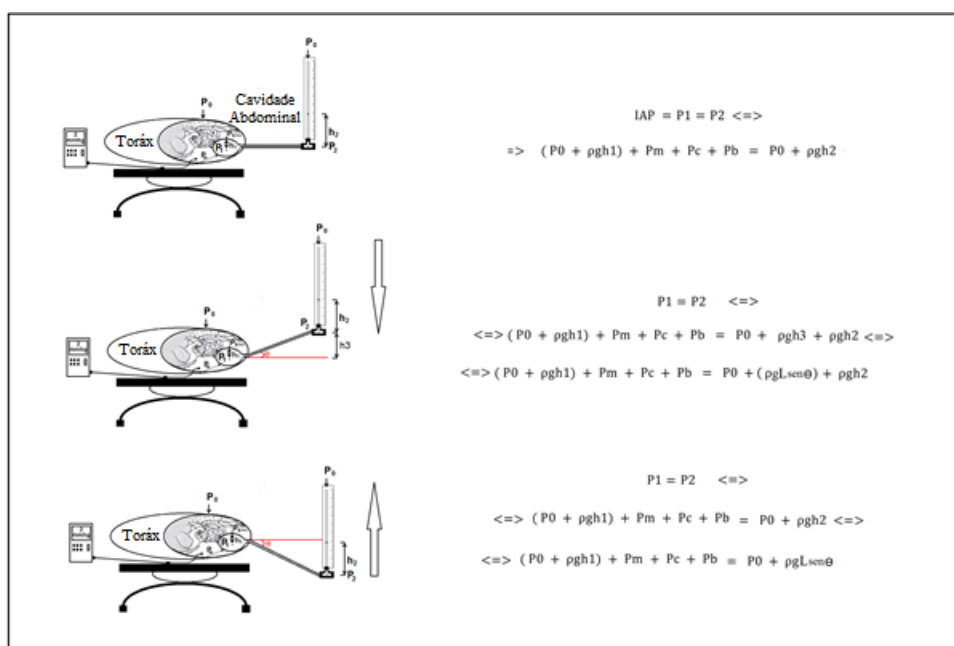


Figura 3-12- Representação esquemática das forças envolvidas no método transvesical variando a posição do manómetro de água. P_0 representa a pressão atmosférica, P_1 o ponto de pressão no centro da bexiga, P_2 a pressão da coluna de água, h_1 a altura do fluido na bexiga, h_2 a altura do fluido na coluna de água, h_3 a porção da altura do plano inclinado, L corresponde ao segmento da coluna; θ o ângulo de inclinação; ρ a densidade, g a aceleração gravítica, sendo F_m a força dos músculos; a letra P refere-se aos estados de Pressão sendo P_m a pressão exercida pelos músculos, P_c a pressão exercida pelo conteúdo peritoneal e P_b a pressão exercida pelos ossos.

Outra das variáveis que o operador pode influenciar na medição da PIA reside na escolha do volume residual instilado na bexiga [13]. O objetivo da instilação de um volume residual na bexiga, é para esta apresentar a quantidade fisiológica mínima para permitir o equilíbrio com o manómetro de água traduzindo a PIA. A instilação de um grande volume residual (V_u) na bexiga vai fazer aumentar o volume de fluido na mesma, provocando um aumento da força exercida (F_u) sem alteração da área (A_u). Estas alterações traduzem-se num aumento da pressão hidrostática da bexiga (P_u). A pressão hidrostática de um fluido também pode ser calculada pelo cociente entre a força (F) aplicada por unidade de área (A) [48,109]. As modificações ocorridas na bexiga vão ser transmitidas ao fluido e provocar um aumento do volume no manómetro de água (V_2), traduzindo-se num aumento da pressão hidrostática. Segundo a sobreposição de princípios físicos este facto traduz-se na equação (3.4)

$$P_1(\text{Pressão no centro da bexiga}) = P_2(\text{Pressão na coluna de fluidos}) \quad (3.4)$$

Em vez de calcularmos a pressão das componentes hidrostáticas pela equação fundamental da hidrostática, mas utilizarmos a definição física de pressão pela equação (3.1) ficamos com a equação (3.17):

$$P_o + \frac{F_u}{A_u} + P_m + P_c + P_b = P_o + \frac{F_2}{A_2} \quad (3.17)$$

Aplicando a segunda lei de Newton na componente da força do fluido, ficamos com o seguinte equilíbrio:

$$P_o + \frac{m_u g}{A_u} + P_m + P_c + P_b = P_o + \frac{m_2 g}{A_2} \quad (3.18)$$

Como a pressão exercida pelos músculos, conteúdo peritoneal e pela estrutura óssea (P_m , P_c , P_b) é constante (k) e a influência da pressão atmosférica anula-se, ficamos com a seguinte expressão:

$$\frac{m_u g}{A_u} + k = \frac{m_2 g}{A_2} \quad (3.19)$$

Aplicando a definição de densidade, que é resultado da divisão da massa pelo volume ficamos com:

$$\frac{\rho V_u g}{A_u} + k = \frac{\rho V_2 g}{A_2} \quad (3.20)$$

Assim a instilação de um grande volume na bexiga (V_u) provoca uma sobrestimação da PIA pois leva a aumento de V_2 pois todos os outros elementos se mantêm constantes, Figura 3-13.




Figura 3-13- Representação esquemática das forças envolvidas no método transvescical com instilação de grande volume residual. P_0 representa a pressão atmosférica, P_1 o ponto de pressão no centro da bexiga, P_2 a pressão da coluna de água, h_1 a altura do fluido na bexiga, h_2 a altura do fluido na coluna de água; ρ a densidade, g a aceleração gravítica, sendo F_u a força exercida pelo fluido contido na bexiga e F_2 a força exercida pela coluna de fluido no manómetro; a letra P refere-se aos estados de Pressão sendo P_u a pressão hidrostática do fluido na bexiga, P_m a pressão exercida pelos músculos, P_c a pressão exercida pelo conteúdo peritoneal e P_b a pressão exercida pelos ossos; a letra m representa a massa, sendo m_u a massa do fluido contido na bexiga e m_2 a massa de fluido contido no manómetro; a letra V representa o volume sendo V_u o volume contido na bexiga e V_2 o volume contido no manómetro; a letra A representa as áreas sendo A_u a área da bexiga e A_2 a área de secção do manómetro.

Quando colocamos um volume residual na bexiga de 5 ml/kg, que corresponde a cerca de 5 vezes mais do descrito na literatura e utilizamos a sobreposição de princípios para determinar a PIA obtivemos resultados médios de 219340.1 ± 56109.7 Pa. Estes resultados apresentaram diferenças estatisticamente significativas ($P < 0.05$) comparativamente às medições realizadas com 1 ml/kg tendo demonstrado uma sobrestimação de PIA aproximadamente duas vezes superior.

3.4 - Discussão

Com a modelação tridimensional da cavidade abdominal de cães, obtivemos um dos parâmetros cruciais na determinação da PIA: a área de superfície da cavidade abdominal. Numa segunda fase do trabalho elaborou-se a formulação matemática de um modelo biofísico baseado nos princípios da hidrostática, cujo objetivo foi fundamentar o MT (principal método utilizado para medição da PIA) e as variáveis que influenciam a PIA. O MT apesar de amplamente utilizado a sua baixa reprodutibilidade coloca em causa a sua fiabilidade [9–13,78].

Assim foi criado um modelo anatómico, que permitisse explicar e compreender melhor a génese da PIA. O conhecimento intrínseco das variáveis que a influenciam irá permitir uma maior facilidade na última fase de criação de um sistema de IC capaz de determinar a PIA através da monitorização multiparamétrica.

A importância da monitorização da PIA encontra-se bem documentada, assim como as alterações fisiopatológicas derivadas da hipertensão abdominal. É um parâmetro clínico com grande impacto no prognóstico do paciente responsável por provocar alterações marcadas em todos os sistemas orgânicos [35,39,41,45,142]. Estas alterações, quando verificadas, produzem a síndrome de compartimentalização, que apresenta uma taxa de mortalidade bastante elevada 50-80% [28,29]. Devido a este facto, a monitorização e a medição de forma fiável da PIA toma particular importância nas unidades de cuidados intensivos.

Dos métodos diretos e indiretos disponíveis para a sua monitorização o MT é o mais utilizado devido a apresentar um baixo custo, ser bastante prático de utilizar, permitir a leitura isolada ou contínua, ser um método minimamente invasivo em comparação com os métodos diretos e apresentar uma boa correlação de valores quando comparado com as medições diretas [9,75–77].

Nesta fase do trabalho tentou-se ainda, validar o uso do MT de forma a ultrapassar as suas limitações. A metodologia utilizada neste estudo, modelo animal não vivo, foi escolhida por três razões: 1- As dificuldades ligadas à experimentação em modelos vivos e todas as condicionantes éticas; 2- A dificuldade em criar um modelo artificial da cavidade abdominal; e por último 3- A dificuldade de erradicar algumas das variáveis descritas na literatura passíveis de alterar a medição da PIA. Para cumprir este fim, optou-se pela utilização de um modelo animal não vivo, de forma a eliminar algumas das variáveis descritas de influenciar a medição da PIA, conseguindo assim um maior controlo de variáveis. A utilização deste tipo de modelo permitiu assim o estudo da PIA isoladamente, sem ser influenciada pela contração muscular, reflexo de micção e respiração. Variáveis estas descritas na literatura de influenciarem a PIA e os métodos de aferição [10,125,134].

Este modelo anatómico devido à sua similaridade pode facilmente ser adaptado ao Homem uma vez que a sua principal diferença é a orientação anatómica dos órgãos. Isto deve-se aos humanos andarem sobre os membros pélvicos enquanto os cães se apoiam nos quatro membros o que poderá afetar a tensão da parede abdominal, o que poderá afetar a PIA. Esta e outras diferenças levam a diferentes valores de PIA entre espécies. Contudo o tipo de cavidade, os constituintes anatómicos e a definição da pressão abdominal são idênticas em ambas as espécies.

Os valores normais de PIA para a espécie humana estão entre 0.2 – 12.2 mmHg enquanto o intervalo normal para o cão é entre 0 – 3.75 mmHg, podendo chegar a valores de 11.25 mm Hg em animais submetidos a ovariectomia [15,17,143]. Recentemente Way e colaboradores (2014) descreveram valores médios de PIA superiores aos anteriormente descritos (5.9 ± 1.0 mmHg) [16]. No nosso estudo os valores de PIA obtidos pela metodologia direta encontram-se dentro dos limites

descritos para a espécie em todas as posições. No entanto, os valores de PIA obtidos podem ser considerados baixos em comparação com os estudos *in vivo* devido à diminuição da tensão dos tecidos, a inexistência de movimentos respiratórios e a ausência de contração pelos músculos abdominais. Está documentado que o bloqueio da contração muscular pode levar a uma diminuição de 25% da PIA se for realizado um bloqueio neuromuscular aquando a realização de cirurgia abdominal [144]. O efeito dos movimentos respiratórios na PIA foi estudado por Wilson (1933) que concluiu que havia um aumento da PIA durante a inspiração proporcional à profundidade da inspiração. Este também concluiu que não existe alteração da PIA na expiração normal [126]. Como no modelo animal não vivo, não existe movimentos respiratórios, não irá haver alteração da PIA medida, independentemente do mecanismo fisiológico. O facto dos valores da PIA em cadáveres serem similares aos valores *in vivo*, está diretamente relacionado com a definição da PIA, que não é nada mais que um estado de pressão. O estado de pressão da cavidade abdominal é determinado pelo índice de massa corporal, postura, atividade muscular da parede abdominal e respiração [8,26,145]. Esta definição teórica da PIA foi a razão pela qual o estudo foi realizado em modelo não vivo.

Os valores de PIA obtidos no nosso estudo pelos métodos indiretos (MT e MI), quando comparados com os valores obtidos pelo método direto utilizando um sensor, não revelaram diferenças estatisticamente significativas ($P > 0.05$) na posição lateral, ventral e dorsal. Dos métodos indiretos utilizados o MT apresentou os valores de correlação mais elevados, quando comparado com o método direto tal como está descrito na literatura [146]. O facto de a MI apresentar piores valores de correlação com os métodos diretos, pode ser devido ao facto do conteúdo gástrico não ser totalmente líquido e poder influenciar a leitura. Em estudos realizados *in vivo* apresenta-se também como explicação o facto das contrações peristálticas poderem influenciar a medição [9]. A utilização da MI em vez do MT é geralmente considerada por não interferir com a produção de urina e o risco de infeção ser mínimo [9].

A determinação dos parâmetros morfométricos individuais de cada cadáver, dentro do âmbito do procedimento de necropsia, foram de crucial importância de forma a obter os valores necessários, para substituição na sobreposição de princípios biofísicos. Os valores calculados da área de superfície corporal foram de $0.52 \pm 0.17 \text{ m}^2$ e da ASCA de $9.69 \times 10^{-2} \pm 2.93 \times 10^{-2} \text{ m}^2$. A cavidade abdominal apresentou um volume médio de $2.15 \times 10^{-3} \pm 1.17 \times 10^{-3} \text{ m}^3$ (Tabela 3-4). Para o cálculo direto de pressões, um dos fatores com maior importância é a área. Isto porque, a definição de pressão é o resultado das forças exercidas por unidade de área [87]. Assim sendo a ASCA é determinante para o cálculo físico da PIA. A determinação da ASCA, foi realizada recorrendo a uma fórmula baseada no peso e previamente determinada por métodos de modelação tridimensional. Estes métodos, apresentam alguma margem de erro associado quando comparados com as estruturas reais, estando descrito na literatura erros entre 2.9 % e 4.95 %, sendo este considerado um erro baixo [94,96,98]. Este tipo de metodologia foi adotado devido à dificuldade de medir uma cavidade orgânica de forma precisa.

A determinação física das dimensões de vísceras e de cavidades orgânicas, como o volume e a área de superfície, é muitas vezes um desafio nos vários campos da medicina [86,88–92]. Ao longo do tempo foram utilizadas e descritas muitas técnicas para este fim, como a: medição direta de um órgão com uma fita métrica [92,147]; decalcamento para papel da estrutura anatómica para medição da área de superfície [92,148]; medição da quantidade de líquido que perfaz uma cavidade para determinar um volume [86,91,149]; aplicação do princípio de Arquimedes para definir um volume [95,140]; fórmulas matemáticas baseadas em estruturas orgânicas e muitas outras técnicas [90–92,95,147]. A medição das áreas de superfície do estômago e da bexiga apresenta também um nível de dificuldade acrescido. A determinação das áreas é importante porque os métodos indiretos utilizam esta superfície de área para determinar a PIA. De forma a determinar estas medidas, com o menor erro associado, foi adotada uma técnica de processamento de imagem e cálculo por software matemático [141]. A técnica utilizada para medir as áreas da bexiga e do estômago foi uma técnica implementada, pela primeira vez para este fim, com enorme sucesso. Este procedimento além de ser bastante rápido de efetuar permite

determinar com exatidão a área de um órgão que unicamente só seria possível por métodos imagiológicos.

Após a determinação das áreas de superfície e de forma a realizar o cálculo matemático dos valores de pressão, foi necessário determinar as forças exercidas. A utilização do modelo em cadáver foi fundamental, uma vez que as únicas forças presentes são as exercidas pelo peso das estruturas. Assim, para obtermos outro dos parâmetros cruciais para a determinação da PIA, foi realizada a determinação do peso de todas as estruturas abdominais e através da segunda lei de Newton converteu-se os resultados nas forças exercidas.

A determinação de todos os valores morfométricos necessários permitiu a substituição das variáveis na sobreposição criada baseada em princípios biofísicos (equação (3.3), (3.4), (3.5), (3.6) e (3.7)). Assim, pudemos comparar valores de pressão calculados com valores de pressão determinados por métodos diretos e indiretos. Verificamos então, que o valor de pressão calculado para o ponto P_1 (equação (3.5) - ponto dentro da bexiga) não apresentava diferenças estatisticamente significativas ($P=0.07$) com o ponto de pressão P_2 (equação (3.6) - ponto na coluna de água). Isto significa que a pressão dentro da bexiga, ou seja, exercida por todo o conteúdo abdominal é idêntica ao valor de pressão demonstrado pelo manómetro de água. Comparando os valores calculados de P_1 e P_2 com as medições diretas da PIA por sensor (equação (3.9)), verificou-se que estes não apresentavam diferenças estatisticamente significativas entre si ($P=0.192$). Ou seja, a determinação direta da PIA por sensor é idêntica à PIA calculada no ponto P_1 , que por sua vez é idêntica à PIA calculada no ponto P_2 (método transvesical). Para avaliar a força de associação de variáveis foi calculado o coeficiente de correlação tendo-se verificado uma alta correlação entre a variável P_1 e P_2 (cc, 0.737), uma correlação média entre P_2 e a PIA medida diretamente por sensor (cc, 0.342) e uma correlação mais baixa entre a P_1 e a PIA medida diretamente (cc, 0.02). Estes resultados demonstraram que o MT é explicado fisicamente e pode ser utilizado para medição da PIA. As variações, obtidas entre P_1 , P_2 e os valores diretos da PIA obtidos por sensor só foram possíveis de determinar recorrendo a cálculo

computacional, o que acarreta um erro associado. Este pode ter influenciado o valor de P mais baixo, contudo o significado estatístico manteve-se. Para além disto, outras razões que podem explicar o valor de P baixo é a dimensão da amostra e o erro associado à determinação das forças do peso das estruturas. A utilização de cadáveres também pode levar a alterações físicas, como a perda de tensão da parede abdominal, gástrica e vesical, influenciando o valor da PIA. Apesar disto, a pressão continua a ser um estado físico em determinado momento temporal, calculado pelas forças exercidas por unidade de área [87].

A definição clínica da PIA é a de um estado de pressão na cavidade abdominal que é determinado pelo índice de massa corporal, postura, atividade muscular e respiração [1,121]. Neste trabalho devido ao modelo usado foi possível eliminar a contração muscular e os movimentos respiratórios resultando a PIA apenas da força exercida pelo índice de massa corporal na ASCA.

As fórmulas físicas criadas permitiram a validação do MT e a explicação das variáveis descritas na literatura como podendo influenciar a medição da PIA. Uma das variáveis fisiológicas que está descrita influenciar a PIA é o peso do indivíduo [22,123]. No nosso estudo verificou-se que existe entre a PIA e o peso uma associação estatística significativa de variáveis, segundo o modelo de regressão linear ($P=0.04$), apresentando, contudo, um grau de correlação baixo ($cc, 0.23$). O resultado obtido está em concordância com o descrito na literatura embora os valores apresentados nos estudos de Varela e Rader apresentem uma maior correlação estatística [22,123]. Este facto pode dever-se ao tipo de modelo utilizado no nosso estudo. O modelo em cadáver não apresenta a contração muscular, nem variações associadas à respiração. Contudo, mesmo assim, verifica-se que à medida que aumenta o peso existe um aumento da PIA. Em termos físicos e utilizando a sobreposição de princípios criada facilmente se conclui, que se o peso aumentar e a ASCA se mantiver relativamente constante vai provocar um aumento da PIA de forma proporcional (Figura 3-8).

Outra das variáveis que influencia a PIA é a contração dos músculos abdominais. A prensa abdominal, corresponde em termos biofísicos a um aumento da força exercida na mesma área. No Homem a

contração dos músculos abdominais pode exercer uma força média suplementar na região abdominal de 46.4 Kg força [150]. Quando utilizamos a sobreposição de princípios para calcular a PIA, mimetizando uma força de contração abdominal de 10 Kg efetuada por pressão, verificou-se diferenças estatisticamente significativas ($P=0.0005$) com os valores normais (Figura 3-9). A contração do músculo detrusor, responsável pelo reflexo da micção, pode também influenciar a PIA de forma idêntica, mas atuando no fluido contido na bexiga. No estudo realizado por Johna e colaboradores em 1999, estes compararam as medições de PIA obtidas por medição direta com o MT. Estes concluíram que os valores obtidos pelo MT, apresentavam uma pressão superior, quando comparada com os valores de PIA obtidos por medição direta [10]. Os autores explicaram este facto com a atividade do músculo detrusor da bexiga. O despoletar do funcionamento do músculo, poderia ser provocado pela instilação da solução fisiológica na bexiga, a sua taxa de infusão ou a temperatura da solução salina instilada. A contração do músculo detrusor devido ao reflexo da micção é outro dos factos que pode levar à alteração da PIA devido ao aumento da força exercida. Isto pode também explicar as variações obtidas entre autores na medição da PIA em cães utilizando o MT. Recentemente Way e colaboradores (2014) descreveram valores médios de PIA superiores aos anteriormente descritos em cães utilizando o MT (5.9 ± 1.0 mmHg) [16,138]. Este facto pode ser devido ao MT apresentar uma linha de pressão superior tal como foi identificado por Johna e colaboradores.

A influência da contração muscular na medição da PIA pode ser muitas vezes ser detetada devido à forma como ocorre. Quando a contração ocorre, existe um período de contração muscular e outro de relaxamento muscular observando-se este facto na PIA através de um valor máximo e de um valor mínimo num curto intervalo de tempo [10].

Na literatura está descrito que PIA sofre um aumento durante a inspiração proporcional à sua profundidade [126,128]. Chieveley-Williams e colaboradores (2002) realizaram um estudo, em pacientes sob condições de ventilação assistida tendo concluído que a pressão vesical e a pressão venosa central promoviam um reflexo nos músculos respiratórios quando a pressão de suporte era

reduzida. No nosso estudo, os resultados obtidos de PIA com uma pressão torácica de 10 mmHg, quando comparados com os valores obtidos sem pressão torácica, revelaram diferenças estatisticamente significativas ($P=0.038$). Estes resultados estão de acordo com o descrito na literatura sendo os valores de PIA superiores na inspiração [126]. Em termos biofísicos e aplicando a sobreposição de princípios criada observa-se uma variação da área abdominal, na respiração com um aumento ou uma diminuição da área abdominal, consoante o momento de respiração o que provoca uma alteração da PIA (Figura 3-10).

Grande parte dos pacientes humanos acamados em unidades de cuidados intensivos é colocada com uma elevação na cabeça da cama, de forma a reduzir o risco de pneumonias associadas à ventilação mecânica e da prevalência das úlceras de pressão [151]. A medição da PIA pelo MT, na posição supina é considerada o método padrão. Contudo, estas medições são muitas vezes realizadas com uma elevação da cama [152] o que pode conduzir a erros. Está descrito que a PIA é influenciada pelo posicionamento do paciente. De acordo com Yi e colaboradores, 2012, a elevação da cabeça em pacientes em estado crítico, num ângulo de 30 a 45°, aumenta os valores de PIA [12]. Em gatos está também descrito que a posição pode afetar a mensuração quando utilizado o decúbito ventral em comparação com o lateral [22]. No nosso estudo, a comparação dos valores diretos da PIA por sensor nas várias posições, não evidenciaram diferenças estatisticamente significativas ($P=0.765$). Este facto leva a concluir que não existe alteração da PIA quando se muda de posição. Contudo, em todos os estudos que relataram diferenças de PIA devido à posição corporal, utilizaram métodos indiretos de aferição. Como já foi referido, a medição pelos métodos indiretos é dependente dos princípios da hidrostática [12,22,121]. O que permite explicar os resultados obtidos. A comparação dos valores obtidos pelo método direto, MT e MI não evidenciaram diferenças estatisticamente significativas nas posições lateral, ventral e dorsal, mas verificaram-se diferenças nas posições de Trendelenburg e Trendelenburg reversa. Nestas duas posições quando se procedeu à inclinação da marquesa segundo um ângulo de 45 ° observou-se um movimento da coluna de fluido contido no manómetro. Este

movimento está diretamente relacionado com a altura da coluna, o que influencia o equilíbrio de pressões. O novo equilíbrio de pressões, acontece porque ao criarmos uma inclinação (ângulo Θ), a força submetida sobre a coluna de fluido vai alterar-se devido à altura (Figura 3-11).

A sobreposição de princípios criada permite explicar este facto e calcular o novo ponto de equilíbrio. Assim, na posição de Trendelenburg ocorre um aumento da altura do manómetro de água, provocando um aumento de pressão. Este, leva ao deslocamento de fluido no sentido da menor pressão, neste caso a bexiga. O nosso estudo revelou este facto, pois na posição de Trendelenburg os valores de PIA foram mais baixos (2.57 ± 3.14 mmHg) que os valores obtidos na posição normal (4.52 ± 3.12 mmHg), ou seja, foi subestimada. Na posição de Trendelenburg reversa os valores da PIA encontravam-se ligeiramente sobrestimados (4.55 ± 2.98 mmHg), uma vez que ocorre o inverso. Como a medição da PIA foi efetuada simultaneamente pelos três métodos, foi observado que ao alterar-se a inclinação da mesa, o fluido contido nos manómetros acompanhou a inclinação, dando um valor errado pois o sensor direto de pressão não demonstrou alteração. Pode então concluir-se que os métodos indiretos não devem ser utilizados para medir a PIA em posições inclinadas, de forma a obter um valor de PIA fiável.

Outro dos erros comuns na aferição da PIA, por métodos indiretos baseados em colunas de fluidos, consiste na presença de bolhas de ar e posições erradas do manómetro de água levando a erros de aferição [9]. Variações de valores entre -6 a +30 mmHg, foram reportadas em estudos prévios, revelando alguns deles um coeficiente de variação de reprodutibilidade entre 25 a 66% [78,120]. Soler Morejon e colegas, 2012, concluíram que a posição do manómetro é de grande relevância de forma a aferir corretamente os valores da PIA [11]. A referência zero, da escala métrica do manómetro de pressão, deve estar nivelada a nível da crista ilíaca, para diminuir os erros de aferição. Caso o manómetro de pressão não esteja nivelado, podem surgir erros tanto de sobre como de subestimação dos valores. Isto acontece pela criação de um ângulo diferente na coluna de fluido levando a alterações do equilíbrio hidrostático. Ao aumentar ou diminuir-se o ângulo fazemos variar a altura da coluna de

água contida no transdutor de pressão, causando uma sobre ou subestimação de forma idêntica ao que acontece na posição de Trendelenburg e Trendelenburg reversa (Figura 3-12).

A escolha do volume residual instilado na bexiga é outra das variáveis que pode influenciar na medição da PIA [13]. Em medicina humana, os volumes usados não são uniformes estando descrito a utilização de volumes de 50 a 250 ml de solução salina. A instilação de mais de 50 ml numa bexiga não distendida vai aumentar a pressão intravesical e sobrestimar a PIA [137]. Com a determinação da PIV, através da construção de curvas de volume, chegou-se à conclusão que a utilização de volumes entre os 50 a 100 ml, não afeta a medição [122]. Atualmente, está aconselhado a instilação de volumes menores sendo aconselhado, pela WSACS, 25 ml de solução [1].

Em cães o volume instilado, é de 0.5 a 1 ml/kg de solução fisiológica, adotando-se usualmente o valor de 1 ml/kg [16,17]. Segundo a sobreposição de princípios biofísicos criada, a instilação de uma elevada quantidade de fluido residual na bexiga vai aumentar a pressão no seu interior, Figura 3-13.

O volume que deve ser instilado deve ser o suficiente para que ocorra a distensão fisiológica. Ao aumentar-se a pressão na bexiga, por causa de um volume excessivo instilado, o equilíbrio dinâmico com a coluna de água vai ser superior para que se estabeleça um ponto de equilíbrio. No nosso estudo utilizou-se uma quantidade de fluido 5 vezes superior (5 ml/kg) ao recomendado pelo que obtivemos valores de PIA muito superiores aos normais através do MT. Estes valores quando comparados com os normais apresentavam diferenças estatisticamente significativas. Este facto pode estar correlacionado com a perda de distensibilidade de tecidos em cadáveres, contudo a explicação mais plausível é a instilação de um grande volume de fluido numa área de superfície limitada.

A última das variáveis descritas de poder alterar a PIA é a cirurgia abdominal. Em medicina humana a distensão abdominal aguda, após cirurgia abdominal complexa pode resultar na dilatação gástrica levando a oligúria e aumento das pressões respiratórias [18]. Também em medicina veterinária foi identificado um aumento da PIA no período pós-cirúrgico em cadelas (medições submetidas ao longo de 24 horas) e gatas submetidas a ovariectomia [15,145]. Recentemente Way e colaboradores

(2014) publicaram um estudo em cães saudáveis, onde referiram que a PIA não foi afetada pela cirurgia abdominal, no entanto neste estudo foi realizada apenas uma medição de PIA imediatamente após a cirurgia, numa amostra de 15 cães. Em medicina humana Cleva e colaboradores, 2014, correlacionaram clinicamente a PIA e os volumes pulmonares após cirurgia abdominal superior e inferior numa população de 60 doentes [19]. Além do facto anteriormente referido, que a utilização do MT em comparação com as medições diretas apresenta uma base line superior [10].

A variável cirurgia pode estar associada ao aumento da PIA devido a várias razões. Todos os fatores que alterem as condições e forças submetidas no interior da cavidade abdominal podem levar ao aumento da PIA. No caso da cirurgia, o edema visceral, a prensa abdominal devido a dor ou mesmo a entrada de ar na cavidade abdominal podem levar a alteração da PIA. Se houver edema ou inflamação de algum órgão visceral existe uma alteração da força do peso exercida, levando ao aumento da PIA, tal como é explicado na Figura 3-8, se houver prensa abdominal devido a dor ou contração da musculatura lisa irá também levar a um aumento da PIA, como é apresentado na Figura 3-9. Independentemente do mecanismo, todos estes fatores podem explicar o aumento da PIA devido a um aumento das forças na mesma superfície de área.

Os princípios biofísicos formulados com o intuito de fundamentar o MT e os fatores que o influenciam, trouxeram informação adicional que irá permitir uma melhor aplicação do mesmo e uma interpretação mais adequada dos resultados obtidos em unidades de cuidados intensivos. Desta forma a aplicação de manobras terapêuticas tenderão a serão mais rápidas e conseqüentemente apresentar melhores taxas de sucesso. Na verdade, a formulação biofísica pode vir a ser aplicada em algoritmos mais complexos de forma a continuar a aumentar o conhecimento da PIA.

Capítulo 4 – Medição da PIA com métodos de Inteligência Computacional

Este capítulo levou às comunicações orais em congresso:

Lopes AM, Niza MMRE, Dourado A. “Non-invasive system for measuring intra-abdominal pressure” in *Proceedings of the 3rd World Congress on Electrical Engineering and Computer Systems and Science (EECSS'17), Rome, Italy – June 5 – 6, 201*, 4th International Conference on Biomedical Engineering and Systems (ICBES'17), part of EECSS'17.

Lopes AM, Dourado A, Niza MMRE. “Pressão intra-abdominal novas descobertas.” XIII Hospital Veterinário de Montenegro, Santa Maria da Feira, Portugal – 18 e 19 fevereiro de 2017

Apresentações em poster:

Lopes AM, Niza MMRE, Dourado A. “System for indirect measurement of Intra-abdominal pressure.” Encontro com a Ciência e Tecnologia em Portugal 2017, Fundação para a Ciência e Tecnologia, Lisboa, Portugal – Centro de Congressos de 3 a 5 de julho de 2017.

4.1 - Introdução

A Inteligência computacional (IC) pode ser definida como uma abordagem ou metodologia de computação que permite desenvolver algoritmos com capacidade de aprendizagem, aplicados à resolução de problemas complexos do mundo real. Esta denominação é utilizada como um termo generalista que engloba várias técnicas. Redes neuronais artificiais, sistemas difusos (*fuzzy systems*), computação evolucionária, máquinas de vetores de suporte (SVM), sistemas híbridos, entre outras são técnicas centrais à IC, mas não a esgotam. Esta metodologia pode-se aplicar a todos os ramos da ciência e engenharia, na resolução de problemas para os quais não existem modelos matemáticos baseados nos primeiros princípios, e em consequência tem que se encarar a sua resolução através da aquisição e processamento de dados [153]. Este tipo de metodologia exhibe a capacidade de aprender e de lidar com novas situações (novos dados) e por isso tem um elevado potencial para a obtenção de soluções de problemas complexos [153].

Os três primeiros capítulos deste trabalho permitiram a caracterização e investigação da PIA, identificando as principais variáveis que a afetam, tornando possível a escolha dos parâmetros de forma a construir um sistema de IC. A seleção adequada destas características é imprescindível para a eficácia dos sistemas biomédicos de determinação de parâmetros fisiológicos, influenciando diretamente o funcionamento dos sistemas computacionais construídos com esse objetivo.

Segundo Marios Polycarpou [154], Presidente da Sociedade de Inteligência Computacional, a IC é em grande medida o coração para o desenvolvimento de novas tecnologias. Com o avanço tecnológico, existe a capacidade de gerar quantidades massivas de dados e transmiti-los automaticamente para onde desejarmos. A interpretação destes dados e utilização do conhecimento gerado em tempo real, são chaves essenciais para os dispositivos computacionais “inteligentes”. A abordagem através da IC possibilita a construção das ferramentas necessárias para este tipo de dispositivos [154].

4.1.1 - Redes Neurais

Os primeiros trabalhos de neurocomputação surgiram na década de quarenta do século XX numa parceria entre Warren McCulloch, neurofisiologista e especialista em neuroanatomia, e o matemático Walter Pitts. Ambos estabeleceram uma analogia entre as células nervosas vivas, os neurónios e o processamento eletrónico. Neste trabalho eles tentavam simular o comportamento neuronal utilizando modelos matemáticos [155]. Desde essa altura, têm sido desenvolvidos múltiplos trabalhos, tendo em vista a utilização deste tipo de tecnologia na resolução de problemas de reconhecimento de padrões que geralmente são baseados num conjunto de informações conhecidas.

As redes neuronais artificiais visam solucionar problemas de inteligência artificial, modelando através de circuitos (conexões) o sistema nervoso humano, tal como a sua capacidade de aprender através da experiência e observação [156]. As RNA apresentam, na sua maioria, uma estrutura similar às encontradas nos neurónios e respetivas conexões biológicas. Estas estruturas tentam mimetizar os axónios e dendrites, na qual o processamento se encontra distribuído por um grande número de pequenas unidades densamente interligadas [157]. O funcionamento dos neurónios artificiais baseia-se, na generalidade dos casos, neste modelo simplificado dos neurónios biológicos. Cada unidade possui ligações com outras unidades, recebendo e enviando sinais, podendo também apresentar memória local. As RNA são ferramentas computacionais não-lineares apropriadas para uma grande quantidade de aplicações devido à sua flexibilidade e adaptabilidade. Estas têm vastas aplicações em diversos campos como a banca, defesa, indústria, medicina, e robótica, entre outros [158].

As principais características das redes neuronais são a sua capacidade de aprender relações funcionais a partir de dados conhecidos, e generalizar depois essas relações para dados novos, desconhecidos. São aproximadores universais de funções e de mapeamentos [159,160].

Nos últimos anos, as RNA tem vindo a ser aplicadas em várias áreas da medicina como na epidemiologia, neurologia, radiologia, farmacologia, urologia, oncologia, cardiologia, imagiologia, entre outras [161–164].

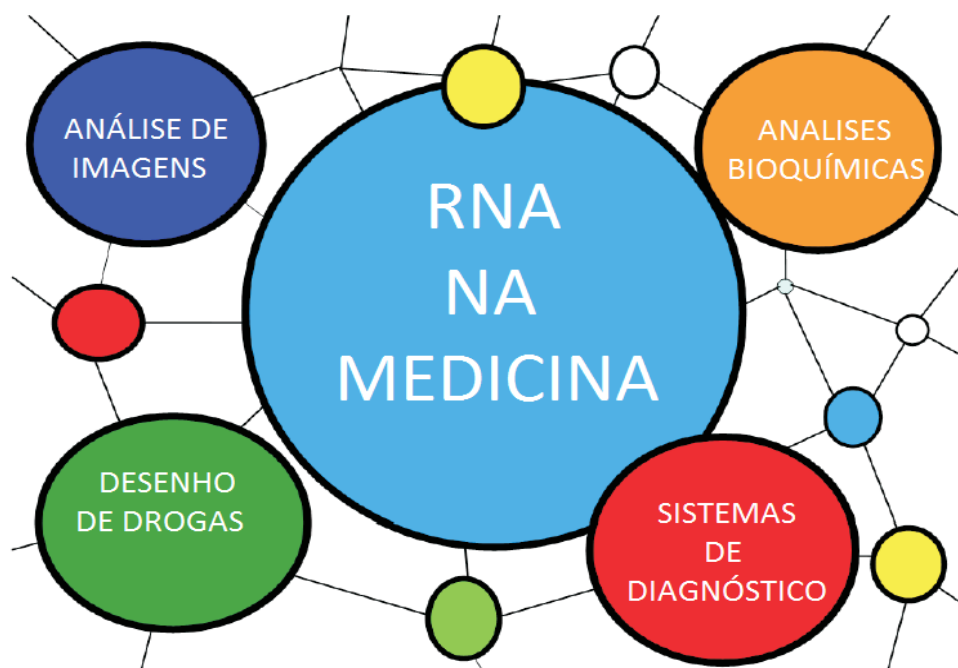


Figura 4-1- Apresentação esquemática das principais aplicações das redes neurais artificiais na medicina; traduzido e adaptado de Patel et al 2007 [160].

A aplicação das RNA no diagnóstico médico foi feita pela primeira vez no trabalho pioneiro de Szolovits e colaboradores (1988) [165], tendo levado a um aumento da utilização dos algoritmos adaptativos de aprendizagem na tomada de decisão e na aplicação a dispositivos médicos de diagnóstico [166]. Para a construção de uma RNA de suporte médico é fundamental a escolha das características (sintomas, parâmetros clínicos, dados instrumentais) que irão possibilitar determinar o parâmetro clínico/diagnóstico alvo. A capacidade de modelação das RNA baseia-se no facto de não necessitarem de um conhecimento profundo entre o relacionamento intrínseco ou da estrutura de relacionamento entre variáveis de um problema particular tal como é necessário para a modelação matemática mais clássica [163].

Existem vários exemplos da aplicação das RNA em instrumentos médicos de diagnóstico como é o caso da eletrocardiografia, da classificação de sinais na eletromiografia, da identificação de células

sanguíneas em máquinas de análise, e mesmo em aparelhos de ressonância magnética [167]. No presente estudo aplicam-se, pela primeira vez, as RNA na determinação da pressão intra-abdominal criando assim uma forma não invasiva de mensuração.

A estrutura da rede neuronal compreende os neurónios e os pesos das ligações entre neurónios. Os neurónios podem organizar-se em paralelo, formando camadas, e as camadas organizam-se em série. O comportamento da rede depende largamente da interação entre os blocos de construção. Quando uma rede tem várias camadas em série, existem três tipos de camadas: camada de entrada (“*input layer*”), em que as unidades recebem os dados de entrada; camadas escondidas (“*hidden layers*”) onde é feito processamento computacional, e a camada de saída (“*output*”) que conclui o processamento e apresenta o resultado final. A cada ligação está associado um determinado peso, que mede a sua importância, existindo múltiplas formas de a informação ser processada, tal como diferentes maneiras de conectar os vários neurónios. Nas redes para sistemas dinâmicos, que têm memória, pode-se implementar realimentação (feedback) de modo que a saída de uma camada pode ser dada como entrada a uma camada anterior; no presente estudo trata-se de um sistema estático, e por isso este tipo de redes não é abordado. No corpo de cada neurónio executa-se uma função matemática, chamada função de ativação, que pode ter diversas formas. Combinando todas essas possibilidades (número de neurónios por camada, número de camadas, funções de ativação, pesos das ligações, polarizações dos neurónios) é possível construir múltiplos tipos de redes neuronais. Neste facto reside uma das suas grandes vantagens: para um dado problema procura-se a arquitetura mais adequada, normalmente por um processo de tentativa e erro [166,168].

A estrutura adequada depende do problema a resolver, das camadas internas e da camada de saída. As camadas internas têm usualmente polarização e funções de ativação não lineares, monótonas (crescentes), por exemplo sigmoidais (no caso particular das redes RBF, *Radial Basis Function*, não usadas neste trabalho, essas funções não são monótonas, mas radiais em relação ao seu centro, como por exemplo a função gaussiana). O número de camadas é geralmente dependente do problema a

resolver. Para se determinar adequadamente os parâmetros da rede (os pesos e as polarizações), estes devem ser em menor número que o conjunto de pontos usados no seu treino, a fim de evitar uma rede sobreajustada que terá pouca capacidade de generalização. Deve-se usar sempre a rede mais simples que seja capaz de resolver o problema [168]. A capacidade de generalização é a capacidade de uma rede apresentar resultados coerentes para “dados que nunca viu”. A escolha do número apropriado de neurónios a integrar nas camadas escondidas é extremamente importante para a capacidade de generalização da rede. O treino incorreto das redes pode levar a situações de sub-ajuste (*under-fitting*) (treino insuficiente, por defeito) ou de sobre-ajuste (*over-fitting*) (treino excessivo). De maneira a prevenir o sub-ajuste deve ter-se em conta o número de neurónios suficientes para a rede. Um número reduzido de neurónios poderá resultar na incapacidade de a rede neuronal aproximar corretamente uma dada transformação. Pelo contrário, um número de neurónios excessivo poderá redundar num fenómeno de sobre ajuste e perda da capacidade de generalização. A rede deve ser treinada o número de épocas suficientes, de forma a minimizar adequadamente o critério de ajuste, normalmente uma função quadrática dos erros da rede [168].

O tipo de funções de ativação (também chamadas funções de transferência) escolhido é naturalmente muito importante para a capacidade de mapeamento e portanto de aprendizagem da rede neuronal [169,170]. Entre as funções de ativação mais utilizadas estão as funções sigmóide logística, a tangente hiperbólica e a linear [171].

A função logística (*Log-Sigmoid*, *Logsig*), é semelhante ao relacionamento que acontece entre as entradas e saídas nos neurónios biológicos, embora não exatamente o mesmo [172], e é ilustrada na Figura 4-2 [173,174]. Esta função de transferência aceita uma entrada entre mais e menos infinito, e dá uma saída entre 0 e 1, isto é, uma função unipolar [174,175].




Figura 4-2- Função de transferência Log-sigmoid [174].

A função tangente hiperbólica (*Hyperbolic tangente, Tansig*), representada na Figura 4-3, tem uma saída entre -1 a +1 e, por ser bipolar, permite que um neurónio produza uma saída negativa [174]. Este tipo de função é equivalente a $\tanh(n)$, sendo, contudo, mais rápida que esta e apresenta poucas diferenças de resultados numéricos. Este tipo de função é uma boa escolha para as RNA quando a velocidade é mais importante do que a forma exata da função de transferência [174].




Figura 4-3- Função de transferência Tan-sigmoid [175]

A grande parte dos modelos reais existentes tem geralmente características não lineares entre as entradas e as saídas. Contudo existem alguns modelos que, quando operados dentro dos parâmetros nominais, têm um comportamento bastante próximo do linear. A função de transferência *Purelin* (Figura 4-4) pode ser uma representação aceitável das entradas/saídas do sistema neste tipo de situações [174].




Figura 4-4- Função de transferência linear [175].

O treino das RNA é outro dos fatores cruciais para o desempenho da rede e para o seu funcionamento [171]. Existem vários algoritmos de treino disponíveis e no decorrer deste trabalho utilizamos três: o *Levenberg-Marquardt* (*trainlm*), o algoritmo *Scaled conjugate gradient backpropagation* (*trainscg*), e

o algoritmo *Bayesian Regularization* (*trainbr*) [176]. Estas são técnicas de otimização que de algum modo derivam do método do gradiente [174].

Levenberg-Marquardt (*trainlm*) é uma função de treino que atualiza os valores dos pesos e das polarizações de acordo com o algoritmo de otimização de *Levenberg-Marquardt*. É um método simples de aproximação de funções e altamente recomendado como uma primeira escolha de treino supervisionado, sendo além disso computacionalmente bastante rápido. Um dos principais inconvenientes deste algoritmo é que para alguns problemas é necessário uma grande capacidade de memória [176].

O algoritmo *Scaled conjugate gradient backpropagation* (*trainscg*), desenvolvido por Moller (1993), foi desenhado para evitar o excesso de consumo de tempo computacional [177]. Este tipo de algoritmo é bastante complexo, atualizando os pesos e as polarizações da rede de acordo com um método de gradiente conjugado, o *Scaled conjugate gradient* [177].

Um dos problemas que pode ocorrer durante o treino de rede é o sobre-ajuste (*overfitting*). Se o treino for excessivo, a rede fica “viciada” com os dados de treino, perdendo a capacidade de generalização para novos dados de teste. Uma das soluções para este problema é a utilização da *Bayesian Regularization backpropagation* (*Trainbr*). Este tipo de algoritmo atualiza o peso e as polarizações da rede de acordo com a otimização de *Levenberg-Marquardt* [178], minimizando a combinação dos erros quadráticos com os pesos das ligações e depois determina a combinação correta de forma a produzir uma rede que generalize bem [174,178].

4.1.2 - Sistemas difusos

Outro das técnicas de IC que pode ser utilizada na abordagem da resolução de problemas são os sistemas difusos. Um conjunto difuso (*fuzzy set*) é composto por elementos que lhe pertencem com graus de pertença reais entre 0 (zero) e 1 (um). Este tipo de conjuntos forma a base da lógica difusa

(*fuzzy logic*) que é uma extensão da lógica binária aristotélica baseada nas noções de verdadeiro e falso. A lógica difusa admite valores lógicos intermédios entre o FALSO (0) e o VERDADEIRO (1); por exemplo o valor 'TALVEZ' é simultaneamente falso (0.5) e verdadeiro (0.5). Isto significa que um valor lógico difuso é um valor real qualquer no intervalo de valores entre 0 e 1. Este tipo de lógica tem alguma analogia com alguns conceitos estatísticos principalmente na área de inferência [179,180]. A lógica difusa permite computar com conceitos imprecisos, difusos, expressos por palavras em vez de números.

O conceito de conjuntos difusos foi pela primeira vez proposto por Lofti A. Zadeh em 1965, tendo tido um amplo desenvolvimento desde então [179]. A sua aplicação tornou-se um sucesso, na análise de dados, inteligência artificial e IC. É uma lógica adequada à tomada de decisão em ambientes de incerteza, como estudos demográficos, comportamentais, sociológicos, de ciência política, antropológicos, entre outros [181].

Um sistema neuro-difuso (*neuro-fuzzy*) constrói regras difusas a partir de um conjunto de dados, usando técnicas de aprendizagem próprias de redes neuronais. Os sistemas difusos e as redes neuronais têm em comum o facto de poderem ser usados para resolver um problema, mesmo que não exista um modelo matemático do mesmo. As redes neuronais unicamente podem ser usadas se o problema for expresso por uma quantidade suficiente de amostras. Estas observações são usadas para treinar a rede que funciona como uma caixa negra [180]. Por um lado, a rede neuronal não necessita de nenhum tipo de conhecimento do problema dado, contudo não consegue extrair do conjunto de dados regras compreensíveis. Por outro lado, os sistemas difusos implementam regras linguísticas que exprimem conhecimento qualitativo do problema; as suas variáveis de entrada e saída (*input* e *output*) têm que ser descritas linguisticamente. Se o conhecimento é incompleto, errado ou contraditório, então o sistema difuso tem que ser sintonizado. Como não existe nenhuma abordagem formal de realizar a sintonia de regras, esta é realizada de forma heurística ou por processos de otimização [180].

As vantagens dos sistemas difusos são: a capacidade de representar incertezas inerentes ao conhecimento humano através da utilização de variáveis linguísticas; a interação mais simples do especialista da área com o projetista do sistema; a fácil interpretação dos resultados, devido à representação quase natural das regras; a fácil extensão da base de conhecimento através da adição de novas regras, sem perda do conhecimento anterior; a possibilidade de aplicação, sem necessidade de modelos matemáticos do processo, requerendo apenas conhecimento empírico; a robustez em relação a perturbações no sistema [182]. As grandes desvantagens estão ligadas com alguns aspetos já referidos: responde ao que está descrito com base nas suas regras; não é robusto em relação a mudanças topológicas do sistema ao qual é aplicado, pois tais mudanças exigiriam alterações na base de regras; e por último é sensível à subjetividade quando um especialista é usado para determinar as regras [182].

4.1.3 – Clustering para a aprendizagem de Sistemas Difusos

A análise de agrupamentos (*clustering*) é a técnica básica para classificação de objetos em diferentes grupos (*clusters*) [183,184]. Assim, o *clustering* é uma etapa fundamental na análise de dados [185] para reconhecimento de padrões, extração de características, quantificação de vetores, segmentação de imagens e aproximação de funções [185]. É amplamente usado na bioinformática, na sequenciação genética, no agrupamento de genes, e na imagiologia médica na segmentação de imagem [185].

Os agrupamentos são formados de maneira a que os objetos em cada grupo sejam muito similares, e objetos em grupos diferentes muito distintos [183,184]. A normalização é necessária, naqueles casos em que a medida de dissimilaridade entre variáveis, dada por exemplo pela distância euclidiana, é sensível a diferenças de magnitude de escala das variáveis de entrada [186].

Nos sistemas neuro-difusos os métodos de *clustering* usam-se para determinar o número e localização dos centros dos *clusters*. Cada *cluster* dá origem a uma função de pertença multidimensional e esta

originará uma regra, projetando essa função de pertença em cada dimensão para obter as funções de pertença unidimensionais [185].

Existem múltiplas técnicas de *clustering* e diversas medidas de similaridade para criar os agrupamentos. A avaliação dos agrupamentos determina o número ótimo de grupos para o conjunto de dados usando diferentes critérios de seleção [183]. As medidas de similaridade pelas quais os grupos são modelados são frequentemente definidas a partir de distâncias, sendo a euclidiana a mais frequente [183].

Os métodos de agrupamento permitem agrupar os dados com características idênticas, sendo cada grupo caracterizado por um centro e um raio de influência [183]. Os métodos de agrupamento de dados podem ser divididos em dois tipos: os crespos e os difusos. No agrupamento que admite grupos difusos, os dados podem pertencer simultaneamente a vários grupos, com pertenças diferentes a cada um, havendo assim sobreposição dos mesmos. Dentro dos métodos crespos de agrupamentos de dados, em que não há qualquer sobreposição dos grupos (um ponto pertence a um e um só grupo), os mais utilizados são o agrupamento das *k*-médias (ou *c*-médias, conforme os autores), e o agrupamento subtrativo [183]. O método de agrupamento das *c*-médias consiste na divisão dos dados em *c* grupos e na procura dos centros dos grupos que minimizam uma função baseada numa medida da distância (normalmente euclidiana) dos dados. Cada grupo de dados do referido espaço pertence apenas a um único grupo de uma forma binária [187]. A metodologia de agrupamento de dados pelo método subtrativo é baseada no cálculo dos centros de forma sequencial baseando-se na medida da maior densidade de dados de grupos hipersféricos com um determinado raio. Este processo vai sendo repetido até que seja gerado um número suficiente de grupos para representar a heterogeneidade dos dados. Os centros destes grupos serão posteriormente os centros das funções de pertença difusa a definir na construção do sistema neuro-difuso [187]. As RNA também podem ser utilizadas para agrupamento dos dados criando Mapas de Auto-Organização (*Self-Organizing Maps: SOM*) onde o modelo de *clustering* é formado por RNA que aprendem a tipologia e distribuição dos dados [188].

O número de regras produzidas pelos sistemas neuro-difusos depende em larga medida do método de agrupamento usado e da sua parametrização.

4.1.4 - Sistemas de redes adaptativas baseadas em sistemas de inferência difusa

Nos últimos anos têm também sido utilizados sistemas de redes adaptativas baseadas em sistemas de inferência difusa (*ANFIS- Adaptive Neuro-Fuzzy Inference System*) em várias aplicações médicas. Um ANFIS é um sistema de inferência difusa (FIS) implementado numa rede neuronal multicamada que computa, de modo adaptativo, as diversas operações envolvidas na inferência difusa [189] para regras do tipo Takagi-Sugeno [190,191]. A técnica foi desenvolvida nos anos noventa do séc XX e integra princípios das redes neuronais e da lógica difusa, procurando os benefícios de ambas; permite, após treino conveniente, aproximar funções não-lineares [192]. A grande ideia de um sistema ANFIS é interpretar os valores nos vetores de entrada, baseado num conjunto de regras, e determinar os valores do vetor de saída [193]. A estrutura básica de um sistema difuso compreende a entrada, o processo de fuzificação, uma base de conhecimento baseada nos dados e no conjunto de regras, o motor de inferência, o processo de desfuzificação e a saída do sistema [193]. De uma forma geral ele pode ser representado como a figura 4-5.

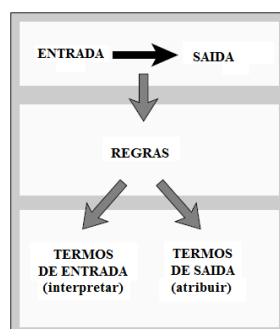


Figura 4-5- Descrição geral de um sistema Fuzzy; adaptado de *Matlab Fuzzy Toolbox* [193].

Os sistemas de inferência Mamdani foram os primeiros sistemas de controlo construídos utilizando a lógica difusa. Nos sistemas de inferência Mamdani as saídas são representadas por conjuntos difusos

com funções de pertinência de saída. Quando diversas regras ficam ativas, há agregação dos conjuntos difusos de saída de cada regra, a que se segue uma operação de desfuzificação para encontrar a saída global no domínio real.

Nos sistemas de Sugeno as saídas não são difusas, mas definidas por um polinómio de coeficientes crespos; calculam a saída global através da média ponderada das saídas de cada regra individual [193], sendo a intensidade de disparo de cada regra o seu coeficiente de ponderação. Os sistemas tipo Sugeno apresentam funções de saída crespas, lineares ou constantes [105]. Um sistema típico de Sugeno funciona como mostra o diagrama da figura 4-6.

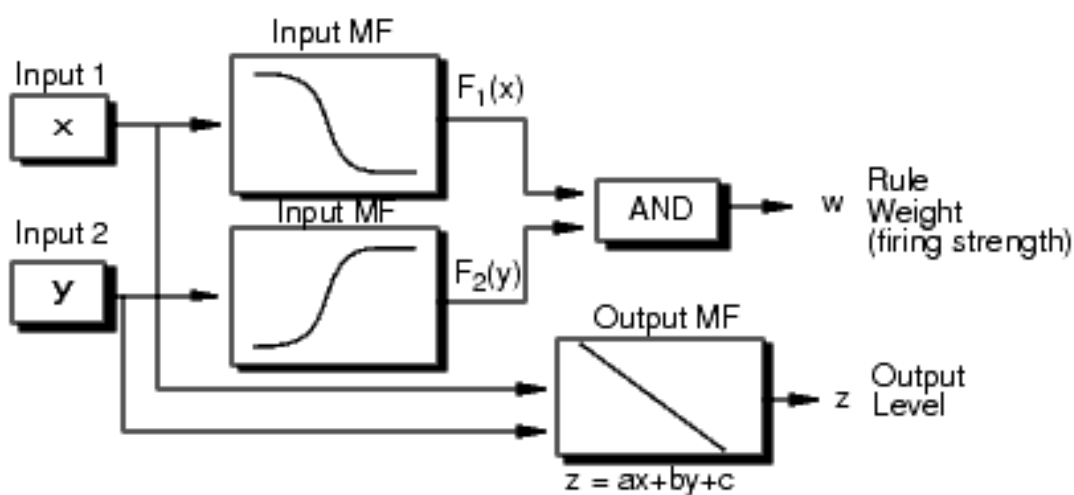


Figura 4-6- Diagrama de funcionamento do sistema de inferência Sugeno (Fuzzy Logic Toolbox do Matlab), [193].

O típico modelo de Sugeno de ordem zero apresenta as regras na forma (4.1):

$$SE\ x\ é\ A\ e\ y\ é\ B\ ENTÃO\ z = k \tag{4.1}$$

Onde A e B são conjuntos difusos do antecedente e k uma constante definida no conseqüente. Distinguem-se dos sistemas do tipo Mamdani pelo facto dos conseqüentes não serem difusos mas

constantes reais bem definidas [193]. Os modelos Sugeno de primeira ordem apresentam as regras na forma (4.2):

$$SE\ x\ \acute{e}\ A\ e\ y\ \acute{e}\ B\ ENT\ \tilde{A}O\ z = p * x + q * y + r \quad (4.2)$$

Onde A e B são conjuntos difusos do antecedente enquanto que p , q e r são constantes reais. Sistemas Sugeno de ordem superior a um, são também possíveis, mas introduzem significativa complexidade com poucos ganhos [193].

Tal como as RNA, existem várias aplicações dos ANFIS no diagnóstico médico. A sua utilização já foi descrita para o diagnóstico de doenças como a diabetes [194], para deteção da acidez sanguínea [195], nas doenças cardíacas valvulares [196], na artrite reumatoide [197], nos ataques epiléticos [198], no diagnóstico de tumores [199], nas alterações do nervo ótico [200], na análise do sinal de *Doppler* [201], e na deteção de características de sinais de eletroencefalogramas [202].

Da pesquisa bibliográfica realizada, não se conhecem aplicações quer de uma RNA, quer de um ANFIS, para determinar a PIA.

4.2 - Material e Métodos

A última parte do trabalho teve início com a recolha e construção da base de dados. A recolha dos parâmetros foi realizada numa população de cães vivos, onde foram registados os valores da PIA e os parâmetros fisiológicos e morfológicos de cada indivíduo quando sujeito a monitorização multiparamétrica.

4.2.1 - População

A população estudada consistiu num total de 43 cães, submetidos a cirurgia abdominal onde foram efetuadas 371 medições diretas da PIA em monitorização contínua. Da população estudada, 22 eram fêmeas e 21 machos, com peso médio de 16.35 ± 11.19 quilogramas (kg). A população total foi dividida em dois subgrupos do modo seguinte:

População saudável: vinte e seis cães, 18 fêmeas e 8 machos, com peso médio de 14.92 ± 11.66 kg.

Critérios de inclusão: indivíduos sem indícios de doença, comprovado por exame clínico e exames complementares, tal como sem alterações da PIA, que se apresentem para cirurgia abdominal eletiva.

Critérios de exclusão: todos os indivíduos não saudáveis ou que demonstrem ter alterações da PIA.

População doente: dezassete cães, 4 fêmeas e 13 machos, com peso médio de 17.39 ± 10.76 kg.

Critérios de inclusão: indivíduos doentes e com diagnóstico confirmado, por exames complementares, que possa levar a alterações na PIA. Critérios de exclusão: animais que não apresentem diagnóstico confirmado, ou que não apresentem todos os exames necessários para recolha dos parâmetros em estudo.

Todos os indivíduos que não apresentassem todos elementos necessários ao estudo foram eliminados do conjunto de dados.

4.2.2- Parâmetros fisiológicos e morfológicos

Os parâmetros fisiológicos recolhidos foram os necessários de forma a monitorizar o indivíduo durante o protocolo anestésico e cirúrgico [69–72]. Foram assim recolhidos para a base de dados, através de um monitor multiparamétrico, Cygnus 1000 C Vet (Servive, Portugal), os seguintes parâmetros: frequência cardíaca (FC) e respetivo traçado de eletrocardiograma na derivação II (1 centímetro (cm)/milivolt(mV), 50 mm/s). Por interpretação individual dos eletrocardiogramas foram

determinados os valores da amplitude e duração da onda P (Ampl. P, Dur. P), o intervalo PR ([PR]), a duração do complexo QRS (QRS), a amplitude da onda R (Ampl. R), a amplitude e duração da onda T (Ampl. T, Dur. T), e o intervalo QT ([QT]) [203]; pressão arterial sistólica (PAS), média (PAM), e diastólica (PAD) obtidas de forma não invasiva por método de oxilometria; valores de capnografia (EtCO₂) obtidos por *main stream* e valores de pulsoximetria (SpO₂). Foram também recolhidos os valores da PIA de forma contínua pelo método direto durante todo o protocolo cirúrgico. A medição direta da PIA foi realizada através de um cateter intraperitoneal usando um sensor CODMAN (Codman, Johnson & Johnson). O sensor foi inicialmente conectado ao transdutor e posteriormente calibrado a zero, sendo o valor de referência a pressão atmosférica, consoante indicações do fabricante. O sensor foi então inserido pelo cateter peritoneal até entrar na cavidade abdominal. Aguardou-se um minuto antes de começar as leituras. Este tipo de sensor permite a monitorização contínua da PIA [54,113]. Todos os dados foram obtidos e registados de cinco em cinco minutos durante todo o procedimento cirúrgico. Sempre que era medida a PIA eram registados todos os outros parâmetros. Os parâmetros morfológicos registados na base de dados compreendem: o peso vivo (Adam CPW Plus 150, USA), o perímetro abdominal, e a área de superfície da cavidade abdominal (ASCA). A área de superfície foi calculada através da fórmula: $ASCA = 0.0044 \text{ peso vivo (kg)} + 0.041$ [204–206] determinada na primeira fase do trabalho com recurso à segmentação e modelação tridimensional. Todos os valores determinados, para construção da base de dados e da rede neuronal, foram recolhidos através da monitorização padrão dos cães sujeitos a cirurgia abdominal. Os dados recolhidos não foram obtidos com o intuito de realização deste estudo, mas no âmbito da monitorização cirúrgica normal. Devido a ser um estudo de recolha de parâmetros fisiológicos e morfológicos existe a necessidade de ser realizada em animais vivos. Durante a recolha de dados, foram cumpridas todas as orientações de conduta ética no cuidado e utilização de animais não humanos [207]. O protocolo experimental foi elaborado e realizado segundo a legislação aplicável (Directive 2010/63/EU) e aprovado pelo comité de ética e bem-estar animal da Faculdade de Medicina Veterinária – Universidade Lusófona. Todos os

proprietários deram autorização para utilização dos dados [208]. Os protocolos anestésicos e analgésicos foram supervisionados e criados segundo o risco anestésico do paciente.

4.2.3 - Análise Estatística

Todos os dados foram submetidos a análise de variância (ANOVA, *general linear model*) através do *software* SPSS para averiguar se havia diferenças estatisticamente significativas entre eles. Nos testes estatísticos de comparações de médias, as diferenças são consideradas estatisticamente significativas quando $P < 0.05$. O coeficiente de correlação de Pearson foi utilizado para verificar a força da associação de variáveis. A correlação entre as variáveis é tanto maior quanto mais próximo estiver de 1 o coeficiente de correlação.

Na construção do modelo de IC, a base de dados de variáveis fisiológicas e morfológicas foi submetida a tratamento estatístico. Os dados de todas as variáveis recolhidas foram correlacionados estatisticamente e clinicamente. A correlação estatística entre variáveis serviu para diminuir o número de variáveis de entrada, de forma a criar um modelo de IC mais compreensível e suficientemente fidedigno.

O tratamento estatístico e análise de correlação de variáveis de entrada é uma metodologia que permite reduzir o número de entradas, eliminando a redundância de informação contida em variáveis altamente correlacionadas.

4.2.4 - Modelo da PIA usando Inteligência Computacional (IC)

O processamento, tratamento e implementação dos métodos de IC foram realizados recorrendo ao programa Matlab (R2016a). O modelo de IC criado consistiu na definição das entradas e saídas do sistema e nos parâmetros de rede para criar a solução mais eficaz de determinação da PIA. Os

parâmetros foram definidos tendo como base as características do sistema e as variáveis que podem ter um maior peso na PIA. A Figura 4-7 esquematiza este modelo.

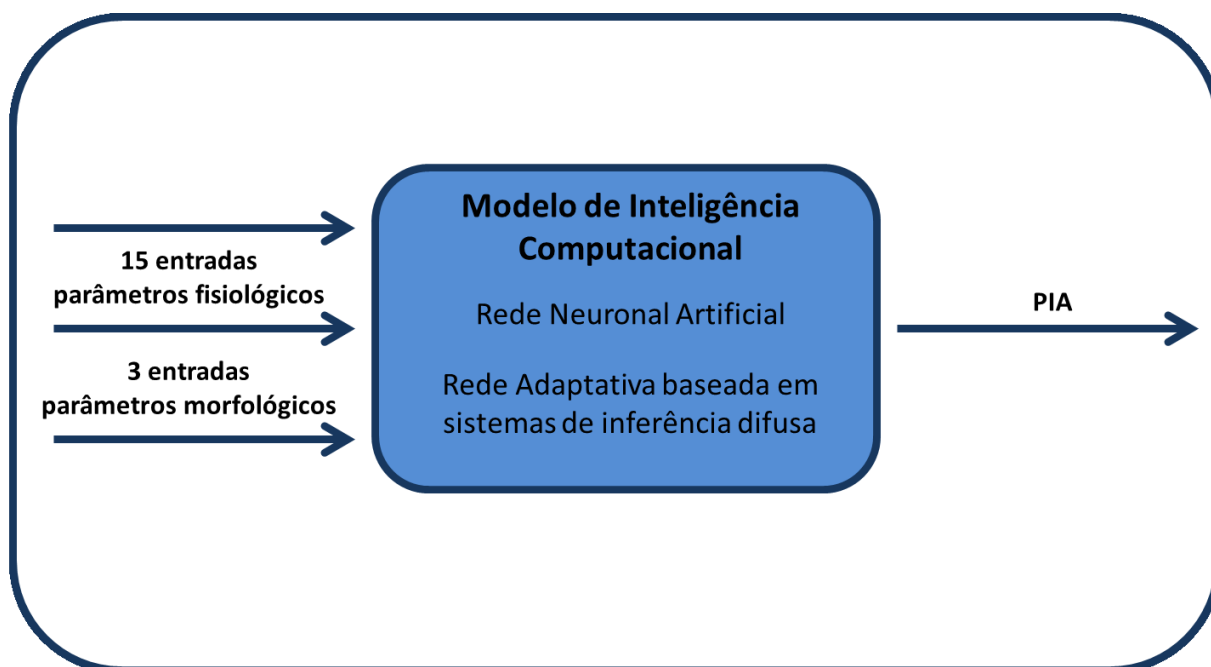


Figura 4-7- Modelo de inteligência computacional com 18 entradas e 1 saída.

Na resolução do problema usaram-se RNA e ANFIS. As entradas do sistema corresponderam às 18 variáveis recolhidas, das quais 3 correspondem aos parâmetros morfológicos (peso, perímetro abdominal, e ASCA) e 15 correspondem aos parâmetros fisiológicos (FC, SpO₂, EtCO₂, PAM, PAS, PAD, T.º, Ampl. P, Dur. P, [P-R], QRS, Ampl. R, Ampl. T, Dur. T, [Q-T]); a saída do sistema corresponde à PIA. Na construção das RNA e dos ANFIS, foram construídas redes para os dados totais da população, para a população saudável, e para a população doente.

4.2.4.1- Redes Neurais Artificiais

Na implementação da RNA foram desenhadas redes multicamada, de maneira a comparar o seu comportamento e desempenho segundo várias arquiteturas. Foram construídas 54 redes neuronais

artificiais para cada uma das populações (total, saudável e doente). Os dados de cada uma das populações foram divididos em três grupos: 70% dos dados foram utilizados para treino, 15 % para validação e 15 % para teste da rede neuronal. A arquitetura das redes consistiu em redes de 2 camadas (1 camada oculta e 1 de saída), de 3 camadas (2 camadas ocultas e 1 de saída) e de 4 camadas (3 camadas ocultas e 1 de saída). Nas camadas ocultas variou-se o número de neurónios entre 10, 15 e 20 por camada. Utilizaram-se três funções de ativação da rede: a função Logarítmica-Sigmoidal (*logsig*), a função Tangente Hiperbólica Sigmóide (*tansig*) e a função Linear (*purelin*). Como funções de treino da rede usaram-se a Retropropagação com Regularização Bayesiana (*Bayesian Regularization Backpropagation (trainbr)*), a Retropropagação de *Levenberg-Marquard (trainlm)* e a função de Retropropagação de Gradientes Conjugados Escalonados (*Scaled conjugate gradient backpropagation (trainscg)*). Inicialmente foram construídas 54 redes para todas as variáveis de entrada e de seguida foram construídas mais 54 redes, mas só utilizando as entradas com maior correlação estatística com a saída, de forma a simplificar o modelo (modelo reduzido). O treino das redes baseou-se numa função de desempenho dada pela soma dos erros quadráticos da saída. De forma a escolher a melhor arquitetura de rede e o número de neurónios a utilizar foi realizado um estudo comparativo entre as várias arquiteturas comparando o índice de regressão linear entre as saídas das redes e os alvos dos vários modelos criados. O valor de R (coeficiente de regressão linear) é o valor indicativo do relacionamento entre as saídas e os alvos, quanto mais próximo de 1 maior o relacionamento linear quando mais próximo de 0 representa a ausência de relacionamento [209].

4.2.4.2- Redes adaptativas baseadas em sistemas de inferência Difusa

Na construção dos ANFIS, os dados foram em primeiro lugar normalizados (entre -1 e 1) e foram utilizados três tipos de *clustering* de forma a organizar os dados. Um dos métodos utilizado foi o agrupamento dos dados por aprendizagem competitiva realizando o *clustering* dos dados por RNA,

utilizando mapas de auto-organização (SOM- *Self Organized Maps*). Além deste método utilizámos o método das c-médias difusas (*fuzzy c-means clustering*) e o método do agrupamento subtrativo (*subtractive clustering*).

A construção dos ANFIS teve início na criação de um sistema de inferência difusa (FIS, *Fuzzy Inference System*). Para criar o sistema de inferência utilizámos a função do Matlab `genfis3`, que vai criar um FIS agrupando os dados através do método das c-médias difusas (FCM, *Fuzzy C-Means*) ou do agrupamento subtrativo, extraíndo um conjunto de regras que modele o comportamento dos dados. O comando para gerar o FIS vai ser: `fismat = genfis3 (Xin, Xout, Type, cluster_n)`. Este comando, através do argumento *Type*, permite escolher o tipo de FIS criado, por defeito ele cria um FIS do tipo Sugeno, contudo com este comando podemos também criar FIS do tipo Mamdani. A cada agrupamento (*cluster*) corresponderá uma regra, e a partir dele são geradas as funções de pertença. O número de regras pode ser pré-definido, atribuindo um valor numérico ao argumento *cluster_n*. Se se der ao argumento *cluster_n* o valor 'auto', então é usado o *clustering* subtrativo (com um *radii* de 0.5 por defeito) que calcula ele próprio o número de *clusters*. Inicialmente foi usado o modo 'auto', deixando a função criar o número de regras. De seguida geraram-se FIS com o número de regras do *clustering* realizado aos dados pelo SOM. A função de pertença dos antecedentes é a gaussiana (`gaussmf`) sendo a função tipo de saída linear (sistema Sugeno de ordem 1); contudo quando especificamos um sistema de inferência Mamdani a função de saída é do tipo gaussiana.

Utilizámos também a função `genfis2` do Matlab, para criar FIS: `fismat = genfis2 (Xin,Xout,radii)`. Esta função cria um FIS com uma estrutura do tipo Sugeno usando o método subtrativo para efetuar os *clusters*. Este tipo de função determina o número de regras automaticamente a utilizar no FIS. O método de extração de regras usa em primeiro lugar a função `subclust` para determinar o número de regras e funções de pertença dos antecedentes e depois utiliza o método dos mínimos quadráticos lineares para determinar as equações dos consequentes das regras. Através desta função conseguimos definir o *radii* que é o vetor que especifica o raio de influência do *cluster* em cada dimensão de dados.

Após criação inicial das várias FIS foi utilizado o *Neurofuzzydesigner* do Matlab para efetuar a sua otimização, através de uma fase de treino e seguida de uma fase de teste. Os dados da população total foram então divididos em três grupos: 50% dos dados eram utilizados para treino; 25 % para validação e 25 % para testar a rede. Devido à influência da divisão dos dados no comportamento dos ANFIS foram também realizados testes com outras divisões percentuais dos dados. No *clustering* dos dados efetuado por RNA, utilizando os SOM, utilizámos os próprios dados dos *clusters* na divisão para treino e teste.

A função de desempenho da rede é definida pelo somatório dos erros quadráticos das saídas atuais em relação às desejadas. O erro de treino é obtido pela diferença entre os valores reais das saídas com os dados de treino e os valores de saída do ANFIS com os mesmos dados das entradas de treino (erro quadrático médio (RMSE)). O erro de validação é dado pela diferença entre os valores dos dados de saída para validação e os valores de saída do ANFIS com os mesmos dados de entrada de validação correspondentes [190,191,210]. Na construção dos ANFIS usaram-se modelos com a totalidade das entradas (18) e depois outros modelos utilizando somente as variáveis com maior correlação estatística com a saída, modelo reduzido (7 entradas).

4.3 - Resultados

Os parâmetros morfológicos e fisiológicos recolhidos para a população total apresentaram resultados constantes da tabela 4-1.

Tabela 4-1 – Estatística descritiva das 19 variáveis obtidos na população total

| Variável | Limite superior | Limite Inferior | Média | Desvio Padrão |
|--|-----------------|-----------------|--------|---------------|
| Peso (Kg) | 40 | 1.5 | 16.35 | 11.19 |
| Perímetro abdominal (cm) | 88.30 | 25.00 | 49.89 | 15.28 |
| Área de superfície da cavidade abdominal (m ²) | 0.22 | 0.03 | 0.11 | 0.05 |
| Frequência Cardíaca (bpm) | 208 | 43 | 100.65 | 26.50 |
| Pulsoximetria (%) | 100 | 0 | 94.69 | 12.92 |
| Capnografia (mmHg) | 57 | 0 | 38.87 | 11.99 |
| Pressão arterial sistólica (mmHg) | 204 | 0 | 109.88 | 28.72 |
| Pressão arterial média (mmHg) | 138 | 0 | 75.41 | 23.28 |
| Pressão arterial diastólica (mmHg) | 129 | 0 | 57.07 | 22.56 |
| Temperatura (°C) | 37.90 | 32 | 36.06 | 1.08 |
| Amplitude onda P (mV) | 0.60 | 0 | 0.25 | 0.11 |
| Duração onda P (s) | 0.16 | 0 | 0.05 | 0.02 |
| Intervalo P-R (s) | 0.18 | 0 | 0.12 | 0.03 |
| Duração QRS (s) | 0.08 | 0 | 0.05 | 0.02 |
| Amplitude Onda R (mV) | 2.80 | 0 | 1.26 | 0.56 |
| Amplitude Onda T (mV) | 0.60 | -0.80 | 0.05 | 0.30 |
| Duração Onda T (s) | 0.24 | 0 | 0.08 | 0.04 |
| Intervalo Q-T (s) | 0.40 | 0 | 0.27 | 0.05 |
| Pressão intra-abdominal | 17 | 0 | 4.50 | 3.60 |

4.3.1 - População Saudável

Os 3 parâmetros morfológicos e os 15 fisiológicos recolhidos para a população saudável apresentaram os valores constantes da Tabela 4-2.

Tabela 4-2- Estatística descritiva das 19 variáveis obtidos na população saudável

| Variável | Limite superior | Limite Inferior | Média | Desvio Padrão |
|--|-----------------|-----------------|--------|---------------|
| Peso (Kg) | 40 | 2.10 | 14.92 | 11,66 |
| Perímetro abdominal (cm) | 72.50 | 31.00 | 46.34 | 12.59 |
| Área de superfície da cavidade abdominal (m ²) | 0,22 | 0.03 | 0.10 | 0.05 |
| Frequência Cardíaca (bpm) | 152 | 43 | 89.17 | 21.06 |
| Pulsoximetria (%) | 100 | 69 | 96.01 | 3.95 |
| Capnografia (mmHg) | 54 | 19 | 40.76 | 7.04 |
| Pressão arterial sistólica (mmHg) | 204 | 60 | 108.06 | 28.27 |
| Pressão arterial média (mmHg) | 115 | 32 | 71.69 | 20.17 |
| Pressão arterial diastólica (mmHg) | 96 | 15 | 52.42 | 19.79 |
| Temperatura (°C) | 37.80 | 34.40 | 36.38 | 0.83 |
| Amplitude onda P (mV) | 0.50 | 0,10 | 0,23 | 0,11 |
| Duração onda P (s) | 0.16 | 0.04 | 0.06 | 0.03 |
| Intervalo P-R (s) | 0.18 | 0,08 | 0,13 | 0,03 |
| Duração QRS (s) | 0.08 | 0,04 | 0,05 | 0,01 |
| Amplitude Onda R (mV) | 2.80 | 0.30 | 1.07 | 0.54 |
| Amplitude Onda T (mV) | 0.60 | -0.40 | 0.23 | 0.23 |
| Duração onda T (s) | 0.24 | 0.02 | 0,09 | 0,04 |
| Intervalo Q-T (s) | 0.40 | 0.20 | 0.29 | 0.05 |
| Pressão intra-abdominal | 15 | 0 | 4.53 | 2.99 |

4.3.2 - População Doente

Os parâmetros morfológicos e fisiológicos recolhidos para a população doente apresentaram resultados constantes da Tabela 4-3.

Tabela 4-3- Estatística descritiva das 19 variáveis obtidos na população doente.

| Variável | Limite superior | Limite Inferior | Média | Desvio Padrão |
|--|-----------------|-----------------|--------|---------------|
| Peso (Kg) | 37 | 1.50 | 17.39 | 10.76 |
| Perímetro abdominal (cm) | 88.30 | 25 | 52.48 | 16.53 |
| Área de superfície da cavidade abdominal (m ²) | 0.20 | 0.03 | 0.12 | 0.05 |
| Frequência Cardíaca (bpm) | 208 | 45 | 108.99 | 26.97 |
| Pulsoximetria (%) | 100 | 0 | 93.74 | 16.58 |
| Capnografia (mmHg) | 57 | 0 | 37.50 | 14.44 |
| Pressão arterial sistólica (mmHg) | 167 | 0 | 111.21 | 29.03 |
| Pressão arterial média (mmHg) | 138 | 0 | 78.09 | 25.02 |
| Pressão arterial diastólica (mmHg) | 129 | 0 | 60.45 | 23.85 |
| Temperatura (°C) | 37.90 | 32 | 35.83 | 1.19 |

| | | | | |
|--------------------------------|------|-------|-------|------|
| Amplitude onda P (mV) | 0.60 | 0 | 0.27 | 0.09 |
| Duração onda P (s) | 0.08 | 0 | 0.05 | 0.01 |
| Intervalo P-R (s) | 0.16 | 0 | 0.11 | 0.03 |
| Duração QRS (s) | 0.08 | 0 | 0.05 | 0.02 |
| Amplitude Onda R (mV) | 2.60 | 0 | 1.39 | 0.55 |
| Amplitude onda T (mV) | 0.60 | -0.80 | -0.08 | 0.29 |
| Duração onda T (s) | 0.20 | 0 | 0.08 | 0.04 |
| Intervalo Q-T (s) | 0.40 | 0 | 0.25 | 0.05 |
| Pressão intra-abdominal | 17 | 0 | 4.48 | 3.99 |

4.3.3 - Redução do número de características: correlação estatística entre as variáveis de entrada

A correlação estatística entre os 18 parâmetros morfológicos e fisiológicos (entradas do sistema), foi efetuada de forma a encontrar pares de variáveis com uma correlação estatística muito forte, de forma a eliminar algumas delas do modelo de IC, com vista à sua simplificação. A correlação linear mais forte encontrada foi entre o peso e o perímetro (cc 0.91) e entre o peso e a ASCA (cc 1.00), sendo os restantes índices de correlação apresentados na tabela 4-4.

Tabela 4-4- Valores de correlação entre as 18 variáveis de entrada.

| Variável | Peso | Per. | ASCA | FC | SpO ₂ | EtCO ₂ | PAS | PAM | PAD | T.° | Amp. P | Dur. P | [P-R] | QRS | Ampl. R | Ampl. T | Dur. T | [Q-T] |
|-------------------------|-------------|-------------|-------------|-------|------------------|-------------------|-------|-------|-------|-------|--------|--------|-------|-------|---------|---------|--------|-------|
| Peso | 1,00 | 0,91 | 1,00 | -0,09 | 0,22 | 0,16 | 0,47 | 0,53 | 0,57 | 0,24 | 0,22 | 0,35 | 0,31 | 0,07 | 0,58 | 0,04 | -0,39 | 0,04 |
| Perímetro | 0,91 | 1,00 | 0,91 | -0,01 | 0,29 | 0,28 | 0,43 | 0,44 | 0,46 | 0,26 | 0,19 | 0,29 | 0,23 | -0,01 | 0,56 | 0,01 | -0,41 | -0,05 |
| ASCA | 1,00 | 0,91 | 1,00 | -0,11 | 0,27 | 0,20 | 0,47 | 0,53 | 0,56 | 0,25 | 0,25 | 0,37 | 0,35 | 0,09 | 0,60 | 0,01 | -0,41 | 0,06 |
| FC | -0,09 | -0,01 | -0,11 | 1,00 | -0,29 | -0,19 | -0,05 | 0,01 | 0,02 | -0,20 | 0,18 | -0,13 | -0,53 | -0,14 | -0,02 | -0,16 | -0,01 | -0,53 |
| SpO₂ | 0,22 | 0,29 | 0,27 | -0,29 | 1,00 | 0,58 | 0,27 | 0,19 | 0,16 | 0,30 | 0,28 | 0,30 | 0,46 | 0,24 | 0,33 | -0,08 | 0,10 | 0,48 |
| EtCO₂ | 0,16 | 0,28 | 0,20 | -0,19 | 0,58 | 1,00 | 0,03 | -0,02 | 0,02 | 0,33 | 0,19 | 0,21 | 0,27 | 0,21 | 0,30 | -0,05 | -0,05 | 0,20 |
| PAS | 0,47 | 0,43 | 0,47 | -0,05 | 0,27 | 0,03 | 1,00 | 0,89 | 0,72 | 0,27 | 0,04 | 0,19 | 0,31 | 0,04 | 0,32 | 0,07 | -0,17 | 0,22 |
| PAM | 0,53 | 0,44 | 0,53 | 0,01 | 0,19 | -0,02 | 0,89 | 1,00 | 0,92 | 0,20 | 0,07 | 0,21 | 0,19 | 0,11 | 0,35 | 0,04 | -0,15 | 0,14 |
| PAD | 0,57 | 0,46 | 0,56 | 0,02 | 0,16 | 0,02 | 0,72 | 0,92 | 1,00 | 0,17 | 0,12 | 0,24 | 0,13 | 0,14 | 0,38 | 0,00 | -0,15 | 0,08 |
| T.° | 0,24 | 0,26 | 0,25 | -0,20 | 0,30 | 0,33 | 0,27 | 0,20 | 0,17 | 1,00 | -0,13 | 0,04 | 0,39 | -0,05 | 0,23 | 0,19 | -0,04 | 0,21 |
| Amp. P | 0,22 | 0,19 | 0,25 | 0,18 | 0,28 | 0,19 | 0,04 | 0,07 | 0,12 | -0,13 | 1,00 | 0,39 | 0,27 | 0,30 | 0,48 | -0,21 | -0,13 | 0,01 |
| Dur. P | 0,35 | 0,29 | 0,37 | -0,13 | 0,30 | 0,21 | 0,19 | 0,21 | 0,24 | 0,04 | 0,39 | 1,00 | 0,46 | 0,30 | 0,32 | 0,19 | -0,09 | 0,28 |
| [P-R] | 0,31 | 0,23 | 0,35 | -0,53 | 0,46 | 0,27 | 0,31 | 0,19 | 0,13 | 0,39 | 0,27 | 0,46 | 1,00 | 0,13 | 0,34 | 0,15 | -0,16 | 0,54 |
| QRS | 0,07 | -0,01 | 0,09 | -0,14 | 0,24 | 0,21 | 0,04 | 0,11 | 0,14 | -0,05 | 0,30 | 0,30 | 0,13 | 1,00 | 0,34 | -0,17 | 0,06 | 0,24 |
| Ampl. R | 0,58 | 0,56 | 0,60 | -0,02 | 0,33 | 0,30 | 0,32 | 0,35 | 0,38 | 0,23 | 0,48 | 0,32 | 0,34 | 0,34 | 1,00 | -0,10 | -0,13 | 0,15 |
| Ampl. T | 0,04 | 0,01 | 0,01 | -0,16 | -0,08 | -0,05 | 0,07 | 0,04 | 0,00 | 0,19 | -0,21 | 0,19 | 0,15 | -0,17 | -0,10 | 1,00 | -0,05 | 0,18 |
| Dur. T | -0,39 | -0,41 | -0,41 | -0,01 | 0,10 | -0,05 | -0,17 | -0,15 | -0,15 | -0,04 | -0,13 | -0,09 | -0,16 | 0,06 | -0,13 | -0,05 | 1,00 | 0,39 |
| [Q-T] | 0,04 | -0,05 | 0,06 | -0,53 | 0,48 | 0,20 | 0,22 | 0,14 | 0,08 | 0,21 | 0,01 | 0,28 | 0,54 | 0,24 | 0,15 | 0,18 | 0,39 | 1,00 |

4.3.4 - Correlação estatística entre as variáveis de entrada e de saída

A correlação estatística entre cada variável de entrada e a variável de saída foi calculada com o intuito de descobrir quais as entradas que potencialmente mais afetam a saída, ou seja, a PIA. Dentro dos dezoito parâmetros de entrada, os sete que demonstraram uma maior correlação estatística com a PIA foram o peso (cc 0.48), a ASCA (cc 0.46), o perímetro (cc 0.34), a PAD (cc 0.25), a duração do QRS (cc 0.20), a PAM (cc 0.17) e a amplitude da onda R (cc 0.12) (Tabela 4-5 e Figura 4-8).

A definição de pressão é igual ao quociente da força do peso com a área de superfície, neste caso a ASCA [48,108,109]. Embora o peso e a ASCA tenham uma correlação linear forte, como ambas são necessárias para o cálculo físico da pressão, ambas foram mantidas no modelo reduzido de IC.

Tabela 4-5- Correlação estatística, coeficiente de correlação de Pearson, entre as variáveis de entrada e a variável de saída.

| Variável | Peso | Per. | ASCA | FC | SpO ₂ | EtCO ₂ | PAS | PAM | PAD |
|----------|------|---------|--------|------|------------------|-------------------|---------|--------|-------|
| PIA | 0,48 | 0,33 | 0,46 | 0,04 | -0,11 | 0,07 | 0,07 | 0,17 | 0,25 |
| Variável | T.º | Ampl. P | Dur. P | QRS | [QR] | Ampl. R | Ampl. T | Dur. T | [Q-T] |
| PIA | 0,07 | -0,03 | 0,08 | 0,20 | 0,01 | 0,12 | 0,01 | -0,15 | -0,14 |




Figura 4-8-Índices de correlação entre as entradas e saídas do sistema

4.3.5 - Redes Neurais Artificiais

Na população total foram criadas 54 redes neuronais diferentes, primeiro utilizando os 18 parâmetros de entrada e depois, uma versão reduzida, utilizando apenas os 7 parâmetros de entrada com a maior correlação estatística com a saída. As redes foram criadas inicialmente para todo o conjunto de dados (população saudável e doente) e depois individualmente para cada grupo. Como funções de ativação utilizámos a *purelin*, a *logsig* e a *tansig*, e como funções de treino utilizamos a *trainscg*, a *trainlm*, e a *trainbr*. A função de ativação da camada de saída das RNA construídas foi sempre do tipo linear.

Em termos da arquitetura da rede criaram-se redes com 2, 3, 4 e 5 camadas e fizemos variar o número de neurónios nas camadas ocultas de forma a avaliar a rede mais indicada por avaliação do índice de regressão linear. Os melhores resultados obtidos com as RNA são apresentados resumidamente na Tabela 4-6.

Tabela 4-6- Resumo dos melhores resultados obtidos nas RNA, o R representa o coeficiente de regressão linear entre as saídas e o alvo.

| População | 18 Variáveis de entrada | | | 7 Variáveis de entrada | | |
|-----------|-------------------------|--------------------------------|---------|------------------------|--------------------------------|---------|
| | Função de ativação | Função de treino | R | Função de ativação | Função de treino | R |
| Total | <i>Tansig</i> | <i>Bayseian regularization</i> | 0.96706 | <i>Tansig</i> | <i>Bayseian regularization</i> | 0.97341 |
| Saudável | <i>Logsig</i> | <i>Bayseian regularization</i> | 0.97699 | <i>Logsig</i> | <i>Bayseian regularization</i> | 0.94607 |
| Doente | <i>Logsig</i> | <i>Bayseian regularization</i> | 0.96810 | <i>Tansig</i> | <i>Bayseian regularization</i> | 0.96829 |

Utilizando os dados da população total através do modelo reduzido (7 variáveis de entrada) fez-se o estudo de comparação de arquiteturas e do número de neurónios por camada. Pela observação dos gráficos da figura 4-9 e 4-10, de comparação dos vários coeficientes de regressão linear entre as saídas e os alvos, de cada arquitetura na fase de treino e em todas as fases (treino e teste) os melhores resultados obtidos foram utilizando

redes de 2 camadas (1 camada escondida e 1 de saída), 3 camadas (2 camadas escondidas e 1 de saída) e 4 camadas (3 camadas escondidas e 1 de saída). As arquiteturas de rede com 3 e 4 camadas apresentaram os melhores resultados no modelo reduzido (7 variáveis de entrada). Estas redes apresentavam sempre índices de correlação, quer na fase de treino quer na de teste, iguais ou superiores a 0.9. Utilizando o modelo com as 18 variáveis de entrada, as arquiteturas com melhores resultados, foram as de 2 camadas. Foi observado que à medida que se aumentava o número de camadas, o tempo de calculo da RNA aumentava, apresentando a arquitetura com 5 camadas tempos elevados de calculo e índices de correlação por vezes quase ausentes entre as saídas e os alvos, quer na fase de treino quer na de teste.

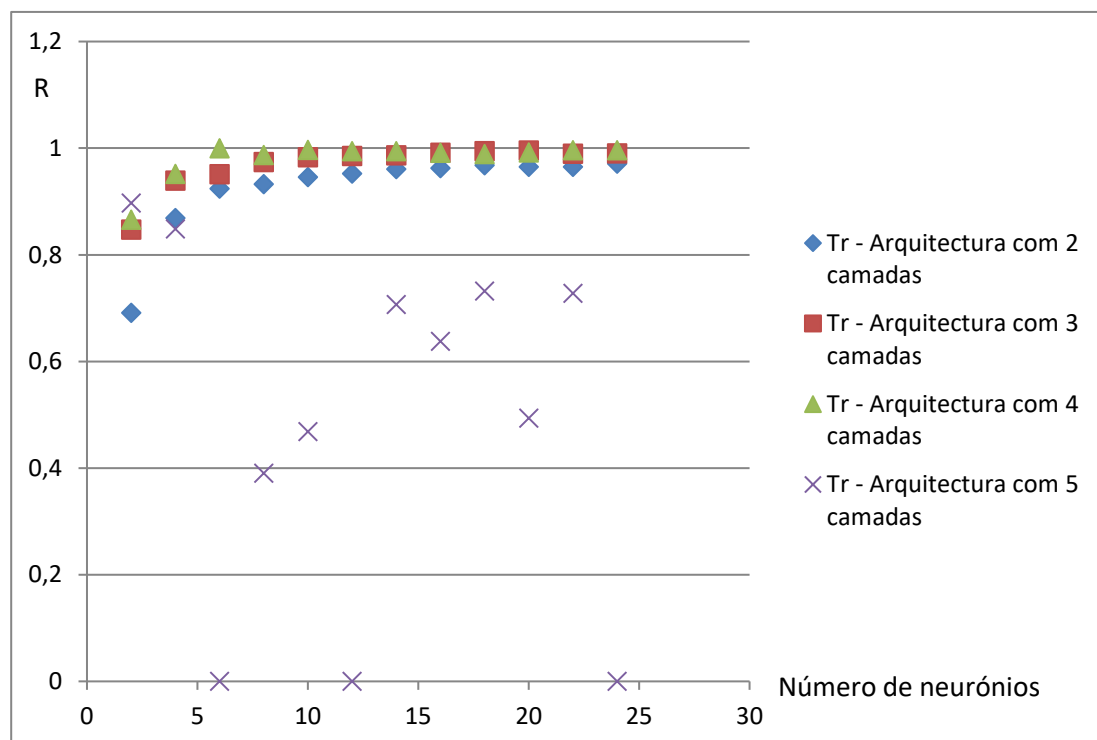


Figura 4-9- Comparação do índice de regressão linear de treino, entre as saídas e os alvos, das várias arquiteturas de RNA testadas, na população total usando o modelo reduzido. No eixo horizontal estão representados o número de neurónios por cada camada.




Figura 4-10- Comparação do índice de regressão linear total (treino e teste), entre as saídas e os alvos, das várias arquiteturas de RNA testadas, na população total usando o modelo reduzido. No eixo horizontal estão representados o número de neurónios por cada camada.

Relativamente ao número de neurónios por camada verificou-se que a partir dos 10 neurónios por camada os índices de regressão entre as saídas e os alvos mantêm-se praticamente constantes, não havendo vantagens em elevar o número de neurónios da rede.

População total

Dentro das redes neuronais criadas para a população total, utilizando as 18 variáveis de entrada, os melhores resultados foram obtidos utilizando a função de ativação *tansig* e a função de treino *Bayesian regularization* numa rede de duas camadas, tendo a camada oculta 11 neurónios. Utilizando esta arquitetura de rede obtivemos resultados, no conjunto de treino, com índices de correlação de regressão entre as saídas obtidas pela rede e as saídas-alvo (*target*), de 0.98. O valor de R no conjunto de teste da RNA foi de

0.86 e no conjunto de dados total de 0.97. O histograma de erro do modelo apresenta os erros, calculados por subtração entre os alvos (*target*) e a saída da rede obtida. O histograma mostra que existem poucos *outliers* nos dados, caindo o erro no intervalo $[-2.83, 2.87]$. Contudo ainda existem três pontos de teste com um erro de 4.58, 5.15 e -5.69 e um ponto de treino com um erro de -3.96 (Figura 4-11).




Figura 4-11- Histograma de erro da melhor RNA utilizando os 18 parâmetros de entrada. A barra azul representa os dados de treino e a barra a vermelho os dados de teste.

No modelo reduzido, utilizando unicamente as 7 variáveis de entrada selecionadas pela análise de correlação, o melhor resultado obtido foi utilizando a função de ativação *tansig*, a função de treino *Bayesian regularization* e utilizando uma rede de três camadas, tendo a primeira e segunda camada ocultas 10 e 12 neurónios respetivamente, figura 4-12.




Figura 4-12 – Arquitetura da melhor RNA utilizando os 7 parâmetros de entrada para a população total (figura criada pelo Matlab).

Utilizando esta arquitetura de rede obtivemos resultados de treino de rede com valores de R de 0.99. O valor de R de teste da RNA foi de 0.91 e o resultado total do valor R de 0.97 como se pode observar pelos gráficos da Figura 4-13.

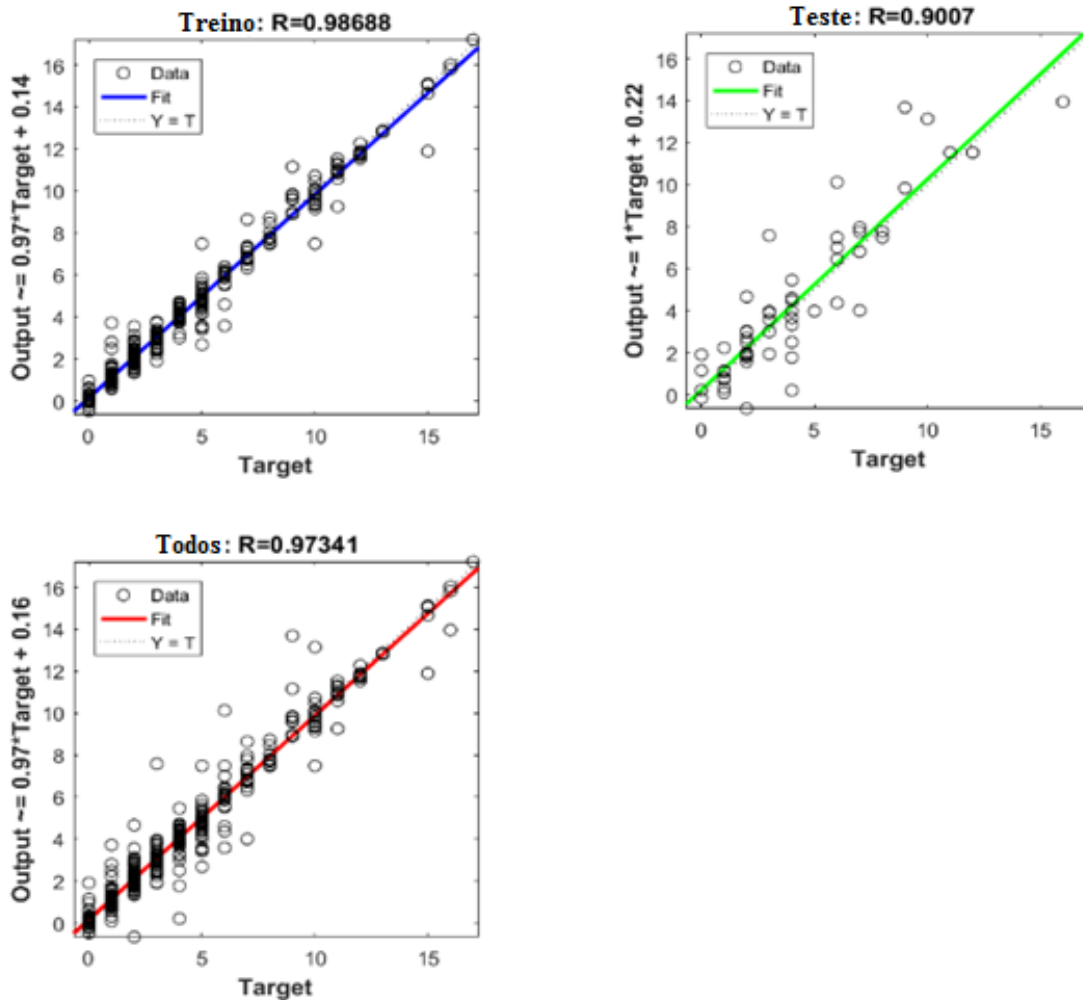


Figura 4-13 -Gráficos de regressão do treino da rede, de teste, e total, utilizando 7 parâmetros de entrada na população total.

O histograma de erro demonstra que existem poucos outliers nos dados, caindo o erro entre o intervalo -4.45 e 3.59. Havendo unicamente um ponto de teste com um erro de -7.84, Figura 4-14.




Figura 4-14. Histograma de erro da melhor RNA utilizando os 7 parâmetros de entrada. A barra azul representa os dados de treino e a barra a vermelho os dados de teste.

A apresentação gráfica dos valores reais, determinados por sensor direto em cada uma das medições comparativamente com os valores determinados pela melhor RNA criada utilizando o modelo reduzido de 7 variáveis de entrada, pode ser visualizado na Figura 4-15. Podemos observar que os valores obtidos por sensor direto são muito próximos dos valores determinados pela RNA, apresentando-se a maioria dos pontos azuis (valores reais da PIA) muito próximos dos pontos vermelhos (valores determinados pela RNA). Os primeiros 259 pontos são do conjunto de treino (70%) e os restantes do conjunto de teste e validação (15% de cada).

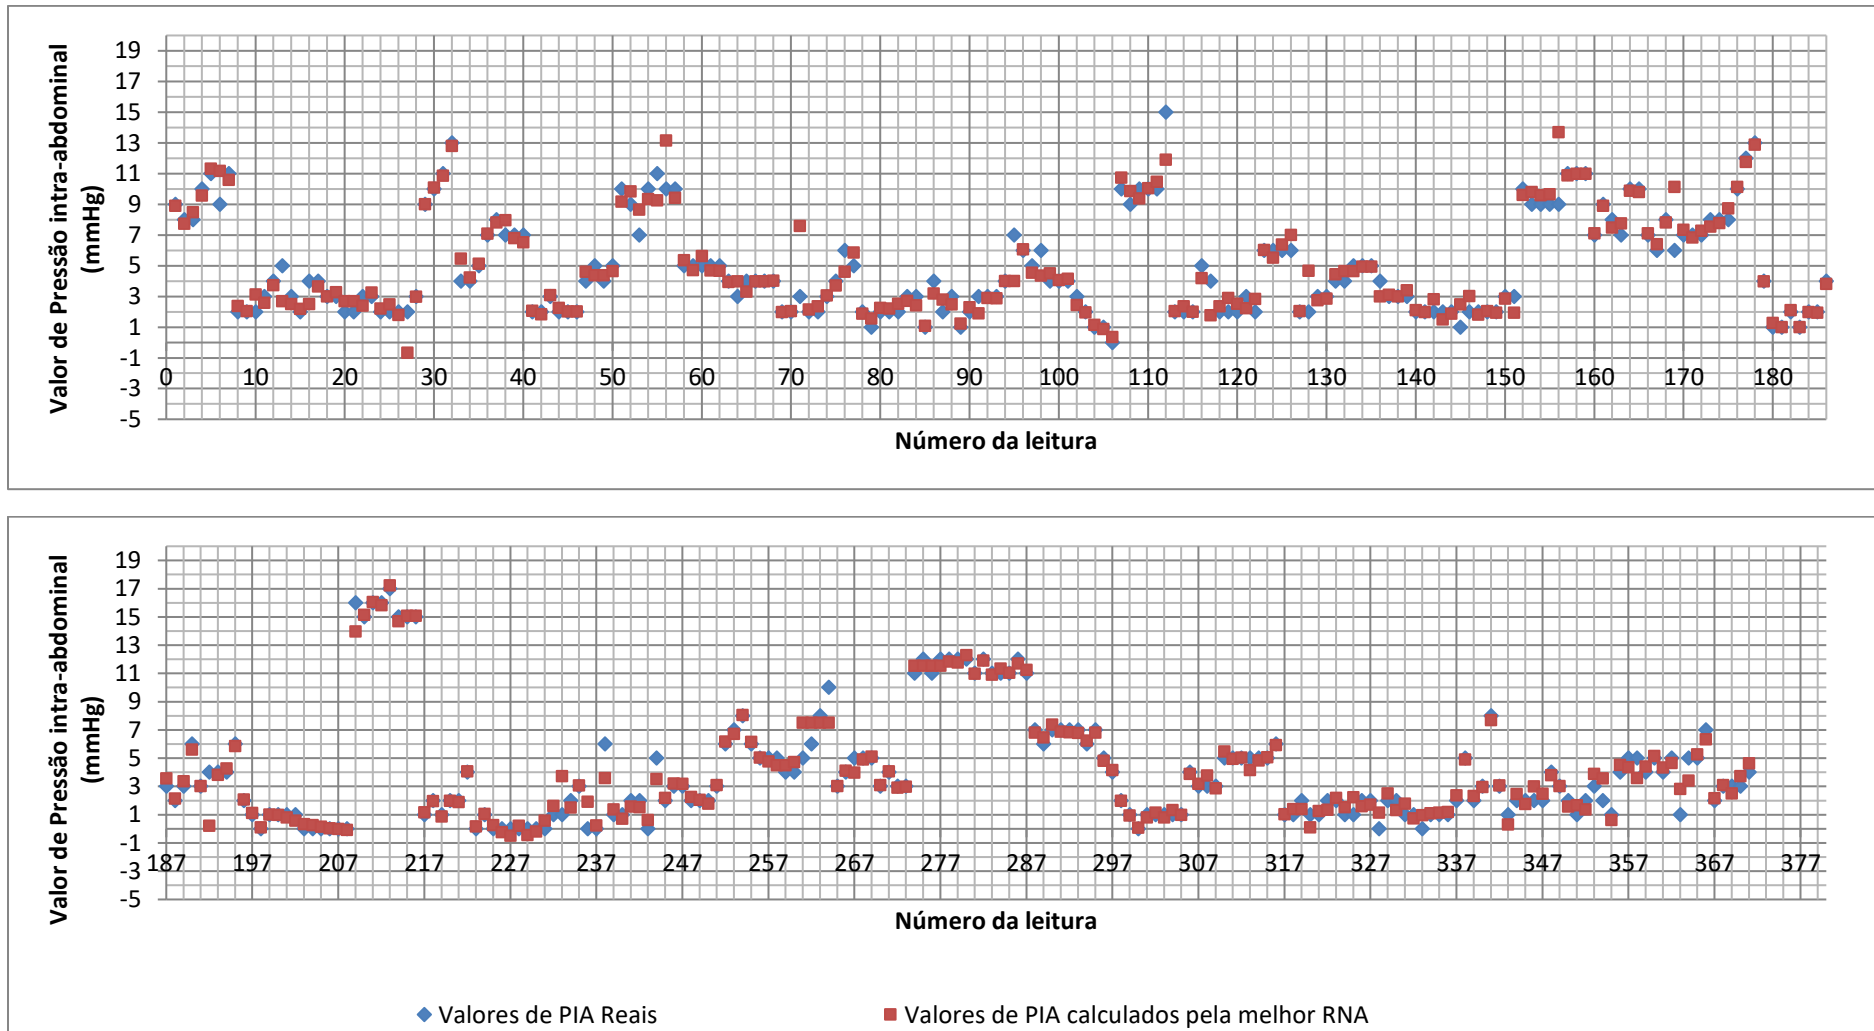


Figura 4-15- Gráfico de comparação dos valores reais de PIA obtidos por sensor direto (pontos azuis) com os valores determinados pela melhor RNA do modelo reduzido com 7 entradas de sistema (valores a vermelho).

População Saudável

Utilizando unicamente o grupo de dados da população saudável, com as 18 variáveis de entrada, o melhor resultado obtido foi utilizando a função de ativação *Logsig* e a função de treino *Bayesian regularization* e uma rede de duas camadas, tendo a camada oculta 20 neurónios. Utilizando esta arquitetura de rede o valor de R de teste da RNA foi de 0.85, o de treino de 0.99 e o resultado total do valor R de 0.98 (Figura 4-16). Este foi o índice de regressão linear mais alto obtido.

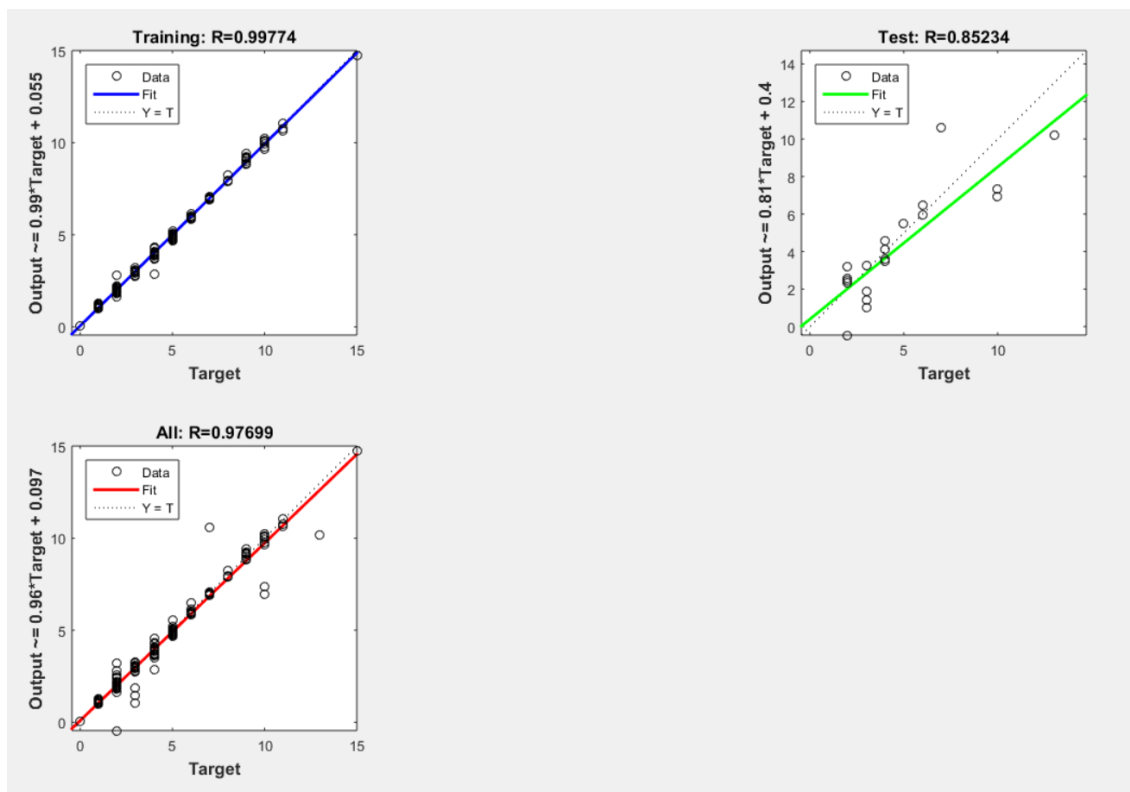


Figura 4-16- Gráficos de regressão do treino da rede de teste e total, utilizando os 18 parâmetros de entrada na população saudável.

A melhor performance de treino foi obtida na época 140 com uma performance de aproximadamente 0.6 (Figura 4-17).




Figura 4-17- Gráfico de performance da RNA utilizando os 18 parâmetros de entrada na população saudável.

O histograma de erro do modelo apresenta os erros que correspondem à subtração das saídas dos alvos. Este mostra que ainda existem alguns pontos que a rede não consegue prever com exatidão, caindo o erro na maior parte dos casos dentro do intervalo -1.10 e 1.23. Havendo vários pontos de teste com um erro de 1.56, 2.57, 2.90 e -3.44, Figura 4-18.




Figura 4-18- Histograma de erro da melhor RNA utilizando os 18 parâmetros de entrada na população saudável. A barra azul representa os dados de treino e a barra a vermelho os dados de teste.

As RNA criadas para este grupo, utilizando apenas as 7 variáveis de entrada, também obtiveram os melhores resultados com a função de ativação *Logsig* e com a função de treino *Bayesian regularization*. A grande diferença entre os modelos com as 18 entradas e as de 7 entradas, foi a arquitetura de rede, tendo este último modelo três camadas, com 15 neurónios em cada camada oculta. Utilizando esta arquitetura de rede, obtivemos resultados de treino de rede com um índice de regressão de 0.96 entre as saídas da rede e os alvos, tendo sido o valor de teste de 0.94 e o resultado total de 0.95.




Figura 4-19- Gráfico de performance da RNA utilizando os 7 parâmetros de entrada na população saudável. MSE – erro quadrado médio.

O histograma de erro do modelo apresenta os erros, caindo o erro entre o intervalo -2.69 e 2.74. Havendo dois pontos de teste com um erro de -5.20 e -3.94 (Figura 4-20).




Figura 4-20- Histograma de erro da melhor RNA utilizando os 7 parâmetros de entrada na população saudável. A barra azul representa os dados de treino e a barra a vermelho os dados de teste.

População Doente

Nas RNA criadas para a população doente, utilizando as 18 variáveis de entrada, os melhores resultados foram obtidos utilizando com a função de ativação *Logsig* e com a função de treino *Bayesian regularization*. Estes resultados são idênticos aos obtidos para a população total e para a população saudável. A melhor arquitetura de rede neste grupo era uma rede de duas camadas, tendo a camada oculta 10 neurónios. Utilizando esta arquitetura obtivemos resultados de treino com um coeficiente de correlação entre as saídas e os alvos de 0.99. O valor de R de teste foi de 0.76 e o resultado total de 0.97. O histograma de erro demonstra que entre o intervalo -2.07 e 3.4 o erro diminui, havendo, no entanto, vários pontos de teste com um erro de 4.92, -3.56, -4.06, -4.57 (figura 4-21).




Figura 4-21- Histograma de erro da melhor RNA utilizando os 18 parâmetros de entrada na população doente. A barra azul representa os dados de treino e a barra a vermelho os dados de teste.

Utilizando as 7 variáveis de entrada, os melhores resultados de rede foram obtidos com a função de ativação *tansig* o que divergiu dos resultados anteriores que tinham sido obtidos com a função *Logsig*. A função de treino que continuou a obter melhores resultados foi a função *Bayesian regularization*. A arquitetura de rede com melhores resultados foi uma

rede de três camadas, tendo as camadas ocultas 10 e 12 neurónios. Utilizando esta arquitetura obtivemos resultados de treino com índices de correlação entre os alvos e as saídas da rede de $R= 0.99$. O valor de teste da RNA foi de $R=0.90$ e o resultado total $R=0.97$. O histograma de erro demonstra que existem poucos outliers nos dados, caindo o erro dentro do intervalo $[-4.08,4.071]$. Há um ponto de teste com um erro de -7.84 (figura 4-22).




Figura 4-22- Histograma de erro da melhor RNA utilizando os 7 parâmetros de entrada na população doente. A barra azul representa os dados de treino e a barra a vermelho os dados de teste.

4.3.6 - Agrupamento por mapas auto-organizados

No agrupamento dos dados por aprendizagem competitiva realizando o *clustering* dos dados por RNA utilizando mapas auto-organizados (SOM), os melhores resultados obtidos foram com a arquitetura da figura 4-23.




Figura 4-23- Arquitetura de rede, *Neural clustering* (nctool) da totalidade dos dados. Os dados totais foram agrupados em 4 grupos.

Este tipo de agrupamento organizou os dados num conjunto de 4 *clusters*, como pode ser observado pela projeção comprimida a duas dimensões do SOM obtido, onde cada neurónio mostra o número de vetores de entrada que classificou (figura 4-24 - canto inferior esquerdo). A relação entre cada neurónio e cada vetor é mostrada na figura 4-24 no canto superior esquerdo, onde a escala de cor, do preto ao amarelo, representa a proximidade entre neurónios vizinhos, sendo o amarelo a de maior proximidade. O gráfico na figura 4-24 do lado direito representa os vetores de entrada a cor verde e mostra como o SOM classificou o espaço de entrada com pontos azul-cinza para cada vetor do peso dos neurónios conectando os neurónios vizinhos com linhas vermelhas. Os centros dos clusters podem também ser observados nesta figura.

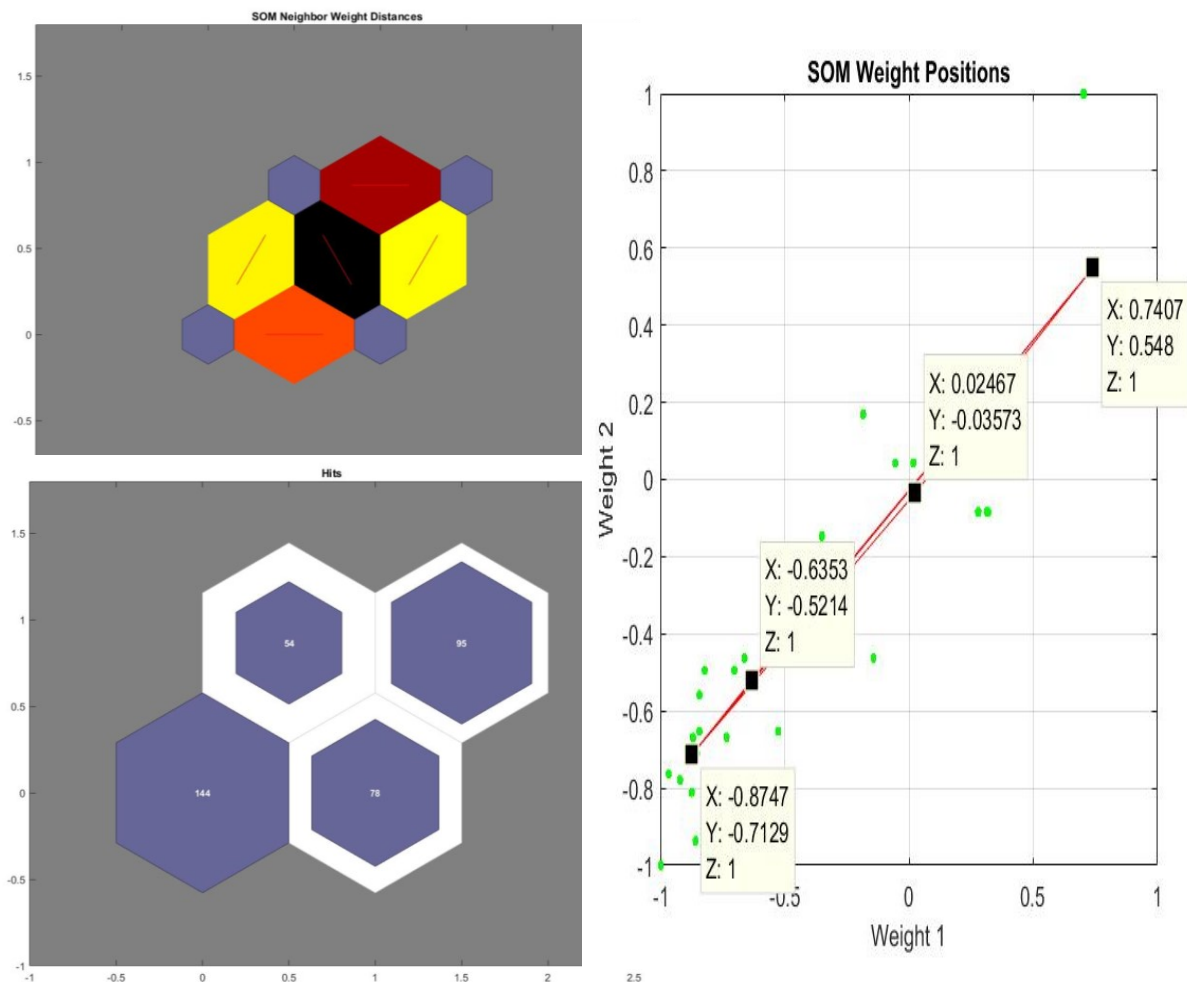


Figura 4-24- Representação compacta a duas dimensões do SOM, onde se pode ver no canto superior esquerdo os pesos das distâncias entre neurónios vizinhos. No canto inferior esquerdo as camadas do SOM, onde cada neurónio mostra o número de vetores de entrada que classificou. Do lado direito o gráfico demonstra o peso das posições do SOM, com os valores dos pontos azul cinza.

4.3.7- Redes adaptativas baseadas em sistemas de inferência difusa

Na construção das redes adaptativas começamos por criar um FIS, utilizando a função *genfis3* e sistemas de inferência difusa do tipo Sugeno e do tipo Mamdani. Os dados da população total, como já foi referido, foram divididos inicialmente em três grupos: 50% dos dados foram utilizados para treino (185 pontos); 25 % para validação (93 pontos) e 25 % para testar a rede (93 pontos).

Nos FIS inicialmente criados, utilizando a função *genfis3*, foi permitido criar automaticamente o número de regras através do método do clustering subtrativo. Quando utilizamos a função *genfis3* e todas as variáveis de entrada (18 entradas) o sistema criou um modelo FIS com uma estrutura com 46 regras. Tal como nas RNA, criou-se primeiro um modelo com todas as variáveis de entrada e depois criou-se um FIS da versão reduzida, unicamente com as 7 variáveis de entrada com maior correlação estatística. Quando utilizamos o modelo reduzido o sistema criou um FIS com um conjunto de 11 regras. Como já foi anteriormente referido, além de deixarmos o sistema determinar o número de regras automaticamente, utilizamos também o FIS com o número de regras pré-estabelecido usando o *clustering* dos dados por SOM. O agrupamento dos dados pelo SOM sugeriu um agrupamento em 4 *clusters*. Depois estes FIS são otimizados pela estrutura neurodifusa do ANFIS usando o seu GUI no Matlab. Os resultados ótimos obtidos com o ANFIS com os vários números de regras são apresentados na Tabela 4-7.

Tabela 4-7- Resultados obtidos inicializando o sistema difuso com a função *genfis3* com 18 e 7 variáveis de entrada com o erro de teste, de treino e de validação obtidos com a divisão dos dados 50% para treino, 25% para teste e 25% para validação. Os resultados FIS são do tipo Sugeno de ordem 1. O erro representa o RMSE, a média do quadrado dos erros obtido em cada ponto. Nos sistemas com 11 e 46 regras, quando utilizamos a função automática este utiliza o método subtrativo (SUB) e o método FCM quando estipulamos o número de regras. Algumas das redes apresentadas têm um número de pesos superior ao número de dados de treino, levando provavelmente a sobre-treino nos dados de treino, e conseqüentemente a uma pobre capacidade de generalização. Foram, no entanto, incluídas na tabela para que esta reflita o trabalho desenvolvido.

| | ANFIS | Regras | Clustering | Função treino | Modelo completo (18 entradas) | | | Clustering | Modelo reduzido (7 entradas) | | |
|---------|---------|--------|------------|------------------------|-------------------------------|-------|-----------|------------|------------------------------|-------|-----------|
| | | | | | RMSE | | | | RMSE | | |
| | | | | | Treino | Teste | Validação | | Treino | Teste | Validação |
| Genfis3 | Sugeno | 4 | SOM | <i>Backpropagation</i> | 0.28 | 3.96 | 5.05 | SOM | 0.20 | 0.29 | 0.67 |
| | Sugeno | 4 | SOM | <i>Hybrid</i> | 0.11 | 3.97 | 4.98 | SOM | 0.20 | 0.36 | 0.66 |
| | Sugeno | 11 | FCM | <i>Backpropagation</i> | 0.45 | 2.54 | 3.12 | SUB | 0.15 | 1.69 | 3.85 |
| | Sugeno | 11 | FCM | <i>Hybrid</i> | 0.07 | 2.38 | 2.82 | SUB | 0.14 | 1.89 | 3.79 |
| | Sugeno | 20 | FCM | <i>Backpropagation</i> | 1.03 | 13.24 | 5.29 | FCM | 0.15 | 6.93 | 3.87 |
| | Sugeno | 20 | FCM | <i>Hybrid</i> | 0.04 | 13.24 | 5.41 | FCM | 0.08 | 6.83 | 3.87 |
| | Sugeno | 46 | SUB | <i>Backpropagation</i> | 1.28 | 5.37 | 7.75 | FCM | 0.14 | 6.56 | 5.19 |
| | Sugeno | 46 | SUB | <i>Hybrid</i> | 0.05 | 5.45 | 7.49 | FCM | 0.05 | 9.28 | 5.41 |
| | Mamdani | 4 | FCM | <i>Backpropagation</i> | 10.74 | 10.32 | 23.11 | FCM | 7.39 | 8.07 | 20.77 |
| | Mamdani | 11 | FCM | <i>Backpropagation</i> | 9.22 | 23.13 | 7.78 | FCM | 6.24 | 19.01 | 9.52 |
| | Mamdani | 20 | FCM | <i>Backpropagation</i> | 11.19 | 4.29 | 19.16 | FCM | 5.38 | 8.30 | 20.25 |
| | Mamdani | 46 | FCM | <i>Backpropagation</i> | 6.33 | 18.64 | 2.98 | FCM | 4.98 | 19.87 | 7.95 |

Os melhores resultados obtidos para a população total com esta divisão de dados (50% treino, 25% teste e 25% validação), utilizando as 18 variáveis de entrada, corresponderam a um ANFIS utilizando o sistema de inferência Sugeno de ordem 1, com a função de treino *Backpropagation* e um conjunto de 11 regras. O ANFIS foi construído com a função *genfis3* que gera um FIS usando o método das *fuzzy c*-médias. Os resultados obtidos com este ANFIS foram de 0.45 para o erro de treino, de 2.54 para o de teste e de 3.12 para o de validação. Como se pode verificar o erro de teste e validação subiu muito em comparação com o erro de treino do FIS. As regras deste ANFIS podem-se visualizar na Figura 4-25.

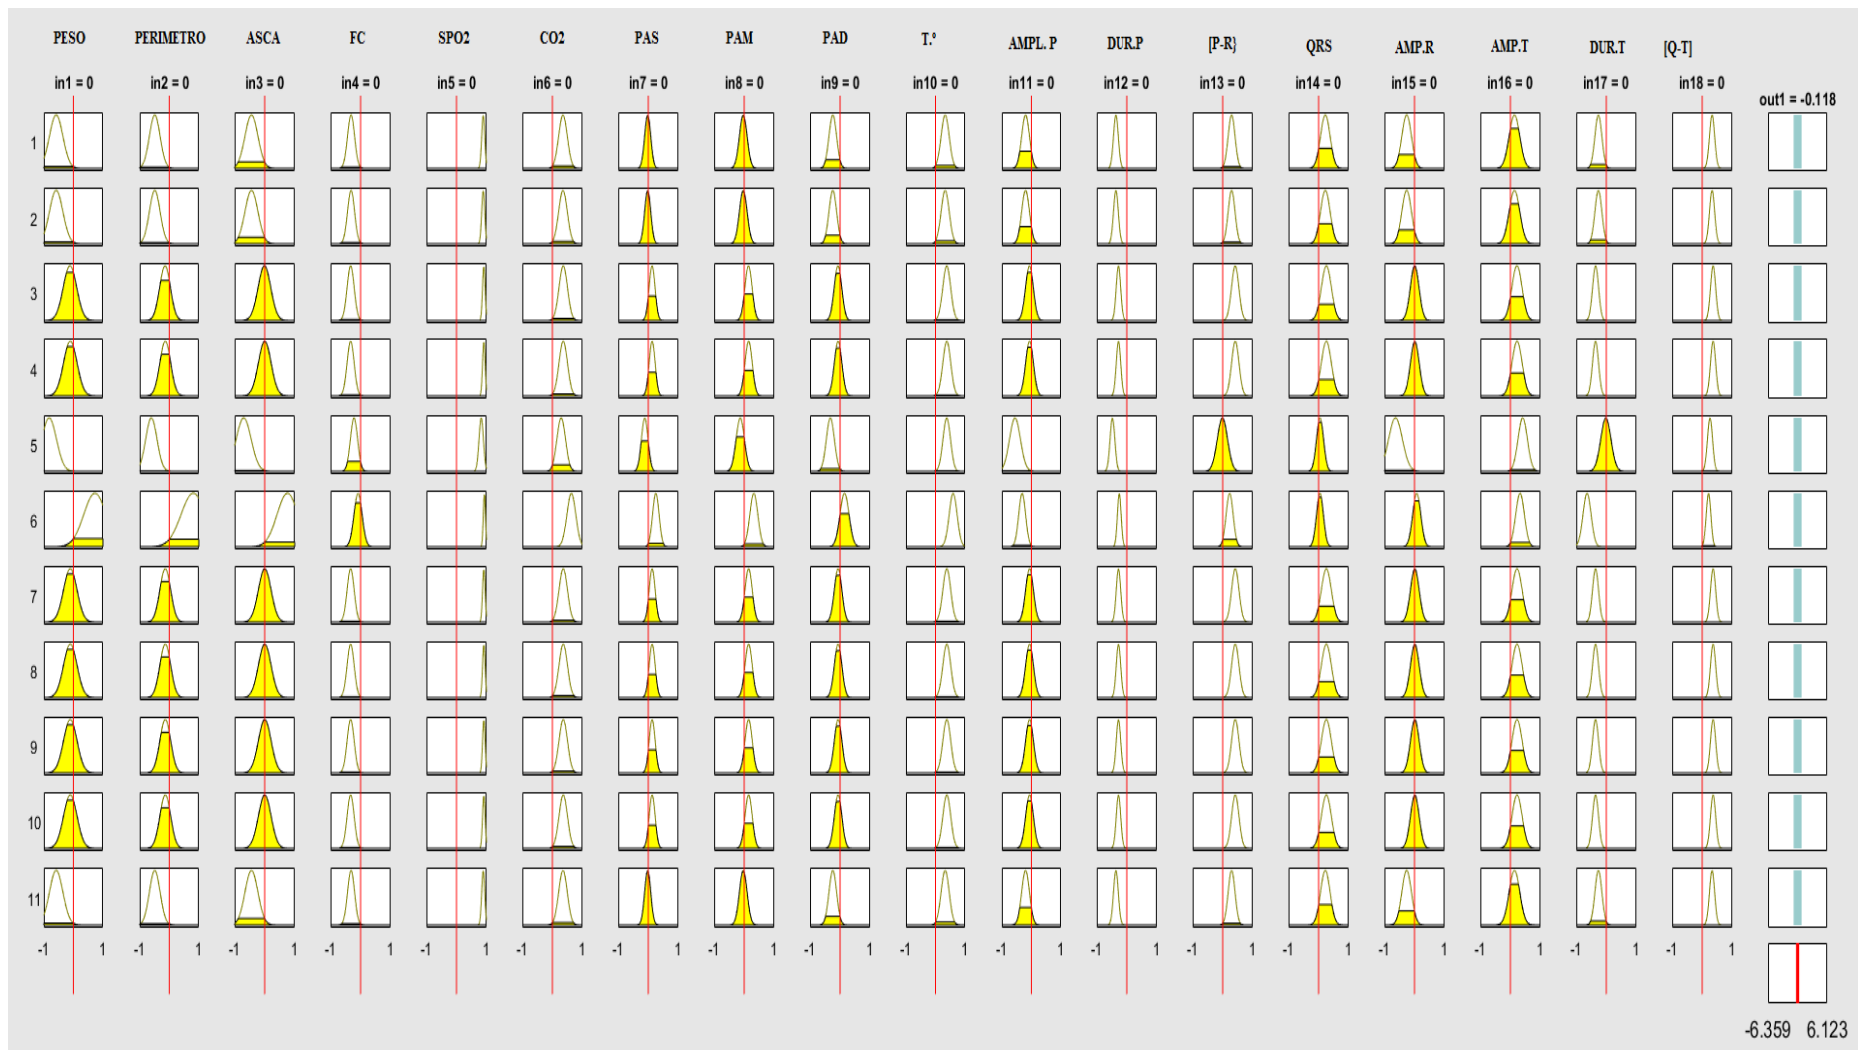


Figura 4-25- Visualizador de regras para o ANFIS do modelo com 18 entradas. Representação gráfica das funções de pertença gaussianas das entradas, com o limite máximo e mínimo para cada uma delas e na última coluna a saída do sistema (PIA). Variáveis de entrada normalizadas em [-1 1].

Nesta figura, cada coluna, corresponde a uma entrada e respetivas funções de pertinência gaussianas, normalizadas em $[-1 \ 1]$. A última coluna representa a saída do sistema com uma função polinomial linear. Contudo como podemos observar pela Tabela 4-7 muitos dos erros obtidos são extremamente altos. Verifica-se também por observação dos gráficos dos antecedentes das funções de pertinência gaussianas de algumas entradas, caso da pulsoximetria (SPO_2) e da capnografia (CO_2) entre outras (figura 4-25), apresentam valores de zero o que vai influenciar a FIS, levando a maus resultados de predição. Estas entradas, apresentam muitos valores de zero relativo, devido às características físicas dos métodos de medição e da influência fisiológica do individuo. No caso da capnografia (CO_2) muito dos valores das leituras do sensor são zero, devido ao simples facto de o paciente estar em apneia temporária e não expirar dióxido de carbono. No caso da pulsoximetria (SPO_2), como se pode verificar pela (figura 4-25), esta entrada faz a saída nula, exptuando para valores muito elevados. Estas variáveis de entrada, nestas condições, influenciam diretamente o FIS devido à determinação dos antecedentes e dos consequentes. Desta forma, na construção dos FIS, os modelos com as 18 entradas não são modelos aceitáveis de predição da saída (PIA).

Nos sistemas criados com o modelo reduzido, já não se verifica o problema observado nas funções de pertinência gaussianas das entradas visto que só utilizávamos as entradas com maior correlação estatística com a saída (PIA).

O ANFIS construído para o modelo reduzido, com 7 variáveis de entrada, 50% dos dados para treino (185 pontos), 25 % para validação (93 pontos) e 25 % para testar a rede (93 pontos), que obteve melhores resultados foi obtido com o sistema de inferência Sugeno de ordem 1 e com a função de otimização *Backpropagation*. O FIS gerado, tal como no modelo anterior é baseado no algoritmo FCM. Dos vários números de regras testados no ANFIS, o melhor comportamento foi obtido com 4 regras, de forma a obter a menor

diferença entre o erro de treino, teste e validação. Este ANFIS sendo o mais simples de todo o conjunto testado, unicamente com 7 entradas, foi a melhor solução encontrada com esta divisão de dados. A estrutura do ANFIS pode ser visualizada na figura 4-26.

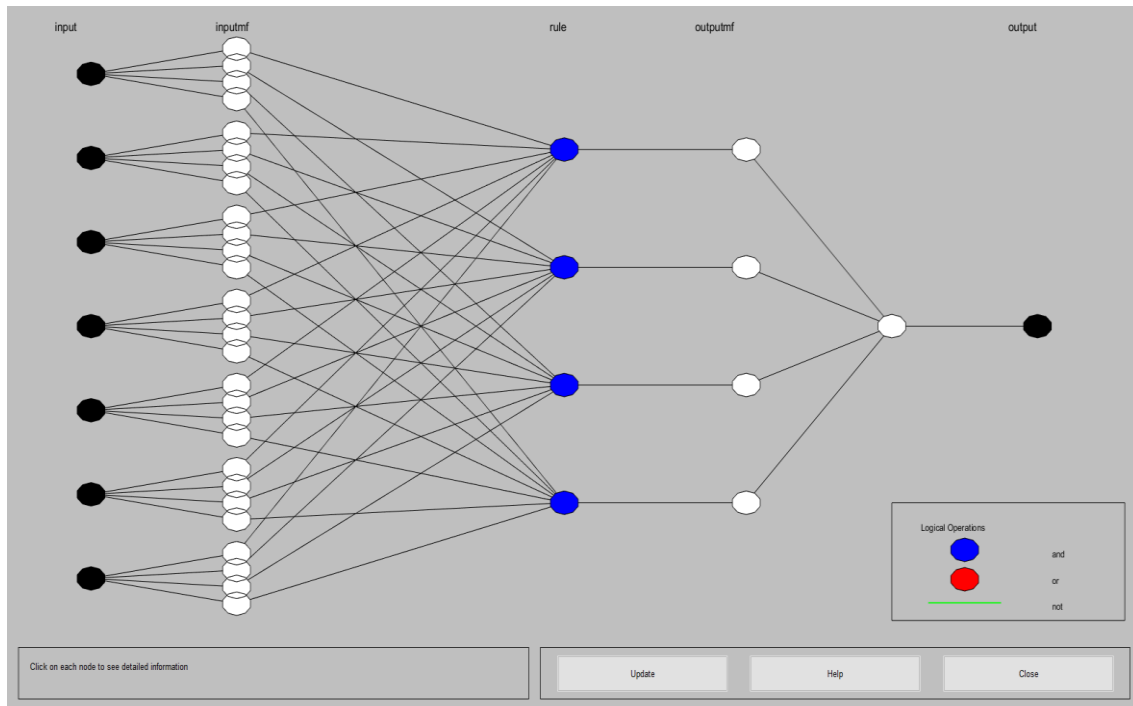


Figura 4-26- Estrutura da ANFIS com 7 entradas e um conjunto de 4 regras.

O ANFIS construído com o modelo reduzido demonstrou assim um erro de treino de 0.20, de teste de 0.36 e de validação de 0.66. Como pode ser verificado pela tabela 4-7 este foram os melhores resultados encontrados tendo também em atenção a não existência de sobre-treino. Fato este verificado quando existe um aumento pronunciado do erro de teste em comparação com o erro de treino.

Na Figura 4-27 podem ser observadas as 7 entradas do sistema com as suas funções de pertinência gaussianas, e os limites máximos e mínimos para cada entrada, a última coluna refere-se à representação linear da saída do sistema (PIA).

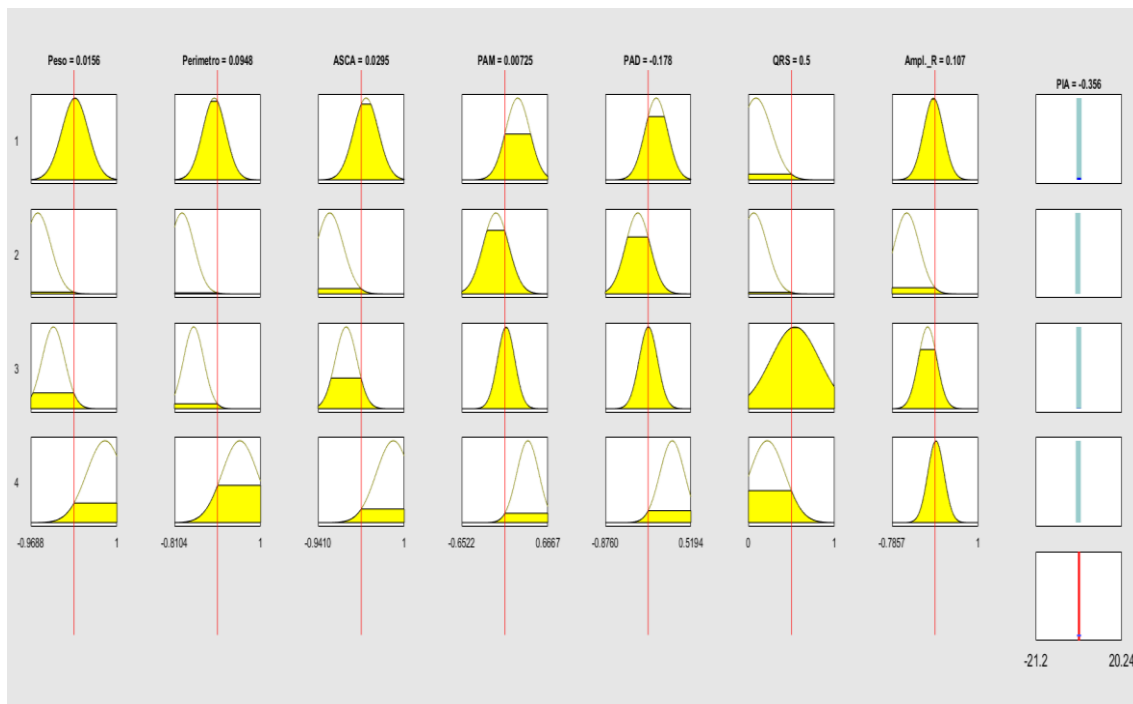


Figura 4-27- Visualizador de regras para o ANFIS do modelo reduzido com representação gráfica das gaussianas das entradas, com o limite máximo e mínimo para cada uma delas e na última coluna a saída do sistema (PIA).

Criamos também ANFIS, do tipo Sugeno de ordem 1, com a função *genfis2* que utiliza o método de *clustering* subtrativo de forma a averiguar se obtínhamos melhores resultados. Este tipo de função realiza o *clustering* dos dados automaticamente, tendo atribuído 46 regras quando utilizamos todas as variáveis de entrada e 11 regras quando utilizamos o modelo reduzido com 7 variáveis. Esta função utiliza o algoritmo *subclust* para determinar as funções de pertença e o método dos mínimos quadrados lineares para determinar as equações dos consequentes das regras. O *clustering* subtrativo requer a definição da região de influência do centro do *cluster*, através do parâmetro *radii*. Neste caso as funções de pertença utilizadas foram as gaussianas estando o *radii* ligado à variância da gaussiana. Utilizando esta metodologia o valor mais adequado de *radii* foi de 0.5. Os vários resultados obtidos podem ser observados na Tabela 4-8, contudo todos eles foram bastante piores dos que os obtidos com a função *genfis3*.

Tabela 4-8- Resultados dos ANFIS obtidos com a função *genfis2* com 18 e 7 variáveis de entrada com o erro de teste, de treino e de validação obtidos com a divisão dos dados 50% para treino, 25% para teste e 25% para validação.

| | | | | Modelo completo (18 entradas) | | | Modelo reduzido (7 entradas) | | | |
|--------|--------|------------|---------------|-------------------------------|-------|-----------|------------------------------|-------|-----------|------|
| ANFIS | Regras | Clustering | Função treino | RMSE | | | RMSE | | | |
| | | | | Treino | Teste | Validação | Treino | Teste | Validação | |
| Genfis | Sugeno | 11 | SUB | <i>Hybrid</i> | 0.01 | 13.00 | 36.00 | 0.13 | 31.45 | 6.93 |
| | Sugeno | 46 | SUBv | <i>Backpropagation</i> | 0.02 | 12.09 | 34.53 | 0.14 | 31.39 | 6.94 |

Devido à influência da divisão de dados nos resultados de treino e teste dos ANFIS, os dados foram organizados de outras formas, com o intuito de melhorar os resultados obtidos, para o modelo reduzido, com a divisão: 50% dos dados para treino (185 pontos), 25 % para validação (93 pontos) e 25 % para testar a rede (93 pontos). Ao contrário do que acontece com a *Neural Network Toolbox* do Matlab, que divide os dados num grupo de treino, validação e teste, servindo o grupo de validação para controlar o sobre treino da rede, no caso do ANFIS, isto não acontece. O desempenho, do ANFIS, é medido nos dados de teste não havendo vantagem efetiva na divisão dos dados num grupo de validação. Por esse motivo e de forma a melhorar os resultados, os dados, passaram a ser divididos unicamente em dados de treino e teste.

Os dados foram então divididos num grupo com 77% dos dados para treino (286 pontos) e os outros 23 % para teste (85 pontos). Utilizamos os dados exportados dos *clusters* da SOM e dividimos os mesmos pelo grupo de treino e de teste, tendo o cuidado de usar uma parte de cada cluster nos 2 grupos. Como se pode verificar pela Tabela 4-9 os resultados das ANFIS melhoram muito em comparação com os valores previamente obtidos.

Tabela 4-9- Resultados dos ANFIS obtidos, com a função *genfis3*, para o modelo reduzido com o RMSE de teste e de treino, com a divisão dos dados 77% para treino e 23% para teste. O erro representa o RMSE, a média do quadrado dos erros obtido em cada ponto.

| Modelo reduzido (7 entradas) | | | | | | | | | | |
|------------------------------|--------|------------|------------------|--------------------------|-------|-----------|--------------------------|-------|-----------|-------|
| ANFIS | Regras | Clustering | Função de Treino | RMSE (Sugeno de ordem 1) | | | RMSE (Sugeno de ordem 0) | | | |
| | | | | Treino | Teste | Diferença | Treino | Teste | Diferença | |
| Genfis3 | Sugeno | 4 | SOM | <i>Bacpropagation</i> | 0.21 | 0.34 | 0.13 | 0.34 | 0.39 | 0.05 |
| | Sugeno | 4 | SOM | <i>Hybrid</i> | 0.20 | 0.35 | 0.14 | 0.37 | 0.25 | -0.11 |
| | Sugeno | 11 | SUB | <i>Bacpropagation</i> | 0.17 | 1.71 | 1.55 | 0.28 | 0.32 | 0.05 |
| | Sugeno | 11 | SUB | <i>Hybrid</i> | 0.14 | 1.79 | 1.55 | 0.14 | 0.33 | 0.18 |
| | Sugeno | 20 | FCM | <i>Bacpropagation</i> | 0.18 | 2.39 | 2.20 | 0.27 | 0.47 | 0.19 |
| | Sugeno | 20 | FCM | <i>Hybrid</i> | 0.13 | 2.99 | 2.27 | 0.12 | 0.47 | 0.35 |
| | Sugeno | 46 | FCM | <i>Bacpropagation</i> | 0.29 | 4.05 | 3.76 | 0.28 | 5.01 | 4.73 |
| | Sugeno | 46 | FCM | <i>Hybrid</i> | 0.04 | 4.64 | 3.96 | 0.04 | 5.01 | 4.97 |

Por observação, dos gráficos de treino e de teste dos ANFIS criados, verificámos que existia um conjunto de dados da saída no grupo de teste que tinha valores muito diferentes dos valores dados para o treino da rede. Dividimos então esse conjunto de dados pelo grupo de treino e pelo grupo de teste de forma a possibilitar uma melhor aprendizagem da rede. Foram então utilizados para treino 67.4% dos dados (250 pontos) e 32.6% (121 pontos) para teste. Como se pode verificar, pela Tabela 4-10, o erro médio obtido nos vários ANFIS baixou em comparação com os resultados obtidos anteriormente com as outras divisões de dados.

Tabela 4-10- Resultados dos ANFIS obtidos, com a função genfis3, para o modelo reduzido com o RMSE de teste e de treino, com a divisão dos dados 67,4% para treino e 32,6 % para teste. O erro representa o RMSE, a média do quadrado dos erros obtido em cada ponto.

| Modelo reduzido (7 entradas) | | | | | | | | | | |
|------------------------------|--------|------------|------------------|--------------------------|-------|-----------|--------------------------|-------|-----------|-------|
| ANFIS | Regras | Clustering | Função de Treino | RMSE (Sugeno de ordem 1) | | | RMSE (Sugeno de ordem 0) | | | |
| | | | | Treino | Teste | Diferença | Treino | Teste | Diferença | |
| Genfis3 | Sugeno | 4 | SOM | <i>Bacpropagation</i> | 0.21 | 0.35 | 0.14 | 0.36 | 0.31 | -0,05 |
| | Sugeno | 4 | SOM | <i>Hybrid</i> | 0.18 | 0.35 | 0.17 | 0.36 | 0.31 | -0,05 |
| | Sugeno | 11 | SUB | <i>Bacpropagation</i> | 0.16 | 1.79 | 1.63 | 0.28 | 0.34 | 0.06 |
| | Sugeno | 11 | SUB | <i>Hybrid</i> | 0.13 | 1.78 | 1.64 | 0.29 | 0.33 | 0.03 |
| | Sugeno | 20 | FCM | <i>Bacpropagation</i> | 0.14 | 3.59 | 3.45 | 0.26 | 0.82 | 0.56 |
| | Sugeno | 20 | FCM | <i>Hybrid</i> | 0.09 | 2.89 | 2.79 | 0.27 | 0.86 | 0.59 |
| | Sugeno | 46 | FCM | <i>Bacpropagation</i> | 0.28 | 4.45 | 4.16 | 0.32 | 6.55 | 6.23 |
| | Sugeno | 46 | FCM | <i>Hybrid</i> | 0.04 | 4.51 | 4.47 | 0.19 | 3.86 | 3.67 |

Como se pode observar, nos gráficos da figura 4-28 e figura 4-29 de comparação dos RMSE obtidos no treino e no teste dos ANFIS, das várias divisões de dados efetuadas, verifica-se que os melhores resultados obtidos e com um menor erro em todos eles foi na divisão 67.4% (250 pontos) para treino e 32.6% dos dados (121 pontos) para teste. Contudo pode verificar-se, pelo gráfico de comparação da influência da divisão de dados nos resultados de teste dos ANFIS, figura 4-29, que esta divisão teve resultados muito próximos da divisão 77% dos dados para treino (286 pontos) e 23 % para teste (85 pontos).




Figura 4-28- Gráfico de comparação da influência da divisão de dados nos resultados de treino dos ANFIS. No eixo dos X está representado as ANFIS com vários números de regras e no eixo dos Y o RMSE obtido em cada divisão de dados.




Figura 4-29- Gráfico de comparação da influência da divisão de dados nos resultados de teste dos ANFIS. No eixo dos X está representado as ANFIS com vários números de regras e no eixo dos Y o RMSE obtido em cada divisão de dados.

Verificou-se também que o sistema de inferência Sugeno de ordem 0 ou ordem 1 influenciava os resultados quer de treino quer de teste dos ANFIS. Como se pode verificar nos resultados obtidos, na divisão de dados 67.4% (250 pontos) para treino e 32.6 (121 pontos) para teste, o RMSE é menor no treino quando utilizamos um sistema Sugeno de ordem 1 do que no Sugeno de ordem 0, gráfico da figura 4-30.




Figura 4-30- Gráfico da influência do sistema de inferência Sugeno de ordem 0 ou 1 no RMSE de treino da ANFIS na melhor divisão de dados conseguida, 67.4% (250 pontos) para treino e 32.6 (121 pontos) para teste.

Contudo nos resultados de teste, na mesma divisão de dados, os RMSE são menores quando utilizamos um sistema de inferência Sugeno de ordem 0 do que quando utilizamos um Sugeno de ordem 1, gráfico da figura 4-31. Verificou-se ainda que a diferença de erro, entre o treino e teste dos ANFIS, era sempre menor quando é utilizado um sistema Sugeno de ordem 0, podendo-se afirmar daí que o Sugeno de ordem 0 tem maior capacidade de generalização.

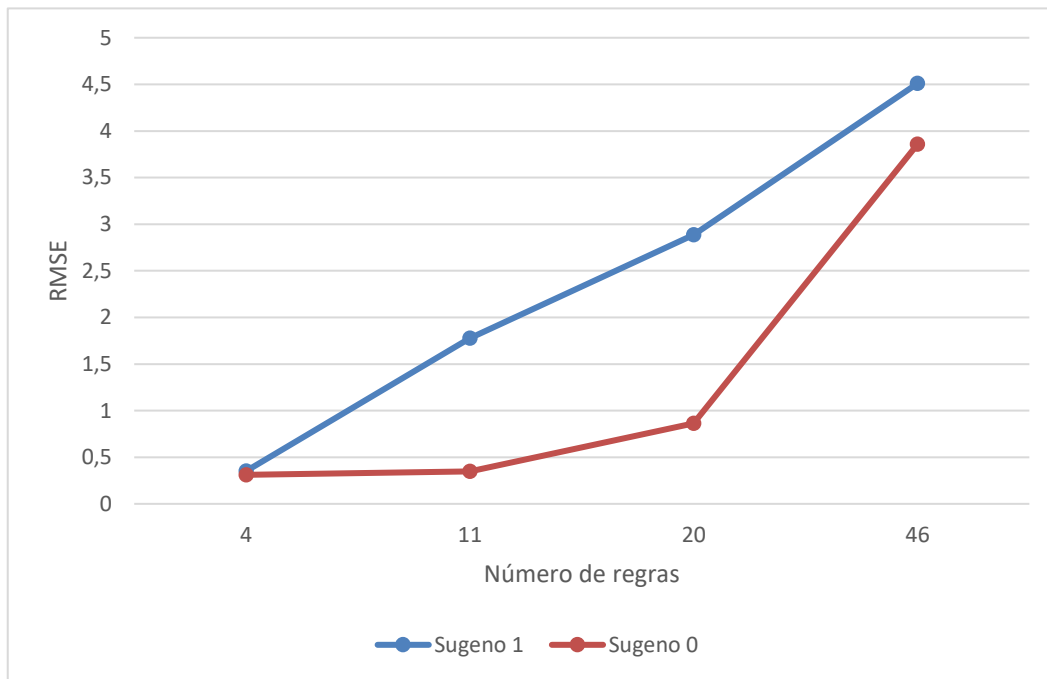


Figura 4-31- Gráfico da influência do sistema de inferência Sugeno de ordem 0 ou 1 no RMSE de teste do ANFIS na melhor divisão de dados conseguida, 67.4% (250 pontos) para treino e 32.6 (121 pontos) para teste.

Nas três divisões de dados realizadas, verificou-se também que à medida que se aumentava o número de regras dos ANFIS o erro de treino diminuía muito, como se pode observar na Figura 4-32 (RMSE de 0.04) de um sistema Sugeno de ordem 1 com 46 regras. Neste gráfico os dados de treino a azul estão bastante próximos da saída da ANFIS, a vermelho. Contudo, à medida que aumentamos o número das regras, o erro de treino diminui muito, mas o erro de teste aumenta bastante piorando muito o desempenho, como se pode verificar na Figura 4-33 com um RMSE de 4.51. Com um grande número de regras verifica-se o fenómeno de sobre-treino (*overfitting*).




Figura 4-32- Gráfico de dispersão dos pontos de treino de uma ANFIS Sugeno de ordem 1 com 46 regras. Os círculos abertos azuis são os dados de treino e os asteriscos vermelhos os dados de saída da FIS, RMSE de 0.04




Figura 4-33- Gráfico de dispersão dos pontos de teste de uma ANFIS Sugeno de ordem 1 com 46 regras. Os pontos azuis são os dados de teste e os asteriscos vermelhos os dados de saída da FIS, RMSE de 4.51.

No conjunto de todas as ANFIS criadas, e tendo em atenção o melhor desempenho e tentando evitar o sobre-treino, o melhor resultado foi obtido para a população total (doente e saudável), utilizando a função genfis3 no modelo reduzido (7 entradas), utilizando 67.4% dos dados (250 pontos) para treino e 32.6 % (121 pontos) para teste (figura 4-34).

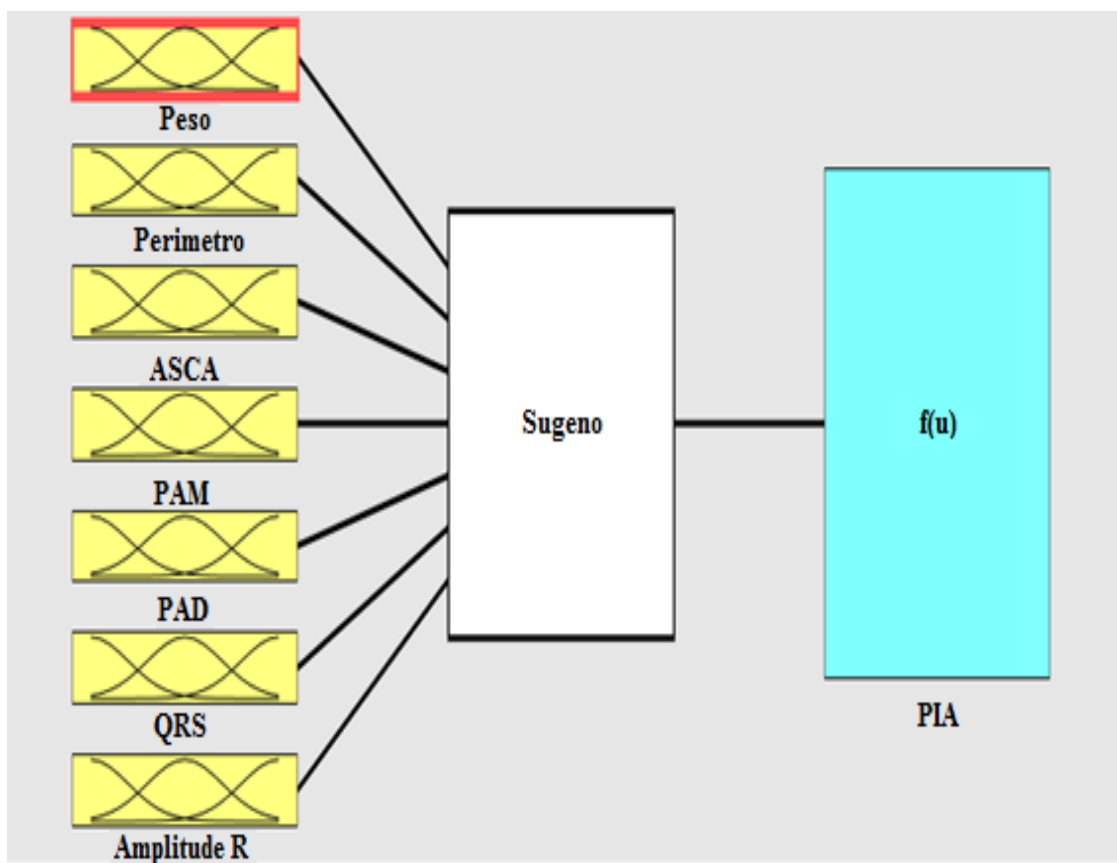


Figura 4-34- Desenho da lógica do sistema difuso do Tipo Sugeno de ordem 0 de 11 regras no modelo reduzido (7 entradas), utilizando 67.4% dos dados (250 pontos) para treino e 32.6 % (121 pontos) para teste.

Neste ANFIS foi utilizado um sistema de inferência do tipo Sugeno de ordem 0 com 11 regras, obtidas através do método SUB e com uma função de treino *hybrid*. A estrutura da ANFIS pode ser visualizada na Figura 4-35.

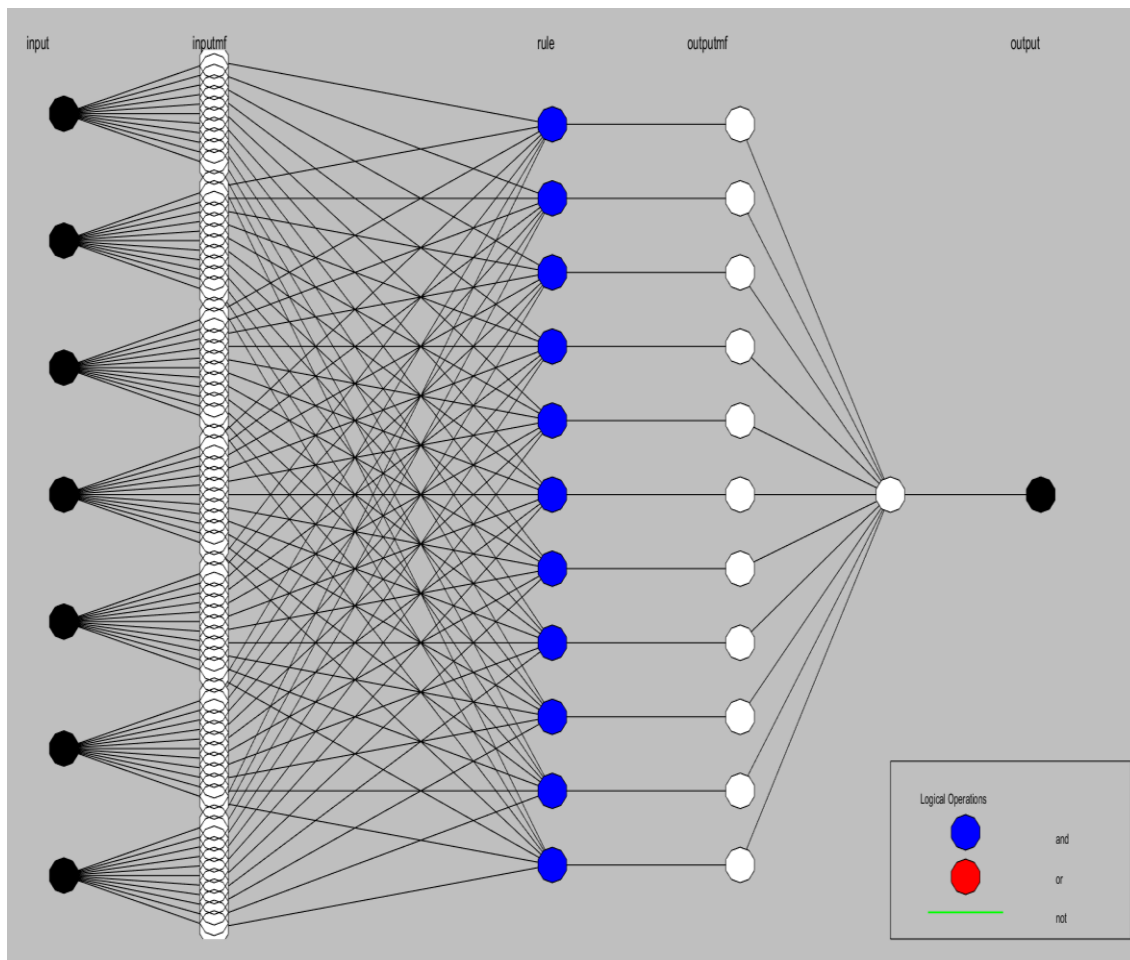


Figura 4-35- Modelo da estrutura do ANFIS do tipo Sugeno de ordem 0 com 11 regras no modelo reduzido (7 entradas), utilizando 67.4% dos dados (250 pontos) para treino e 32.6 % (121 pontos) para teste.

Este ANFIS apresentou uma diferença muito pequena entre o erro de treino, RMSE de 0.29 (Figura 4-36) e o erro de teste, RMSE de 0.33 (Figura 4-37), não havendo uma variação tão pronunciada entre o treino e o teste. Por observação do gráfico da figura 4-27, embora o erro seja relativamente baixo, verifica-se que o FIS não consegue prever com exatidão (asteriscos a vermelho) os pontos de teste (pontos a azul).




Figura 4-36- Gráfico de dispersão dos pontos de treino, Sugeno de ordem 0 com 11 regras no modelo reduzido (7 entradas), utilizando 67.4% dos dados (250 pontos) para treino e 32.6 % (121 pontos) para teste. Os círculos abertos azuis são os dados de treino e os asteriscos vermelhos correspondem aos dados de saída da FIS, MRSE de 0.29.




Figura 4-37- Gráfico de dispersão dos pontos de teste, Sugeno de ordem 0 com 11 regras no modelo reduzido (7 entradas), utilizando 67.4% dos dados (250 pontos) para treino e 32.6 % (121 pontos) para teste. Os pontos azuis são os dados de teste e os asteriscos vermelhos correspondem aos dados de saída da FIS, MRSE de 0.33.

Os gráficos das funções de pertinência de cada variável, podem ser observados na figura 4-38, mas como se pode observar as funções não são bem distinguidas, sendo difícil atribuir um significado semântico.




Figura 4-38- Funções de pertinência no ANFIS Sugeno de ordem 0 com 11 regras no modelo reduzido (7 entradas), utilizando 67.4% dos dados (250 pontos) para treino e 32.6 % (121 pontos) para teste.

Tal como acontece com as funções de pertinência é difícil atribuir linguisticamente um significado às regras criadas devido à complexidade do sistema e do sistema biológico em si, figura 4-39.

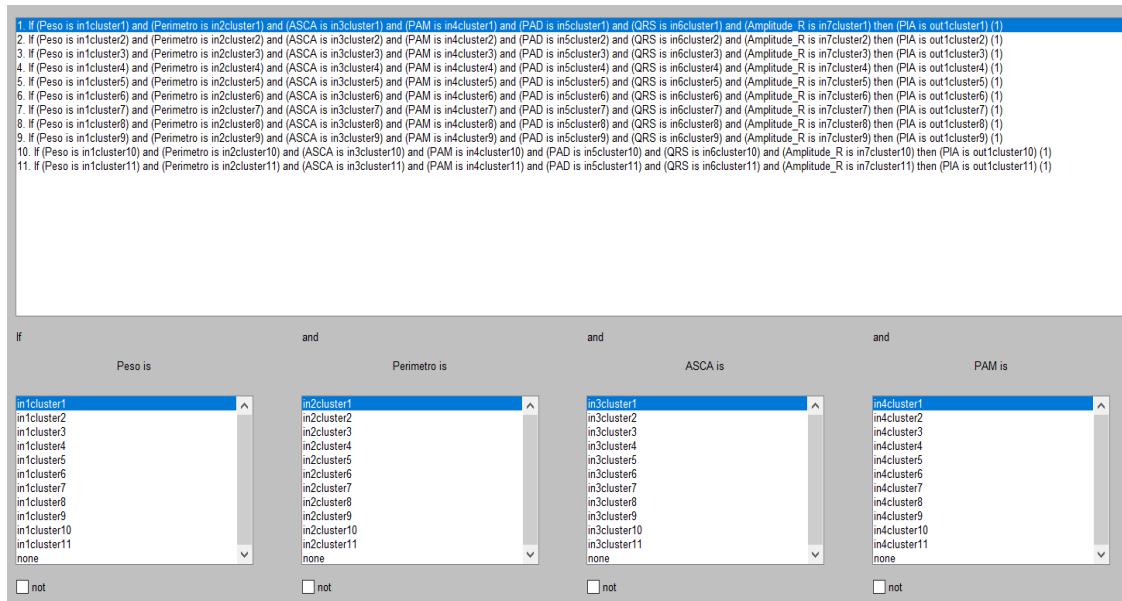


Figura 4-39- Editor das 11 regras do sistema ANFIS Sugeno de ordem 0, no modelo reduzido (7 entradas), utilizando 67.4% dos dados (250 pontos) para treino e 32.6 % (121 pontos) para teste.

Na figura 4-40 visualizamos as regras da ANFIS onde se pode observar todo o processo de inferência *fuzzy*. Em cada linha estão representados graficamente os antecedentes e os consequentes de cada regra. Cada regra é uma linha de gráficos e cada coluna corresponde a uma variável. As sete primeiras colunas de gráficos (gráficos a amarelo) mostram as funções de pertinência referenciadas pelo antecedente. A última coluna (gráficos a azul) mostram as funções de pertinência referenciadas pelo consequente. No topo das colunas é especificado a variável e o seu valor corrente.

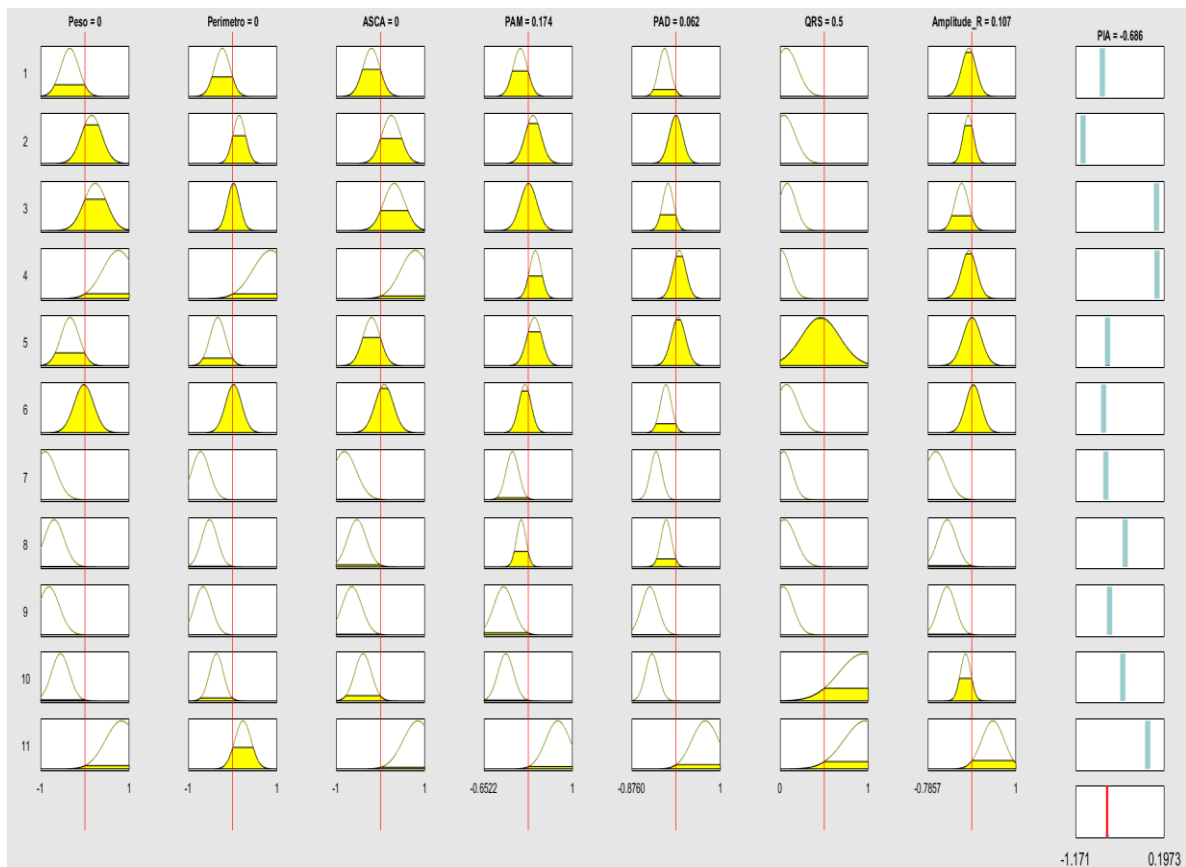


Figura 4-40- Visualizador das regras do ANFIS Sugeno de ordem 0, no modelo reduzido (7 entradas), utilizando 67.4% dos dados (250 pontos) para treino e 32.6 % (121 pontos) para teste.

Através do visualizador de superfície das entradas podemos observar a curva tridimensional entre o peso e a ASCA que apresenta a maior correlação com a saída, PIA.




Figura 4-41- Visualizador de superfície das entradas com maior correlação com a saída, no eixo dos x o peso, no eixo dos y a ASCA, e no eixo do Z a saída (PIA).

4.4 - Discussão

Neste capítulo apresentou-se a integração e análise dos dados recolhidos em pacientes cirúrgicos para criação de um sistema de IC para medir a PIA de modo não invasivo. Através da análise da base de dados de parâmetros vitais construída, e aplicando os conhecimentos apreendidos na primeira parte do trabalho, avaliaram-se os melhores parâmetros para avaliação da PIA e construiu-se um sistema inteligente que permita determinar a PIA de forma não invasiva.

Na construção de uma RNA de suporte médico é fundamental a escolha das características (dados, sintomas, parâmetros clínicos) que irão possibilitar determinar o parâmetro clínico ou diagnóstico alvo [163]. A seleção das características e análise de fatores assumem assim um papel crucial pois permitem a eliminação de fatores que unicamente providenciam informação redundante ou que contribuem unicamente para o ruído do sistema. A escolha cuidadosa das características que irão permitir criar a rede neuronal deve ser feita na primeira fase [166]. Características que tragam significativa redundância, informação ou ruído inespecífico relativamente ao problema sobre investigação devem ser evitadas [166].

Neste estudo, a escolha das características, de forma a servirem de entrada ao sistema para construção da RNA e do ANFIS, foi apoiada na bibliografia existente relativa aos parâmetros clínicos mais suscetíveis de se encontrarem alterados, quando existe alteração da PIA. Os parâmetros morfológicos utilizados neste estudo, como o peso, o perímetro e a ASCA, foram recolhidos e utilizados por causa da definição física de pressão. A definição de pressão corresponde à força exercida sobre unidade de área [87,206]. Assim, estes parâmetros trazem informação crucial, porque caracterizam as dimensões da cavidade abdominal e de parte das forças nela exercida [206]. No nosso estudo, estes três

parâmetros revelaram, como seria de esperar, uma das correlações estatísticas mais altas com a PIA, com índices de correlação de 0.48, 0.34 e 0.46 respectivamente (Tabela 4-5). Na escolha dos parâmetros fisiológicos utilizados foi seguido o mesmo princípio. Está documentado que o aumento da PIA pode provocar alterações a nível respiratório devido a um aumento da pressão intratorácica, podendo provocar hipoxia, hipercapnia e acidose [26,35–37]. Este aumento de PIA leva a um aumento da pressão média de inspiração enquanto o volume tidal e a complacência pulmonar estão diminuídos [211,212]. Na recolha de parâmetros foram então selecionados os valores de capnografia, que representam a expiração de dióxido de carbono e os valores de pulsoximetria, que representam o valor de oxigenação sanguínea, de forma a monitorizar as alterações respiratórias [70]. Embora, esteja documentado que o aumento da PIA leva a alteração destes parâmetros, no presente estudo apresentaram correlações matemáticas baixas com a PIA (cc de 0.07 e -0.11 respectivamente). A nível hemodinâmico está também descrito que as alterações na PIA levam a alterações marcadas neste sistema orgânico. A alteração da PIA leva a alteração da frequência cardíaca, a uma diminuição do retorno venoso [26,36,37], provocando um aumento da pressão venosa central e da pressão de oclusão da artéria pulmonar [26,37]. A pressão venosa femoral aparece também aumentada por consequência do aumento da pressão na veia cava inferior [2,26,213]. A pressão arterial média é também geralmente afetada, subindo inicialmente e depois eventualmente normalizando ou diminuindo [214,215]. Neste estudo foram então recolhidas a frequência cardíaca, a pressão arterial sistólica, média e diastólica, de forma a controlar as alterações hemodinâmicas resultantes da PIA. Dentro destes parâmetros, os que apresentaram uma maior correlação matemática com a PIA foram a pressão arterial média e a pressão diastólica (cc de 0.17 e de 0.25 respectivamente). Os índices de correlação encontrados estão de acordo com o descrito na literatura, pois o aumento da PIA influencia

diretamente a pós e a pré carga cardíaca levando a alterações da pressão arterial [214,215]. Contudo, a medição da pressão arterial por métodos não invasivos, nomeadamente o método de oxilometria, apresenta um erro em comparação com a medição da pressão arterial por métodos invasivos [216,217]. Em medicina humana está descrito que a diferença entre a oxilometria e o método invasivo é geralmente próximo de 5 mmHg, podendo ocasionalmente ocorrer variações mais marcadas, atingindo valores de 37 mmHg [218,219]. Em gatos está também documentado que estas alterações podem ir de 10 a 22 mmHg [217]. Como se pode observar, pela tabela 4.1, os limites inferiores da PAM, PAD e PAS são zero devido a falhas de leitura da pressão por este método. A ausência de leitura pode estar relacionada com episódios de hipotensão ou dificuldade de leitura do sensor. Este facto pode ter influenciado os resultados no nosso estudo. No entanto, mesmo havendo um diferencial de valores, os valores de pressão arterial obtidos pelo método de oxilometria mantêm uma correlação alta com os valores de pressão obtidos por outros métodos [217,220,221] e continua a ser um método aceite nos dias de hoje para monitorização da pressão arterial [222]. Como foi anteriormente referido, a PIA leva também a várias alterações de pressão no sistema venoso. Contudo neste estudo não foram utilizados estes parâmetros clínicos de monitorização, porque o objetivo era conseguir criar um sistema de IC apoiado na monitorização clínica padrão de um monitor multiparamétrico. A frequência cardíaca, no nosso estudo, demonstrou um índice de correlação baixo com a PIA. Este resultado pode estar diretamente ligado com o facto de haver muitas outras variáveis que possam levar ao aumento ou à diminuição da frequência cardíaca, tornando-a assim um preditor sem grande força estatística. Por último, está também documentado que a PIA pode levar a uma redução da complacência e contractilidade ventricular [26,36,37]. Assim, neste estudo, foram também registadas as alterações eletrocardiográficas em todos os momentos de medição da PIA. Verificou-se

que a duração do complexo QRS e a amplitude da onda R apresentam uma correlação estatística de 0.20 e de 0.12 respetivamente com a PIA.

Nunca antes tinha sido identificado, em cães, que a PIA poderia provocar alterações a nível do traçado eletrocardiográfico. Em humanos foi identificado anteriormente que a PIA pode ter impacto na despolarização e repolarização levando a um aumento do ângulo QRS-T e da voltagem do segmento ST [223]. Pensamos que este facto pode ser devido à influência da PIA na contractilidade ventricular visto que a onda R corresponde à despolarização ventricular e a duração do QRS ao período de tempo que demora a ocorrer a despolarização dos ventrículos [203]. O resto dos parâmetros eletrocardiográficos: amplitude e duração da onda P, o intervalo PR, a amplitude e duração da onda T e o intervalo QT, apresentaram índices de correlação baixos com a PIA (Tabela 4-5).

Na implementação de um sistema de IC é muito importante a construção da base de dados. A qualidade do treino e a generalização resultantes da RNA e do ANFIS, e consequentemente a sua capacidade de predição, depende fortemente da base de dados utilizados para o treino. A base de dados deve conter um número suficiente de exemplos fiáveis. No nosso estudo a base de dados total é composta por 371 leituras de PIA e pelos dezoito parâmetros de entrada respetivos (Peso, Perímetro, ASCA, FC, SpO₂, EtCO₂, PAM, PAS, PAD, T.º, Ampl. P, Dur. P, [P-R], QRS, Ampl. R, Ampl. T, Dur. T, [Q-T]). Estas leituras foram recolhidas de duas populações distintas (saudável e doente) de forma a obter o maior número de leituras fiáveis para o sistema de IC. O processamento e limpeza de dados são também bastante importantes. Após a construção, análise e validação da base de dados, devem ser eliminados os valores extremos ou que saiam do padrão dos dados [166]. Na nossa base de dados após análise detalhada não foi eliminado nenhum conjunto de valores. Os valores obtidos durante o período experimental foram recolhidos por monitorização direta, e no momento de medição sempre que havia um

valor duvidoso a medição era efetuada várias vezes para comprovar o valor. Este procedimento foi implementado de forma a reduzir o erro dos dados e por esse motivo não foi eliminado nenhum valor extremo.

Na implementação da RNA foram construídas 54 redes neuronais artificiais para cada uma das populações (total, saudável e doente). Tal como está descrito na literatura a verificação das RNA de suporte de diagnóstico médico foi feita num conjunto de dados diferente do usado para o treino da rede [166].

Verificou-se que utilizando o modelo com as 18 variáveis de entrada em todos os grupos (população total, saudável e doente) as redes com melhores resultados foram as com arquiteturas de 2 camadas. Utilizando o modelo reduzido, unicamente com as 7 variáveis de entrada com maior correlação com a saída, as redes com melhores resultados foram as com uma arquitetura de 3 e 4 camadas (ver figura 4-9 e 4-10). Os índices de regressão, entre as saídas e os alvos, com arquiteturas de 3 e 4 camadas eram bastante similares apresentando sempre valores acima dos 0.9. Verificou-se que à medida que se aumentava o número de camadas, o tempo de cálculo da rede aumentava e os índices de regressão diminuían, como se pode verificar nas redes de 5 camadas (figura 4-9). A variação do número de neurónios da camada oculta permitiu verificar que para aumentos superiores a 10-15 neurónios não se observavam grandes alterações dos índices de regressão (figura 4-10).

Utilizando os dados da população total o tipo de rede que obteve melhores resultados, foi sempre utilizando como função de ativação a tangente hiperbólica sigmóidal (*tansig*) e a função de treino *Bayesian Regularization backpropagation* (*trainbr*), quer no modelo com as 18 entradas quer no modelo reduzido (7 entradas). Os resultados obtidos, utilizando o modelo com as 18 variáveis de entrada e o modelo reduzido, foram bastante similares, apresentando sempre índices de regressão superiores a 0.94 (Tabela 4-6). Os valores

obtidos são bastante bons, visto que o erro representa a relação entre as saídas dos modelos e os alvos pretendidos. Visto que os coeficientes de correlação, obtidos nas RNA são muito próximos de 1, indica que existe uma relação linear entre eles, quanto mais próximo de 0 pior a relação entre as saídas e os alvos [224].

Os melhores resultados de rede foram sempre obtidos com a função de treino *Bayesian Regularization Backpropagation (Trainbr)*. Este tipo de função é utilizado geralmente para diminuir o overfitting, atualizando os pesos da rede de acordo com a otimização de *Levenberg-Marquardt*. Esta regularização, minimiza a combinação dos erros quadráticos com os pesos e depois determina a combinação correta de forma a produzir uma rede que generalize bem [174,176]. Este facto pode estar ligado à dificuldade de predição da PIA e devido à complexidade do modelo. Contudo, como podemos observar na apresentação gráfica da Figura 4-15, da comparação dos valores reais determinados por sensor direto com os valores determinados pela melhor RNA criada (modelo reduzido de 7 variáveis de entrada) os valores são muito idênticos, daí haver uma grande sobreposição de pontos. Este gráfico evidencia a boa capacidade de predição de valores de PIA pela rede criada. As RNA construídas unicamente com a população saudável e doente obtiveram também resultados muito semelhantes. O coeficiente de regressão na população saudável com as 18 entradas e com as 7 entradas, foi de respetivamente de $R=0.98$ (R total de 0.97699, R de treino de 0.99774 e R de teste de 0.85234) e de 0.95 (R total de 0.94607, R de treino de 0.96266 e R de teste de 0.94005) (Tabela 4-6). Na população doente os resultados com as 18 entradas e com as 7 entradas, foram de respetivamente de $R=0.97$ (R total de 0.9681, R de treino de 0.99778 e R de teste de 0.76319) e de 0.97 (R total de 0.96675, R de treino de 0.98753 e R de teste de 0.89652) (Tabela 4-6). A diminuição do número de dados na população saudável e doente refletiu-se sobretudo na função de ativação das redes. Nestas populações os melhores resultados foram obtidos com a função de ativação sigmoideal

logarítmica (*logsig*) enquanto que na população total utilizou-se a função de transferência tangente hiperbólica (Tabela 4-6). As redes neuronais construídas, com base nos 7 parâmetros de entrada, serão a escolha mais indicada visto que se deve usar sempre a rede mais simples capaz de resolver o problema [168]. Assim, a rede neuronal mais indicada para determinação da PIA seria uma rede apoiada no modelo reduzido e na população total, unicamente com 7 entradas, utilizando a função de ativação tangente hiperbólica, a função de treino *Bayesian Regularization backpropagation* e uma arquitetura de rede de 3 camadas com um número de neurónios nas camadas ocultas de [10,12]. Esta rede obteve índices de regressão linear de 0.97 em comparação com as leituras diretas por sensor. No terceiro capítulo onde foi efetuada a comparação do método transvesical, considerado o *gold standard* [9], com o método direto para medição da PIA este revelou um coeficiente de regressão linear de 0.76 . Quanto maior a correlação entre as variáveis maior a aproximação de 1.

É bem conhecido que as redes neuronais são capazes de tolerar um determinado nível de ruído nos dados e conseqüentemente continuam a providenciar uma precisão suficiente [159,160,163]. Contudo, este ruído pode muitas vezes causar resultados duvidosos [160]. Como a PIA integra um sistema biológico complexo, o ruído pode não só causar incerteza nos dados medidos, mas também pode ser influenciado por fatores secundários, como é o caso de haver múltiplos parâmetros alterados devido a outras condições fisiológicas ou devido às várias condições de doença. Os resultados apresentados são bastante bons para um problema complexo como este. No entanto, acreditamos, que aumentando o número de indivíduos e de condições existentes, irá aumentar ainda mais a fiabilidade das redes. Com o aumento da aplicação dos sistemas de redes adaptativas baseadas em sistemas de inferência difusa em várias aplicações médicas, testámos a nossa base de dados na criação de um ANFIS capaz de prever a PIA. Com este tipo de solução conseguimos integrar os

princípios das redes neuronais e da lógica difusa, aproveitando assim o potencial de capturar os benefícios de ambas numa só rede [192]. Na construção dos ANFIS, começamos por criar um sistema de inferência difusa (FIS), utilizando dois sistemas de inferência, o de Sugeno e o de Mamdani. Os dados da população foram divididos sequencialmente, utilizando as primeiras 185 leituras da base de dados (50% dos dados) para o grupo de treino; as seguintes 93 leituras (25 %) para validação e as restantes 93 leituras (25 %) para testar a rede. Neste modelo de validação, os vetores de entrada das entradas/saídas dos grupos de dados para os quais o FIS não foi treinado, são apresentados ao modelo de FIS treinado, de forma a ver como prevê o FIS os dados correspondentes dos valores de saída [225].

Na criação dos FIS a escolha do número de regras é um passo importante, pois vai influenciar o funcionamento da rede. Usualmente a análise dos dados por métodos de agrupamento irá determinar o número de grupos que por sua vez determina o número de regras [183]. Todos os ANFIS criados foram testados inicialmente utilizando métodos de agrupamento de forma a encontrar o número de regras. As funções *genfis3*, quando em modo automático, e a função *genfis2* utilizam o algoritmo de agrupamento subtrativo (*subclust*), com um radii de 0.5 e um mínimo e um máximo correspondente aos valores máximos do *Xin* e do *Xout* para descobrir o número de grupos.

Nos ANFIS criados isto traduziu-se num número de 46 regras para o modelo com as 18 variáveis de entrada e de 11 regras para o modelo com as 7 variáveis de entrada mais significativas. No início do trabalho aplicou-se também outra técnica de agrupamento dos dados por aprendizagem competitiva realizando o *clustering* dos dados por RNA com aprendizagem não supervisionada, utilizando mapas auto-organizados (SOM). Este método de agrupamento organizou o conjunto de dados num grupo de 4 *clusters* tendo sido, por isso utilizado também este número de regras.

Como já foi referido, inicialmente começamos por utilizar uma divisão de dados de 50% para treino (185 pontos), 25 % para validação (93 pontos) e 25 % para testar a rede (93 pontos). Com esta divisão o melhor resultado obtido para a população total, utilizando as 18 variáveis de entrada, foi um ANFIS utilizando o sistema de inferência Sugeno de ordem 1, com a função de treino *Backpropagation* e um conjunto de 11 regras. Neste ANFIS o erro obtido para treino foi de 0.45, para os dados de teste de 2.54 e para os dados de validação de 3.12. Verificou-se que várias das funções de pertinência gaussianas das entradas (modelo com 18 entradas), figura 4-25, eram influenciadas pelos vários valores de zero relativo das suas medições. Estes valores influenciam diretamente a determinação dos antecedentes e dos consequentes influenciando a predição da saída do FIS. O modelo com 18 entradas, apresenta todos os resultados dos parâmetros de monitorização de pacientes, sendo alguns destes parâmetros fracos indicadores da PIA (figura 4-8), que corresponde à saída do sistema. Além do fato de serem fracos indicadores da PIA muitos destes parâmetros tem nas suas leituras vários valores de zero. Estes valores são derivados de fiabilidades do método de monitorização ou do próprio estado fisiológico do paciente. A título de exemplo o parâmetro de capnografia, que representa o valor em mmHg de dióxido de carbono resultante da expiração, é em muitas leituras de zero, o que simplesmente indica que o paciente se encontrava em apneia temporária. No entanto, as características da base de dados em si, influencia a determinação dos antecedentes e dos consequentes levando a modelos não aceitáveis de predição de saída. Nos sistemas criados unicamente com as entradas com maior correlação com a saída, variáveis que traduzem direta ou indiretamente o estado da PIA, este fato já não se verificou. Deste modo, todos os FIS construídos após esta constatação foram baseados no modelo simplificado.

A versão simplificada do ANFIS, construído apenas com as 7 variáveis de entrada (maior correlação estatística com a PIA) e utilizando 50% dos dados para treino (185 pontos), 25 % para validação (93 pontos) e 25 % para testar a rede (93 pontos), já demonstrou resultados mais coerentes e satisfatórios. Este FIS, com um sistema de inferência Sugeno de ordem 1 e com a função de otimização *Backpropagation* e um conjunto de 4 regras, apresentou um erro de treino de 0.20, de teste de 0.36 e de validação de 0.66, tabela 4-7. Verificamos também que as redes construídas, com o sistema de inferência Mamdani, apresentaram todos piores resultados que os construídos com o método Sugeno (Tabela 4-8) o que está de acordo com a bibliografia [182]. O método de Sugeno apresenta algumas vantagens, que se verificaram neste estudo, como a eficiência computacional, melhor adaptação à análise matemática e a capacidade de trabalhar bem com técnicas lineares, de otimização e adaptativas [193].

Embora os primeiros resultados, obtidos para os ANFIS com o modelo reduzido, fossem satisfatórios foi observado nos gráficos de dispersão, entre os pontos de treino/teste e dos valores de saída de vários FIS, que havia um conjunto de valores no grupo de teste que apresentavam um erro muito elevado com estrutura anômala, figura 4-33. Assim, de forma a dar a maior capacidade de predição à FIS, os dados foram divididos com outras proporções de maneira a melhorar os resultados. Observando as tabelas 4-7, 4-9 e 4-10 em conjunto com os gráficos de comparação, figura 4-28 e 4-29, rapidamente se observa que os resultados melhoraram utilizando outras divisões de dados. Verificou-se, que a divisão dos dados é de extrema importância para a capacidade de predição do ANFIS. Como se pode observar pelos gráficos da Figura 4.28 e 4.29 os melhores resultados foram obtidos utilizando 67.4% dos dados para treino (250 pontos) e 32.6% (121 pontos) para teste. A divisão de dados, utilizando os 4 *clusters* da SOM, para constituir a divisão de 77% dos dados para treino (286 pontos) e 23 % para teste (85 pontos) obtiveram

resultados intermédios. Como se observa pelos gráficos de comparação, o RMSE de treino e de teste das redes baixou em todas as FIS.

Ao analisar os FIS criados verificou-se também que a utilização de um sistema Sugeno de ordem 0 ou 1 afetava os resultados quer de treino quer de teste. O erro era menor no treino quando era usado um sistema Sugeno de ordem 1, gráfico da figura 4-30. Contudo nos resultados de teste o erro era menor quando utilizávamos um sistema de inferência Sugeno de ordem 0, gráfico da figura 4-31. Verificou-se ainda que a diferença de erro entre o treino e teste dos ANFIS era sempre menor quando era usado um sistema Sugeno de ordem 0, demonstrando que o Sugeno de ordem 0 tem maior capacidade de generalização.

Uma das vantagens em usar sistemas difusos é poder implementar regras linguísticas que exprimem conhecimento qualitativo do problema, em comparação com as redes neuronais que não precisam de nenhum tipo de conhecimento do problema dado. Contudo, também não conseguem extrair do conjunto de dados regras compreensíveis [180]. Uma das dificuldades nos ANFIS criados ao longo deste trabalho foi o de traduzir em conceitos linguísticos as regras criadas. Embora seja possível dizer como cada variável de entrada afeta a variável de saída em termos biológicos, devido às múltiplas combinações existentes não é possível atribuir um conceito linguístico às regras dos sistemas criados. Como se pode observar, pela figura 4-39, as regras criadas para o sistema e a interligação biológica que estas exigem entre tantos parâmetros fisiológicos, tornam muito difícil de atribuir um significado compreensível às mesmas. A este facto associa-se uma das desvantagens dos modelos Sugeno, a dificuldade associada em atribuir um conceito linguístico ao consequente das regras [193]. Este facto foi observado em todos os ANFIS criados para predição da PIA podendo também estar relacionado com

a dependência existente de um especialista para determinar as regras de inferência, sendo desta forma sensível à subjetividade do especialista [182].

Foi também observado nos gráficos das funções de pertinência de cada variável (figura 4-38) que as funções não se conseguem distinguir bem, sendo difícil atribuir um significado semântico. Este resultado é comum quando o espaço de dimensão das entradas é elevado, 7 no caso do modelo reduzido. Quando utilizamos o modelo completo com as 18 entradas ainda é mais difícil fazer esta distinção sendo também uma das razões que levou à não utilização deste modelo.

Relativamente ao número das regras utilizado nos ANFIS, observou-se que ao aumento do número de regras levava a uma diminuição acentuada do erro de treino, contudo o erro de teste subia muito como se pode verificar na Figura 4-32 e Figura 4-33, verificando-se o fenómeno de sobre-treino. Além do facto do erro de teste subir muito, as funções de pertinência dos antecedentes não têm interpretabilidade.

No conjunto, de todas as ANFIS criadas e tendo em atenção o melhor desempenho e tentando evitar o sobre-treino, o melhor resultado foi obtido para a população total utilizando a função *genfis3*, Sugeno de ordem 0, no modelo reduzido (7 entradas), com 11 regras obtidas pelo método SUB e com uma função de treino *hybrid*, utilizando 67.4% dos dados (250 pontos) para treino e 32.6 % (121 pontos) para teste (Figura 4-35). Este ANFIS apresentou uma diferença muito pequena entre o erro de treino, RMSE de 0.29 (Figura 4-36) e o erro de teste, RMSE de 0.33 (Figura 4-37), não havendo uma variação tão pronunciada entre o treino e o teste. Mesmo assim, por observação do gráfico da figura 4-27, embora o erro seja relativamente baixo, verifica-se que o FIS não consegue prever com exatidão (asteriscos a vermelho) os pontos de teste (pontos a azul). Na construção dos ANFIS, embora os resultados obtidos sejam satisfatórios, a estrutura dos dados pode ter influenciado o seu desempenho. Em futuros estudos deverão ser adotadas técnicas de

pruning de forma a reduzir a complexidade do classificador final levando à melhoria das capacidades preditivas pela redução do sobre-treino aumentando a sua interpretabilidade. A escolha dos parâmetros utilizados nos modelos reduzidos (7 variáveis de entrada) das RNA e dos ANFIS podem, no entanto, ser considerados uma limitação das redes criadas e do próprio estudo. A correlação matemática entre variáveis de entrada demonstrou haver uma correlação alta entre o peso, perímetro e ASCA, podendo duas destas variáveis ser descartadas no modelo reduzido, visto que matematicamente as variáveis traduzem informação idêntica. Contudo fisicamente a definição de pressão correlaciona diretamente duas destas variáveis, pressão é igual ao quociente da força do peso com a área de superfície (neste caso a ASCA) [48,108,109]. Por este motivo ambas as variáveis foram mantidas no modelo reduzido podendo ser este facto encarado como uma limitação.

As técnicas de IC utilizadas permitiram criar uma RNA e um ANFIS que permite determinar a PIA com bons resultados em comparação com as leituras diretas por sensor. O método desenvolvido, sendo um método indireto, não apresenta as desvantagens dos já existentes e apresentou melhores resultados de comparação ($R=0.97$) com as leituras diretas do que o método transvesical ($R=0.76$) e a manometria intra-gástrica [10,206]. O método desenvolvido ultrapassa em grande medida algumas das desvantagens existentes nos outros métodos, sendo a principal não ser invasivo para o paciente nem necessitar de nenhuma ponte de contacto com o aparelho urinário (algaliação) ou gástrico (entubação). Este método permite a monitorização continua da PIA de forma fácil e eficaz permitindo determinar manobras terapêuticas atempadas e de forma mais incisiva.

Capítulo 5 – Conclusão final

A monitorização em pacientes cirúrgicos e em unidades de cuidados intensivos é um procedimento usual, em todas as unidades hospitalares de todo o mundo. Os parâmetros mínimos de avaliação e sua metodologia variam segundo o estado do paciente, mas a importância da monitorização da PIA é inquestionável sempre que existe alguma condição suscetível de a alterar [1,27].

Os métodos atualmente disponíveis para medição da PIA, são métodos que devido às suas características, complicam por vezes o trabalho do clínico, podendo levar a dúvidas de aferição e de decisão terapêutica. Os métodos diretos invasivos, não permitem a monitorização contínua e podem induzir trauma ao paciente não sendo a primeira escolha dos clínicos. Dentro dos métodos indiretos o mais utilizado e considerado o *Gold standard* é o MT [9], havendo no entanto várias variáveis que podem afetar a sua medição gerando controvérsia na sua utilização [9–11,13,78,119,206]. Existem estudos indicando que este mesmo método apresenta variações de reprodutibilidade entre 25 a 66% [120]. O objetivo, deste trabalho, foi criar um sistema alternativo de medição da PIA realizando para esse fim um estudo exaustivo da fisiologia da PIA. Os primeiros três capítulos deste trabalho, relativos ao estudo da PIA e dos métodos utilizados para a sua aferição, tornaram possível a sua compreensão e identificação das variáveis que suportam o sistema de medição desenvolvido.

No segundo capítulo o tipo de metodologia utilizado, num modelo canino, para a segmentação e modelação 3D da cavidade abdominal com determinação de fórmulas de cálculo da ASCA, foi aplicado pela primeira vez e pode ser utilizado e extrapolado para na medicina humana. Este tipo de metodologia desenvolvida permite determinar a área e o volume de forma simples, o que é muito difícil de realizar sem as ferramentas ideais. Futuros estudos podem ser efetuados levando à caracterização da ASCA no Homem, característica anatómica ainda não descrita, segundo o conhecimento do autor. O estudo,

das bases de dados de TAC's de medicina humana, irá levar a um maior nível de significância e fórmulas matemáticas mais precisas, visto que apresentam um maior número de amostras. Foi também identificado que a ASCA é um dos parâmetros com maior correlação com a PIA. Facto este de fácil compreensão, visto que a PIA é uma pressão e o conceito físico de pressão é igual ao quociente da força pela unidade de área [48].

O estudo realizado dos vários métodos existentes para aferição da PIA, tornou claro que existem várias metodologias para determinar as pressões da cavidade abdominal, havendo várias alternativas disponíveis para condições específicas de monitorização. O terceiro capítulo deste trabalho permitiu validar e caracterizar os principais métodos indiretos de medição da PIA comparando-os com as medições diretas. A comparação da medição direta da PIA com o MT permitiu determinar um coeficiente de regressão de 0.76. Verificou-se ainda que os métodos indiretos existentes, MT e MI, são sustentados em modelos biofísicos válidos, contudo deverá ter-se em atenção as variáveis que podem influenciar a medição da PIA. O modelo biofísico, proposto para a validação do MT, poderá ser utilizado para explicar os outros métodos e permitir uma maior compreensão dos fenómenos que levam à alteração da PIA. Nesta parte do estudo, foram também utilizadas técnicas de medição de órgãos, através da análise digital de imagens e com cálculo da área de superfície por programação computacional. Técnicas estas pouco utilizadas, mas que facilitam a medição e diminuem o erro associado a estes procedimentos. Pela primeira vez a PIA foi determinada matematicamente e comparada com as medições diretas por sensor de forma a validar a definição teórica da PIA.

O estudo inicial da PIA permitiu a sua caracterização e identificação das variáveis e parâmetros a recolher para a construção do sistema de IC. Como foi dito anteriormente a

seleção das características é fundamental para a eficácia dos sistemas biomédicos, de diagnóstico ou de determinação de parâmetros médicos, baseados em sistemas de IC.

O tipo de método indireto criado para medir a PIA, baseado em RNA e ANFIS, é uma metodologia que elimina muitas das desvantagens existentes nos métodos usuais para a sua medição. O sistema criado além de ser facilmente aplicado em monitores médicos, é não invasivo, permite a monitorização contínua do paciente e o pessoal médico não tem que realizar nenhum procedimento médico de forma a obter a PIA. Desta forma pode ainda ser calculado o valor da pressão de perfusão abdominal que é determinada pela subtração dos valores da PIA aos valores da pressão arterial média (PAM) [24–26]. Assim, existe a possibilidade de obter dois parâmetros de forma simples e não invasiva que são usados rotineiramente na classificação da hipertensão abdominal [1,24–26]. A sua aplicação, em monitores padrão de monitorização do paciente, permite a vigilância da PIA continuamente. Este facto não inviabiliza tal, como em qualquer outro método indireto de medição de parâmetros na medicina, em caso de necessidade ou dúvida recorrer-se a outro método de referência.

As redes neuronais e as redes adaptativas baseadas em sistemas de interferência difusa criadas permitiram prever a PIA com baixo erro em comparação com os valores reais. Verificou-se que dentro dos dezoito parâmetros de entrada estudados, os sete que demonstraram uma maior correlação estatística com a PIA foram o peso, a ASCA, o perímetro, a PAD e PAM, a duração do QRS e a amplitude da onda R da eletrocardiograma. Observou-se também que os modelos criados com as 18 entradas eram complexos, tornavam os sistemas mais lentos e influenciavam os resultados de predição. Os modelos computacionais criados, apoiados unicamente em 7 parâmetros de entrada, permitiram prever a saída com sucesso. A melhor RNA criada para determinar a PIA

apresentou um coeficiente de regressão linear de 0.97 em comparação com as medições diretas por sensor, contra 0.76 do MT, considerado o *gold standard*.

Os sistemas de IC criados podem ser alvos de estudos e melhoramento futuro de forma a aumentar o desempenho e capacidade de predição dos sistemas. Nas RNA o aumento do número de pacientes nos dois grupos, saudável e doente, tal como um maior número de situações de medição das entradas do sistema irá sem dúvida aumentar a eficácia do sistema. Nos ANFIS é importante realizar estudos também com um maior número de dados e deverão ser adotadas técnicas de *pruning* tendo em vista a melhoria das capacidades preditivas do sistema e aumentar a sua interpretabilidade humana.

O desenvolvimento deste sistema indireto de medição da PIA está também relacionado com a sua aplicação em medicina humana. De forma a implementar e desenvolver o sistema, é importante que sejam recolhidos valores em pacientes humanos, saudáveis e doentes, em várias situações e condições, de forma a construir os sistemas com o menor erro possível. Estes estudos deverão ser realizados nos serviços de anestesiologia e cirurgia, nomeadamente no campo da cirurgia laparoscópica onde podem ser obtidos dados credíveis e de elevado número.

O método de determinação de PIA desenvolvido, irá facilitar o controlo e monitorização dos pacientes cirúrgicos e das unidades de cuidados intensivos, aumentando a probabilidade de manobras terapêuticas mais rápidas e com uma maior probabilidade de sucesso.

Bibliografía:

1. Kirkpatrick AW, Roberts DJ, De Waele J, Jaeschke R, Malbrain MLNG, De Keulenaer B, et al. Intra-abdominal hypertension and the abdominal compartment syndrome: Updated consensus definitions and clinical practice guidelines from the World Society of the Abdominal Compartment Syndrome. *Intensive Care Medicine*. 2013;39:1190–206.
2. Cheatham ML. Abdominal Compartment Syndrome: pathophysiology and definitions. *Scandinavian journal of trauma, resuscitation and emergency medicine* [Internet]. 2009;17:10. Available from: <http://www.ncbi.nlm.nih.gov/pubmed/19254364>
3. R. V. On ischemic muscle paralysis and contraction. *Centralblatt für Chirurgie*. 1881;51:801–3.
4. Marey EJ. *Physiologie médicale de la circulation du sang: basée sur l'étude graphique*. *Archiv Gesamte Physiologie*. 1863;
5. Kron IL, Harman PK, Nolan SP. The measurement of intra-abdominal pressure as a criterion for abdominal re-exploration. *Annals of surgery* [Internet]. 1984;199:28–30. Available from: <http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=1353253&tool=pmcentrez&rendertype=abstract>
6. Cheatham M. Intraabdominal Pressure: A Revised Method for Measurement. *Journal of the American College of Surgeons* [Internet]. Elsevier; 1998 [cited 2015 Oct 9];186:594–5. Available from: <http://www.journalacs.org/article/S1072751598001227/fulltext>
7. Hunter JD, Damani Z. Intra-abdominal hypertension and the abdominal compartment syndrome. *Anaesthesia*. 2004;59:899–907.
8. Castellanos G, Piñero A, Fernández JÁ. La hipertensión intraabdominal y el síndrome compartimental abdominal: ¿qué debe saber y cómo debe tratarlos el cirujano? *Cirugia Espanola*. 2007;81:4–11.
9. Malbrain MLNG. Different techniques to measure intra-abdominal pressure (IAP): time for a critical re-appraisal. *Intensive care medicine*. 2004;30:357–71.
10. Johna S, Taylor E, Brown C, Zimmerman G. Abdominal compartment syndrome: does intra-cystic pressure reflect actual intra-abdominal pressure? A prospective study in surgical patients. *Critical Care*. 1999;3:135–8.
11. Soler Morejón CDD, Lombardo TA, Tamargo Barbeito TO, Sandra BG. Effects of zero reference position on bladder pressure measurements: an observational study.

Annals of intensive care [Internet]. Springer Open Ltd; 2012;2 Suppl 1:S13. Available from:

<http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=3390299&tool=pmcentrez&rendertype=abstract>

12. Yi M, Leng Y, Bai Y, Yao G, Zhu X. The evaluation of the effect of body positioning on intra-abdominal pressure measurement and the effect of intra-abdominal pressure at different body positioning on organ function and prognosis in critically ill patients. *Journal of Critical Care* [Internet]. Elsevier Inc.; 2012;27:222.e1-222.e6. Available from: <http://dx.doi.org/10.1016/j.jcrc.2011.08.010>

13. Fusco MA, Martin RS, Chang MC. Estimation of intra-abdominal pressure by bladder pressure measurement: validity and methodology. *The Journal of trauma*. 2001;50:297–302.

14. Smith SE, Sande AA. Measurement of intra-abdominal pressure in dogs and cats. *Journal of Veterinary Emergency and Critical Care*. 2012;22:530–44.

15. Conzemius MG, Sammarco JL, Holt DE, Smith GK. Clinical determination of preoperative and postoperative intra-abdominal pressures in dogs. *Veterinary surgery : VS : the official journal of the American College of Veterinary Surgeons*. 1995;24:195–201.

16. Way LI, Monnet E. Determination and validation of volume to be instilled for standardized intra-abdominal pressure measurement in dogs. *Journal of Veterinary Emergency and Critical Care*. 2014;24:403–7.

17. Drellich, Sharon (University of California D. Intraabdominal Pressure and Abdominal Compartment Syndrome. *Compend Contin Edu Prac Vet*. 2000;22: N.º 8:764–9.

18. Mahajna A, Mitkal S, Krausz MM. Postoperative gastric dilatation causing abdominal compartment syndrome. *World journal of emergency surgery : WJES*. 2008;3:7.

19. de Cleve R, de Assumpção MS, Sasaya F, Chaves NZ, Santo MA, Fló C, et al. Correlation between intra-abdominal pressure and pulmonary volumes after superior and inferior abdominal surgery. *Clinics*. 2014;69:483–6.

20. Bosch L, Rivera del Alamo MM, Andaluz a., Monreal L, Torrente C, Garcia-Arnas F, et al. Effects of ovariohysterectomy on intra-abdominal pressure and abdominal perfusion pressure in cats. *Veterinary Record* [Internet]. 2012;171:622–622. Available from: <http://veterinaryrecord.bmj.com/cgi/doi/10.1136/vr.100791>

21. Lopes AM, Félix N, Mestrinho LA, Costa MI, Niza MMRE, Silva MF, Iglésias L FA. Intra-abdominal pressure in cats - a preliminary study. *Proceedings - Journal Vet Emerg*

Crit Care. Vienna; 2007. p. 17(3): 17-18.

22. Rader RA, Johnson JA. Determination of normal intra-abdominal pressure using urinary bladder catheterization in clinically healthy cats. *Journal of Veterinary Emergency and Critical Care*. 2010;20:386–92.

23. Caldwell CB, Ricotta JJ. Changes in visceral blood flow with elevated intraabdominal pressure. *The Journal of surgical research*. 1987;43:14–20.

24. Cheatham ML, White MW, Sagraves SG, Johnson JL, Block EF. Abdominal perfusion pressure: a superior parameter in the assessment of intra-abdominal hypertension. *The Journal of trauma* [Internet]. 2000;49:621-6-7. Available from: <http://www.ncbi.nlm.nih.gov/pubmed/11038078>

25. Al-Dorzi HM, Tamim HM, Rishu AH, Aljumah A, Arabi YM. Intra-abdominal pressure and abdominal perfusion pressure in cirrhotic patients with septic shock. *Annals of Intensive Care* [Internet]. Springer Open Ltd; 2012;2:S4. Available from: <http://www.annalsofintensivecare.com/content/2/S1/S4>

26. Papavramidis TS, Marinis AD, Pliakos I, Kesisoglou I, Papavramidou N. Abdominal compartment syndrome - Intra-abdominal hypertension: Defining, diagnosing, and managing. *Journal of emergencies, trauma and shock*. 2011;4:279–91.

27. Schachtrupp a, Jansen M, Bertram P, Kuhlen R, Schumpelick V. Abdominal compartment syndrome: significance, diagnosis and treatment. *Der Anaesthesist*. 2006;55:660–7.

28. Ejike JC, Newcombe J, Baerg J, Bahjri K, Mathur M. Understanding of Abdominal Compartment Syndrome among Pediatric Healthcare Providers. *Critical care research and practice*. 2010;2010:876013.

29. Malbrain MLNG, Chiumello D, Pelosi P, Bihari D, Innes R, Ranieri VM, et al. Incidence and prognosis of intraabdominal hypertension in a mixed population of critically ill patients: a multiple-center epidemiological study. *Critical care medicine*. 2005;33:315–22.

30. Harman PK, Kron IL, McLachlan HD, Freedlender a E, Nolan SP. Elevated intra-abdominal pressure and renal function. *Ann Surg* [Internet]. 1982;196:594–7. Available from: <http://www.ncbi.nlm.nih.gov/pubmed/7125746>

31. Shoemaker W, Velmahos GC, Demetriades D. *Procedures and Monitoring for the Critically Ill*. First edit. Saunders;

32. Andrade JI de. A síndrome de compartimento do abdome. *Medicina, Ribeirão Preto*. 1998;31:563–7.

33. Doty JM, Saggi BH, Blocher CR, Fakhry I, Gehr T, Sica D, et al. Effects of increased renal parenchymal pressure on renal function. *The Journal of trauma*. 2000;48:874–7.
34. Sugrue M, Jones F, Deane S a, Bishop G, Bauman a, Hillman K. Intra-abdominal hypertension is an independent cause of postoperative renal impairment. *Archives of surgery (Chicago, Ill : 1960)* [Internet]. 1999;134:1082–5. Available from: <http://www.ncbi.nlm.nih.gov/pubmed/10522851>
35. Obeid F, Saba A, Fath J, Guslits B, Chung R, Sorensen V, et al. Increases in intra-abdominal pressure affect pulmonary compliance. *Archives of surgery*. 1995.
36. Kashtan J, Green JF, Parsons EQ, Holcroft JW. Hemodynamic effects of increased abdominal pressure. *Journal of Surgical Research* [Internet]. 1981;30:249–55. Available from: <http://www.sciencedirect.com/science/article/pii/0022480481901566>
37. Malbrain M, ML C. Cardiovascular effects and optimal preload markers in intra-abdominal hypertension. In: Vincent J, editor. *Yearbook of intensive care and emergency medicine*. Springer; 2004. p. 519–43.
38. Cremonesi E, Mizumoto N, Rodrigues IJ. Effect of etomidate administered by single venous injection on intracranial pressure and cerebral perfusion pressure of dogs. *Rev Bras Anesthesiol* [Internet]. 1989 [cited 2015 Dec 28];3–8. Available from: <http://pesquisa.bvsalud.org/sms/resource/pt/lil-72343#.VoCCvIHq35I.mendeley>
39. Bloomfield GL, Blocher CR, Fakhry IF, Sica DA, Sugerman HJ. Elevated intra-abdominal pressure increases plasma renin activity and aldosterone levels. *The Journal of trauma*. 1997;42:997-1004-1005.
40. Mogilner JG, Bitterman H, Hayari L, Brod V, Coran AG, Shaoul R, et al. Effect of elevated intra-abdominal pressure and hyperoxia on portal vein blood flow, hepatocyte proliferation and apoptosis in a rat model. *European Journal of Pediatric Surgery: Official Journal of Austrian Association of Pediatric Surgery [et Al] = Zeitschrift Für Kinderchirurgie* [Internet]. 2008;18:380–6. Available from: <http://www.ncbi.nlm.nih.gov/pubmed/19061158>
41. Polat C, Aktepe OC, Akbulut G, Yilmaz S, Arıkan Y, Dilek ON, et al. The effects of increased intra-abdominal pressure on bacterial translocation. *Yonsei Medical Journal*. 2003;44:259–64.
42. Diebel LN, Dulchavsky S a, Wilson RF. Effect of increased intra-abdominal pressure on mesenteric arterial and intestinal mucosal blood flow. *The Journal of trauma*. 1992;33:45-48-49.
43. Reintam A, Parm P, Kitus R, Starkopf J, Kern H. Gastrointestinal failure score in

- critically ill patients: a prospective observational study. *Critical care* (London, England) [Internet]. 2008;12:R90. Available from: <http://ccforum.com/content/12/4/R90%5Cnpapers3://publication/doi/10.1186/cc6958>
44. Leng Y, Zhang K, Fan J, Yi M, Ge Q, Chen L, et al. Effect of acute, slightly increased intra-abdominal pressure on intestinal permeability and oxidative stress in a rat model. *PLoS One*. 2014;9:e109350.
45. Le Roith D, Bark H, Nyska M, Glick SM. The effect of abdominal pressure on plasma antidiuretic hormone levels in the dog. *Journal of Surgical Research* [Internet]. Elsevier; 1982 [cited 2015 Jun 6];32:65–9. Available from: <http://www.journalofsurgicalresearch.com/article/002248048290186X/fulltext>
46. Morris JAJ, Eddy VA, Blinman TA, Rutherford EJ, Sharp KW. The staged celiotomy for trauma. Issues in unpacking and reconstruction. *Annals of surgery*. 1993;217:576.
47. Perry C, Phillips B. The Abdominal Compartment Syndrome : Enteric Feeding May Prolong Closure. *Internet Scientific publications*. 2002;4:1–4.
48. White FM. *Fluid Mechanics* [Internet]. Book. 2009. Available from: <http://dx.doi.org.proxy.lib.utk.edu:90/10.1007/978-3-540-71343-2>
49. Kasten K, Kordas N, Kappert H, Mokwa W. Capacitive pressure sensor with monolithically integrated CMOS readout circuit for high temperature applications. *Sensors and Actuators A: Physical* [Internet]. 2002;97–98:83–7. Available from: <http://www.sciencedirect.com/science/article/pii/S0924424701007993>
50. Dimitropoulos PD, Kachris C, Karampatzakis DP, Stamoulis GI. A new SOI monolithic capacitive sensor for absolute and differential pressure measurements. *Sensors and Actuators, A: Physical*. 2005;123–124:36–43.
51. Chevalier R, Chamberlin M. The advantages of strain gauge technology. *European Medical Device Technology* [Internet]. 2011;March, vol. Available from: <http://www.emdt.co.uk/article/advantages-strain-gauge-technology>
52. Raboel PH, Bartek J, Andresen M, Bellander BM, Romner B. Intracranial pressure monitoring: Invasive versus non-invasive methods-A review. *Critical Care Research and Practice*. 2012;2012:3–7.
53. Koskinen L-OD, Olivecrona M. Clinical Experience with the Intraparenchymal Intracranial Pressure Monitoring Codman MicroSensor System. *Neurosurgery* [Internet]. 2005;56:693–8. Available from: <http://content.wkhealth.com/linkback/openurl?sid=WKPTLP:landingpage&an=00006123-200504000-00008>

54. Pracca FF, Biestro AA, Moraes L, Puppo CB, Calvo SM, Gorrasi J, et al. Direct measurement of intra-abdominal pressure with a solid microtransducer. *Journal of Clinical Monitoring and Computing*. 2007;21:167–70.
55. Ye X, Fang L, Liang B, Wang Q, Wang X, He L, et al. Studies of a high-sensitive surface acoustic wave sensor for passive wireless blood pressure measurement. *Sensors and Actuators, A: Physical* [Internet]. Elsevier B.V.; 2011;169:74–82. Available from: <http://dx.doi.org/10.1016/j.sna.2011.05.022>
56. Ho JJ. The design and fabrication of a micro-thermal/pressure-sensor for medical electro-skin application. *Solid-State Electronics*. 2002;46:1205–9.
57. Gonzalez P, Guo B, Rakowski M, De Meyer K, Witvrouw A. CMOS compatible polycrystalline silicon-germanium based pressure sensors. *Sensors and Actuators, A: Physical* [Internet]. Elsevier B.V.; 2012;188:9–18. Available from: <http://dx.doi.org/10.1016/j.sna.2011.12.018>
58. User manuals Honeyell: ASDX Series Silicon Pressure Sensors. USA: Honeyell; 2010.
59. Goddard W a, Cagin T, Blanco M, Vaidehi N, Dasgupta S, Floriano W, et al. Strategies for multiscale modeling and simulation of organic materials: polymers and biopolymers. *Computational and Theoretical Polymer Science*. 2001;11:329–43.
60. Zhou D, Wang H. Design and evaluation of a skin-like sensor with high stretchability for contact pressure measurement. *Sensors and Actuators, A: Physical* [Internet]. Elsevier B.V.; 2013;204:114–21. Available from: <http://dx.doi.org/10.1016/j.sna.2013.10.002>
61. Ramuz M, Tee BCK, Tok JBH, Bao Z. Transparent, optical, pressure-sensitive artificial skin for large-area stretchable electronics. *Advanced Materials*. 2012;24:3223–7.
62. Schwartz G, Tee BC-K, Mei J, Appleton AL, Kim DH, Wang H, et al. Flexible polymer transistors with high pressure sensitivity for application in electronic skin and health monitoring. *Nature communications* [Internet]. 2013;4:1859. Available from: <http://www.ncbi.nlm.nih.gov/pubmed/23673644>
63. Lipomi DJ, Vosgueritchian M, Tee BC-K, Hellstrom SL, Lee J a., Fox CH, et al. Skin-like pressure and strain sensors based on transparent elastic films of carbon nanotubes. *Nature Nanotechnology* [Internet]. 2011;6:788–92. Available from: <http://dx.doi.org/10.1038/nnano.2011.184>
64. Hu W, Niu X, Zhao R, Pei Q. Elastomeric transparent capacitive sensors based on an interpenetrating composite of silver nanowires and polyurethane. *Applied Physics*

Letters. 2013;102:6–11.

65. Someya T, Kato Y, Sekitani T, Iba S, Noguchi Y, Murase Y, et al. Conformable, flexible, large-area networks of pressure and thermal sensors with organic transistor active matrixes. *Proceedings of the National Academy of Sciences of the United States of America*. 2005;102:12321–5.

66. Tee BC, Wang C, Allen R, Bao Z. An electrically and mechanically self-healing composite with pressure- and flexion-sensitive properties for electronic skin applications. *Nature Nanotechnology* [Internet]. 2012;7:825–32. Available from: <http://dx.doi.org/10.1038/nnano.2012.192>
<http://www.nature.com/doi/10.1038/nnano.2012.192>

67. Uemura S, Watanabe Y, Yoshida M, Tokuhisa H, Takada N. Pressure Sensor Array Fabricated with Polyamino Acid. *Journal of Photopolymer Science and Technology* [Internet]. 2013;26:411–4. Available from: <http://jlc.jst.go.jp/DN/JST.JSTAGE/photopolymer/26.411?lang=en&from=CrossRef&type=abstract>

68. Tan R, Schulam P, Schmidt JJ. Implantable electrolyte conductance-based pressure sensing catheter, I. Modeling. *Biomedical Microdevices*. 2013;15:1025–33.

69. Kipnis E, Ramsingh D, Bhargava M, Dincer E, Cannesson M, Broccard A, et al. Monitoring in the intensive care. *Critical care research and practice* [Internet]. 2012;2012:473507. Available from: <http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=3433116&tool=pmcentrez&rendertype=abstract>

70. American Society of Anesthesiologists. STANDARDS FOR BASIC ANESTHETIC MONITORING [Internet]. Committee of Origin: Standards and Practice Parameters of American Society of Anesthesiologists. p. 1–4. Available from: <http://www.asahq.org/quality-and-practice-management/standards-and-guidelines>

71. Anesthesiologists AS of. GUIDELINES FOR THE PRACTICE OF CRITICAL CARE BY ANESTHESIOLOGISTS [Internet]. Committee of Origin: Critical Care Medicine. p. 1–3. Available from: <http://www.asahq.org/quality-and-practice-management/standards-and-guidelines>

72. Alhashemi JA, Cecconi M, Hofer CK. Cardiac output monitoring: an integrative perspective. *Critical care (London, England)* [Internet]. 2011;15:214. Available from: <http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=3219410&tool=pmcentrez&rendertype=abstract>

73. Suominen PK, Pakarinen MP, Rautiainen P, Mattila I, Sairanen H. Comparison of direct and intravesical measurement of intraabdominal pressure in children. *Journal of Pediatric Surgery*. 2006;41:1381–5.
74. Turnbull D, Webber S, Hammegard CH, Mills GH. Intra-abdominal pressure measurement: validation of intragastric pressure as a measure of intra-abdominal pressure. *British journal of anaesthesia* [Internet]. 2007;98:628–34. Available from: <http://www.ncbi.nlm.nih.gov/pubmed/17456490>
75. Davis PJ, Koottayi S, Taylor A, Butt WW. Comparison of indirect methods of measuring intra-abdominal pressure in children. *Intensive care medicine*. 2005;31:471–5.
76. Wauters J, Spincemaille L, Dieudonne AS, Van Zwam K, Wilmer A, Malbrain MLNG. A novel method (CiMON) for continuous intra-abdominal pressure monitoring: Pilot test in a pig model. *Critical Care Research and Practice*. 2012;2012.
77. Ece I, Vatansev C, Kucukkartallar T, Tekin A, Kartal A, Okka M. The Increase of Intra-Abdominal Pressure Can Affect Intraocular Pressure. 2015;2015.
78. Dias FS, Almeida N, Wawrzeniack IC, Nery PB, Froemming J a, Guerreiro MO, et al. 22nd International Symposium on Intensive Care and Emergency. 2002;9:19–22.
79. Collee GG, Lomax DM, Ferguson C, Hanson GC. Bedside measurement of intra-abdominal pressure (IAP) via an indwelling naso-gastric tube: clinical validation of the technique. *Intensive Care Med* [Internet]. 1993;19:478–80. Available from: http://www.ncbi.nlm.nih.gov/entrez/query.fcgi?cmd=Retrieve&db=PubMed&dopt=Citation&list_uids=8294633
80. Iberti TJ, Lieber CE, Benjamin E. Determination of intra-abdominal pressure using a transurethral bladder catheter: clinical validation of the technique. *Anesthesiology* [Internet]. 1989;70:47–50. Available from: http://www.ncbi.nlm.nih.gov/entrez/query.fcgi?cmd=Retrieve&db=PubMed&dopt=Citation&list_uids=2912315
81. Goody PC, Stickland NC, Evans SA. *Color Atlas of Veterinary Anatomy: Volume 3. The Dog and Cat*. 1st Editio. Mosby;
82. Sisson S. Sisson and Grossman's *The anatomy of the domestic animals*. In: Robert Getty, Cynthia Ellenport Rosenbaum, N. G. Ghoshal DH, editor. *Sisson and Grossman's The anatomy of the domestic animals*. 5th Editio. Philadelphia: Saunders; 1975. p. 479.
83. Gardell C. *Miller's Anatomy of the Dog*. Fourth Edition. In: Elsevier Saunders, editor. *Miller's Anatomy of the Dog*. Fourth edi. Ithaca, New York: Elsevier Inc.; 2013.

84. Aspinall V, O'Reilly M. *Introducción a la anatomía y fisiología veterinarias*. Acribia, editor. 2007.
85. Albanese AM, Albanese EF, Miño JH, Gómez E, Gómez M, Zandomeni M, et al. Peritoneal surface area: Measurements of 40 structures covered by peritoneum: Correlation between total peritoneal surface area and the surface calculated by formulas. *Surgical and Radiologic Anatomy*. 2009;31:369–77.
86. Breton E, Choquet P, Bergua L, Barthelmebs M, Haraldsson B, Helwig JJ, et al. In vivo peritoneal surface area measurement in rats by micro-computed tomography (μ CT). *Peritoneal Dialysis International*. 2008;28:188–94.
87. Ikai M, Fukunaga T. Calculation of muscle strength per unit cross-sectional area of human muscle by means of ultrasonic measurement. *Internationale Zeitschrift für Angewandte Physiologie Einschließlich Arbeitsphysiologie*. 1968;26:26–32.
88. Klein GJ, Teng X, Schoenemann PT, Budinger TF. <title>Sensitivity analysis of brain morphometry based on MRI-derived surface models</title>. In: Hoffman EA, editor. 1998. p. 294–303. Available from: http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.119.3615&rep=rep1&type=pdf%5Cnfile:///Users/cmquesada/OneDrive/Documentos/Papers_Old/Articles/1998/Unknown/1998.pdf%5Cnpapers2://publication/uuid/EC421A06-B432-42FF-A8B0-E1F8D02BBA6A
89. Vanderoost J. From histology to micro-CT: Measuring and modeling resorption cavities and their relation to bone competence. *World Journal of Radiology* [Internet]. 2014;6:643. Available from: <http://www.wjgnet.com/1949-8470/full/v6/i9/643.htm>
90. Manjunath KY. Correlation between the cross sectional area of skull base with existing formulae to determine skull volume . i:51–4.
91. Sholts SB, Wärmländer SKTS, Flores LM, Miller KWP, Walker PL. Variation in the measurement of cranial volume and surface area using 3d laser scanning technology. *Journal of Forensic Sciences*. 2010;55:871–6.
92. Ruggieri G, Rocca AR. Analysis of past and present methods of measuring and estimating body surface area and the resulting evaluation of its doubtful suitability to universal application. *Blood Purification*. 2010;30:296–305.
93. Ohlerth S, Scharf G. Computed tomography in small animals - Basic principles and state of the art applications. *Veterinary Journal*. 2007;173:254–71.
94. Breiman RS, Beck JW, Korobkin M, Glenney R, Akwari OE, Heaston DK, et al. Volume determinations using computed tomography. *American Journal of*

Roentgenology. 1982;138:329–33.

95. Erić M, Anderla A, Stefanović D, Drapšin M. Breast volume estimation from systematic series of CT scans using the Cavalieri principle and 3D reconstruction. *International journal of surgery (London, England)* [Internet]. 2014;12:912–7. Available from: <http://www.ncbi.nlm.nih.gov/pubmed/25063210>

96. Chul Kim J. Animal study of renal volume measurement on abdominal CT using digital image processing. *Clinical Imaging* [Internet]. 2004;28:135–7. Available from: <http://linkinghub.elsevier.com/retrieve/pii/S0899707103001153>

97. Yetter EM, Acosta KB, Olson MC, Blundell K. Estimating Splenic Volume: Sonographic Measurements Correlated with Helical CT Determination. *American Journal of Roentgenology*. 2003;181:1615–20.

98. Moss AA, Friedman MA, Brito AC. Determination of liver, kidney, and spleen volumes by computed tomography: an experimental study in dogs. *Journal of computer assisted tomography*. 1981;5:12–4.

99. Han JHJ, Jia YJY. CT Image Processing and Medical Rapid Prototyping. 2008 *International Conference on BioMedical Engineering and Informatics*. 2008;2.

100. Ljung L. Perspectives on system identification. *Annual Reviews in Control*. 2010;34:1–12.

101. Hill RC, Scott KC. Energy requirements and body surface area of cats and dogs. *Journal of the American Veterinary Medical Association*. 2004;225:689–94.

102. Price GS, Frazier DL. Use of body surface area (BSA)-based dosages to calculate chemotherapeutic drug dose in dogs: I. Potential problems with current BSA formulae. *Journal of veterinary internal medicine / American College of Veterinary Internal Medicine*. 1998;12:267–71.

103. Mawby DI, Bartges JW, D'Avignon A, Laflamme DP, Moyers TD, Cottrell T. Comparison of various methods for estimating body fat in dogs. *Journal of the American Animal Hospital Association* [Internet]. 2004;40:109–14. Available from: <http://www.ncbi.nlm.nih.gov/pubmed/15007045>

104. Gundersen H, Jensen E. The efficiency of system sampling in stereology and its prediction. *Journal of Microscopy*. 1987;147:229–63.

105. Computing N. Numerical computing with MATLAB. *Choice Reviews Online* [Internet]. 2005;42:42-3475-42-3475. Available from: <http://www.cro3.org/cgi/doi/10.5860/CHOICE.42-3475>

106. Hussain Z, Roberts N, Whitehouse GH, García-Fiñana M, Percy D. Estimation of

- breast volume and its variation during the menstrual cycle using MRI and stereology. *British Journal of Radiology*. 1999;72:236–45.
107. Geraghty EM, Boone JM. Determination of height, weight, body mass index, and body surface area with a single abdominal CT image. *Radiology*. 2003;228:857–63.
108. Okuno E, Caldas IL, Chow. *Física para Ciências Biológicas e Biomédicas*. First. Harbra, editor. 1986.
109. Sternheim MM, Kane WK. *General Physics*. 2nd Editio. General Physics, 2nd Edition. Wiley; 1991.
110. Chang R, Goldsby KA. *Chemistry*. 11th editi. Lange M, David K, editors. McGraw-Hill Companies; 2013.
111. Holwill M, Silvestre N. Properties of fluids. *Introduction to biological Physics*. 1 st editi. Jonh Wiley; 1973. p. 59–88.
112. Duncan G. *Fluids: Pressure and Gases*. *Physics in the life sciences*. 3.^a Editio. Disce Publications; 1999. p. 57–86.
113. Aspesi M, Gamberoni C, Severgnini P, Colombo G, Chiumello D, Minoja G, et al. The abdominal compartment syndrome. Clinical relevance. *Minerva Anestesiol* [Internet]. 2002;68:138–46. Available from: http://www.ncbi.nlm.nih.gov/entrez/query.fcgi?cmd=Retrieve&db=PubMed&dopt=Citation&list_uids=12024071
114. Otto J, Kaemmer D, Binnebösel M, Jansen M, Dembinski R, Schumpelick V, et al. Direct intra-abdominal pressure monitoring via piezoresistive pressure measurement: a technical note. *BMC surgery*. 2009;9:5.
115. Smith J, Frood R, Southern S, May J, Sadri A, Wood F. A simple technique to reduce surgeon radiation exposure during the use of the mini C-arm fluoroscope Stryker ® intracompartamental pressure monitor in the triage of circumferential limb burns Greater palatine block in the treatment of acute epistaxis. 2015;160–1.
116. Whitesides TE, Haney TC, Morimoto K, Harada H. Tissue pressure measurements as a determinant for the need of fasciotomy. *Clinical orthopaedics and related research*. 1975;43–51.
117. Boody AR, Wongworawat MD. Accuracy in the measurement of compartment pressures: a comparison of three commonly used devices. *The Journal of bone and joint surgery American volume*. 2005;87:2415–22.
118. Malbrain MLNG, De laet I, Van Regenmortel N, Schoonheydt K, Dits H. Can the abdominal perimeter be used as an accurate estimation of intra-abdominal pressure?

Critical care medicine [Internet]. 2009;37:316–9. Available from: <http://www.ncbi.nlm.nih.gov/pubmed/19050639>

119. Yi M, Leng Y, Bai Y, Yao G, Zhu X. The evaluation of the effect of body positioning on intra-abdominal pressure measurement and the effect of intra-abdominal pressure at different body positioning on organ function and prognosis in critically ill patients. *Journal of critical care* [Internet]. Elsevier; 2012 [cited 2015 Jun 1];27:222.e1-6. Available from: <http://www.jccjournal.org/article/S0883944111003868/fulltext>

120. Malbrain MLNG. No Title Prevalence of intra-abdominal hypertension in the ICU. *Intensive care medicine*. 2001;27 (Suppl.

121. De Keulenaer BL, De Waele JJ, Powell B, Malbrain MLNG. What is normal intra-abdominal pressure and how is it affected by positioning, body mass and positive end-expiratory pressure? *Intensive Care Medicine*. 2009. p. 969–76.

122. Gudmundsson FF, Viste A, Gislason H, Svanes K. Comparison of different methods for measuring intra-abdominal pressure. *Intensive care medicine*. 2002;28:509–14.

123. Varela JE, Hinojosa M, Nguyen N. Correlations between intra-abdominal pressure and obesity-related co-morbidities. *Surgery for Obesity and Related Diseases* [Internet]. Elsevier Inc.; 2009;5:524–8. Available from: <http://dx.doi.org/10.1016/j.soard.2009.04.003>

124. Hodges PW, Cresswell AG, Daggfeldt K, Thorstensson A. In vivo measurement of the effect of intra-abdominal pressure on the human spine. *Journal of Biomechanics*. 2001;34:347–53.

125. Davis KG, Marras WS. The effects of motion on trunk biomechanics. *Clinical Biomechanics*. 2000;15:703–17.

126. Wilson WH. <Effect of Breathing on the Intra Abdominal Pressure.Pdf>. *J Physiol*. 1933;Oct 25; 79:481–6.

127. Hodges PW, Gandevia SC. Changes in intra-abdominal pressure during postural and respiratory activation of the human diaphragm. *Journal of applied physiology* (Bethesda, Md : 1985). 2000;89:967–76.

128. Chieveley-Williams S, Dinner L, Puddicombe A, Field D, Lovell a. T, Goldstone JC. Central venous and bladder pressure reflect transdiaphragmatic pressure during pressure support ventilation. *Chest*. 2002;121:533–8.

129. de Cleve R, Assumpcao M, Sasaya F, Chaves N, Santo M, Flo C, et al. Correlation between intra-abdominal pressure and pulmonary volumes after superior and inferior abdominal surgery. *Clinics* [Internet]. 2014;69:483–6. Available from:

<http://www.ncbi.nlm.nih.gov/pmc/articles/PMC4081878/>

130. Sugrue M, Buist MD, Lee A, Sanchez DJ, Hillman KM. Intra-abdominal pressure measurement using a modified nasogastric tube: description and validation of a new technique. *Intensive care medicine* [Internet]. 1994;20:588–90. Available from: <http://www.ncbi.nlm.nih.gov/pubmed/7706574>

131. Shafik A, El-Sharkawy A, Sharaf WM. Direct measurement of intra-abdominal pressure in various conditions. *Eur J Surg* [Internet]. 1997;163:883–7. Available from: http://www.ncbi.nlm.nih.gov/entrez/query.fcgi?cmd=Retrieve&db=PubMed&dopt=Citation&list_uids=9449439

132. Lacey SR, Bruce J, Brooks SP, Griswald J, Ferguson W, Allen JE, et al. The relative merits of various methods of indirect measurement of intraabdominal pressure as a guide to closure of abdominal wall defects. *Journal of pediatric surgery*. 1987;22:1207–11.

133. Lee SL, Anderson JT, Kraut EJ, Wisner DH, Wolfe BM. A simplified approach to the diagnosis of elevated intra-abdominal pressure. *The Journal of trauma* [Internet]. 2002;52:1169–72. Available from: <http://www.ncbi.nlm.nih.gov/pubmed/12045648>

134. Cresswell AG. Responses of intra-abdominal pressure and abdominal muscle activity during dynamic trunk loading in man. *European Journal of Applied Physiology and Occupational Physiology*. 1993;66:315–20.

135. De Waele JJ, De Laet I, De Keulenaer B, Widder S, Kirkpatrick AW, Cresswell AB, et al. The effect of different reference transducer positions on intra-abdominal pressure measurement: A multicenter analysis. *Intensive Care Medicine*. 2008;34:1299–303.

136. Ahmadi-Noorbakhsh S, Malbrain ML. Integration of inspiratory and expiratory intra-abdominal pressure: a novel concept looking at mean intra-abdominal pressure. *Annals of intensive care* [Internet]. Springer Open Ltd; 2012;2 Suppl 1:S18. Available from:

<http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=3527153&tool=pmcentrez&rendertype=abstract>

137. Malbrain MLNG, Deeren DH. Effect of bladder volume on measured intravesical pressure: a prospective cohort study. *Critical care (London, England)*. 2006;10:R98.

138. Fetner M, Prittie J. Evaluation of transvesical intra-abdominal pressure measurement in hospitalized dogs. *Journal of Veterinary Emergency and Critical Care* [Internet]. 2012;22:230–8. Available from: <http://doi.wiley.com/10.1111/j.1476-4431.2012.00725.x>

139. Antippa a F. Unification of Newton’s laws of motion. *Canadian Journal of Physics*.

2003;81:713–35.

140. Kayar R, Civelek S, Cobanoglu M, Gungor O, Catal H, Emiroglu M. Five methods of breast volume measurement: A comparative study of measurements of specimen volume in 30 mastectomy cases. *Breast Cancer: Basic and Clinical Research*. 2011;5:43–52.

141. Papazoglou ES, Zubkov L, Mao X, Neidrauer M, Rannou N, Weingarten MS. Image analysis of chronic wounds for determining the surface area. *Wound repair and regeneration : official publication of the Wound Healing Society [and] the European Tissue Repair Society* [Internet]. 2010;18:349–58. Available from: <http://www.ncbi.nlm.nih.gov/pubmed/20492631>

142. Caldwell CB, Ricotta JJ. Changes in visceral blood flow with elevated intraabdominal pressure. *The Journal of surgical research*. 1987. p. 14–20.

143. Balogh Z, Moore F a., Moore EE, Biffl WL. Secondary abdominal compartment syndrome: A potential threat for all trauma clinicians. *Injury*. 2007;38:272–9.

144. Van Wijk RM, Watts RW, Ledowski T, Trochsler M, Moran JL, Arenas GW. Deep neuromuscular block reduces intra-abdominal pressure requirements during laparoscopic cholecystectomy: a prospective observational study. *Acta Anaesthesiologica Scandinavica*. 2015;59:434–40.

145. Bosch L, del Alamo MMR, Andaluz A, Monreal L, Torrente C, Garcia-Arnas F, et al. Effects of ovariohysterectomy on intra-abdominal pressure and abdominal perfusion pressure in cats. *Veterinary Record*. 2012.

146. Engum S a., Kogon B, Jensen E, Isch J, Balanoff C, Grosfeld JL. Gastric tonometry and direct intraabdominal pressure monitoring in abdominal compartment syndrome. *Journal of Pediatric Surgery*. 2002;37:214–8.

147. Esperanca MJ, Collins DL. Peritoneal dialysis efficiency in relation to body weight. *Journal of Pediatric Surgery* [Internet]. Elsevier; 1966 [cited 2015 Aug 24];1:162–9. Available from: <http://www.jpedsurg.org/article/0022346866902223/fulltext>

148. Rubin J, Clawson M, Planch A, Jones Q. Measurements of peritoneal surface area in man and rat. *The American journal of the medical sciences*. 1988;295:453–8.

149. Bushkovitch VJ. An automatic apparatus for the measurement of cranial capacity. *American Journal of Physical Anthropology* [Internet]. 1927;10:355–63. Available from: <https://doi.org/10.1002/ajpa.1330100306>

150. Noguchi T, Demura S. Relationship between Abdominal Strength Measured by a Newly Developed Device and Abdominal Muscle Thickness. *Advances in Physical*

- Education [Internet]. 2014;4:70–6. Available from: <http://www.scirp.org/journal/PaperDownload.aspx?DOI=10.4236/ape.2014.42010>
151. Metheny N a, Frantz R a. Head-of-bed elevation in critically ill patients: A review. *Critical Care Nurse*. 2013;33:53–67.
152. Pinsky MR (University of PMC, Laurent B (Hopital HM, Mancebo J (Hospital de SP, Antonelli M (Universita C des SC. *Applied Physiology in Intensive Care Medicine 2*. Third edit. Springer Heidelberg New York Dordrecht London; 2012.
153. Duch W. Towards comprehensive foundations of computational intelligence. *Challenges for Computational Intelligence* [Internet]. 2007. p. 261–316. Available from: <http://www.springerlink.com/index/R3746K5388187740.pdf>
http://link.springer.com/chapter/10.1007/978-3-540-71984-7_11
154. Polycarpou M. *Computational Intelligence Society* [Internet]. Available from: <http://cis.ieee.org/about-cis.html>
155. McCulloch WS, Pitts W. A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*. 1943;5:115–33.
156. Harvey RL. *Neural Network Principles*. 1st editio. Prentice Hall; 1994.
157. Hertz J, Krogh A, Palmer RG. *Introduction to the Theory of Neural Computation* [Internet]. *Introduction to the Theory of Neural Computation*. 1991. Available from: http://books.google.com/books?id=9a_SyUG-A24C&pgis=1
158. Marini F, Bucci R, Magrì a. L, Magrì a. D. Artificial neural networks in chemometrics: History, examples and perspectives. *Microchemical Journal*. 2008;88:178–85.
159. Yegnanarayana B. *Artificial Neural Networks*. 1st edtion. Prentice-Hall of India Pvt.Ltd; 2004.
160. Jigneshkumar L. Patel Ramesh K. Goyal. *Applications of Artificial Neural Networks in Medical Science*. *Curr Clin Pharmacol*. 2007;2:217–26.
161. Itchhaporia D, Snow PB, Almassy RJ, Oetgen WJ. Artificial neural networks: current status in cardiovascular medicine. *Journal of the American College of Cardiology*. 1996;28:515–21.
162. Ganesan N. Application of Neural Networks in Diagnosing Cancer Disease Using Demographic Data. *International Journal of Computer Applications* (0975. 2010;1:76–85.
163. Robertson G, Lehmann ED, Sandham W, Hamilton D. Blood Glucose Prediction Using Artificial Neural Networks Trained with the AIDA Diabetes Simulator : A Proof-

of-Concept Pilot Study. 2011;2011.

164. Dourado A, Henriques JO, Carvalho P. Intelligent and Adaptive Systems in Medicine, Medical Physics and Biomedical Engineering. In: Olivier C. L. Haas and Keith J Burnham(Eds), editor. Neural, Fuzzy, and Neurofuzzy Systems for Medical Applications. CRC Press; 2008. p. 127–72.

165. Szolovits P, Patil RS, Schwartz WB. Artificial intelligence in medical diagnosis. *Annals of Internal Medicine*. 1988;1081:80–7.

166. Amato F, López A, Peña-Méndez EM, Vañhara P, Hampl A, Havel J. Artificial neural networks in medical diagnosis. *Journal of Applied Biomedicine* [Internet]. 2013;11:47–58. Available from: <http://linkinghub.elsevier.com/retrieve/pii/S1214021X14600570>

167. Ablameyko S, Goras L, Gori M, Piuri V. Neural Networks in the Medical Field. *Neural Networks for Instrumentation, Measurement and Related Industrial Application. Series III*. IOS Press Ohmsha; 2001. p. 291–329.

168. Zhang Q-J, Gupta KC, Devabhaktuni VK. Artificial neural networks for rf and microwave design-from theory to practice. *IEEE Transactions on Microwave Theory and Techniques* [Internet]. 2003;51:1339–50. Available from: http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=1193152
<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=1193152>

169. Hornik K. Approximation capabilities of multilayer feedforward networks. *Neural Networks*. 1991;4:251–7.

170. Hornik K. Some new results on neural network approximation. *Neural Networks* [Internet]. 1993;6:1069–1072. Available from: <http://www.sciencedirect.com/science/article/pii/S089360800980018X>

171. Haykin S. *Neural Networks: A Comprehensive Foundation*. 2nd ed. New Jersey: Prentice Hall PTR Upper Saddle River, NJ, USA; 1998.

172. Balaji SA. DESIGN AND DEVELOPMENT OF AN ARTIFICIAL NEURAL NETWORKING (ANN) SYSTEM USING SIGMOID ACTIVATION FUNCTION TO PREDICT ANNUAL RICE PRODUCTION IN. 2013;3:13–31.

173. Han J, Moraga C. The influence of the sigmoid function parameters on the speed of backpropagation learning. *From Natural to Artificial Neural Computation* [Internet]. 1995;930:195–201. Available from: http://dx.doi.org/10.1007/3-540-59497-3_175

174. Demuth H. *Neural Network Toolbox*. *Networks* [Internet]. 2002;24:1–8. Available from:

<http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.123.6691&rep=rep1&type=pdf>

175. Dorofki M, Elshafie AH, Jaafar O, Karim O a. Comparison of Artificial Neural Network Transfer Functions Abilities to Simulate Extreme Runoff Data. International Conference on Environment, Energy and Biotechnology (IPCBEE). 2012;33:39–44.
176. Kaur H, Salaria DS. Bayesian Regularization Based Neural Network Tool for SoftwareEffort Estimation. Global Journal of Computer Science and Technology Neural & Artificial Intelligence [Internet]. 2013;13:44–50. Available from: https://globaljournals.org/GJCST_Volume13/6-Bayesian-Regularization-Based-Neural.pdf
177. Moller MF. A scaled conjugate gradient algorithm for fast supervised learning. Neural Networks. 1993;6:525–33.
178. Burden F, Winkler D. Bayesian regularization of neural networks. Methods in Molecular Biology. 2008;458:25–44.
179. Zadeh LA. Fuzzy Sets. Information and Control. 1965;8:338–53.
180. Mares M. Fuzzy sets. Scholarpedia [Internet]. 2006;1:2031. Available from: http://www.scholarpedia.org/article/Fuzzy_sets
181. Singh H, Gupta M, Meitzler T. Real-life applications of fuzzy logic. Advances in Fuzzy Systems [Internet]. 2013;2013:1–3. Available from: <http://www.hindawi.com/journals/afs/aip/581879/>
182. Vieira JAB, Mota AMN. Sistemas Neuro-Difusos : Técnicas de Modelização Não Linear. REVISTA DO DETUA. 2004;4.
183. Theodoridis S, Koutroumbas K. An Introduction to Pattern Recognition: A MATLAB Approach, Second Edition [Internet]. Publishing Research Quarterly. 2006. Available from: <http://onlinelibrary.wiley.com/doi/10.1002/cbdv.200490137/abstract%5Cnhttp://www.amazon.com/Pattern-Recognition-Edition-Sergios-Theodoridis/dp/1597492728>
184. Jain a. K, Murty MN, Flynn PJ. Data clustering: a review. ACM Computing Surveys [Internet]. 1999;31:264–323. Available from: <http://portal.acm.org/citation.cfm?doid=331499.331504>
185. Du K. Clustering : A neural network approach \$. 2010;23:89–107.
186. Miuigan GW, Cooper MC. A study of standardization of variables in cluster analysis. Journal of Classification. 1988;204:181–204.
187. Chiu SL. Fuzzy Model Identification Based on Cluster Estimation. Journal of

- Intelligent and Fuzzy Systems [Internet]. 1994;2:267–78. Available from: https://www.researchgate.net/publication/233932671_Fuzzy_Model_Identification_Based_on_Cluster_Estimation
188. Rojas I, Ortega J, Prieto A. Approximation. IEEE TRANSACTIONS ON NEURAL NETWORKS. 2002;13:132–42.
189. Hosseini MS, Zekri M. Review of Medical Image Classification using the Adaptive Neuro-Fuzzy Inference System. Journal Of Medical Signals And Sensors [Internet]. 2012;2:49–60. Available from: <http://search.ebscohost.com/login.aspx?direct=true&db=cmedm&AN=23493054&site=ehost-live&scope=site&authtype=shib&custid=s8000044>
190. Jang J. Fuzzy Modeling Using Generalized Neural Networks and Kalman Filter Algorithm. Proceedings of the 9th National Conference on Artificial Intelligence [Internet]. 1991. p. 762–7. Available from: <http://www.aaai.org/Library/AAAI/1991/aaai91-119.php>
191. Jang JSR. ANFIS: Adaptive-Network-Based Fuzzy Inference System. IEEE Transactions on Systems, Man and Cybernetics. 1993;23:665–85.
192. Abraham a. Adaptation of fuzzy inference system using neural learning. Fuzzy Systems Engineering [Internet]. 2005;83:53–83. Available from: <http://www.springerlink.com/index/AJ9JTCUH9541YX59.pdf>
193. MATLAB. Fuzzy Logic Toolbox - MATLAB. The MathWorks Inc [Internet]. 2017; Available from: <https://www.mathworks.com/products/fuzzy-logic.html>
194. Übeyli ED. Automatic diagnosis of diabetes using adaptive neuro-fuzzy inference systems. Expert Systems. 2010;27:259–66.
195. Bani Amer M. An adaptive neurofuzzy technique for determination of blood acidity. Computer methods in biomechanics and biomedical engineering [Internet]. 2010;13:685–91. Available from: <http://www.ncbi.nlm.nih.gov/pubmed/20146128>
196. Das R, Sengur A. Evaluation of ensemble methods for diagnosing of valvular heart disease. Expert Systems with Applications. 2010;37:5110–5.
197. Özkan AO, Kara S, Salli A, Sakarya ME, Güne S. Medical diagnosis of rheumatoid arthritis disease from right and left hand Ulnar artery Doppler signals using adaptive network based fuzzy inference system (ANFIS) and MUSIC method. Advances in Engineering Software. 2010;41:1295–301.
198. Subasi A. Application of adaptive neuro-fuzzy inference system for epileptic seizure detection using wavelet feature extraction. Computers in Biology and Medicine.

2007;37:227–44.

199. Wang Z, Palade V, Xu Y. Neuro-Fuzzy Ensemble Approach for Microarray Cancer Gene Expression Data Analysis. Proc of the Second International Symposium on Evolving Fuzzy System EFS06 IEEE Computational Intelligence Society [Internet]. 2006;0:241–6. Available from:

<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=4016708>

200. Kara S, Güven A. Neural network-based diagnosing for optic nerve disease from visual-evoked potential. Journal of Medical Systems. 2007;31:391–6.

201. Übeyli ED. Adaptive neuro-fuzzy inference system for analysis of Doppler signals. Annual International Conference of the IEEE Engineering in Medicine and Biology - Proceedings. 2006. p. 2167–70.

202. Übeyli ED. Automatic detection of electroencephalographic changes using adaptive neuro-fuzzy inference system employing Lyapunov exponents. Expert Systems with Applications. 2009;36:9031–8.

203. Hall JE. Guyton and Hall Textbook of Medical Physiology. Physiology. 2010;1091.

204. Martinho Lopes A, Pereira H, Onça R, Niza MMRE, Dourado A. 3D Modeling of Abdominal Surface Area in Cats. Journal of Veterinary Science & Technology [Internet]. 2015;6. Available from: <http://dx.doi.org/10.4172/2157-7579.1000269>

205. Lopes AM, Castro M, Ferreira A, Pereira H, Niza MMRE, Dourado An. 3D modeling of abdominal surface area in a dog model. 2016;

206. AM L, M M. Biophysical Validation of Intra- Abdominal Pressure and Transurethral Method. Journal of Veterinary Science & Medical Diagnosis [Internet]. 2016;5. Available from: <http://dx.doi.org/10.4172/2325-9590.1000196>

207. Dumbar G, Higa J, Jones T, Kaminski B, Al E. Guidelines for Ethical Conduct in The Care and Use of Nonhuman Animals in Research. American Psychological Association [Internet]. USA; p. 1–14. Available from: <http://www.apa.org/science/leadership/care/care-animal-guidelines.pdf>

208. Busek, Chastel. Animals used for scientific purposes. Official Journal of the European Union [Internet]. European Commission; 2010;33–69. Available from: http://ec.europa.eu/environment/chemicals/lab_animals/home_en.htm

209. Demuth H, Beale M, Hagan M, Chen Q. Neural network toolbox™ 6. User's guide [Internet]. 2008;9:259–65. Available from: <http://www.springerlink.com/content/c669ekpjypvxxc5w>

210. Jang JSR, Gulley N. Gain scheduling based fuzzy controller design.

NAFIPSIFISNASA 94 Proceedings of the First International Joint Conference of The North American Fuzzy Information Processing Society Biannual Conference The Industrial Fuzzy Control and Intelligence. 1994;1.

211. Gattinoni L, Pelosi P, Suter PM, Pedoto A, Vercesi P, Lissoni A. Acute Respiratory Distress Syndrome Caused by Pulmonary and Extrapulmonary Disease . Different Syndromes? *Am J Respir Crit Care Med* [Internet]. 1998;158:3–11. Available from: <http://ajrcm.atsjournals.org/cgi/content/abstract/158/1/3>

212. Quintel M, Pelosi P, Caironi P, Meinhardt JP, Luecke T, Herrmann P, et al. An increase of abdominal pressure increases pulmonary edema in oleic acid-induced lung injury. *Am J Respir Crit Care Med* [Internet]. 2004;169:534–41. Available from: <http://www.ncbi.nlm.nih.gov/pubmed/14670801> <http://www.atsjournals.org/doi/pdf/10.1164/rccm.200209-1060OC>

213. Goodale RL, Beebe DS, McNevin MP, Boyle M, Letourneau JG, Abrams JH, et al. Hemodynamic, respiratory, and metabolic effects of laparoscopic cholecystectomy. *American journal of surgery*. 1993;166:533–7.

214. Simon RJ, Friedlander MH, Ivatury RR, DiRaimo R, Machiedo GW. Hemorrhage lowers the threshold for intra-abdominal hypertension-induced pulmonary dysfunction. *The Journal of trauma*. 1997;42:395–8.

215. Cheatham M, Malbrain M. Cardiovascular implications of elevated intraabdominal pressure. In: Ivatury R, Cheatham M, Malbrain M, Sugrue M, editors. *Abdominal compartment syndrome*. Georgetown: Landes Bioscience; 2006. p. 89–104.

216. Truijen J, Van Lieshout JJ, Wesselink WA, Westerhof BE. Noninvasive continuous hemodynamic monitoring. *Journal of Clinical Monitoring and Computing*. 2012;26:267–78.

217. Binns SH, Sisson DD, Buoscio DA, Schaeffer DJ. Doppler ultrasonographic, oscillometric sphygmomanometric, and photoplethysmographic techniques for noninvasive blood pressure measurement in anesthetized cats. *Journal of veterinary internal medicine / American College of Veterinary Internal Medicine*. 1995;9:405–14.

218. The EAT. *Protocols for Practice: Applying Research At the Bedside*. *Critical Care Nurse*. 2002;22:123–4.


219. Takci S, Yigit S, Korkmaz A, Yurdakök M. Comparison between oscillometric and invasive blood pressure measurements in critically ill premature infants. *Acta Paediatrica, International Journal of Paediatrics*. 2012;101:132–5.

220. Graettinger WF, Lipson JL, Cheung DG, Weber MA. Validation of portable

- noninvasive blood pressure monitoring devices: Comparisons with intra-arterial and sphygmomanometer measurements. *American Heart Journal*. 1988;116:1155–60.
221. Manolio TA, Fishel SC, Beattie C, Torres J, Christopherson R, Merritt WT, et al. Evaluation of the Dinamap continuous blood pressure monitor. *American journal of hypertension* [Internet]. 1988;1:161S–167S. Available from: <http://www.ncbi.nlm.nih.gov/pubmed/3415794>
222. Smulyan H, Safar ME. Blood pressure measurement: retrospective and prospective views. *American journal of hypertension* [Internet]. Nature Publishing Group; 2011;24:628–34. Available from: <http://dx.doi.org/10.1038/ajh.2011.22/nature06264>
223. Dabrowski W, Jaroszynski A, Jaroszynska A, Rzecki Z, Schlegel TT, Malbrain ML. Intra-abdominal hypertension increases spatial QRS-T angle and elevates ST-segment J-point in healthy women undergoing laparoscopic surgery. *Journal of Electrocardiology* [Internet]. Elsevier Inc.; 2016; Available from: <http://linkinghub.elsevier.com/retrieve/pii/S0022073616302722>
224. Analyze Neural Network Performance After Training [Internet]. MathWorks: Documentation. 2016. Available from: <http://www.mathworks.com/help/nnet/ug/analyze-neural-network-performance-after-training.html>
225. Test Data Against Trained System (GUI) [Internet]. MathWorks: Documentation. 2016 [cited 2016 Apr 13]. Available from: <http://www.mathworks.com/help/fuzzy/test-data-against-trained-system-gui.html>

Anexos

Autorização da Comissão de Ética e Bem-Estar Animal da Universidade Lusófona

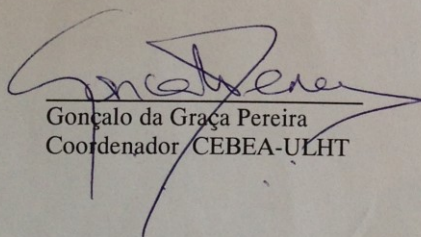


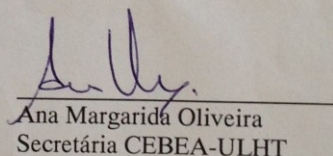
Anexo 4 - Apreciação da CEBEA-ULHT

Lisboa, 30 Outubro de 2014

Exmo Sr Dr António Manuel Correia Martinho Lopes,

A Comissão de Ética e Bem Estar Animal da Universidade Lusófona de Humanidades e Tecnologias, vem por este meio informar, que o projecto intitulado "Sistema Inteligente para Medição de Pressão Intra-abdominal", com o processo nº54-2014, foi considerado aprovado.


Gonçalo da Graça Pereira
Coordenador CEBEA-ULHT


Ana Margarida Oliveira
Secretária CEBEA-ULHT

Dados Totais de Redes Neurais Artificiais obtidos

| População | Camadas | Fx Ativação | Fx de Treino | Neurónios | 18 Variáveis | | | | | | 7 Variáveis (Peso/Perímetro/ASCA/PAM/PAD/QRS/Amplitude Onda R) | | | | | |
|-----------|---------|-------------|--------------|-----------|--------------|-------|----------|-------------|---------|---------|--|-------|----------|-------------|----------|---------|
| | | | | | Performance | EPOCH | Treino R | Validação R | Teste R | Todos R | Performance | EPOCH | Treino R | Validação R | Treino R | Todos R |
| S+T | 2 | purelin | Trainscg | 10 | 407 | 25 | 0,65817 | 0,79335 | 0,68621 | 0,68736 | 83,1 | 16 | 0,68823 | 0,36812 | 0,56781 | 0,63206 |
| | 2 | purelin | Trainscg | 15 | 409 | 44 | 0,69878 | 0,7477 | 0,77186 | 0,71302 | 409 | 27 | 0,64294 | 0,62059 | 0,48669 | 0,62104 |
| | 2 | purelin | Trainscg | 20 | 797 | 32 | 0,72065 | 0,69655 | 0,60634 | 0,69897 | 229 | 20 | 0,65169 | 0,59469 | 0,63536 | 0,63939 |
| | 2 | purelin | Trainlm | 10 | 125 | 5 | 0,76288 | 0,61808 | 0,55083 | 0,71339 | 206 | 4 | 0,6463 | 0,46984 | 0,7515 | 0,64402 |
| | 2 | purelin | Trainlm | 15 | 299 | 7 | 0,71312 | 0,7859 | 0,64419 | 0,71286 | 521 | 5 | 0,63459 | 0,63574 | 0,706446 | 0,64608 |
| | 2 | purelin | Trainlm | 20 | 2020 | 5 | 0,7174 | 0,76709 | 0,61574 | 0,70664 | 397 | 5 | 0,6231 | 0,67438 | 0,7448 | 0,645 |
| | 2 | purelin | Trainbr | 10 | 186 | 1000 | 0,72757 | | 0,66021 | 0,7166 | 138 | 1000 | 0,63823 | | 0,67509 | 0,64365 |
| | 2 | purelin | Trainbr | 15 | 237 | 1000 | 0,72505 | | 0,66486 | 0,71663 | 223 | 1000 | 0,63971 | | 0,68447 | 0,64574 |
| | 2 | purelin | Trainbr | 20 | 3740 | 1000 | 0,72681 | | 0,64591 | 0,71734 | 362 | 1000 | 0,66186 | | 0,51272 | 0,64454 |
| | 3 | purelin | Trainscg | [10,10] | 276 | 34 | 0,81058 | 0,71232 | 0,68182 | 0,77912 | 148 | 20 | 0,73993 | 0,70422 | 0,68488 | 0,72492 |
| | 3 | purelin | Trainscg | [15,15] | 443 | 50 | 0,83384 | 0,71228 | 0,73604 | 0,78979 | 178 | 50 | 0,79768 | 0,77599 | 0,66906 | 0,78135 |
| | 3 | purelin | Trainscg | [20,20] | 258 | 44 | 0,88237 | 0,75676 | 0,72566 | 0,84003 | 73,9 | 50 | 0,85237 | 0,88581 | 0,77217 | 0,84905 |
| | 3 | purelin | Trainlm | [10,10] | 47,1 | 17 | 0,88423 | 0,56355 | 0,85517 | 0,82576 | 227 | 25 | 0,88671 | 0,88306 | 0,80191 | 0,86903 |
| | 3 | purelin | Trainlm | [15,15] | 141 | 19 | 0,92561 | 0,8204 | 0,68596 | 0,86457 | 253 | 25 | 0,85313 | 0,80875 | 0,70537 | 0,82441 |
| | 3 | purelin | Trainlm | [20,20] | 317 | 12 | 0,88711 | 0,77111 | 0,69175 | 0,84301 | 52,9 | 14 | 0,91394 | 0,88873 | 0,76755 | 0,88965 |
| | 3 | purelin | Trainbr | [10,10] | 515 | 116 | 0,99118 | | 0,55138 | 0,91743 | 564 | 240 | 0,94831 | | 0,90065 | 0,94106 |
| | 3 | purelin | Trainbr | [15,15] | 819 | 111 | 0,9988 | | 0,65367 | 0,95068 | 730 | 1000 | 0,96887 | | 0,89807 | 0,9584 |
| | 3 | purelin | Trainbr | [20,20] | 723 | 158 | 0,83816 | | 0,80466 | 0,83112 | 468 | 1000 | 0,97684 | | 0,88142 | 0,96263 |
| | 2 | Logsig | Trainscg | 10 | 134 | 13 | 0,49189 | 0,15535 | 0,4512 | 0,42423 | 89,2 | 33 | 0,67739 | 0,60711 | 0,5813 | 0,65241 |
| | 2 | Logsig | Trainscg | 15 | 68 | 12 | 0,577 | 0,67727 | 0,42607 | 0,565 | 125 | 15 | 0,60028 | 0,72062 | 0,43179 | 0,59549 |
| | 2 | Logsig | Trainscg | 20 | 28,7 | 14 | 0,66449 | 0,59249 | 0,53285 | 0,63236 | 172 | 41 | 0,71711 | 0,73864 | 0,8242 | 0,73988 |
| | 2 | Logsig | Trainlm | 10 | 35,7 | 16 | 0,95532 | 0,77658 | 0,84121 | 0,90432 | 28,1 | 17 | 0,88597 | 0,81769 | 0,87677 | 0,85577 |
| | 2 | Logsig | Trainlm | 15 | 42,5 | 11 | 0,97052 | 0,61628 | 0,82381 | 0,9248 | 23,7 | 15 | 0,91218 | 0,84019 | 0,82934 | 0,8899 |

| | | | | | | | | | | | | | | | |
|---|--------|----------|---------|------|------|---------|---------|----------|---------|------|------|---------|---------|---------|---------|
| 2 | Logsig | Trainlm | 20 | 221 | 16 | 0,98085 | 0,85091 | 0,81944 | 0,93175 | 66,8 | 16 | 0,91558 | 0,87675 | 0,76787 | 0,88852 |
| 2 | Logsig | Trainbr | 10 | 222 | 683 | 0,98491 | | 0,81262 | 0,95366 | 300 | 244 | 0,94418 | | 0,84377 | 0,93174 |
| 2 | Logsig | Trainbr | 15 | 148 | 519 | 0,9964 | | 0,78871 | 0,96617 | 230 | 250 | 0,95229 | | 0,9045 | 0,94604 |
| 2 | Logsig | Trainbr | 20 | 120 | 620 | 0,99713 | | 0,66411 | 0,94559 | 280 | 560 | 0,95736 | | 0,9135 | 0,94941 |
| 3 | Logsig | Trainscg | [10,10] | 38,9 | 16 | 0,39371 | 0,40601 | 0,58674 | 0,4189 | 280 | 42 | 0,76942 | 0,77725 | 0,68725 | 0,75726 |
| 3 | Logsig | Trainscg | [15,15] | 645 | 39 | 0,7259 | 0,66143 | 0,67789 | 0,71188 | 594 | 44 | 0,71543 | 0,65772 | 0,70822 | 0,7959 |
| 3 | Logsig | Trainscg | [20,20] | 89,1 | 28 | 0,70494 | 0,79918 | 0,68325 | 0,71158 | 1490 | 40 | 0,71894 | 0,76388 | 0,74069 | 0,72751 |
| 3 | Logsig | Trainlm | [10,10] | 179 | 17 | 0,95082 | 0,6998 | 0,58396 | 0,86913 | 98,1 | 30 | 0,96051 | 0,88587 | 0,84093 | 0,92039 |
| 3 | Logsig | Trainlm | [15,15] | 26,6 | 12 | 0,92013 | 0,87157 | 0,69694 | 0,87748 | 28,7 | 26 | 0,95061 | 0,83067 | 0,86844 | 0,9203 |
| 3 | Logsig | Trainlm | [20,20] | 203 | 15 | 0,9381 | 0,78442 | 0,68746 | 0,87252 | 110 | 20 | 0,95763 | 0,81294 | 0,82541 | 0,91664 |
| 3 | Logsig | Trainbr | [10,10] | 56,8 | 1000 | 0,99891 | | 0,71894 | 0,94691 | 142 | 365 | 0,97943 | | 0,91781 | 0,96322 |
| 3 | Logsig | Trainbr | [15,15] | 372 | 1000 | 0,99421 | | 0,81257 | 0,95478 | 234 | 1000 | 0,99137 | | 0,82541 | 0,95103 |
| 3 | Logsig | Trainbr | [20,20] | 296 | 1000 | 0,99857 | | 0,6909 | 0,93221 | 285 | 1000 | 0,98899 | | 0,77136 | 0,9368 |
| 2 | tansig | Trainscg | 10 | 45,2 | 23 | 0,70384 | 0,88809 | 0,64546 | 0,71605 | 168 | 24 | 0,65693 | 0,71319 | 0,72307 | 0,67476 |
| 2 | tansig | Trainscg | 15 | 757 | 31 | 0,79167 | 0,75492 | 0,74889 | 0,78008 | 21,3 | 26 | 0,68841 | 0,74209 | 0,75553 | 0,70857 |
| 2 | tansig | Trainscg | 20 | 143 | 27 | 0,80371 | 0,7134 | 0,70266 | 0,768 | 461 | 21 | 0,70278 | 0,5642 | 0,61616 | 0,67432 |
| 2 | tansig | Trainlm | 10 | 329 | 37 | 0,96176 | 0,87612 | 0,7835 | 0,91776 | 68,2 | 39 | 0,93667 | 0,86596 | 0,90393 | 0,91888 |
| 2 | tansig | Trainlm | 15 | 383 | 12 | 0,9649 | 0,8588 | 0,45896 | 0,90303 | 22,6 | 20 | 0,93625 | 0,83153 | 0,92245 | 0,9218 |
| 2 | tansig | Trainlm | 20 | 385 | 15 | 0,77075 | 0,57753 | 0,741487 | 0,72603 | 50,2 | 10 | 0,90962 | 0,74826 | 0,76463 | 0,85673 |
| 2 | tansig | Trainbr | 10 | 1240 | 221 | 0,97997 | | 0,8849 | 0,95512 | 31,3 | 182 | 0,94758 | | 0,7918 | 0,92255 |
| 2 | tansig | Trainbr | 15 | 207 | 437 | 0,99848 | | 0,49328 | 0,92447 | 758 | 354 | 0,96728 | | 0,7182 | 0,93336 |
| 2 | tansig | Trainbr | 20 | 252 | 674 | 0,99994 | | 0,53477 | 0,89593 | 97,4 | 430 | 0,9666 | | 0,79593 | 0,93786 |
| 3 | tansig | Trainscg | [10,10] | 300 | 26 | 0,68781 | 0,73071 | 0,76504 | 0,70724 | 527 | 13 | 0,5771 | 0,54956 | 0,35578 | 0,53737 |
| 3 | tansig | Trainscg | [15,15] | 107 | 16 | 0,66884 | 0,60911 | 0,65285 | 0,65199 | 112 | 50 | 0,85606 | 0,76326 | 0,68718 | 0,81762 |
| 3 | tansig | Trainscg | [20,20] | 782 | 38 | 0,81368 | 0,81034 | 0,69584 | 0,79998 | 82,6 | 28 | 0,71461 | 0,77467 | 0,73343 | 0,72365 |
| 3 | tansig | Trainlm | [10,10] | 98,7 | 11 | 0,91372 | 0,76294 | 0,75119 | 0,86648 | 50,9 | 22 | 0,95123 | 0,87071 | 0,92329 | 0,92993 |
| 3 | tansig | Trainlm | [15,15] | 153 | 16 | 0,96792 | 0,73009 | 0,67959 | 0,87819 | 221 | 13 | 0,94302 | 0,83958 | 0,83628 | 0,91779 |
| 3 | tansig | Trainlm | [20,20] | 114 | 11 | 0,911 | 0,8108 | 0,72855 | 0,86733 | 204 | 15 | 0,92926 | 0,84839 | 0,92065 | 0,91523 |

| | | | | | | | | | | | | | | | | |
|--|---------|-------------|--------------|-----------|-------------|-------|----------|-------------|---------|--|-------------|-------|----------|-------------|----------|---------|
| | 3 | tansig | Trainbr | [10,10] | 263 | 539 | 0,99949 | | 0,65574 | 0,92296 | 961 | 955 | 0,98068 | | 0,82271 | 0,95881 |
| | 3 | tansig | Trainbr | [15,15] | 1830 | 1000 | 0,99974 | | 0,66201 | 0,89275 | 150 | 1000 | 0,98707 | | 0,83538 | 0,94544 |
| | 3 | tansig | Trainbr | [20,20] | 1620 | 1000 | 1 | | 0,65868 | 0,91253 | 44,1 | 1000 | 0,99324 | | 0,72977 | 0,93958 |
| 54 tipo de redes Neurais diferentes | | | | | | | | | | 54 tipo de redes Neurais diferentes | | | | | | |
| | Camadas | Fx Ativação | Fx de Treino | Neurónios | Performance | EPOCH | Treino R | Validação R | Teste R | Todos R | Performance | EPOCH | Treino R | Validação R | Test e R | Todos R |
| | 2 | purelin | Trainscg | 10 | 398 | 16 | 0,73068 | 0,66144 | 0,56361 | 0,69519 | 145 | 12 | 0,7643 | 0,77178 | 0,60907 | 0,75086 |
| | 2 | purelin | Trainscg | 15 | 535 | 27 | 0,80245 | 0,82612 | 0,7471 | 0,8007 | 254 | 32 | 0,79013 | 0,69948 | 0,68677 | 0,7522 |
| | 2 | purelin | Trainscg | 20 | 324 | 32 | 0,85575 | 0,62778 | 0,75727 | 0,82078 | 1470 | 13 | 0,75984 | 0,79934 | 0,32364 | 0,74115 |
| | 2 | purelin | Trainlm | 10 | 302 | 5 | 0,83093 | 0,75543 | 0,88192 | 0,83403 | 172 | 3 | 0,78809 | 0,67043 | 0,69808 | 0,75596 |
| | 2 | purelin | Trainlm | 15 | 456 | 5 | 0,84762 | 0,74036 | 0,88534 | 0,82991 | 235 | 4 | 0,76182 | 0,72765 | 0,77156 | 0,7584 |
| | 2 | purelin | Trainlm | 20 | 298 | 4 | 0,83636 | 0,86883 | 0,78908 | 0,83301 | 92,9 | 3 | 0,79278 | 0,67789 | 0,6428 | 0,75107 |
| | 2 | purelin | Trainbr | 10 | 455 | 1000 | 0,82608 | | 0,80869 | 0,82364 | 210 | 1000 | 0,76689 | | 0,68984 | 0,75882 |
| | 2 | purelin | Trainbr | 15 | 225 | 1000 | 0,81024 | | 0,92694 | 0,82697 | 268 | 1000 | 0,76235 | | 0,74986 | 0,75878 |
| | 2 | purelin | Trainbr | 20 | 166 | 1000 | 0,83529 | | 0,71464 | 0,81665 | 599 | 1000 | 0,75206 | | 0,77903 | 0,75576 |
| | 3 | purelin | Trainscg | [10,10] | 235 | 16 | 0,8124 | 0,57834 | 0,7499 | 0,7263 | 152 | 24 | 0,83827 | 0,86196 | 0,80839 | 0,83564 |
| | 3 | purelin | Trainscg | [15,15] | 233 | 45 | 0,94036 | 0,88938 | 0,83608 | 0,91565 | 110 | 20 | 0,81648 | 0,90516 | 0,67882 | 0,81677 |
| | 3 | purelin | Trainscg | [20,20] | 302 | 36 | 0,92244 | 0,78973 | 0,64286 | 0,84954 | 288 | 30 | 0,86249 | 0,859 | 0,73798 | 0,84084 |
| | 3 | purelin | Trainlm | [10,10] | 31,5 | 16 | 0,84018 | 0,79853 | 0,80701 | 0,82762 | 48,9 | 10 | 0,86161 | 0,60638 | 0,76287 | 0,78973 |
| | 3 | purelin | Trainlm | [15,15] | 130 | 13 | 0,96634 | 0,86354 | 0,67828 | 0,88923 | 56 | 11 | 0,94546 | 0,92524 | 0,80615 | 0,92704 |
| | 3 | purelin | Trainlm | [20,20] | 466 | 11 | 0,80948 | 0,81497 | 0,4642 | 0,73617 | 162 | 11 | 0,93273 | 0,90978 | 0,75706 | 0,8996 |
| | 3 | purelin | Trainbr | [10,10] | 110 | 261 | 0,98497 | | 0,71212 | 0,9432 | 161 | 141 | 0,87097 | | 0,8415 | 0,86454 |
| | 3 | purelin | Trainbr | [15,15] | 202 | 1000 | 0,98777 | | 0,77197 | 0,96626 | 30,7 | 1000 | 0,85416 | | 0,91457 | 0,86543 |
| | 3 | purelin | Trainbr | [20,20] | 1110 | 1000 | 0,99217 | | 0,74848 | 0,94791 | 306 | 73 | 0,86896 | | 0,90306 | 0,86827 |
| | 2 | Logsig | Trainscg | 10 | 27,4 | 21 | 0,82309 | 0,79444 | 0,77455 | 0,79917 | 73,5 | 13 | 0,77899 | 0,91846 | 0,45632 | 0,74604 |
| | 2 | Logsig | Trainscg | 15 | 31,3 | 19 | 0,76299 | 0,72476 | 0,77255 | 0,76079 | 120 | 10 | 0,74729 | 0,74624 | 0,84925 | 0,75591 |
| | 2 | Logsig | Trainscg | 20 | 38 | 17 | 0,7532 | 0,93657 | 0,72146 | 0,77022 | 127 | 13 | 0,63638 | 0,66432 | 0,68369 | 0,66104 |
| | 2 | Logsig | Trainlm | 10 | 110 | 10 | 0,7124 | 0,90339 | 0,55022 | 0,7354 | 112 | 20 | 0,93347 | 0,8875 | 0,83782 | 0,90182 |
| | 2 | Logsig | Trainlm | 15 | 428 | 17 | 0,94638 | 0,80879 | 0,82658 | 0,91158 | 226 | 15 | 0,95926 | 0,92524 | 0,54124 | 0,85943 |

| | | | | | | | | | | | | | | | |
|---|--------|----------|---------|------|------|---------|---------|---------|---------|------|------|---------|----------|---------|---------|
| 2 | Logsig | Trainlm | 20 | 82,6 | 12 | 0,99314 | 0,47504 | 0,80121 | 0,89396 | 46,9 | 12 | 0,94168 | 0,95045 | 0,7485 | 0,92712 |
| 2 | Logsig | Trainbr | 10 | 15,6 | 510 | 0,98803 | | 0,85089 | 0,97225 | 54 | 544 | 0,93887 | | 0,90921 | 0,92255 |
| 2 | Logsig | Trainbr | 15 | 259 | 554 | 0,9993 | | 0,79664 | 0,96004 | 195 | 156 | 0,93928 | | 0,89093 | 0,93204 |
| 2 | Logsig | Trainbr | 20 | 32 | 1000 | 0,99774 | | 0,85234 | 0,97699 | 293 | 147 | 0,94008 | | 0,8938 | 0,93362 |
| 3 | Logsig | Trainscg | [10,10] | 120 | 26 | 0,84347 | 0,86023 | 0,68238 | 0,81927 | 175 | 11 | 0,67702 | 0,65035 | 0,62529 | 0,66109 |
| 3 | Logsig | Trainscg | [15,15] | 140 | 21 | 0,78839 | 0,68763 | 0,79323 | 0,76505 | 179 | 39 | 0,89117 | 0,68818 | 0,70649 | 0,82576 |
| 3 | Logsig | Trainscg | [20,20] | 614 | 27 | 0,86332 | 0,84046 | 0,82845 | 0,84794 | 134 | 44 | 0,88349 | 0,85439 | 0,83973 | 0,85992 |
| 3 | Logsig | Trainlm | [10,10] | 36 | 13 | 0,95805 | 0,85518 | 0,59717 | 0,92257 | 92,7 | 10 | 0,93079 | 0,424453 | 0,62179 | 0,82147 |
| 3 | Logsig | Trainlm | [15,15] | 100 | 13 | 0,89787 | 0,91544 | 0,83077 | 0,88901 | 405 | 12 | 0,84654 | 0,86841 | 0,88547 | 0,85011 |
| 3 | Logsig | Trainlm | [20,20] | 704 | 10 | 0,97742 | 0,86793 | 0,91441 | 0,9452 | 168 | 11 | 0,93832 | 0,73162 | 0,87588 | 0,9037 |
| 3 | Logsig | Trainbr | [10,10] | 66,5 | 1000 | 0,99342 | | 0,77662 | 0,95918 | 64,3 | 1000 | 0,98356 | | 0,68556 | 0,93423 |
| 3 | Logsig | Trainbr | [15,15] | 94,8 | 1000 | 0,99239 | | 0,87955 | 0,97065 | 71,2 | 1000 | 0,96266 | | 0,94005 | 0,94607 |
| 3 | Logsig | Trainbr | [20,20] | 21,4 | 1000 | 0,99793 | | 0,86501 | 0,96892 | 38 | 1000 | 0,96449 | | 0,52407 | 0,93634 |
| 2 | tansig | Trainscg | 10 | 90,6 | 26 | 0,84878 | 0,91597 | 0,62689 | 0,8263 | 126 | 54 | 0,84538 | 0,86947 | 0,78072 | 0,84641 |
| 2 | tansig | Trainscg | 15 | 111 | 22 | 0,89656 | 0,89012 | 0,89197 | 0,89484 | 296 | 16 | 0,80162 | 0,76523 | 0,7946 | 0,79435 |
| 2 | tansig | Trainscg | 20 | 267 | 42 | 0,94695 | 0,87438 | 0,8926 | 0,91664 | 81,7 | 14 | 0,63189 | 0,80338 | 0,72041 | 0,6817 |
| 2 | tansig | Trainlm | 10 | 94 | 14 | 0,96914 | 0,79081 | 0,88531 | 0,94082 | 32,6 | 32 | 0,97514 | 0,86519 | 0,84215 | 0,92852 |
| 2 | tansig | Trainlm | 15 | 381 | 14 | 0,95601 | 0,8837 | 0,95807 | 0,94572 | 856 | 19 | 0,92285 | 0,90457 | 0,8338 | 0,90817 |
| 2 | tansig | Trainlm | 20 | 28,5 | 10 | 0,96007 | 0,89209 | 0,83132 | 0,92955 | 60,4 | 10 | 0,93124 | 0,88122 | 0,90413 | 0,9223 |
| 2 | tansig | Trainbr | 10 | 205 | 790 | 0,99423 | | 0,72408 | 0,96372 | 194 | 349 | 0,92166 | | 0,94571 | 0,926 |
| 2 | tansig | Trainbr | 15 | 419 | 693 | 0,99008 | | 0,76777 | 0,95986 | 188 | 728 | 0,95593 | | 0,68402 | 0,91708 |
| 2 | tansig | Trainbr | 20 | 128 | 1000 | 0,99197 | | 0,7918 | 0,95264 | 80,4 | 851 | 0,92572 | | 0,93645 | 0,92674 |
| 3 | tansig | Trainscg | [10,10] | 70,6 | 53 | 0,95275 | 0,93757 | 0,85238 | 0,93624 | 535 | 19 | 0,8314 | 0,86245 | 0,68216 | 0,81947 |
| 3 | tansig | Trainscg | [15,15] | 910 | 32 | 0,91357 | 0,86467 | 0,86731 | 0,89679 | 113 | 25 | 0,81696 | 0,77253 | 0,8695 | 0,81357 |
| 3 | tansig | Trainscg | [20,20] | 221 | 33 | 0,92196 | 0,89984 | 0,9331 | 0,92238 | 84,7 | 38 | 0,90357 | 0,49584 | 0,92814 | 0,86968 |
| 3 | tansig | Trainlm | [10,10] | 219 | 13 | 0,98703 | 0,87854 | 0,8278 | 0,95658 | 103 | 11 | 0,90652 | 0,87941 | 0,88865 | 0,89577 |
| 3 | tansig | Trainlm | [15,15] | 1170 | 14 | 0,99423 | 0,80442 | 0,76335 | 0,89744 | 148 | 17 | 0,94457 | 0,90102 | 0,78296 | 0,91228 |
| 3 | tansig | Trainlm | [20,20] | 655 | 9 | 0,9617 | 0,85833 | 0,67148 | 0,91002 | 50,3 | 11 | 0,95248 | 0,88387 | 0,86506 | 0,91889 |

| | | | | | | | | | | | | | | | | |
|--|---------|--------------|--------------|-----------|-------------|-------|----------|-------------|---------|---------|-------------|-------|----------|-------------|----------|---------|
| | 3 | tansig | Trainbr | [10,10] | 438 | 1000 | 0,9983 | | 0,82738 | 0,95871 | 136 | 614 | 0,98072 | | 0,82096 | 0,93262 |
| | 3 | tansig | Trainbr | [15,15] | 37,1 | 1000 | 1 | | 0,7046 | 0,94791 | 36,9 | 1000 | 0,96848 | | 0,61093 | 0,91355 |
| | 3 | tansig | Trainbr | [20,20] | 576 | 1000 | 0,99271 | | 0,86348 | 0,9694 | 0,97033 | 1000 | 0,97033 | | 0,72012 | 0,93007 |
| | Camadas | Fx Activação | Fx de Treino | Neurónios | Performance | EPOCH | Treino R | Validação R | Teste R | Todos R | Performance | EPOCH | Treino R | Validação R | Teste R | Todos R |
| | 2 | purelin | Trainscg | 10 | 987 | 26 | 0,71838 | 0,82984 | 0,67034 | 0,73313 | 126 | 24 | 0,6396 | 0,71209 | 0,73332 | 0,66899 |
| | 2 | purelin | Trainscg | 15 | 906 | 21 | 0,7046 | 0,73305 | 0,56325 | 0,69311 | 79,7 | 20 | 0,6324 | 0,74944 | 0,2179 | 0,62633 |
| | 2 | purelin | Trainscg | 20 | 2930 | 34 | 0,7853 | 0,75767 | 0,37085 | 0,74541 | 523 | 23 | 0,64195 | 0,74639 | 0,79792 | 0,68427 |
| | 2 | purelin | Trainlm | 10 | 909 | 5 | 0,7881 | 0,76143 | 0,69184 | 0,76931 | 947 | 5 | 0,67569 | 0,72912 | 0,7498 | 0,68868 |
| | 2 | purelin | Trainlm | 15 | 184 | 6 | 0,74129 | 0,86863 | 0,77771 | 0,76879 | 286 | 5 | 0,71121 | 0,64558 | 0,66116 | 0,6977 |
| | 2 | purelin | Trainlm | 20 | 773 | 5 | 0,75972 | 0,80594 | 0,76109 | 0,76975 | 471 | 4 | 0,68324 | 0,75346 | 0,64602 | 0,68423 |
| | 2 | purelin | Trainbr | 10 | 890 | 1000 | 0,78419 | | 0,71925 | 0,77193 | 147 | 1000 | 0,68053 | | 0,7542 | 0,69096 |
| | 2 | purelin | Trainbr | 15 | 274 | 1000 | 0,78605 | | 0,68356 | 0,77305 | 184 | 1000 | 0,67816 | | 0,70579 | 0,68986 |
| | 2 | purelin | Trainbr | 20 | 993 | 1000 | 0,78213 | | 0,7361 | 0,77372 | 422 | 1000 | 0,69463 | | 0,69122 | 0,69228 |
| | 3 | purelin | Trainscg | [10,10] | 319 | 28 | 0,87307 | 0,85118 | 0,61111 | 0,84095 | 24,3 | 30 | 0,89983 | 0,71416 | 0,89868 | 0,88403 |
| | 3 | purelin | Trainscg | [15,15] | 51,4 | 14 | 0,71214 | 0,86751 | 0,30634 | 0,68047 | 67,7 | 41 | 0,89403 | 0,95586 | 0,83967 | 0,89848 |
| | 3 | purelin | Trainscg | [20,20] | 335 | 19 | 0,82521 | 0,60638 | 0,66597 | 0,77748 | 562 | 72 | 0,94511 | 0,95139 | 0,85355 | 0,92979 |
| | 3 | purelin | Trainlm | [10,10] | 210 | 14 | 0,91161 | 0,85102 | 0,59023 | 0,84686 | 95,4 | 32 | 0,96114 | 0,89449 | 0,88815 | 0,93758 |
| | 3 | purelin | Trainlm | [15,15] | 225 | 17 | 0,95639 | 0,79564 | 0,89532 | 0,93078 | 217 | 14 | 0,93442 | 0,91636 | 0,91361 | 0,92753 |
| | 3 | purelin | Trainlm | [20,20] | 234 | 17 | 0,86126 | 0,92977 | 0,90997 | 0,88203 | 53,4 | 11 | 0,95557 | 0,97723 | 0,82262 | 0,94431 |
| | 3 | purelin | Trainbr | [10,10] | 188 | 641 | 0,99994 | | 0,37706 | 0,95923 | 444 | 371 | 0,96049 | | 0,939 | 0,95589 |
| | 3 | purelin | Trainbr | [15,15] | 1120 | 1000 | 0,99999 | | 0,68696 | 0,93429 | 598 | 79,1 | 0,98585 | | 0,89359 | 0,96642 |
| | 3 | purelin | Trainbr | [20,20] | 1560 | 937 | 0,99965 | | 0,64317 | 0,92497 | 313 | 1000 | 0,98702 | | 0,87606 | 0,95267 |
| | 2 | Logsig | Trainscg | 10 | 107 | 9 | 0,45984 | 0,77682 | 0,4386 | 0,49154 | 128 | 10 | 0,52415 | 0,35793 | 0,071649 | 0,45146 |
| | 2 | Logsig | Trainscg | 15 | 596 | 18 | 0,78709 | 0,61869 | 0,69506 | 0,74066 | 171 | 25 | 0,76076 | 0,7795 | 0,81471 | 0,76336 |
| | 2 | Logsig | Trainscg | 20 | 67 | 13 | 0,65934 | 0,57014 | 0,28129 | 0,58432 | 417 | 33 | 0,84194 | 0,79054 | 0,57336 | 0,79371 |
| | 2 | Logsig | Trainlm | 10 | 666 | 10 | 0,89991 | 0,74839 | 0,83041 | 0,86049 | 83,8 | 15 | 0,94505 | 0,84021 | 0,8502 | 0,91955 |
| | 2 | Logsig | Trainlm | 15 | 21,7 | 11 | 0,96511 | 0,7838 | 0,87931 | 0,93277 | 69,3 | 18 | 0,95776 | 0,91737 | 0,7411 | 0,936 |
| | 2 | Logsig | Trainlm | 20 | 150 | 13 | 0,94551 | 0,57299 | 0,54903 | 0,76345 | 1280 | 19 | 0,94108 | 0,87019 | 0,8831 | 0,91902 |

D

| | | | | | | | | | | | | | | | |
|---|--------|----------|---------|------|------|---------|---------|---------|---------|------|------|---------|---------|----------|---------|
| 2 | Logsig | Trainbr | 10 | 47,4 | 473 | 0,99778 | | 0,76319 | 0,9681 | 227 | 167 | 0,94754 | | 0,95229 | 0,94789 |
| 2 | Logsig | Trainbr | 15 | 53,4 | 656 | 0,99702 | | 0,88943 | 0,96145 | 61,5 | 1000 | 0,97901 | | 0,55326 | 0,8819 |
| 2 | Logsig | Trainbr | 20 | 101 | 1000 | 0,99838 | | 0,8767 | 0,9686 | 1140 | 1000 | 0,96486 | | 0,91649 | 0,95692 |
| 3 | Logsig | Trainscg | [10,10] | 208 | 55 | 0,89966 | 0,85551 | 0,78604 | 0,87916 | 101 | 20 | 0,74341 | 0,56889 | 0,81697 | 0,73615 |
| 3 | Logsig | Trainscg | [15,15] | 58,5 | 20 | 0,65813 | 0,7629 | 0,58613 | 0,6643 | 443 | 17 | 0,63366 | 0,70422 | 0,82264 | 0,66675 |
| 3 | Logsig | Trainscg | [20,20] | 102 | 39 | 0,81177 | 0,78454 | 0,74254 | 0,79687 | 166 | 23 | 0,82501 | 0,68902 | 0,68429 | 0,79491 |
| 3 | Logsig | Trainlm | [10,10] | 345 | 12 | 0,94854 | 0,81257 | 0,84986 | 0,90092 | 350 | 13 | 0,94 | 0,89563 | 0,95341 | 0,93289 |
| 3 | Logsig | Trainlm | [15,15] | 69,3 | 11 | 0,94959 | 0,87586 | 0,80184 | 0,91435 | 444 | 14 | 0,94765 | 0,7451 | 0,91583 | 0,90182 |
| 3 | Logsig | Trainlm | [20,20] | 461 | 13 | 0,91164 | 0,7344 | 0,79652 | 0,87002 | 550 | 20 | 0,97922 | 0,92405 | 0,81139 | 0,94474 |
| 3 | Logsig | Trainbr | [10,10] | 120 | 1000 | 0,99979 | | 0,75072 | 0,88233 | 79,5 | 1000 | 0,99391 | | 0,606073 | 0,94483 |
| 3 | Logsig | Trainbr | [15,15] | 1250 | 1000 | 0,99883 | | 0,7865 | 0,93652 | 363 | 1000 | 0,95251 | | 0,90326 | 0,94355 |
| 3 | Logsig | Trainbr | [20,20] | 234 | 1000 | 0,99833 | | 0,75877 | 0,95262 | 713 | 1000 | 0,95366 | | 0,86039 | 0,94295 |
| 2 | tansig | Trainscg | 10 | 192 | 15 | 0,77943 | 0,77869 | 0,76917 | 0,77412 | 693 | 45 | 0,86234 | 0,79355 | 0,45264 | 0,80104 |
| 2 | tansig | Trainscg | 15 | 95,1 | 30 | 0,80349 | 0,87119 | 0,78266 | 0,80829 | 184 | 32 | 0,86682 | 0,78077 | 0,84554 | 0,85789 |
| 2 | tansig | Trainscg | 20 | 870 | 27 | 0,83824 | 0,81292 | 0,73938 | 0,8205 | 203 | 26 | 0,80166 | 0,81252 | 0,89391 | 0,81359 |
| 2 | tansig | Trainlm | 10 | 39,9 | 12 | 0,96909 | 0,84454 | 0,73068 | 0,91421 | 50,3 | 14 | 0,95311 | 0,83645 | 0,91797 | 0,93491 |
| 2 | tansig | Trainlm | 15 | 36,3 | 10 | 0,95962 | 0,64098 | 0,86092 | 0,90998 | 603 | 12 | 0,89843 | 0,79679 | 0,61683 | 0,83743 |
| 2 | tansig | Trainlm | 20 | 251 | 10 | 0,8746 | 0,63291 | 0,70922 | 0,80817 | 623 | 12 | 0,94742 | 0,89569 | 0,76943 | 0,923 |
| 2 | tansig | Trainbr | 10 | 225 | 751 | 0,99829 | | 0,54713 | 0,91814 | 281 | 216 | 0,95181 | | 0,95192 | 0,94786 |
| 2 | tansig | Trainbr | 15 | 991 | 325 | 0,99682 | | 0,62646 | 0,92432 | 377 | 826 | 0,98271 | | 0,83342 | 0,95848 |
| 2 | tansig | Trainbr | 20 | 107 | 883 | 0,99889 | | 0,59607 | 0,92232 | 265 | 487 | 0,95649 | | 0,8425 | 0,93515 |
| 3 | tansig | Trainscg | [10,10] | 165 | 27 | 0,77741 | 0,68628 | 0,67463 | 0,75225 | 468 | 26 | 0,72768 | 0,77213 | 0,64522 | 0,71846 |
| 3 | tansig | Trainscg | [15,15] | 69,3 | 17 | 0,84314 | 0,72038 | 0,80596 | 0,81958 | 52,9 | 15 | 0,71079 | 0,79901 | 0,60656 | 0,69895 |
| 3 | tansig | Trainscg | [20,20] | 471 | 46 | 0,91598 | 0,86995 | 0,64632 | 0,85657 | 302 | 44 | 0,89264 | 0,9139 | 0,65425 | 0,88007 |
| 3 | tansig | Trainlm | [10,10] | 60,1 | 12 | 0,98031 | 0,89758 | 0,78737 | 0,93227 | 161 | 15 | 0,94907 | 0,85652 | 0,90829 | 0,93203 |
| 3 | tansig | Trainlm | [15,15] | 176 | 12 | 0,97438 | 0,74575 | 0,53018 | 0,87423 | 30,8 | 14 | 0,96699 | 0,77738 | 0,86128 | 0,93721 |
| 3 | tansig | Trainlm | [20,20] | 140 | 12 | 0,95859 | 0,88191 | 0,73994 | 0,92064 | 39,4 | 22 | 0,95222 | 0,91669 | 0,90359 | 0,93667 |
| 3 | tansig | Trainbr | [10,10] | 52,6 | 1000 | 0,99953 | | 0,63282 | 0,91834 | 66,9 | | 0,99172 | | 0,72102 | 0,96829 |

| | | | | | | | | | | | | | | | | |
|--|---|--------|---------|---------|-----|------|---|--|---------|--------|------|------|---------|--|--------|---------|
| | 3 | tansig | Trainbr | [15,15] | 670 | 1000 | 1 | | 0,57456 | 0,892 | 83,5 | 1000 | 0,993 | | 0,8102 | 0,96789 |
| | 3 | tansig | Trainbr | [20,20] | 87 | 1000 | 1 | | 0,75663 | 0,9502 | 110 | 1000 | 0,98787 | | 0,7698 | 0,94804 |

| Grafico de variação de neuronios e camadas utilizando a população total e só as 7 variaveis | | | | | | | |
|---|--------------------|-----------------|------------|---------|---------|------------------|-------------------------|
| População | Camadas escondidas | N. de Neuronios | R Training | R test | R total | Função activação | Função Treino |
| S+D | 1 | 2 | 0,69124 | 0,69351 | 0,69051 | tansig | Bayseian regularization |
| S+D | 1 | 4 | 0,86886 | 0,92979 | 0,8761 | tansig | Bayseian regularization |
| S+D | 1 | 6 | 0,92431 | 0,8284 | 0,91229 | tansig | Bayseian regularization |
| S+D | 1 | 8 | 0,93259 | 0,8497 | 0,91578 | tansig | Bayseian regularization |
| S+D | 1 | 10 | 0,94553 | 0,81827 | 0,92748 | tansig | Bayseian regularization |
| S+D | 1 | 12 | 0,95249 | 0,91931 | 0,94645 | tansig | Bayseian regularization |
| S+D | 1 | 14 | 0,96046 | 0,69492 | 0,9161 | tansig | Bayseian regularization |
| S+D | 1 | 16 | 0,96267 | 0,87225 | 0,95002 | tansig | Bayseian regularization |
| S+D | 1 | 18 | 0,96768 | 0,76542 | 0,9368 | tansig | Bayseian regularization |
| S+D | 1 | 20 | 0,96509 | 0,74377 | 0,9323 | tansig | Bayseian regularization |
| S+D | 1 | 22 | 0,96511 | 0,81678 | 0,94081 | tansig | Bayseian regularization |
| S+D | 1 | 24 | 0,9706 | 0,8242 | 0,94863 | tansig | Bayseian regularization |
| S+D | 1 | 26 | 0,95898 | 0,86036 | 0,94604 | tansig | Bayseian regularization |
| S+D | 1 | 28 | 0,9571 | 0,87823 | 0,93874 | tansig | Bayseian regularization |
| S+D | 1 | 30 | 0,95675 | 0,88587 | 0,94177 | tansig | Bayseian regularization |
| S+D | 1 | 32 | 0,96459 | 0,8713 | 0,94899 | tansig | Bayseian regularization |
| S+D | 1 | 34 | 0,95982 | 0,86303 | 0,94831 | tansig | Bayseian regularization |
| S+D | 1 | 36 | 0,96713 | 0,76596 | 0,93028 | tansig | Bayseian regularization |
| S+D | 2 | [2,2] | 0,8469 | 0,81253 | 0,84251 | tansig | Bayseian regularization |

| | | | | | | | |
|-----|---|------------|----------|---------|----------|--------|-------------------------|
| S+D | 2 | [4,4] | 0,939 | 0,79313 | 0,92487 | tansig | Bayseian regularization |
| S+D | 2 | [6,6] | 0,95083 | 0,85765 | 0,93595 | tansig | Bayseian regularization |
| S+D | 2 | [8,8] | 0,97376 | 0,72663 | 0,92652 | tansig | Bayseian regularization |
| S+D | 2 | [10,10] | 0,9831 | 0,71544 | 0,94683 | tansig | Bayseian regularization |
| S+D | 2 | [10,12] | 0,98507 | 0,91193 | 0,97443 | tansig | Bayseian regularization |
| S+D | 2 | [12,12] | 0,98644 | 0,86135 | 0,96157 | tansig | Bayseian regularization |
| S+D | 2 | [14,14] | 0,99154 | 0,64072 | 0,94957 | tansig | Bayseian regularization |
| S+D | 2 | [16,16] | 0,99443 | 0,70419 | 0,93807 | tansig | Bayseian regularization |
| S+D | 2 | [18,18] | 0,99551 | 0,68783 | 0,93648 | tansig | Bayseian regularization |
| S+D | 2 | [20,20] | 0,98945 | 0,89452 | 0,97127 | tansig | Bayseian regularization |
| S+D | 2 | [22,22] | 0,98999 | 0,74806 | 0,94305 | tansig | Bayseian regularization |
| S+D | 2 | [24,24] | 0,98832 | 0,80609 | 0,94788 | tansig | Bayseian regularization |
| S+D | 3 | [2,2,2] | 0,86578 | 0,82883 | 0,86015 | tansig | Bayseian regularization |
| S+D | 3 | [4,4,4] | 0,95179 | 0,91167 | 0,94449 | tansig | Bayseian regularization |
| S+D | 3 | [8,8,8] | 0,999404 | 0,84496 | 0,95578 | tansig | Bayseian regularization |
| S+D | 3 | [10,10,10] | 0,98688 | 0,9007 | 0,97341 | tansig | Bayseian regularization |
| S+D | 3 | [10,12,10] | 0,99667 | 0,51246 | 0,92015 | tansig | Bayseian regularization |
| S+D | 3 | [12,12,12] | 0,99408 | 0,68537 | 0,94396 | tansig | Bayseian regularization |
| S+D | 3 | [14,14,14] | 0,99422 | 0,83445 | 0,96056 | tansig | Bayseian regularization |
| S+D | 3 | [16,16,16] | 0,99126 | 0,8095 | 0,94775 | tansig | Bayseian regularization |
| S+D | 3 | [18,18,18] | 0,98877 | 0,49883 | 0,90642 | tansig | Bayseian regularization |
| S+D | 3 | [20,20,20] | 0,99164 | 0,7456 | 0,93637 | tansig | Bayseian regularization |
| S+D | 3 | [22,22,22] | 0,99597 | 0,72193 | 0,91001 | tansig | Bayseian regularization |
| S+D | 3 | [24,24,24] | 0,99596 | 0,54212 | 0,89177 | tansig | Bayseian regularization |
| S+D | 4 | [2,2,2,2] | 8,66E-01 | 0,89728 | 8,70E-01 | tansig | Bayseian regularization |

| | | | | | | | |
|-----|---|---------------|---------|----------|---------|--------|-------------------------|
| S+D | 4 | [4,4,4,4] | 0,96246 | 0,84838 | 0,94018 | tansig | Bayseian regularization |
| S+D | 4 | [8,8,8,8] | 0 | 0 | 0 | tansig | Bayseian regularization |
| S+D | 4 | [10,10,10,10] | 0,42114 | 0,39006 | 0,41631 | tansig | Bayseian regularization |
| S+D | 4 | [10,12,12,10] | 0,99614 | 0,46837 | 0,88557 | tansig | Bayseian regularization |
| S+D | 4 | [12,12,12,12] | 0 | 0 | 0 | tansig | Bayseian regularization |
| S+D | 4 | [14,14,14,14] | 0,99637 | 0,706622 | 0,94636 | tansig | Bayseian regularization |
| S+D | 4 | [16,16,16,16] | 0,99658 | 0,63775 | 0,9259 | tansig | Bayseian regularization |
| S+D | 4 | [18,18,18,18] | 0,99698 | 0,7318 | 0,93428 | tansig | Bayseian regularization |
| S+D | 4 | [20,20,20,20] | 0,98808 | 0,49375 | 0,9053 | tansig | Bayseian regularization |
| S+D | 4 | [22,22,22,22] | 0,99396 | 0,7274 | 0,94705 | tansig | Bayseian regularization |
| S+D | 4 | [24,24,24,24] | 0 | 0 | 0 | tansig | Bayseian regularization |

Dados Totais dos ANFIS obtidos

| Treino 50%, teste 25 e validação 25 % | | | | Completo model (18 inputs) | | | Clustering | Reduced model (7 inputs) | | | |
|---------------------------------------|---------|------------|-------------------|-------------------------------|----------|----------|------------|-------------------------------|----------|----------|---------|
| ANFIS | Rules | Clustering | Training function | Average Test error (Sugeno 1) | | | | Average Test error (Sugeno 1) | | | |
| | | | | Training | Testing | Checking | | Training | Testing | Checking | |
| Genfis3 | Sugeno | 4 | SOM/FCM | Bacpropagation | 0,28417 | 3,9607 | 5,0507 | SOM/FCM | 0,20199 | 0,29917 | 0,66904 |
| | Sugeno | 4 | SOM/FCM | Hybrid | 0,11097 | 3,9761 | 4,9771 | SOM/FCM | 0,20357 | 0,36013 | 0,66472 |
| | Sugeno | 11 | FCM | Bacpropagation | 0,45505 | 2,5369 | 3,1166 | SUBCLUST | 0,15534 | 1,6996 | 3,8576 |
| | Sugeno | 11 | FCM | Hybrid | 0,069946 | 2,3812 | 2,8249 | SUBCLUST | 0,13686 | 1,8854 | 3,7955 |
| | Sugeno | 20 | FCM | Bacpropagation | 1,0295 | 13,2355 | 5,295 | FCM | 0,15483 | 6,931 | 3,8719 |
| | Sugeno | 20 | FCM | Hybrid | 0,03814 | 13,2425 | 5,4127 | FCM | 0,080728 | 6,8357 | 3,875 |
| | Sugeno | 46 | SUBCLUST | Bacpropagation | 1,2782 | 5,3746 | 7,7482 | FCM | 0,13871 | 6,567 | 5,1963 |
| | Sugeno | 46 | SUBCLUST | Hybrid | 0,051489 | 5,4535 | 7,4992 | FCM | 0,048197 | 9,2896 | 5,4105 |
| | Mandami | 4 | FCM | Bacpropagation | 10,74 | 10,32 | 23,11 | FCM | 7,39 | 8,0749 | 20,77 |
| | Mandami | 11 | FCM | Bacpropagation | 9,22 | 23,13 | 7,78 | FCM | 6,24 | 19,01 | 9,52 |
| Mandami | 46 | FCM | Bacpropagation | 11,19 | 4,29 | 19,16 | FCM | 4,98 | 19,87 | 7,95 | |
| Genfis 2 | Sugeno | 11 | Subtractiv | Hybrid | 0,016385 | 13,00234 | 36,007 | Subtractiv | 0,12949 | 31,449 | 6,9264 |
| | Sugeno | 46 | Subtractiv | Bacpropagation | 0,018262 | 12,0955 | 34,5301 | Subtractiv | 0,1417 | 31,3895 | 6,9445 |

Treino 77% teste 23%

| | | | | | Reduced model (7 inputs) | | | | | |
|--------|-------|-------|----------------|-------------------|--------------------------------|---------|-----------|--------------------------------|----------------|-----------|
| | ANFIS | Rules | Clustering | Training function | Average Test error (S order 1) | | | Average Test error (S order 0) | | |
| | | | | | Training | Testing | Diferença | Training | Testing | Diferença |
| | | | | | Genfis3 | Sugeno | 4 | SOM | Bacpropagation | 0,21132 |
| Sugeno | 4 | SOM | Hybrid | 0,19632 | | 0,35113 | 0,13481 | 0,36724 | 0,25409 | -0,11315 |
| Sugeno | 11 | SUB | Bacpropagation | 0,16627 | | 1,7171 | 1,55083 | 0,27291 | 0,32152 | 0,04861 |
| Sugeno | 11 | SUB | Hybrid | 0,14252 | | 1,7996 | 1,55208 | 0,14315 | 0,32782 | 0,18467 |
| Sugeno | 46 | FCM | Bacpropagation | 0,29321 | | 4,0526 | 3,75939 | 0,28434 | 5,0148 | 4,73046 |
| Sugeno | 46 | FCM | Hybrid | 0,03996 | | 4,643 | 3,96304 | 0,042002 | 5,0159 | 4,973898 |
| Sugeno | 20 | FCM | Bacpropagation | 0,18153 | | 2,3863 | 2,20477 | 0,27129 | 0,46892 | 0,19763 |
| Sugeno | 20 | FCM | Hybrid | 0,12847 | | 2,9961 | 2,26763 | 0,11794 | 0,47129 | 0,35335 |

treino 67,4% teste 32,6%

| | | | | | Reduced model (7 inputs) | | | | | |
|--------|-------|-------|----------------|-------------------|--------------------------------|---------|-----------|--------------------------------|----------------|-----------|
| | ANFIS | Rules | Clustering | Training function | Average Test error (S order 1) | | | Average Test error (S order 0) | | |
| | | | | | Training | Testing | Diferença | Training | Testing | Diferença |
| | | | | | Genfis3 | Sugeno | 4 | SOM | Bacpropagation | 0,21314 |
| Sugeno | 4 | SOM | Hybrid | 0,18345 | | 0,35144 | 0,16799 | 0,36118 | 0,31126 | -0,04992 |
| Sugeno | 11 | SUB | Bacpropagation | 0,15827 | | 1,7882 | 1,62993 | 0,28094 | 0,3422 | 0,06126 |
| Sugeno | 11 | SUB | Hybrid | 0,134209 | | 1,7758 | 1,641591 | 0,29525 | 0,33506 | 0,03981 |
| Sugeno | 46 | FCM | Bacpropagation | 0,28185 | | 4,4465 | 4,16465 | 0,32423 | 6,555 | 6,23077 |
| Sugeno | 46 | FCM | Hybrid | 0,03564 | | 4,509 | 4,47336 | 0,19557 | 3,8564 | 3,66083 |
| Sugeno | 20 | FCM | Bacpropagation | 0,13853 | | 3,5877 | 3,44917 | 0,25948 | 0,81894 | 0,55946 |
| Sugeno | 20 | FCM | Hybrid | 0,097649 | | 2,8855 | 2,787851 | 0,27069 | 0,86416 | 0,59347 |