



**UNIFACS**  
UNIVERSIDADE SALVADOR  
LAUREATE INTERNATIONAL UNIVERSITIES®

**MESTRADO EM SISTEMAS E COMPUTAÇÃO**

**ROGÉRIO MATOS DA SILVA**

**REDES NEURAIIS APLICADAS NA PARAMETRIZAÇÃO DA VENTILAÇÃO  
MECÂNICA DE PACIENTES COM INSUFICIÊNCIA RESPIRATÓRIA AGUDA**

Salvador  
2019

**ROGÉRIO MATOS DA SILVA**

**REDES NEURAIS APLICADAS NA PARAMETRIZAÇÃO DA VENTILAÇÃO  
MECÂNICA DE PACIENTES COM INSUFICIÊNCIA RESPIRATÓRIA AGUDA**

Dissertação apresentada ao Programa de Pós-Graduação,  
Mestrado Acadêmico em Sistemas e Computação da  
UNIFACS Universidade Salvador, Laureate International  
Universities, como requisito parcial à obtenção do título de  
Mestre.

Orientador: Prof. Dr. Éldman de Oliveira Nunes.

Salvador  
2019

Ficha Catalográfica elaborada pelo Sistema de Bibliotecas da UNIFACS Universidade Salvador, Laureate International Universities.

Silva, Rogério Matos da

Redes neurais aplicadas na parametrização da ventilação mecânica de pacientes com insuficiência respiratória aguda. / Rogério Matos da Silva.- Salvador, 2019.

103 f. : il.

Dissertação apresentada ao Programa de Pós-Graduação, Mestrado Acadêmico em Sistemas e Computação da UNIFACS Universidade Salvador, Laureate International Universities, como requisito parcial à obtenção do título de Mestre.

Orientador: Prof. Dr. Éldman de Oliveira Nunes.

1. Inteligência Artificial. 2. Redes neurais. I. Nunes, Éldman de Oliveira Nunes, orient. I. Título.

CDD: 005

“Nem tampouco é servido por mãos de homens, como que necessitando de alguma coisa; pois Ele mesmo é quem dá a todos a vida, e **a respiração**, e todas as coisas.” (Atos 17:25)

## **AGRADECIMENTOS**

Toda honra e louvor a Deus por ter me contemplado com este Mestrado e me dado forças durante toda esta trajetória.

Agradeço ao Prof. Dr. Éldman de Oliveira Nunes pelo compromisso em me orientar, e dividir seus conhecimentos, paciência e tempo comigo, nesta jornada.

Agradeço a Prof. Dra. Viviane Rech pela sua dedicação, determinação e desprendimento para me coorientar durante o tempo da pesquisa.

A minha ilustre esposa Ana Camilo pelo apoio, compreensão, carinho e estímulos que me fizeram caminhar até o fim.

Agradeço a coordenação do curso de computação da UNIFACS pelo apoio em todos os momentos.

Ao corpo de professores da UNIFACS meu muito obrigado pelos ensinamentos e lições aprendidos.

Aos meus familiares pelo incentivo em todo o tempo.

A todos aqueles cujo nome porventura eu tenha esquecido de mencionar e que me apoiaram também.

Agradeço a FAPESB pelo apoio financeiro tornando possível a realização de mais um sonho.

## RESUMO

A ventilação mecânica substitui total ou parcialmente a ventilação espontânea e está indicada na insuficiência respiratória aguda ou crônica agudizada. A ventilação mecânica propicia melhora das trocas gasosas e diminuição do trabalho respiratório, podendo ser utilizada de forma não-invasiva através de uma interface externa, geralmente uma máscara facial, e de forma invasiva através de um tubo endotraqueal ou cânula de traqueostomia. Em vista disto, para a melhora do paciente, regulagens manuais frequentes devem ser feitas no Ventilador Mecânico, de acordo com determinadas reações ou sinais observados e colhidos do paciente pelo profissional especializado em terapia intensiva, implicando num trabalho constante e exaustivo. Esta dissertação tem por objetivo apresentar uma solução capaz de automatizar a configuração dos parâmetros do Ventilador Mecânico, a nível de software, por meio da aplicação de Redes Neurais Artificiais (RNA), e assim buscar aprimorar o atendimento ao paciente, visando a otimização de recursos humanos de saúde. Nos testes realizados, a metodologia empregada foi eficiente na configuração automática dos parâmetros do ventilador, obtendo um resultado de acerto de 100% na avaliação quantitativa e de 79% na avaliação qualitativa, realizada por um grupo de especialistas em fisioterapia. O estudo demonstrou a viabilidade do emprego do método no auxílio ao tratamento de pacientes, bem como na otimização dos recursos humanos de saúde.

**Palavras-chave:** Inteligência Artificial. Reconhecimento de Padrões. Redes Neurais Artificiais. Ventilação Mecânica. Ventilador Mecânico. Parâmetros Ventilatórios.

## ABSTRACT

Mechanical ventilation substitutes totally or partially spontaneous ventilation and is indicated in the acute breathing insufficiency or acute chronic insufficiency. The mechanical ventilation provides betterment in the gas exchanges and diminishment of breathing work and can be used in a noninvasive form through an external interface, normally a mask, and in an invasive form through an endotracheal tube or a tracheostomy cannula. Given these facts, for the betterment of the patient, frequent manual adjustments must be done to the mechanical ventilator, according to determined reactions or signals observed and obtained from patients by the specialist in intensive care, implying in a constant and exhausting work. This dissertation has the objective of presenting a solution capable of automating the setting of parameters of the mechanical ventilator, regarding software, by the application of Artificial Neural Networks (ANN), and consequently improve the treatment of the patient, with the intention of enhancing human resources of health. On the tests, the methodology employed was efficient on the automatic setting of parameters of the ventilator, obtaining a success rate of 100% in the quantitative evaluation and of 79% in the qualitative evaluation, carried out by a group of physical therapy specialists. The study showed the viability of the employment of the method in helping the treatment of the patients, as well as in the optimization of human resources of health.

**Keywords:** Artificial Intelligence, Pattern Recognition, Artificial Neural Networks, Mechanical Ventilation, Mechanical Ventilator, Ventilators Parameters.

## LISTA DE FIGURAS

Figura 2. 1 - Representação do sistema respiratório em ventilação mecânica .....	20
Figura 2. 2 - Ventilador <i>Servo-s System V6.1</i> .....	21
Figura 2. 3 - Ventilador DIXTAL DX 3012.....	21
Figura 2. 4 - Diagrama de componentes de um ventilador mecânico .....	22
Figura 2. 5 - Capnografia normal .....	28
Figura 2. 6 - Interface de um ventilador mecânico.....	30
Figura 2. 7 - Curvas do volume, fluxo e pressão da (VCV) .....	31
Figura 4. 1 - Estrutura de um neurônio biológico.....	39
Figura 4. 2 - Tipos de redes .....	40
Figura 4. 3 - Modelo de um neurônio artificial .....	41
Figura 4. 4 - Função limiar .....	43
Figura 4. 5 - Função linear .....	43
Figura 4. 6 - Função sigmóide.....	44
Figura 4. 7 - Sinais do algoritmo <i>backpropagation</i> .....	46
Figura 4. 8 - Separador de classes desejado .....	49
Figura 4. 9 - Principais técnicas de reconhecimento de padrões .....	50
Figura 4. 10 - Separação das classes por meio da função lógica “ou” .....	51
Figura 4. 11 - Diagrama de aprendizagem com um professor.....	52
Figura 4. 12 - Procedimento de validação cruzada tripla .....	53
Figura 5. 1 - Topologia da rede neural .....	58
Figura 5. 2 - Projeto do ventilador automatizado .....	61
Figura 5. 3 - Interface da simulação .....	64
Figura 5. 4 - Botão tela de treinamento .....	66
Figura 5. 5 - Código que chama a 2ª interface (tela de treinamento) .....	66
Figura 5. 6 - Tela de treinamento (2ª interface).....	67
Figura 5. 7 - Código de treinamento da rede .....	68
Figura 5. 8 - <i>Neural Network Training</i> .....	68
Figura 5. 9 - Botão para empregar a RNA.....	69
Figura 5. 10 - Função que emprega a RNA .....	69
Figura 5. 11 - Exemplo da Simulação .....	70
Figura 6. 1 - Desempenho da rede .....	74
Figura 6. 2 - Regressão (2ª Simulação) .....	75
Figura 6. 3 - Regressão (3ª Simulação) .....	76
Figura 6. 4 - Regressão (4ª Simulação) .....	76



Figura 6. 5 - Histograma de erro (4ª Simulação).....	78
Figura 6. 6 - Matriz de confusão .....	79
Figura 6. 7 - Nível de conhecimento dos entrevistados.....	80
Figura 6. 8 - Caso 1 – Avaliação dos entrevistados às questões A, B, C e D .....	83
Figura 6. 9 - Caso 2 – Avaliação dos entrevistados às questões A, B, C e D .....	84
Figura 6. 10 - Caso 3 – Avaliação dos entrevistados às questões A, B, C e D .....	86
Figura 6. 11 - Caso 4 – Avaliação dos entrevistados às questões A, B, C e D .....	87
Figura 6. 12 - Caso 5 – Avaliação dos entrevistados às questões A, B, C e D .....	88
Figura 6. 13 - Avaliação geral da simulação .....	89

## LISTA DE TABELAS

Tabela 3. 1 - Resultados da Pesquisa.....	33
Tabela 5. 1 - Valores do EQM com 10 neurônios .....	63
Tabela 5. 2 - Valores do EQM com 30 neurônios .....	64
Tabela 6. 1 - Valores de R .....	77
Tabela B. 1 - Subconjunto de teste e generalização .....	102
Tabela C. 1 - Saídas simuladas do ventilador mecânico .....	103

## LISTA DE QUADROS

Quadro 2. 1 - Componentes básicos de um ventilador mecânico.....	23
Quadro 2. 2- Níveis de oxigênio ofertados no início da VM .....	25
Quadro 2. 3 - Cálculo do peso predito.....	26
Quadro 2. 4 - Valores de disparo a fluxo e pressão.....	27
Quadro 2. 5 - Equações para o cálculo das pressões respiratórias máximas .....	28
Quadro 3. 1 - Publicações selecionadas (Continua) .....	34
Quadro 5. 1 - Valores quantitativos: dados fixos .....	59
Quadro 5. 2 - Valores quantitativos: dados variáveis.....	59
Quadro 5. 3 - Valores quantitativos: dados de saída .....	60
Quadro 6. 1 - Questionário da simulação .....	81
Quadro 6. 2 - Faixas e legendas da escala .....	81
Quadro 6. 3 - Dados do paciente Pac01 .....	82
Quadro 6. 4 - Questionário do Caso 1 .....	82
Quadro 6. 5 - Dados do paciente Pac03 .....	84
Quadro 6. 6 - Questionário do Caso 2 .....	84
Quadro 6. 7 - Dados do paciente Pac06 .....	85
Quadro 6. 8 - Questionário do Caso 3 .....	85
Quadro 6. 9 - Dados do paciente Pac08 .....	86
Quadro 6. 10 - Questionário do Caso 4 .....	87
Quadro 6. 11 - Dados do paciente Pac10 .....	88
Quadro 6. 12 - Questionário do Caso 5 .....	88
Quadro A. 1 - Base para treinamento (Continua).....	99

## LISTA DE ABREVIATURAS

DPOC	Doença Pulmonar Obstrutiva Crônica
E	Elastância do Sistema
EQM	Erro Quadrado Médio
FR	Frequência Respiratória
GUI	Interface Gráfica do Usuário
IRA	Insuficiência Respiratória Aguda
MLP	<i>Multi Layer Perceptron</i>
PAVM	Pneumonia Associada à Ventilação Mecânica
PEEP	Pressão Positiva no Final da Expiração
R	Resistência
RNA	Redes Neurais Artificiais
RPM	Respirações por Minuto
SDRA	Síndrome do Desconforto Respiratório Agudo
UTI	Unidade de Terapia Intensiva
VC	Volume Corrente
VCV	Ventilação Controlada a Volume
VM	Ventilação Mecânica
VMI	Ventilação Mecânica Invasiva
VMNI	Ventilação Mecânica Não Invasiva
Vmin	Volume por Minuto

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>15</b>
<b>2</b>	<b>INSUFICIÊNCIA RESPIRATÓRIA E VENTILAÇÃO MECÂNICA</b>	<b>18</b>
2.1	INSUFICIÊNCIA RESPIRATÓRIA AGUDA	18
2.2	VENTILAÇÃO MECÂNICA	19
2.3	VENTILADOR MECÂNICO	20
<b>2.3.1</b>	<b>Parâmetros Ventilatórios</b>	<b>24</b>
<b>2.3.2</b>	<b>Modos Ventilatórios</b>	<b>29</b>
<b>2.3.3</b>	<b>Ventilação Controlada a Volume (VCV)</b>	<b>31</b>
2.4	CONSIDERAÇÕES FINAIS DO CAPÍTULO	32
<b>3</b>	<b>REVISÃO DA LITERATURA</b>	<b>33</b>
3.1	METODOLOGIA	33
3.2	TRABALHOS RELACIONADOS	35
3.3	CONSIDERAÇÕES FINAIS DO CAPÍTULO	37
<b>4</b>	<b>REDES NEURAIS ARTIFICIAIS (RNA)</b>	<b>38</b>
4.1	REDES NEURAIS BIOLÓGICAS	38
4.2	REDES NEURAIS ARTIFICIAIS (RNA)	39
<b>4.2.1</b>	<b>Número de Camadas de uma RNA</b>	<b>40</b>
<b>4.2.2</b>	<b>Funcionamento de um Neurônio Artificial</b>	<b>41</b>
<b>4.2.3</b>	<b>Funções de Ativação de uma RNA</b>	<b>42</b>
<b>4.2.4</b>	<b>Treinamento, Validação e Verificação de uma RNA</b>	<b>45</b>
<b>4.2.5</b>	<b>Algoritmo Backpropagation</b>	<b>46</b>
4.3	COMO AS RNA RECONHECEM PADRÕES	47
4.4	MÉTODOS DE VALIDAÇÃO CRUZADA	52
<b>4.4.1</b>	<b>Procedimentos de Validação Cruzada</b>	<b>54</b>
<b>4.4.2</b>	<b>Particionamento do Conjunto de Dados</b>	<b>55</b>
<b>4.4.3</b>	<b>Critérios de Parada</b>	<b>56</b>
4.5	CONSIDERAÇÕES FINAIS DO CAPÍTULO	56
<b>5</b>	<b>PROJETO DE SIMULAÇÃO</b>	<b>57</b>
5.1	NÚMERO DE CAMADAS, ENTRADAS E SAÍDAS DA REDE NEURAL	57
5.2	DOMÍNIO DOS DADOS DE ENTRADA E SAÍDA NA RNA	59
5.3	ESPECIFICAÇÕES DA RNA	60
5.4	ARQUITETURA DO PROJETO	61
5.5	FERRAMENTA PARA DESENVOLVIMENTO DO PROGRAMA	62

5.6 NÚMERO DE NEURÔNIOS DA CAMADA OCULTA DA RNA .....	63
5.7 INTERFACE DO PROGRAMA, ENTRADA E SAÍDA DE DADOS .....	64
5.8 FUNCIONAMENTO .....	66
<b>5.8.1 Treinamento da RNA .....</b>	<b>66</b>
<b>5.8.2 Emprego da RNA na 1ª interface .....</b>	<b>69</b>
5.9 CONSIDERAÇÕES FINAIS DO CAPÍTULO .....	71
<b>6 RESULTADOS E DISCUSSÃO .....</b>	<b>72</b>
6.1 AQUISIÇÃO DOS DADOS E TREINAMENTO DA RNA .....	72
6.2 DESEMPENHO DA RNA (ABORDAGEM QUANTITATIVA) .....	73
<b>6.2.1 Gráfico de Performance .....</b>	<b>74</b>
<b>6.2.2 Gráficos de Regressão .....</b>	<b>75</b>
<b>6.2.3 Gráfico de Erro .....</b>	<b>77</b>
<b>6.2.4 Matriz de Confusão .....</b>	<b>78</b>
6.3 DESEMPENHO DA RNA (ABORDAGEM QUALITATIVA) .....	80
<b>6.3.1 Análise de Especialistas e Estudantes .....</b>	<b>80</b>
<b>6.3.2 Questionário Para os Entrevistados .....</b>	<b>81</b>
<b>6.3.3 Respostas aos Resultados Obtidos .....</b>	<b>82</b>
<b>6.3.3.1 Caso 1 .....</b>	<b>82</b>
<b>6.3.3.2 Caso 2 .....</b>	<b>84</b>
<b>6.3.3.3 Caso 3 .....</b>	<b>85</b>
<b>6.3.3.4 Caso 4 .....</b>	<b>86</b>
<b>6.3.3.5 Caso 5 .....</b>	<b>88</b>
6.4 AVALIAÇÃO GERAL DOS RESULTADOS .....	89
6.5 CONSIDERAÇÕES FINAIS DO CAPÍTULO .....	90
<b>7 CONCLUSÃO E TRABALHOS FUTUROS .....</b>	<b>91</b>
<b>8 PUBLICAÇÕES VINCULADAS À PESQUISA .....</b>	<b>93</b>
<b>REFERÊNCIAS .....</b>	<b>94</b>
<b>APÊNDICE A – SUBCONJUNTO DE TREINAMENTO/TESTE E VALIDAÇÃO .....</b>	<b>99</b>
<b>APÊNDICE B – SUBCONJUNTO DE TESTE E GENERALIZAÇÃO .....</b>	<b>102</b>
<b>APÊNDICE C – SIMULAÇÕES .....</b>	<b>103</b>

## 1 INTRODUÇÃO

A ventilação mecânica (VM), é largamente utilizada em Unidades de Terapia Intensiva (UTI), e durante cirurgias em pacientes que estão totalmente sedados e não podem manter a respiração espontaneamente. Em hospitais que prestam assistência a pacientes graves, em tratamento eletivo ou de urgência, os ventiladores mecânicos são parte integrante do suporte à vida, como uma prática constante (SARMENTO, 2011). Um desempenho adequado na VM, favorece uma recuperação mais eficaz do paciente em uma UTI, papel este desempenhado pelo especialista em terapia intensiva ao abordar as orientações práticas na ventilação mecânica invasiva (VMI) e ventilação mecânica não invasiva (VMNI), a sistematização da assistência de enfermagem nos diferentes momentos da ventilação mecânica, desde a instalação, manuseio, prevenção e controle de complicações, ações para o controle de infecção e cuidados com o equipamento (AMORIM; GOMES, 2015).

Segundo Sarmiento (2011), a arte de ventilar é muito mais abrangente que a manipulação dos equipamentos. Para a monitoração de um paciente que necessita de ventilação artificial, é necessário um alto nível de experiência clínica por parte dos médicos, fisioterapeutas, enfermeiros, engenheiros, entre outros que atuam com ventilação mecânica. Os objetivos da monitoração incluem: diagnóstico preciso das condições fisiopatológicas, relacionadas à mecânica respiratória, ajuste adequado dos parâmetros do ventilador respeitando limites fisiológicos e alvos terapêuticos, de forma individualizada, avaliação sequencial da resposta a diversos tratamentos instituídos, facilitando o trabalho e incrementam a segurança do paciente (BARBAS *et al.* 2014; COSTA *et al.*, 2010), afirmam que “a monitorização deve ser realizada rotineiramente em todo paciente submetido a suporte ventilatório invasivo e não invasivo”.

Apesar dos avanços na área da ventilação mecânica, tais equipamentos ainda necessitam que seus parâmetros respiratórios sejam medidos e reajustados continuamente, sendo assim um desafio constante, pois requer vigilância, habilidade, respeito e sensibilidade (SOUZA, 2011). Com isto, muitas pesquisas tem surgido no âmbito da ventilação mecânica, visando o desenvolvimento de novas técnicas, com vistas a facilitar a arte de ventilar, procurando otimizar esforços, reduzir tarefas repetitivas e erros frequentes, que podem comprometer a vida do paciente, no momento de ajustar os parâmetros do ventilador mecânico (SCHENEKENBERG *et al.*, 2011). Dentre algumas destas pesquisas, soluções computacionais

utilizando-se de técnicas de Inteligência Artificial (IA), buscaram sugerir aos especialistas, responsáveis pela ventilação mecânica, ajustes nos parâmetros do ventilador mecânico, com a finalidade de auxiliar da melhor forma a demanda ventilatória do paciente (KARBING *et al.*, 2011). Em alguns destes estudos, porém, foram constatados que certos modelos ilustraram uma aparente falta de consenso em relação às configurações do ventilador entre especialistas clínicos (ALLEROD, 2012).

Esta dissertação propõe uma solução computacional, utilizando-se de Redes Neurais Artificiais (RNA), que dinamizará o atendimento ao paciente, otimizando os recursos humanos de saúde e, como um diferencial aos modelos anteriores, um software simulará, em tempo real, os ajustes necessários do ventilador mecânico por meio da análise dos dados recebidos do paciente. Segundo Peralez (2011), redes neurais artificiais tem sido empregadas no desenvolvimento de sistemas de Inteligência Artificial para solução de problemas complexos, em particular, no auxílio à tomada de decisões médicas.

A solução proposta nesta dissertação permitirá, com emprego da Inteligência Computacional aplicada a área de saúde, a utilização de equipamentos de ventilação mecânica com mais autonomia e com respostas adequadas. Tudo com o propósito de reduzir falhas humanas e auxiliar num melhor tratamento de pacientes, além de otimizar tempo e mão de obra qualificada.

Portanto, esta é uma pesquisa de natureza aplicada, com objetivos de caráter descritivos, que emprega uma abordagem quali-quantitativa, com procedimentos fundamentados em pesquisa de desenvolvimento e condução em laboratório (PASCHOARELLI; MEDOLA; BONFIM, 2018). Trata-se de uma pesquisa aplicada porque visa o desenvolvimento de uma solução computacional para o problema da parametrização dos ajustes do ventilador mecânico. É uma pesquisa descritiva, pois tem, por objetivo, indicar a existência de associação entre as variáveis do paciente e do ventilador mecânico. A pesquisa tem abordagem quali-quantitativa, tendo em vista que a validação do modelo possui tanto caráter subjetivo quanto objetivo, aliando a concordância de juízes-especialistas da área médica com a análise estatística dos resultados obtidos pela RNA. Quanto aos procedimentos técnicos, é uma pesquisa de desenvolvimento, com propósito de modelar uma Rede Neural, capaz de realizar automaticamente os ajustes necessários no ventilador mecânico. Quanto à localização,



esta é uma pesquisa de laboratório, pois a construção, emprego e validação da RNA foi conduzida em um ambiente controlado.

Esta dissertação está organizada da seguinte forma: O capítulo 2, trata dos conceitos acerca da insuficiência respiratória e ventilação mecânica. O capítulo 3 aborda os trabalhos relacionados, no tocante a área de ventilação mecânica dentro do contexto da Inteligência Artificial. O capítulo 4 apresenta um estudo amplo das redes neurais artificiais (RNA), explicando suas utilidades e funcionamento. O capítulo 5, detalha o projeto de simulação no qual os ajustes do ventilador mecânico serão realizados. O capítulo 6 descreve a análise dos resultados e as discussões decorrentes. O capítulo 7 apresenta as considerações finais e trabalhos futuros.

## **2 INSUFICIÊNCIA RESPIRATÓRIA E VENTILAÇÃO MECÂNICA**

O objetivo deste capítulo é abordar as teorias e fundamentos acerca da insuficiência respiratória aguda e ventilação mecânica, onde será abordada a insuficiência respiratória aguda e as implicações desta na vida dos pacientes; os conceitos sobre a ventilação mecânica e o ventilador mecânico, analisando seus componentes, parâmetros e modos ventilatórios.

### **2.1 INSUFICIÊNCIA RESPIRATÓRIA AGUDA**

O conjunto harmônico formado pelas vias tubulares e alveolares situadas na cabeça, pescoço e pulmão, formam o sistema respiratório. O sistema respiratório tem como função principal a difusão, que se caracteriza pelas trocas gasosas entre o ar dos alvéolos e o sangue capilar dos pulmões, proporcionando assim o oxigênio necessário para o metabolismo dos tecidos (VERON *et al.*, 2016).

Veron *et al.* (2016) afirmam ainda que, falhas em um ou mais destes componentes do sistema respiratório, podem resultar no quadro de insuficiência respiratória aguda (IRA), que frequentemente tem múltiplas origens como, por exemplo, um paciente vítima de traumatismo crânio-encefálico, contusão pulmonar e choque hemorrágico apresenta múltiplos componentes para desenvolvimento de IRA.

Dentre as muitas manifestações de IRA, este trabalho em particular, dará enfoque à pneumonia, visto ser esta a patologia mais predominante no meio clínico, ou seja, o número de casos de internamentos por pneumonia em UTI's, tem sido algo alarmante e preocupante, devido ao crescente aumento no número de óbitos por indivíduos acometidos pela mesma (VIANA; MACHADO; SOUZA, 2017).

A pneumonia é um distúrbio infeccioso/inflamatório do parênquima pulmonar. A maioria dos pacientes apresenta febre, calafrios, sintomas pulmonares (tosse, dispneia, produção de catarro, dor torácica pleurítica) e um ou mais infiltrados/opacidades no raio X de tórax (CUNHA, 2012).

Segundo Cunha (2012), os alvéolos e/ou interstício pulmonar são preenchidos com leucócitos, hemácias e fibrina; o peso pulmonar aumenta; e o germe responsável pode ser recuperado em culturas ou colorações.

A Pneumonia adquirida no hospital (PAH), geralmente é classificada como pneumonia associada à ventilação mecânica (PAVM) ou pneumonia não associada a ventilação mecânica (CUNHA, 2012).

Estudos demonstram que a pneumonia associada a ventilação mecânica (PAVM), é a infecção mais comum que atinge os pacientes em estado crítico que são submetidos à ventilação mecânica nas UTI's (RODRIGUES *et al.*, 2016). Ainda segundo Rodrigues *et al.* (2016), a PAVM se manifesta após um período prolongado na ventilação mecânica, mais precisamente depois de 48 horas a partir da intubação (inserção na ventilação), que não estava incubada no período da admissão do paciente, e 72 horas após a extubação (retirada da ventilação).

## **2.2 VENTILAÇÃO MECÂNICA**

De extrema importância em hospitais e em UTI's (Unidades de Terapia Intensiva), aparelhos de ventilação mecânica são utilizados como suporte a pacientes que se encontram com alguma deficiência respiratória (HESS, 2013).

A ventilação mecânica (VM), substitui total ou parcialmente a ventilação espontânea, ou seja, a respiração normal, que está associada ao bom funcionamento do sistema respiratório, e está indicada nos casos de insuficiência respiratória aguda ou crônica agudizada.

Segundo Sarmiento (2011, p. 16):

a ventilação mecânica (VM) consiste em um método que oferece ao paciente suporte ventilatório adequado em condições de insuficiência respiratória aguda ou crônica agudizada. Foi introduzida de forma significativa no início dos anos 1950, durante a epidemia de poliomielite, como forma de tratamento para os acidentados graves.

São inúmeras as utilidades da ventilação mecânica, das quais pode-se destacar: a melhora e a manutenção das trocas gasosas por meio da constante avaliação e monitorização da ventilação alveolar e da oxigenação arterial; aumento do volume pulmonar; alívio ou redução

do trabalho da musculatura respiratória; diminuição do consumo de oxigênio do miocárdio; conforto do paciente; reversão ou impedimento da fadiga da musculatura; manutenção das vias aéreas p rvias e protegidas; garantia da estabilidade do sistema respirat rio; redu o do gasto energ tico em situa es de instabilidade hemodin mica; revers o da hipoxemia e da acidose respirat ria aguda; preven o ou revers o de atelectasias, mantendo assim o pulm o expandido, a caixa tor cica estabilizada, al m de permitir seda o/anestesia (SARMENTO, 2011).

### 2.3 VENTILADOR MEC NICO

O sistema respirat rio pode ser analisado como um sistema linear, conforme a Figura 2.1, em que um pist o em (1), comparado a um ventilador mec nico,   conectado a um tubo r gido (2), an logo   pr tese invasiva administrada nas vias a reas, sendo este o elemento resistivo do sistema, unido no final a um bal o (3), que corresponde ao sistema el stico (par nquima pulmonar e caixa tor cica) (SARMENTO, 2011).

Figura 2. 1 - Representa o do sistema respirat rio em ventila o mec nica



Fonte: Sarmento (2011).

A press o aplicada pr ximo ao pist o (1) tem como resultante duas press es, a saber: uma resistiva ( $P_{res}$ ) e a el stica ( $P_{el}$ ), em que a  $P_{el}$  corresponde a press o aplicada na extremidade do tubo, jun o com o bal o, e a  $P_{res}$  corresponde a press o aplicada entre o pist o e a jun o do tubo com o bal o (SARMENTO, 2011). Assim tem-se definido a equa o (2.1), do movimento para o sistema respirat rio:

$$P_{insp} (P_{res} + P_{el}) = (R \times \Delta V) + (E \times \Delta VC) \quad (2.1)$$

Onde:

$P_{insp}$  = press o inspirat ria;

$R$  = resist ncia;

$\Delta V$  = variação de fluxo;

E = elastância do sistema;

$\Delta VC$  = variação do volume.

Segundo Sarmiento (2011), ventiladores modernos utilizam softwares cada vez mais avançados e diferentes apresentações de gráficos/tabelas, para otimizar a monitorização, possibilitando assim melhor adaptação e sincronia entre o paciente e o ventilador. As Figuras 2.2 e 2.3, ilustram exemplos de diferentes ventiladores mecânicos modernos.

Figura 2. 2 - Ventilador *Servo-s System V6.1*



Fonte: Maquet (2012).

O *SERVO-s Ventilator System V6.1*, foi concebido para o tratamento e monitorização de pacientes, desde pacientes pediátricos a adultos, com falha respiratória ou insuficiência respiratória (MAQUET, 2012).

Figura 2. 3 - Ventilador *DIXTAL DX 3012*

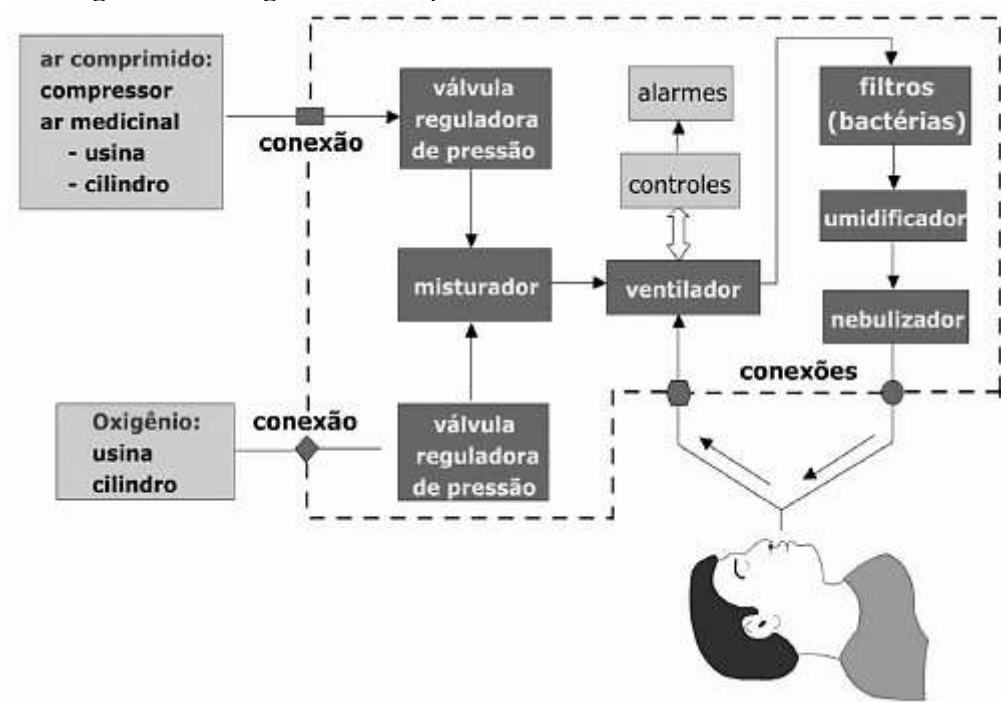


Fonte: Morato, Sandri e Guimarães (2015).

Os ventiladores mecânicos são usados também para descanso dos músculos respiratórios, até o momento em que o paciente possa respirar por conta própria (ANVISA, 2011). Conforme a Figura 2.4, os componentes básicos de um ventilador mecânico são:

- Válvulas reguladoras de pressão;
- Misturador;
- Controles;
- Filtro de bactérias;
- Nebulizador;
- Umidificador;
- Válvula de exalação ou expiratória;
- Alarmes.

Figura 2. 4 - Diagrama de componentes de um ventilador mecânico



Fonte: ANVISA (2011).

O Quadro 2.1, detalha os componentes básicos de um ventilador mecânico e suas funcionalidades.

Quadro 2. 1- Componentes básicos de um ventilador mecânico

<b>Componentes</b>	<b>Funcionalidades</b>
Válvulas reguladoras de pressão.	São os elementos que fazem a regulação da pressão na entrada do ventilador, bem como dos gases entregues ao paciente.
Misturador	Tem a função de misturar adequadamente os diferentes gases nas proporções, ou concentrações exatas.
Controles	São os circuitos responsáveis pelos modos ventilatórios responsáveis pela ventilação ao paciente. Os modos ventilatórios terão um capítulo exclusivo neste estudo.
Filtro de bactérias.	Este filtro tem como função purificar o ar, elevando a sua qualidade, até ser entregue ao paciente, evitando a contaminação por bactérias que prejudicariam o paciente.
Nebulizador	Utilizado para administrar determinadas drogas por meio da via respiratória, na forma de aerossol. Como broncodilatadores.
Umidificador	É responsável por adicionar vapor d'água ao gás inspirado pelo paciente. Este componente serve para evitar a desidratação dos tecidos pulmonares. A água utilizada tem que ser desmineralizada, e deve ser trocada periodicamente, com vistas a evitar possível contaminação.
Válvula de exalação ou expiratória.	Essa válvula tem a função de fechar o circuito de saída, quando na inspiração, e abrir o circuito na expiração. A mesma válvula pode ser do tipo liga e desliga, ou da forma incremental.
Alarmes	Os alarmes servem para monitorar falhas que ocorrem na execução do equipamento. Os modelos atuais de ventiladores mecânicos são controlados por microprocessadores. Tais alarmes não podem ser desativados permanentemente.

Fonte: ANVISA (2011).

A monitorização em todo paciente, submetido a suporte ventilatório invasivo e não-invasivo, deve ser realizada rotineiramente. Um bom desempenho na ventilação mecânica proporciona uma recuperação eficaz do paciente, em uma UTI, embora tais equipamentos necessitem que seus parâmetros respiratórios sejam medidos e reajustados continuamente.

Equipamentos de ventilação mecânica só podem ser manuseados por pessoas que tenham o conhecimento técnico e experiência com tratamento por ventilação (MAQUET, 2012).

### 2.3.1 Parâmetros Ventilatórios

Num ventilador mecânico, uma interface é utilizada para controlar as definições do ventilador manualmente. As definições podem ser ajustadas utilizando as teclas de membrana da tela, ou através dos botões. Os parâmetros respiratórios são medidos e controlados continuamente. A diferença entre o valor real de um parâmetro medido, e o valor predefinido ou calculado resulta no ajuste do fornecimento de gás, para conseguir o valor ideal (MAQUET, 2012). Dentre muitos parâmetros que um ventilador possui, para este trabalho destacam-se os seguintes:

Pressão positiva no final da expiração (PEEP), que é a força ou pressão responsável em evitar o colapamento pulmonar, ou seja, o esvaziamento do pulmão através do fechamento das cordas vocais/epiglote e pela manutenção do surfactante alveolar (BARBAS *et al.*, 2014).

Segundo as Barbas *et al.*, (2014), no início da VM, no momento em que o paciente já se encontra intubado, deve-se utilizar uma PEEP mínima para evitar o colapamento/colapso. Os valores de máximo e mínimo, especificados para a PEEP são de 3 a 5 cmH<sub>2</sub>O.

Frequência respiratória (FR), é o número de respirações ou incursões que o paciente executa em um minuto, ou seja, respirações por minuto (rpm). Em condições normais fisiológicas, a FR tem valor de 12rpm. Em VM são três as definições utilizadas para a FR: A frequência controlada ou programada, que é frequência ajustada no painel do ventilador pelo encarregado da monitoração. A frequência espontânea, que é o número de respirações efetuadas pelo esforço do paciente, a qual pode sofrer interferências por diversos fatores como, por exemplo, sedação, febre, dor, ansiedade e dentre outros e a frequência total que resume-se à soma da frequência programada + espontânea.

Logo após a intubação orotraqueal do paciente, a meta da ventilação é garantir as trocas gasosas e o equilíbrio entre a pressão arterial de gás carbônico (PaCO<sub>2</sub>) e a pressão arterial de oxigênio (PaO<sub>2</sub>), ajustando a FR (YOKOYAMA *et al.*, 2010). A frequência respiratória inicial (controlada ou programada), pode ser ajustada de 12 a 16 rpm.



Fração inspirada de oxigênio ( $FiO_2$ ), é o parâmetro que mede a quantidade de oxigênio ( $O_2$ ) ofertada ao paciente, para manter a saturação de oxigênio ( $SatO_2$ ) em níveis aceitáveis. Nas condições fisiológicas normais, um indivíduo respira a concentração de 21% (ou 0,21) de  $O_2$  presente no ar ambiente, isto é, se o mesmo se encontra ao nível do mar (MORATO; SANDRI; GUIMARÃES, 2015). Para Malbouisson e Oliveira (2017), o uso indiscriminado de altos níveis de  $FiO_2$  pode levar à toxicidade pulmonar direta, com desenvolvimento de fibrose intersticial<sup>1</sup>, atelectasias<sup>2</sup> de reabsorção e traqueobronquite<sup>3</sup>.

O Quadro 2.2, indica os níveis de oxigênio que devem ser administrados aos pacientes no início, ou seja, a  $FiO_2$  inicial que deve ser o suficiente para manter  $SatO_2$  entre 93 e 97%, salvo em situações específicas: (BARBAS *et al.*, 2014).

Quadro 2. 2- Níveis de oxigênio ofertados no início da VM

Paciente	$FiO_2$
Obstrutivos (asma e DPOC)	$SatO_2$ entre 92 e 95%
Pacientes com síndrome do desconforto respiratório agudo (SDRA)	$SatO_2 > 92\%$

Fonte: Barbas *et al.* (2014).

Volume corrente (VC), é outro parâmetro ventilatório que mede o volume que deve ser entregue ao paciente a cada ciclo respiratório (TURRIN, 2011). Este valor é a cerca de 500mL em condições fisiológicas normais, que representa o gás que entra (inspiração) e sai (expiração) dos pulmões.

O volume corrente tende a modificar-se a depender de certas características individuais como, por exemplo, sexo, idade e repouso, ou esforço. O VC possui uma variação de 8 a 10mL/Kg. Como exemplo, uma pessoa que pesa 70Kg deve receber um VC conforme a expressão (2.2):

$$\text{Volume corrente: } 8 \times 70, \text{ ou } 10 \times 70 = \text{volume corrente } 560 \text{ a } 700\text{mL} \quad (2.2)$$

<sup>1</sup> Tecido de sustentação localizado nos interstícios de um órgão, esp. vasos sanguíneos e tecido conjuntivo.

<sup>2</sup> Colapso total ou parcial do pulmão ou do lóbulo pulmonar, que acontece quando os alvéolos (pequenos sacos pulmonares) se esvaziam.

<sup>3</sup> Inflamação na traqueia e nos brônquios dificultando o funcionamento do sistema respiratório.

São dois os tipos de volume corrente na VM, a saber, o volume corrente inspiratório que é determinado pela quantidade de ar que entra nos pulmões, durante a inspiração, e o volume corrente expiratório, determinado pela quantidade de ar que sai dos pulmões. Como nem todo o volume corrente inspirado chega aos pulmões, devido a alguns componentes do circuito ventilatório, este volume corrente expiratório expressa a quantidade de gás que realmente chegou ao espaço alveolar.

Volume minuto obrigatório ( $V_{min}$ ), é um parâmetro ajustado a volume corrente e a frequência respiratória, definindo determinado volume de gases por minuto, ou seja, é a quantidade circulante de gás dentro dos pulmões durante um minuto (MORATO; SANDRI; GUIMARÃES, 2015) (ANVISA, 2011). O volume minuto é o volume corrente (VC) multiplicado pela frequência respiratória (FR), medida em um minuto, ou seja,  $V_{min} = VC \times FR$ . Seu valor, em condições fisiológicas, varia de 5 a 8L/min.

O volume minuto é um dos principais fatores na determinação das concentrações de dióxido de carbono ( $CO_2$ ) e oxigênio ( $O_2$ ), nas artérias e alvéolos. Deste modo, determinadas alterações no  $V_{min}$ , como aumento ou diminuição do mesmo, irão afetar os valores de pH e  $PaCO_2$ , o que causa a Hipercapnia, ou aumento da concentração de  $CO_2$  arterial,  $PaCO_2 > 45$  mmHg; ou a Hipocapnia, ou seja, a redução da concentração de  $CO_2$  arterial,  $PaCO_2 < 45$  mmHg.

O valor ideal do  $V_{min}$ , na ventilação mecânica, deve ser capaz de manter o pH em seu estado normal, podendo ser calculado utilizando o peso predito que é um cálculo feito a partir da estatura do indivíduo (MORATO; SANDRI; GUIMARÃES, 2015). O Quadro 2.3, ilustra como é feito o cálculo por meio do peso predito.

Quadro 2. 3 - Cálculo do peso predito

<b>Gênero</b>	<b>Peso Predito</b>
Masculino	$50 + 0,91(\text{altura em cm} - 152,4)$
Feminino	$45,5 + 0,91(\text{altura em cm} - 152,4)$

Fonte: Morato, Sandri e Guimarães (2015).

Após o cálculo do peso predito, o volume minuto ideal pode ser encontrado por meio da expressão (2.3).

$$\text{Volume-minuto ideal: } 100\text{mL} \times \text{peso em Kg (peso predito)} \quad (2.3)$$

O disparo é um parâmetro ajustado no ventilador mecânico, com vistas a fazer a transição entre a inspiração e a expiração do paciente. Este ajuste está relacionado à sensibilidade do ventilador mecânico em que, o mesmo, pode ser alterado de acordo com o esforço do paciente, ou ajustado a tempo. No esforço do paciente, o ventilador reage à variação de pressão negativa gerada no interior do tubo endotraqueal, por meio de um sensor, e começa a operar juntamente com todo o circuito respiratório. A sensibilidade pode ser a fluxo ou a pressão, e quanto maior o valor da mesma, mais difícil será para o paciente disparar o ventilador (MORATO; SANDRI; GUIMARÃES, 2015). O Quadro 2.4, ilustra os valores utilizados para a sensibilidade do ventilador.

Quadro 2. 4 - Valores de disparo a fluxo e pressão

<b>Modalidades de Disparo</b>	<b>Valores</b>
Disparo a pressão	-0,5 a -2 cmH <sub>2</sub> O
Disparo a fluxo	1 a 5 L/min

Fonte: Morato, Sandri e Guimarães (2015).

O disparo a tempo, acontece quando se ajusta a FR no ventilador, ou seja, seleciona em qual intervalo de tempo o ventilador mecânico irá iniciar um ciclo respiratório, de modo automático, mesmo que o paciente não faça esforço. Esses valores podem ser ajustados, por exemplo, se um ventilador for ajustado com FR de 12rpm e uma janela de tempo de 60 segundos. Então divide-se esta janela por 12, o que resulta em 5 segundos. O resultado disso é que cada ciclo respiratório durará 5 segundos.

Ciclagem é a fase de mudança da inspiração para a expiração, ou seja, o ventilador interrompe a fase inspiratória, logo após a pausa inspiratória, e assim dá início a fase expiratória.

A P<sub>I</sub>máx e P<sub>E</sub>máx são variáveis que se caracterizam pela pressão respiratória estática máxima, que é gerada na boca após inspiração e expiração completas, respectivamente, e que indicam a força dos grupos musculares inspiratórios e expiratórios (COSTA *et al.*, 2010). Segundo Costa *et al.* (2010), a P<sub>I</sub>máx é uma medida da força muscular inspiratória, ao passo que a P<sub>E</sub>máx mede a força dos músculos abdominais e intercostais. A determinação de P<sub>I</sub>máx e P<sub>E</sub>máx é um método simples, prático e eficaz por meio de um equipamento clássico e

confiável, denominado *manovacuômetro* (SANTOS *et al.*, 2017). O Quadro 2.5, ilustra as equações para o cálculo da P<sub>I</sub>máx e P<sub>E</sub>máx em homens e mulheres de 20 a 80 anos.

Quadro 2. 5 - Equações para o cálculo das pressões respiratórias máximas

Gênero	P <sub>I</sub> máx(cmH <sub>2</sub> O)	P <sub>E</sub> máx(cmH <sub>2</sub> O)
Homens	$-1,24 \times \text{idade} + 232,37$	$-1,26 \times \text{idade} + 183,31$
Mulheres	$-0,46 \times \text{idade} + 74,25$	$-0,68 \times \text{idade} + 119,35$


Fonte: Costa (2010).

Outro aparelho, o *capnógrafo*, mede o dióxido de carbono (CO<sub>2</sub>) expirado, mediante um tubo endotraqueal (num doente intubado), ou através das vias aéreas (boca ou nariz) num doente não intubado. O mesmo constitui um indicador, em tempo real, da função respiratória. A capnometria mensura a quantidade de CO<sub>2</sub> nos gases expirados, e a capnografia é a demonstração gráfica do nível de CO<sub>2</sub> expirado (SANTANA; MELO; DUTRA, 2013).

O capnograma é o gráfico exibido num monitor, mudanças no seu formato permite identificar alterações patológicas da função pulmonar. Enquanto que valores da capnometria possibilita verificar a adaptação pulmonar a terapêutica estabelecida (SANTANA; MELO; DUTRA, 2013).

A capnometria apresenta valor de referência de 35 a 37mmHg, que geralmente tem valor aproximado da PaCO<sub>2</sub> (35 a 45mmHg), obtido pela gasometria arterial (SANTANA; MELO; DUTRA, 2013). A Figura 2.5, ilustra a capnografia normal para um paciente que é dividida em 4 fases.

Figura 2. 5 - Capnografia normal



Fonte: Reich (2011).

A fase I (A-B na figura 2.5) é a linha de base, que representa a inspiração, em que normalmente não há CO<sub>2</sub>. A fase II (B-C) é a ascensão expiratória do CO<sub>2</sub>, que apresenta

inclinação íngreme em indivíduos normais. O ar do início da expiração é o gás do espaço morto anatômico, das grandes vias aéreas, portanto não tem CO<sub>2</sub>. A medida que a expiração continua, esse ar é substituído pelo ar alveolar, repleto de CO<sub>2</sub>. Isso resulta na fase III (C-D), chamada de platô alveolar, que pode ter uma inclinação ascendente discreta em indivíduos normais devido à heterogeneidade da relação V/Q (ventilação-perfusão), ou seja, a relação entre o fluxo de ar que penetra os alvéolos e o fluxo sanguíneo para essas mesmas estruturas (REICH, 2011).

Alvéolos com baixa relação V/Q e, portanto, pressões parciais maiores de CO<sub>2</sub>, tendem a esvaziar-se mais lentamente do que aqueles com V/Q normal. A fase IV (D-E), é o descenso inspiratório, e representa a substituição do gás alveolar por gás fresco na câmara de amostragem (REICH, 2011).

As vias aéreas consistem em uma série de tubos ramificados que, quanto mais se aprofundam no parênquima pulmonar, mais se tornam estreitos, curtos e numerosos. A traqueia se divide em brônquio principal direito e brônquio principal esquerdo, os quais, por sua vez, se dividem em brônquios lobares e, após, em brônquios segmentares (WEST, 2013). Esse processo continua até os bronquíolos terminais, que são as menores vias aéreas sem alvéolos. Todos esses brônquios formam os ductos condutores. Sua função é levar o gás inspirado para as regiões pulmonares de troca gasosa. Como as vias aéreas condutoras não contêm alvéolos e, portanto, não participam da troca gasosa, elas constituem o *espaço morto anatômico*, ou espaço morto (EM). Seu volume é de cerca de 150 mL (WEST, 2013).


A reprodução de determinadas características de ventilação espontânea, em indivíduos saudáveis, é obtida por meio da manipulação dos parâmetros de um ventilador mecânico, programado para tal fim (FONTELA *et al.*, 2016). Dessa manipulação dá-se início aos modos ou modalidades ventilatórias.

### **2.3.2 Modos Ventilatórios**

Atualmente, para o ajuste dos parâmetros do ventilador mecânico, uma interface é apresentada ao especialista responsável. Esta interface é utilizada para controlar as definições do ventilador de forma manual. Geralmente os parâmetros respiratórios manipulados no ventilador mecânico são medidos e controlados continuamente. A diferença entre o valor real de um parâmetro medido, e o valor predefinido ou calculado resulta no ajuste do fornecimento

de gás, para conseguir o valor pretendido. As definições podem ser ajustadas, utilizando as teclas de membrana da tela ou os botões rotativos (MAQUET, 2012). A Figura 2.6, ilustra a interface de um ventilador mecânico.

Figura 2. 6 - Interface de um ventilador mecânico



Fonte: Maquet (2012).

Conforme a figura 2.6 (1), os botões, dispostos ao longo da base da tela da interface do utilizador, são os botões de acesso direto, que permitem o controle direto de quatro parâmetros respiratórios selecionados automaticamente em função das modalidades de ventilação.

As modalidades podem ser controladas, ou seja, o paciente não tem nenhuma interação com o ventilador mecânico, pois o mesmo está sedado completamente, ou incapaz de manter a respiração espontânea, ou assisto controlada (A/C) que é derivada da ventilação mecânica controlada, a grande diferença é permitir o ajuste de sensibilidade, ou seja, o paciente é capaz de disparar o ventilador, se fizer um esforço (MORATO; SANDRI; GUIMARÃES, 2015).

Segundo Turrin (2011), na modalidade A/C, mesmo o ventilador atingindo os níveis de pressão ou volume desejados, o momento de início e de término de uma inspiração dependem exclusivamente do paciente.

Segundo Barbas *et al.*, (2014, pg. 31):

A escolha do modo ventilatório deve se basear em três critérios: o conhecimento e habilidade da equipe multiprofissional com o modo; a disponibilidade de ventiladores e a indicação clínica, baseada principalmente na presença ou não de estímulo respiratório, da estabilidade hemodinâmica e da intensidade da lesão pulmonar.


Tais modalidades, tanto a controlada como a A/C, podem ser controladas tanto por volume ou pressão (TURRIN, 2011).

Para o escopo desta dissertação, a ventilação controlada a volume (VCV), será o alvo das análises pelo motivo da mesma ser a mais utilizada em UTI's e hospitais.

### 2.3.3 Ventilação Controlada a Volume (VCV)

No modo ventilação controlada a volume (VCV), é entregue ao paciente um valor já estimado de volume corrente. Neste modo, os parâmetros de frequência respiratória (FR), volume corrente (VC), e o fluxo inspiratório ( $FiO_2$ ) são fixados com valores pré-estabelecidos. O início da ventilação, por meio do disparo, de acordo com o tempo estimado, decorre do ajuste da frequência respiratória pré-determinada (ANVISA, 2011).

A fase de mudança da inspiração para a expiração, só acontece quando todo o volume corrente pré-estabelecido for liberado, com a velocidade resultante do fluxo programado. A Figura 2.7, ilustra as devidas curvas para o volume corrente, o fluxo e a pressão deste modo ventilatório (CARVALHO; TOUFEN; FRANÇA, 2007).



Fonte: Carvalho, Toufen e França (2007).

Tradicionalmente, o modo limitado a volume é utilizado em anestesia (cirurgias) e em pacientes com lesão neurológica grave, em que é preciso controlar com rigor as alterações de  $PaCO_2$  (MORATO; SANDRI; GUIMARÃES, 2015).

## 2.4 CONSIDERAÇÕES FINAIS DO CAPÍTULO

Este capítulo fez uma abordagem sobre a fundamentação teórica acerca da insuficiência respiratória aguda e as causas principais, que levam um paciente a ser colocado sob a ventilação mecânica, dando ênfase à pneumonia, assim como o estudo das partes e o funcionamento do ventilador mecânico, no que tange aos seus parâmetros ventilatórios e seus ajustes, finalizando com a modalidade a ser analisada neste estudo, ou seja, o volume corrente (VC). O próximo capítulo abordará as soluções propostas, no âmbito da inteligência artificial (IA), buscando melhorias na ventilação mecânica, com vistas ao aprimoramento na arte de ventilar.



### 3 REVISÃO DA LITERATURA

Neste capítulo serão apresentados trabalhos acadêmicos que apresentam soluções no tocante a área de ventilação mecânica dentro do contexto da Inteligência Artificial, abordando a metodologia empregada na busca destes trabalhos, analisando a relação dos mesmos com esta dissertação e as considerações finais.

#### 3.1 METODOLOGIA

A busca dos trabalhos, que estivessem relacionados com computação e na área médica, foram feitos de forma automática nas seguintes plataformas de pesquisa: o portal de periódicos da CAPES, *BMC Medical Informatics and Decision Making*, *IEEE Explore*, o portal Scielo e PubMed. As palavras-chaves escolhidas e utilizadas como *strings* de busca, foram as seguintes: ventilação mecânica, *artificial neural networks*, *artificial intelligence*, redes neurais artificiais, *intelligence artificial and mechanical ventilation e mechanical ventilators*. A Tabela 3.1, ilustra as fontes e quantidade de documentos encontrados.

Tabela 3. 1 - Resultados da Pesquisa

<b>Fontes de Busca</b>	<b>Documentos Retornados</b>
BMC	1
PubMed	1
Scielo	1
<b>Total</b>	<b>3</b>

Fonte: Elaboração própria do autor desta dissertação (2019).

Os critérios para a inclusão dos trabalhos se basearam em: trabalhos publicados a partir de primeiro de janeiro de 2011 até 31 de dezembro de 2018, voltados para soluções em ventilação mecânica, com o uso de inteligência artificial (IA) e simulação na área computacional, estudos de caso realizados em humanos adultos de qualquer gênero, trabalhos que estivessem disponíveis para visualização e download, e trabalhos escritos em inglês, português ou espanhol. O Quadro 3.1, ilustra as publicações selecionadas para este referencial teórico.

Quadro 3. 1 - Publicações selecionadas (Continua)

Título e Autor	Ano	Base de dados	Características do estudo
<p>Redes bayesianas para eleição da ventilação mecânica no pós-operatório de cirurgia cardíaca.</p> <p>Schenekenberg <i>et al.</i></p>	2011	Scielo	<p><b>Artigo científico. Objetivos:</b> Este trabalho propõe o uso de redes bayesianas (RB) para auxiliar o profissional no momento da decisão, agilizando o atendimento dos pacientes.</p> <p><b>Materiais e métodos:</b> Para o desenvolvimento da RB fez-se necessário o uso de uma base de dados com casos clínicos, a qual se constituiu de 137 casos. A avaliação foi realizada por meio das medidas de validade operacionais de instrumentos, tabelas de contingência e curvas ROC.</p> <p><b>Resultados:</b> Mostraram que a RB desenvolvida apresentou um adequado desempenho para a eleição da modalidade e parâmetros ventilatórios.</p>
<p>Um sistema de suporte à decisão para determinar as configurações ideais do ventilador.</p> <p>Akbulut <i>et al.</i></p>	2014	<p><i>BMC Medical Informatics and Decision Making</i></p>	<p><b>Artigo científico. Objetivos:</b> O objetivo deste trabalho é minimizar os erros na terapia de ventilação e evitar mortes causadas pela configuração incorreta dos dispositivos de ventilação.</p> <p><b>Materiais e métodos:</b> Este artigo descreve um sistema de suporte à decisão que propõe as configurações do ventilador necessárias para serem aplicadas no tratamento de acordo com as informações fisiológicas dos pacientes. O modelo proposto foi projetado para minimizar a possibilidade de cometer um erro e incentivar o uso mais eficiente do tempo em apoio ao processo de tomada de decisão, enquanto os médicos tomam decisões críticas sobre o paciente.</p> <p><b>Resultados:</b> As informações fisiológicas de 158 pacientes respiratórios com mais de 60 anos de idade e foram tratadas em três hospitais diferentes entre os anos de 2010 e 2012 foram utilizadas no treinamento e teste do sistema. Os dados de doença diagnosticada, temperatura corporal central, pulso, pressão sistólica arterial, pressão arterial diastólica, PEEP, PSO<sub>2</sub>, pH, pCO<sub>2</sub>, dados de bicarbonato, bem como os valores de frequência, volume corrente, FiO<sub>2</sub> e suporte de pressão/suporte de volume adequados para uso em o dispositivo de ventilação foi recomendado aos médicos com uma precisão de 98,44%. Experimentos realizados mostram que o treinamento sequencial de peso/viés de ordem foi considerado o algoritmo de aprendizado de RNA mais ideal para o modelo de regressão, e a retropropagação bayesiana da regulação foi o algoritmo de aprendizado de RNA mais ideal para modelos de classificação.</p>

Quadro 3. 1 - Publicações selecionadas (Conclusão)

Título e Autor	Ano	Base de dados	Características do estudo
<p>Usando inteligência artificial para prever ventilação mecânica prolongada e colocação de traqueostomia.</p> <p>Parreco <i>et al.</i></p>	2018	PubMed	<p><b>Artigo científico. Objetivos:</b> O objetivo deste estudo foi usar o aprendizado de máquina para identificar pacientes em risco de colocação de PMV e traqueostomia.</p> <p><b>Materiais e métodos:</b> O banco de dados de Monitoramento Inteligente Multiparamétrico, em Terapia Intensiva, foi consultado para todas as estadias em UTI's com ventilação mecânica. VMP foi definido como ventilação &gt;7 dias. Classificadores com um algoritmo de árvores de decisão com aumento de gradiente foram criados para os resultados da colocação de VMP e traqueostomia.</p> <p><b>Resultados:</b> Foram identificados 20.262 estadias na UTI. Foi necessário VMP em 13,6% e traqueostomia em 6,6% dos pacientes. O classificador para prever o VMP conseguiu atingir uma área média sob a curva (AUC) de <math>0,820 \pm 0,016</math>, e a traqueostomia foi prevista com uma AUC de <math>0,830 \pm 0,011</math>. Havia 60,7% dos pacientes internados em uma UTI cirúrgica, e os classificadores para esses pacientes previram VMP com AUC de <math>0,852 \pm 0,017</math> e traqueostomia com AUC de <math>0,869 \pm 0,015</math>. A variável de maior importância na predição do VMP foi o componente pulmonar do escore de disfunção orgânica (13%), e a comorbidade mais importante na predição da traqueostomia foi a arritmia cardíaca (12%).</p>

Fonte: Elaboração própria do autor desta dissertação (2019).

### 3.2 TRABALHOS RELACIONADOS

Schenkenberg *et al.* (2011), constataram que, a VM no pós-operatório de cirurgia cardíaca, pode trazer algumas complicações respiratórias ao paciente, e para minimizar esse risco é necessário a adaptação correta e rápida do ventilador mecânico. A dificuldade para isso, está no número expressivo de variáveis para a regulação do ventilador mecânico e na obtenção de todas essas variáveis. Schenkenberg *et al.* (2011), utilizaram Redes Bayesianas (RB), empregando o conhecimento do especialista para representar ajustes ventilatórios, de forma computacional, auxiliando o profissional de saúde na tomada de decisão. Foram selecionadas 35 variáveis, como sendo essenciais à prática da ventilação mecânica, as quais foram distribuídas em classes denominadas: Sinais Clínicos (SC), Exames Bioquímicos (EB), Mecânica Respiratória (MR) e VM. A análise dos resultados, mostrou que a RB desenvolvida na pesquisa em questão, apresentou um adequado desempenho, para a eleição da modalidade e parâmetros ventilatórios. Os resultados com a RB, mostraram assim, uma compatibilidade entre

o raciocínio humano e o computacional. Da mesma forma, a RNA proposta neste trabalho, contará com o conhecimento de um especialista, entretanto a tomada de decisão partirá da própria Rede Neural Artificial, podendo ser validada pelo especialista.

Akbulut *et al.* (2014), observaram que os parâmetros fisiológicos, determinados de acordo com os achados do paciente, conectado ao dispositivo ventilatório, mudam simultaneamente, dependendo do status instantâneo do paciente, após a inserção ao dispositivo. O ponto mais crítico nisto, é determinar os parâmetros do dispositivo na precisão desejada. Como a tarefa de especificar os parâmetros do equipamento de ventilação é realizada inteiramente por um médico, o conhecimento e a experiência do médico na seleção dessas configurações afetam diretamente a precisão de suas decisões. O processo de determinação dos parâmetros do dispositivo, com um sistema de suporte à decisão, a ser desenvolvido para esse processo, pode ser concluído com um erro mínimo, informando o status instantâneo do paciente. Dessa forma, os processos de tomada de decisão dos médicos podem ser implementados de maneira mais rápida e precisa. O estudo descreveu um sistema de apoio à decisão projetado para determinar automaticamente as configurações do ventilador, considerando os dados de ventilação obtidos em dois hospitais diferentes. A proposta da pesquisa apresentada nesta dissertação, diferentemente do trabalho de Akbulut *et al.* (2014), emprega dados fisiológicos do paciente e o ajuste automático do ventilador, feito exclusivamente pela rede neural artificial.

No estudo de Parreco *et al.* (2018), foi constatado que a previsão de quais pacientes de UTI precisariam de ventilação mecânica prolongada (VMP) provou ser difícil. A inteligência artificial (IA), através de classificadores de aprendizado de máquina, foi utilizada para a identificação precoce de pacientes com risco de VMP e traqueostomia. A aplicação de conceitos de aprendizado de máquina à UTI, também se mostrou útil para discernir alarmes de sinais vitais clinicamente relevantes e prever a piora clínica do paciente. Entretanto, segundo os autores, a aplicação dessas técnicas de identificação pôde levar a melhores resultados, permitindo a intervenção num tratamento precoce. Foram utilizados diversos dados de monitoramento, armazenados em banco de dados, os quais continham os registros médicos de 46.520 admissões no Centro Médico Beth Israel Deaconess, de 2001 a 2012. O banco de dados possuía informações detalhadas sobre hospitalizações de pacientes, dados laboratoriais, sinais vitais, administrações de medicamentos e dados de mortalidade do índice de mortes da previdência social. Árvores de regressão foram construídas em paralelo usando todas as

variáveis disponíveis, o que resultou em um conjunto de modelos de árvores de classificação que previram resultados através de estimativas gradualmente melhoradas.

Estes trabalhos tiveram enfoque na utilização da inteligência artificial aplicada à ventilação mecânica, utilizando-se de redes bayesianas, sistemas especialistas e classificadores de aprendizado de máquina. Após a análise, constatou-se que os autores concordam que o uso de sistemas especialistas podem auxiliar num melhor tratamento aos pacientes, em ventilação mecânica, auxiliando os especialistas na tomada de decisão, nos ajustes necessários do ventilador e que, a utilização destes sistemas, tanto para analisar os dados fisiológicos dos pacientes, quanto os dados do ventilador, se assemelha à forma de raciocínio humano. Entretanto, estes trabalhos poderiam ser melhorados com o uso de redes neurais artificiais, no que concerne ao reconhecimento de padrões, nos dados fisiológicos de pacientes, trabalhando estes dados e prevendo o ajuste do ventilador mecânico, com resultados satisfatórios, sendo este o diferencial da pesquisa proposta nesta dissertação.

### 3.3 CONSIDERAÇÕES FINAIS DO CAPÍTULO

Este capítulo apresentou alguns trabalhos relacionados à pesquisa desta dissertação, que foram escolhidos após exaustiva busca, a partir de determinados critérios anteriormente citados. As pesquisas de busca mostraram, dentro do período determinado, que poucos trabalhos se utilizam da técnica de redes neurais artificiais na aplicação prática em ventilação mecânica. O próximo capítulo fará uma revisão conceitual acerca do assunto de Redes Neurais Artificiais (RNA), estudando suas características, arquitetura, tipos, funcionalidade e aplicação.

## 4 REDES NEURAIIS ARTIFICIAIS (RNA)

O objetivo deste capítulo, é apresentar os conceitos e acerca das *Redes Neurais Artificiais (RNA)*, que é uma ferramenta poderosa para identificar padrões e resolver problemas diversos, abordando o funcionamento de um neurônio biológico, assim como a arquitetura de uma RNA e o seu funcionamento, o algoritmo *backpropagation* e as considerações finais.

### 4.1 REDES NEURAIIS BIOLÓGICAS

O cérebro humano, possui a capacidade de organizar os neurônios, para realizar, dentre muitas funções, processamentos como, por exemplo: reconhecimento de padrões, percepção e controle motor, muito mais veloz que o computador mais avançado da atualidade (HAYKIN, 2001).

Segundo Haykin (2001), o cérebro se assemelha a um computador, pelo fato de possuir certo sistema de processamento das informações, sendo de alta complexidade, *não-linear*<sup>4</sup> e *paralelo*<sup>5</sup>.

Os dendritos, os axônios e o corpo celular (*soma*), são os componentes básicos que fazem parte de um neurônio biológico. A função dos dendritos é receber os estímulos e transmiti-los através das *sinapses*<sup>6</sup> a outros neurônios. Os axônios recebem os estímulos e os transmite para as células e, por fim, o corpo celular ou soma, do neurônio, é o receptor das informações, pré-combinadas, advindas de outros neurônios (MIRANDA *et al.*, 2012).

Haykin (2001), afirma que as sinapses são unidades estruturais e funcionais elementares que intermediam as interações entre os neurônios. A Figura 4.1, ilustra a estrutura de um neurônio biológico.

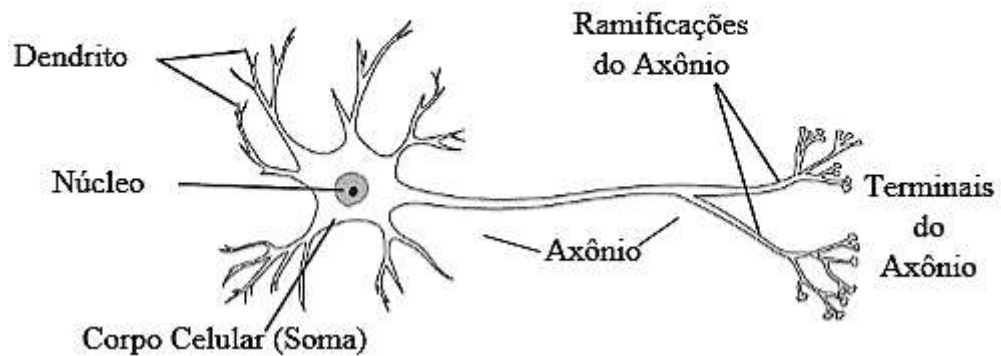
---

<sup>4</sup> Que não representa um sentido único.

<sup>5</sup> Que se realiza, ao mesmo tempo, em duas ou mais atividades semelhantes, mas em locais ou canais diferentes.

<sup>6</sup> Região de proximidade entre um neurônio e outra célula por onde é transmitido o impulso nervoso.

Figura 4. 1 - Estrutura de um neurônio biológico



Fonte: Adaptado de <http://cs231n.github.io/neural-networks-1/>

De acordo com Matsunaga (2012, p. 6):

Estima-se que haja aproximadamente 10 bilhões de neurônios no córtex humano e 60 trilhões de sinapses ou conexões. O cérebro humano, representado pela rede neural (nervosa), é constituído por estruturas, neurônios, que interagem entre si, armazenando e tomando decisões adequadas a partir das informações recebidas.

A forma como o cérebro manipula as informações, processando-as diferentemente dos computadores digitais, tem motivado o estudo das redes neurais artificiais (HAYKIN, 2001).

#### 4.2 REDES NEURAIS ARTIFICIAIS (RNA)

A definição de uma Rede Neural Artificial (RNA), para Haykin (2001, p. 27), é expressa da seguinte forma:

Uma rede neural é um processador maciçamente paralelamente distribuído, constituído de unidades de processamento simples, que tem a propensão natural para armazenar conhecimento experimental e torná-lo disponível para uso.

As unidades que são os neurônios, se interligam por meio de redes a outros neurônios adjacentes (*ligações sinápticas*). Estas ligações, que se caracterizam pelas entradas para um determinado neurônio, resultam diretamente da somatória ponderada de todas as saídas dos outros neurônios a esse conectado.

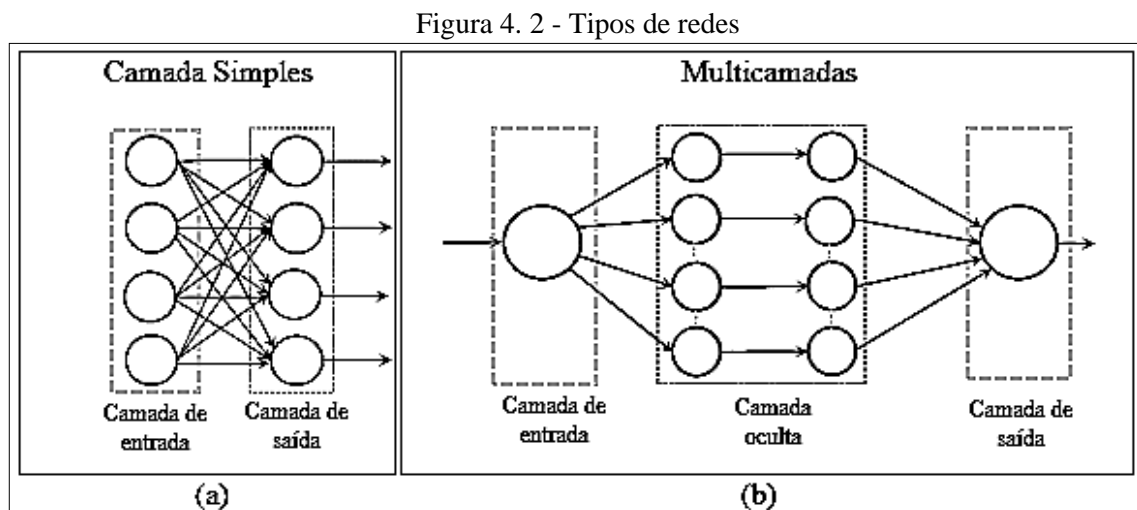
Segundo Miranda *et al.*, (2012, p. 3):

O neurônio matemático, similarmente ao natural, recebe um ou mais sinais de entrada e devolve um único sinal de saída, que pode ser distribuído como sinal de saída da rede, ou como sinal de entrada para um ou vários outros neurônios da camada posterior.

No neurônio matemático, as *sinapses* fazem a parte dos dendritos no neurônio biológico. O papel dos axônios é desempenhado no modelo matemático pelos *bias*<sup>7</sup> (MIRANDA *et al.*, 2012).

#### 4.2.1 Número de Camadas de uma RNA

Uma rede neural é constituída por mais de um neurônio, como foi visto anteriormente. *Redes Perceptron* são a forma mais simples de uma RNA, usada para classificação de padrões linearmente separáveis, ou seja, padrões que estão em lados opostos de um hiperplano. As Redes Perceptron consistem basicamente de um único neurônio com pesos sinápticos ajustáveis e um *bias* (SOUZA, 2012). As redes que apresentam mais de uma camada são chamadas de *Redes Multicamadas*, enquanto o contrário é chamada de simples. Redes multicamadas possuem camadas ocultas, ou seja, camadas que estão entre a camada inicial e a camada final. A Figura 4.2, ilustra os dois tipos de redes, simples e multicamadas.



Fonte: Haykin (2001).

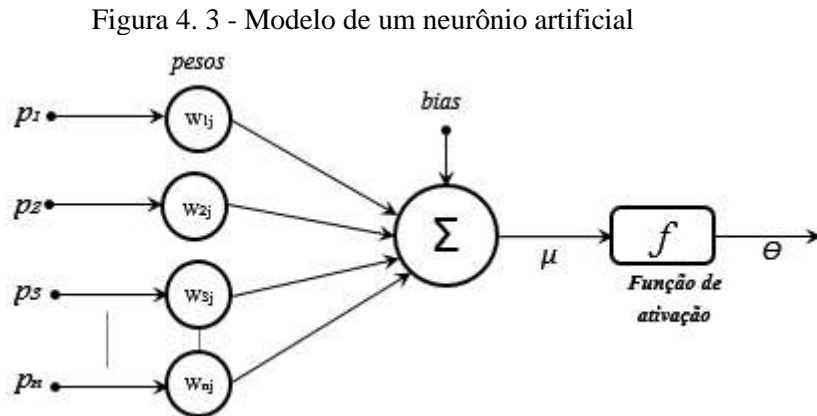
<sup>7</sup> Ativador de um neurônio.



Conforme a figura 4.2(a), de camada simples, a mesma apresenta uma camada de entrada associada a um ou mais neurônios que proporcionarão as devidas saídas. A rede 4.2(b), multicamadas, apresenta camadas intermediárias (ocultas), entre as camadas de entrada e saída. Esta rede multicamadas também denominada Perceptron de Multicamadas (MLP, do inglês *Multilayer Perceptron*) é uma generalização do Perceptron simples, visto anteriormente, constituída de um conjunto de nós fonte, os quais formam a camada de entrada da rede, uma ou mais camadas ocultas de nós computacionais e uma camada de saída, também de nós computacionais. Com exceção da camada de entrada, todas as outras camadas realizam processamento (SOUZA, 2012).

#### 4.2.2 Funcionamento de um Neurônio Artificial

O modelo de rede da Figura 4.3, inclui um sinal adicional *bias* ( $b$ ), o qual favorece ou limita a possibilidade de ativação do neurônio  $k$ . O processo sináptico é representado pelos pesos ( $\omega$ ), que amplificam cada um dos sinais recebidos. A chamada função de ativação ( $f$ ) modela a forma como o neurônio responde ao nível de excitação, limitando e definindo a saída ( $\mu$ ) da rede neural (MATSUNAGA, 2012).



Fonte: Adaptado de Souza (2012).

Observando a figura 4.3, tem-se que, um sinal  $p_n$  na entrada da sinapse, conectado ao neurônio  $k$ , é multiplicado pelo peso sináptico  $\omega_{nj}$ . Cada peso possui índices, em que o primeiro refere-se ao neurônio em questão, e o segundo se refere ao terminal de entrada da sinapse, à qual o peso se refere. Posteriormente, a função somadora ( $\Sigma$ ), é responsável pela soma dos pesos multiplicados, e o limiar de ativação  $b$  (*bias*), é quem permite melhor adaptação

do neurônio ao conhecimento adquirido, e  $f$  (função de ativação) terá, por fim, um cálculo específico para trabalhar com a saída ( $\mu$ ), produzindo o resultado desejado  $\Theta$ .

A função de ativação destina-se a restringir (limitar) a amplitude da saída de um neurônio a um valor finito. Normalmente o intervalo da amplitude de saída de um neurônio é denotado como o intervalo fechado  $[0,1]$ , ou também pode ser  $[-1, 1]$ .

Um neurônio pode ser escrito em termos matemáticos pelas equações (4.1) e (4.2):

$$\mu = \sum_{j=1}^n \omega_{nj} \cdot p_n \quad (4.1)$$

$$\Theta = f(\mu + b) \quad (4.2)$$

onde  $p_1, p_2, \dots, p_n$  são os sinais de entrada;  $\omega_{1j}, \omega_{2j}, \dots, \omega_{nj}$  são os pesos sinápticos do neurônio em questão;  $\mu$  é a saída do combinador linear segundo os sinais de entrada;  $b$  é o *bias*;  $f$  é a função de ativação e  $\Theta$  é o sinal de saída do neurônio. O cálculo da função de ativação de uma RNA padrão, em que os seus pesos são representados por  $\omega$ , as entradas por  $p$ , e o  $b$  é o *bias* da equação, é apresentado pela equação (4.3).

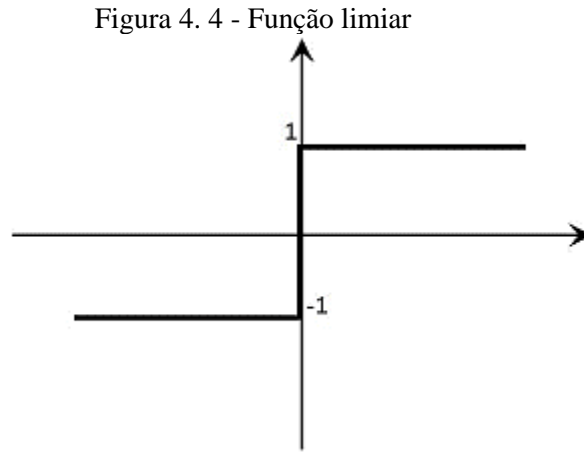
$$\mu = \omega_{nj} \cdot p_n - b \quad (4.3)$$

Os sinais de entrada são passados para os neurônios que, após multiplicar os mesmos pelos seus respectivos pesos, soma-os e, em seguida subtrai, o valor resultante desta soma do limiar de ativação para que, então, se trabalhe neste valor gerado com a função de ativação empregada, resultando, assim, no valor desejado, ou não, pela RNA. Diferentes representações podem ser atribuídas à função de ativação.

### 4.2.3 Funções de Ativação de uma RNA

A saída de um neurônio, no caso  $\Theta$ , apresentado anteriormente, é definida por uma função de ativação. Três são os tipos básicos para esta função: *limiar, linear e sigmóide*.

1. Função de *Limiar*. Para esta função tem-se o seguinte gráfico, como ilustrado na Figura 4.4.



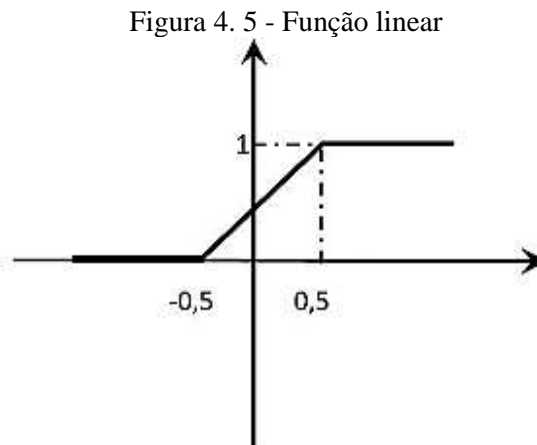
Fonte: Elaboração própria do autor desta dissertação (2019).

A saída de um neurônio que trabalha com este tipo de função é expressa em (4.4):

$$\Theta(\mu) = \begin{cases} 1 & \text{se } \mu \geq 0 \\ 0 & \text{se } \mu < 0 \end{cases} \quad (4.4)$$

Nesta função, se o valor de  $\mu$  for não-negativo a saída do neurônio assume valor 1, caso contrário é 0.

2. Função *Linear*. A função linear é descrita na Figura 4.5.



Fonte: Adaptado de Haykin (2001).


Esta função de ativação, pode ser vista como uma aproximação de um amplificador não-linear (HAYKIN, 2001). A saída do neurônio nesta função de ativação é expressa por (4.5):

$$\Theta(\mu) = \begin{cases} 1, & \mu \geq +\frac{1}{2} \\ \mu, & +\frac{1}{2} > \mu > -\frac{1}{2} \\ 0, & \mu \leq -\frac{1}{2} \end{cases} \quad (4.5)$$

Da expressão anterior surgem duas situações a serem observadas: se a região linear de operação é mantida sem entrar em saturação, surge o valor de  $\mu$ . Se o fator de ampliação da região linear é feito infinitamente maior, então a função linear se reduz à função de limiar.

3. Função *Sigmóide*. A função sigmóide é descrita na Figura 4.6.

Figura 4. 6 - Função sigmóide



Fonte: Elaboração própria do autor desta dissertação (2019).

A função sigmóide é a forma mais utilizada nas construções de RNA. Esta é definida como uma função estritamente crescente, a qual exibe um balanceamento adequado entre o comportamento linear e não-linear. A saída do neurônio é definida por (4.6):

$$\Theta(\mu) = \frac{1}{1 + e^{-a\mu}} \quad (4.6)$$

onde  $a$  é o parâmetro de inclinação da função sigmóide. Variando o valor de  $a$ , a função adquire diferentes inclinações. Quando o parâmetro ' $a$ ' se aproxima do infinito, a função

sigmóide se torna uma função de limiar. Enquanto uma função de limiar assume o valor de 0 ou 1, uma função sigmóide assume um intervalo contínuo de valores entre 0 e 1.

O objetivo de cada projeto, acarretará o tipo da função de ativação específica. Para que uma rede neural tenha êxito em sua construção, é fundamental que a mesma passe pelo processo de treinamento, validação e verificação.

#### 4.2.4 Treinamento, Validação e Verificação de uma RNA

Para que a uma rede neural seja validada é necessário três etapas: treinamento, validação cruzada e verificação.

De acordo com Wuerges e Borba (2010, p. 4):

Antes que uma rede neural possa ser útil, ela precisa ser treinada, isto é, precisa “aprender” o problema. O processo de aprendizagem, determina os pesos sinápticos adequados para cada neurônio, de tal forma que, a saída obtida pelos neurônios da última camada, sejam as mais próximas possíveis das saídas desejadas, para o problema que deve ser resolvido.

Segundo Miranda *et al.*, (2012, p. 4), “o treinamento/aprendizado da rede neural leva em consideração uma regra formal, ou seja, a utilização de informações do supervisor da rede, que atualiza os parâmetros modificáveis da rede como os *bias* e as *sinapses*.”

Para Miranda *et al.*, (2012, p. 4):


A participação do supervisor, pode ser classificada em métodos de treinamento. Quando essa participação for forte, o supervisor fornece um conjunto de entradas correlacionadas, com um conjunto de saída desejada, ou seja, o supervisor apresenta os resultados almejados no vetor de saída desejada, para que se tenha a mesma “correlação” de entradas posteriores, aumentando o aprendizado a cada entrada do treinamento.

O reconhecimento de padrões por meio das RNA, consiste em treinar a rede informando padrões de entrada e recalculando os pesos segundo uma regra de aprendizado. O erro é retropropagado da saída para a entrada, e assim, a rede vai corrigindo possíveis falhas, buscando um erro menor, e a validação cruzada acontece quando a rede se encontra treinada, ou seja, é a certeza de parada quando a rede demonstra encontrar o resultado satisfatório (MIRANDA *et al.*, 2012).

### 4.2.5 Algoritmo Backpropagation

O algoritmo de retropropagação de erro, ou simplesmente retropropagação (*backpropagation*), é um algoritmo utilizado no treinamento de redes neurais multicamadas com uma ou múltiplas camadas escondidas (ocultas).

Na execução de um algoritmo *backpropagation* duas etapas são estabelecidas: a propagação direta (*forward*), do sinal de entrada à rede e que passa de camada a camada, onde neste processo os pesos da rede permanecem fixos; e a retropropagação (*backward*) do sinal, ou seja, o sentido inverso do sinal comparando as saídas da rede com as saídas desejadas (SOUZA, 2012). Nesta etapa um sinal de erro calculado na saída da rede é propagado no sentido contrário, novamente camada a camada, e ao final deste processo os pesos são ajustados de acordo com determinada regra de correção de erro. Na Figura 4.7, tem-se os sinais de propagação e retropropagação de um algoritmo *backpropagation*.



Fonte: Souza (2012).

O treinamento, por retropropagação do erro, já foi mostrado anteriormente. Neste processo é realizado o ajuste nos pesos sinápticos. Nas equações 4.7 e 4.8, é possível observar o cálculo para os ajustes nos pesos sinápticos do algoritmo *backpropagation*.

$$\rho_j(n) = d_j(n) - \Theta_j(n), \quad (4.7)$$

onde  $\rho_j(n)$  é a diferença entre o valor desejado  $d_j(n)$ , para determinada entrada, e saída gerada pela rede  $\Theta_j(n)$ . A soma dos erros quadráticos instantânea da rede é então definida por:

$$\varepsilon(n) = \frac{1}{2} \sum_{j=C}^n \rho_j^2(n) \quad (4.8)$$

onde  $C$  é o conjunto de todos os neurônios que pertencem a camada de saída da rede, e  $\varepsilon(n)$  é o valor instantâneo do erro.

O algoritmo *backpropagation* é um paradigma de aprendizagem do tipo supervisionado, e seu processo de aprendizado é iterativo, ou seja, a saída produzida pela rede é comparada a uma resposta desejada e melhorada a cada interação. De forma genérica, esse método possui uma função erro (*professor*) na saída da rede. Após seu cálculo, é realizada a propagação em sentido contrário (retropropagação). Nesse procedimento os pesos sinápticos das camadas ocultas são atualizados (SOUZA, 2012).

Por fim, esse processo consiste em ajustar os pesos sinápticos visando minimizar o erro entre a saída produzida pela rede, em relação à respectiva saída desejada.

#### 4.3 COMO AS RNA RECONHECEM PADRÕES

O reconhecimento de padrões por meio das RNA, consiste em treinar a rede, informando padrões de entrada e recalculado os pesos, segundo uma regra de aprendizado. Segundo Moraes (2011, p. 26), “O processo de aprendizagem da rede MLP é de forma supervisionada, ou seja, a rede é treinada com pares de conjuntos de entrada e de saída desejada.”

Um conjunto de entrada é apresentado à rede, e esta retorna um conjunto de valores de saída, que é comparado a um conjunto de valores de saída desejado. Os pesos sinápticos e níveis de *bias* são ajustados posteriormente, de forma a minimizar a saída apresentada pela rede e a saída desejada. Este processo se repete para todos os pares de entrada e saída, que constituem o conjunto de treinamento da rede, até que a taxa de acerto seja considerada satisfatória (MORAIS, 2011).

Segundo Martiniano *et al.*, (2016, p. 4):

Uma importante característica das RNAs, é a sua capacidade de aprender, a partir de dados incompletos e sujeitos a ruídos. Em um sistema computacional convencional, se uma parte falha, em geral, o sistema como um todo se deteriora, enquanto que, em uma RNA, a tolerância às falhas faz parte da arquitetura, devido à sua natureza distribuída de processamento. Se um neurônio falha, sua saída errônea é sobrescrita pelas saídas corretas de seus elementos vizinhos.

Alguns problemas toleram certo grau de erro. Dessa maneira, é possível encontrar um separador com um esforço viável que consiga separar os elementos das classes com um bom nível de acerto (MANZAN, 2015).


No entendimento de Haykin, (2001, p. 92), “o reconhecimento de padrões é formalmente definido como o processo pelo qual um padrão/sinal, recebido, é atribuído a uma classe, dentre um número predeterminado de classes (*categorias*)”.

O reconhecimento de padrões, realizado por uma rede neural, é de natureza estatística, onde os padrões são representados por pontos em um espaço de decisão multidimensional, ou seja, o espaço é dividido em regiões, onde cada uma está associada a uma classe. As fronteiras de decisão são estabelecidas pelo processo de treinamento. Essas fronteiras tornam-se estatísticas devido à variabilidade inerente, que existe dentro das classes, e entre as classes (HAYKIN, 2001).

De acordo com Manzan (2015, p. 21), “técnicas de reconhecimento de padrões nem sempre são simples. Em um dado problema, simples ou complexo, busca-se sempre chegar próximo de seu separador ideal.”

Na maioria dos problemas de classificação, a determinação do separador desejado exige muito esforço, tanto na determinação dos parâmetros, da técnica de reconhecimento de padrões utilizada, quanto no custo computacional (MANZAN, 2015). A Figura 4.8, ilustra um reconhecedor que faz a separação de duas classes próximo ao desejado, com alguns erros na separação.





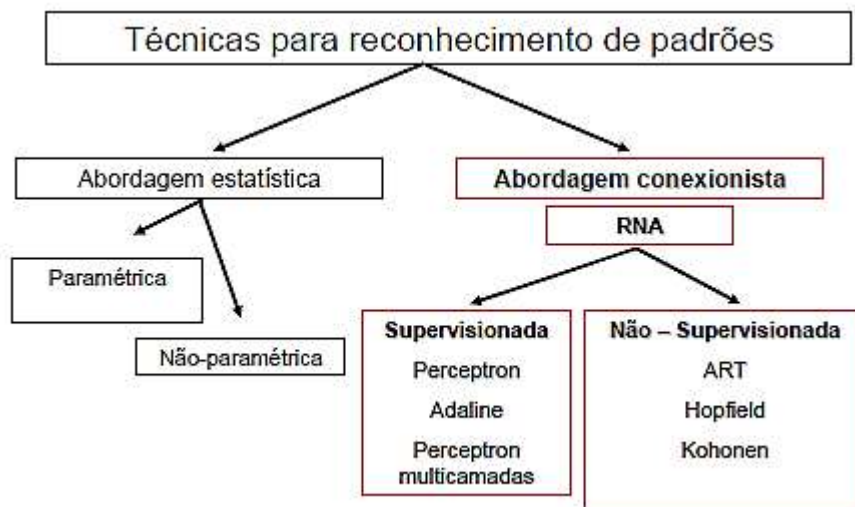
Fonte: Duda *et al.* (2001).

Segundo Manzan (2015, p. 25), “dentre as técnicas de reconhecimento de padrões mais utilizadas, destacam-se a abordagem estatística (*paramétrica*<sup>8</sup> e a *não-paramétrica*) e a abordagem *conexionista*, que utiliza RNA.”

Esta dissertação, em particular, dará enfoque a abordagem *conexionista*, da qual utilizam-se as RNA. São tipos de classificadores mais complexos e são capazes de se adaptar a qualquer tipo de distribuição de dados. Um resumo das técnicas de reconhecimento de padrões pode ser visualizado na Figura 4.9.

<sup>8</sup> Que permitem extrapolar para um conjunto, considerações acerca de parâmetros importantes como: médias, desvios-padrão, etc.

Figura 4. 9 - Principais técnicas de reconhecimento de padrões




Fonte: Manzan (2015).

A abordagem conexionista, baseia-se no funcionamento das estruturas neurais inteligentes, que por meio de exemplos são capazes de aprender. Este aprendizado é consequência da interação entre todas as partes da rede, mas é na camada oculta que ocorre todos os processos computacionais numa rede neural artificial multicamadas, ou seja, é nela que acontece a associação das características, assim como a separação das classes (MANZAN, 2015). Para a camada de saída, resta a apresentação dos resultados finais da rede.

Numa RNA simples, com uma camada de entrada e outra de saída, a separação das classes acontece na própria camada de saída. Redes do tipo simples, são versáteis para problemas que envolvem classes linearmente separáveis. Fazem parte destas, as redes Perceptron e Adaline. A função lógica “ou”, como exemplo para duas entradas, gera apenas um resultado na saída. Considerando o operador lógico verdadeiro como 1, ou falso como -1, tem-se para esta função sempre valores verdadeiros, exceto quando estabelecido entre dois operadores lógicos falsos (MANZAN, 2015). A Figura 4.10, ilustra em um hiperplano, a separação gerada por meio da função “ou”, onde os resultados verdadeiros estão representados por quadrados, e o falso por triângulo.

Figura 4. 10 - Separação das classes por meio da função lógica “ou”



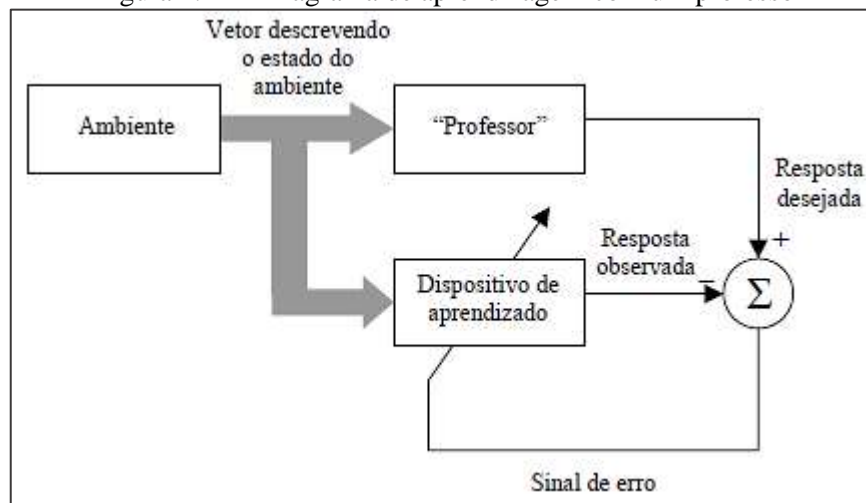
Fonte: Elaboração própria do autor desta dissertação (2019).

Em redes neurais artificiais, dois grupos de técnicas para classificação de padrões são definidos como: técnicas com supervisão e sem supervisão. Anteriormente foi citado a técnica supervisionada que consiste em apontar a saída esperada, de acordo com um conjunto de dados conhecidos previamente, ou seja, o conjunto de dados representa exemplos que farão o treinamento do sistema por experiência. Na técnica não-supervisionada, as classes não estão bem definidas e, sendo assim, o sistema se encarregará de separar essas classes no sentido de levantar as características mais evidentes (MANZAN, 2015).

No método de aprendizagem supervisionado, ou com um “*professor*”, Haykin (2001), considera o professor como conhecedor de todo o ambiente, ou seja, com o conhecimento acerca do conjunto de exemplos de entrada e saída. Com isto, em virtude de seu prévio conhecimento, o professor é capaz de fornecer à rede neural uma resposta desejada para um determinado vetor de treinamento. Essa resposta desejada, refere-se a uma ação ótima a ser realizada pela rede neural.

Sob a influência combinada do vetor de treinamento e do sinal de erro, os parâmetros da rede são ajustados. A Figura 4.11, ilustra o diagrama de aprendizado supervisionado.

Figura 4. 11 - Diagrama de aprendizagem com um professor



Fonte: Haykin (2001).

O sinal de erro é definido como a diferença entre a resposta desejada e a resposta real da rede. O ajuste é realizado passo a passo e, dessa forma, o conhecimento do ambiente, disponível ao professor, é transferido para a rede neural através de treinamento, da forma mais completa possível. Alcançando esta condição, pode-se dispensar o professor e deixar a rede neural lidar com o ambiente inteiramente por si mesma (HAYKIN, 2001).

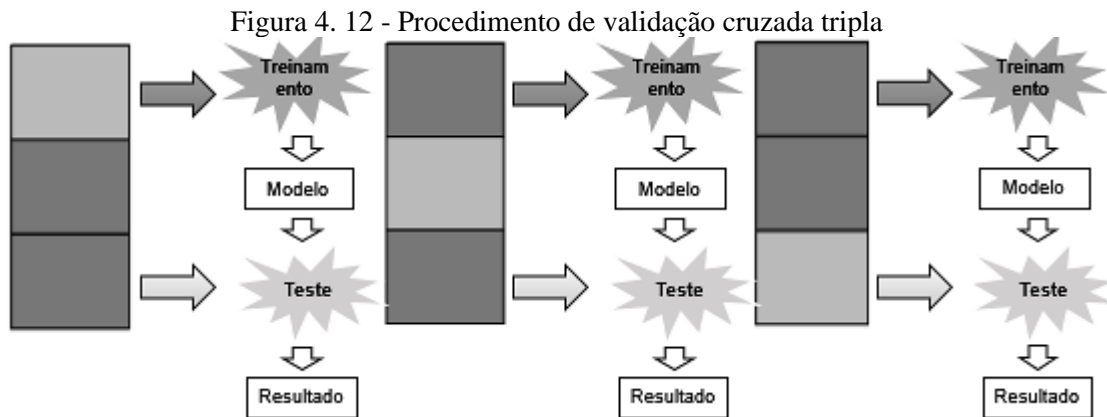
#### 4.4 MÉTODOS DE VALIDAÇÃO CRUZADA

A codificação de um mapeamento entre entrada e saída, ajustando os pesos sinápticos e limiares, numa rede perceptron de múltiplas camadas, é a base de um aprendizado por retropropagação. Portanto, espera-se que a rede torne-se bem treinada e aprenda o suficiente para uma generalização adequada. Sendo assim, o processo de aprendizagem transforma-se em uma escolha de parametrização da rede para determinado conjunto de dados. Observa-se nisto, o problema de seleção da rede em escolher, dentre um conjunto de estruturas, o conjunto ideal de acordo com certo critério (HAYKIN, 2001).

Neste contexto, a *validação cruzada* (do Inglês, *Cross-Validation (CV)*), que é uma ferramenta padrão estatística, divide o conjunto de dados, aleatoriamente, em conjuntos de treinamento e teste. O conjunto de treinamento é dividido adicionalmente em dois subconjuntos disjuntos, ou seja, subconjunto de estimação que é usado para selecionar o modelo e o subconjunto de validação, para testar e validar o modelo (HAYKIN, 2001).

Na validação cruzada típica, os conjuntos de treinamento e validação devem cruzar em rodadas sucessivas, de modo que cada ponto de dados tenha a chance de ser validado. A forma básica de validação cruzada é a validação cruzada  $k$ -fold. Outras formas de validação cruzada são casos especiais de validação cruzada  $k$ -fold, ou envolvem repetidas rodadas de validação cruzada  $k$ -fold (REFAEILZADEH *et al.*, 2009).

Na validação cruzada com  $k$ -fold, os dados são primeiro particionados em  $k$  segmentos de tamanhos iguais (ou quase iguais). Posteriormente,  $k$  iterações de treinamento e validação são executadas de modo que, em cada iteração, um segmento diferente dos dados seja mantido para validação, enquanto os  $k - 1$  segmentos restantes são usados para aprendizado. A Figura 4.12, ilustra um exemplo com  $k = 3$ . A seção mais escura dos dados é usada para treinamento, enquanto as seções mais claras são usadas para validação. Na mineração de dados e no aprendizado de máquina, a validação cruzada  $k = 10$ , é a mais comum (REFAEILZADEH *et al.*, 2009).



Fonte: Adaptado de Refaeilzadeh *et al.* (2009).

A validação cruzada é usada para avaliar ou comparar algoritmos de aprendizado da seguinte maneira: em cada iteração, um ou mais algoritmos de aprendizado usam  $k - 1$  segmentos de dados para aprender um ou mais modelos e, posteriormente, os modelos aprendidos são solicitados a fazer previsões sobre os dados no segmento de validação. O desempenho de cada algoritmo de aprendizado em cada segmento pode ser rastreado usando alguma métrica de desempenho predeterminada, como precisão. Após a conclusão,  $k$  amostras da métrica de desempenho estarão disponíveis para cada algoritmo. Diferentes metodologias, como a média, podem ser usadas para obter uma medida agregada dessas amostras, ou essas

amostras podem ser usadas em um teste de hipótese estatística para mostrar que um algoritmo é superior a outro.

Existem dois objetivos possíveis na validação cruzada:

- Estimar o desempenho do modelo aprendido a partir dos dados disponíveis usando um algoritmo, ou seja, avaliar a generalização de um algoritmo;
- Comparar o desempenho de dois ou mais algoritmos diferentes e descobrir o melhor algoritmo para os dados disponíveis ou, alternativamente, comparar o desempenho de duas ou mais variantes de um modelo parametrizado.

Os dois objetivos descritos anteriormente, estão altamente relacionados, uma vez que o segundo objetivo é alcançado automaticamente quando se conhece as estimativas precisas de desempenho. Dada uma amostra de  $N$  instâncias de dados e um algoritmo de aprendizado  $A$ , a precisão validada cruzada média de  $A$  nessas  $N$  instâncias, pode ser tomada como uma estimativa da precisão de  $A$ , em dados invisíveis, quando  $A$  é treinado em todas as  $N$  instâncias. Como alternativa, se o objetivo final for comparar dois algoritmos de aprendizado, as amostras de desempenho obtidas por meio da validação cruzada podem ser usadas para realizar testes de hipótese estatística de duas amostras, comparando um par de algoritmos de aprendizado (REFAEILZADEH *et al.*, 2009).

#### **4.4.1 Procedimentos de Validação Cruzada**

Geralmente ao treinar uma RNA, espera-se uma rede com uma capacidade de generalização máxima, ou seja, uma maior capacidade de resposta para dados nunca antes utilizados na fase de treinamento. Redes do tipo MLP, estão sujeitas ao chamado ‘*overtraining*’, ou seja, um sobre-treinamento quando a rede aparenta estar representando o problema cada vez melhor, em que o erro do conjunto de treinamento diminui gradativamente, e em algum ponto deste processo a capacidade de responder a um novo conjunto de dados se agrava (HAYKIN, 2001).

O procedimento de validação cruzada, geralmente é feito da seguinte maneira:

- Dividir o conjunto de dados em treinamento, validação e teste;

- Treinar somente com o conjunto de treinamento e avaliar o erro do conjunto de validação a cada  $k$  iterações (épocas);
- Interromper o treinamento quando o erro do conjunto de validação for maior do que  $k$  iterações atrás;
- Utilizar o conjunto de pesos anteriores como o resultado do treinamento.

Segundo Haykin (2001), esta abordagem utiliza o conjunto de validação para antecipar o comportamento em situações reais, ou em um conjunto de teste, assumindo que o erro em ambos os casos será semelhante, ou seja, o erro de validação geralmente é uma estimativa do erro de generalização.

#### 4.4.2 Particionamento do Conjunto de Dados

Para que haja sucesso no emprego de procedimentos de validação cruzada, é necessário que os conjuntos sejam estaticamente independentes e representativos do problema.

Em muitos casos, a avaliação de uma arquitetura desenvolvida ou aperfeiçoada, pode ser possível por meio da geração de um conjunto de amostras. Quando isso ocorre, tem-se mais liberdade e controle sobre os dados, de forma que os pré-requisitos de independência estatística e relevância das amostras podem ser atendidos.

Haykin (2001), propõe que o conjunto de dados seja dividido em: 50% para treinamento, 25% para validação e 25% para teste.

Após o treinamento da rede neural, por um número predefinido de épocas, ou seja, a apresentação de todos os padrões de treinamento disponível que corresponde a uma época, o treinamento é interrompido e a rede é testada com os dados de validação. Repete-se este processo até que o desempenho da rede com os dados de validação se estabilize em um valor considerado aceitável para o problema em análise. A motivação para esta divisão é validar o modelo em um conjunto de dados diferentes do usado para adaptar os pesos sinápticos. Evita-se também, com o emprego desta técnica, que ocorra *overtraining*. Uma rede treinada em excesso, aprende fortemente os dados de treinamento e apresenta péssima capacidade de generalizar este conhecimento.

### 4.4.3 Critérios de Parada

Uma rede perceptron de múltiplas camadas, treinada com *backpropagation*, aprende em estágios, ou seja, realizando funções de mapeamento razoavelmente simples para funções mais complexas. Isto se deve ao Erro Quadrado Médio<sup>9</sup> (EQM), que decresce com o aumento do número de épocas durante o treinamento, começando com um grande valor e decrescendo rapidamente, e então continua diminuindo lentamente até um mínimo local na superfície de erro, conforme a rede é executada. Como o objetivo é uma generalização eficaz, difícil é saber o melhor momento de parada (HAYKIN, 2001).

### 4.5 CONSIDERAÇÕES FINAIS DO CAPÍTULO

Este capítulo abordou sobre os conceitos, arquitetura e funcionamento, relativos às Redes Neurais Artificiais (RNA), que é uma das técnicas de inteligência artificial (AI), utilizada para identificar padrões. Inicialmente abordou-se o neurônio biológico, precursor das redes neurais artificiais, em termos de suas partes estruturais, ligações e estímulos. Em seguida definiu-se as redes neurais artificiais, estudando os tipos de redes simples e multicamadas; analisando o funcionamento de um neurônio artificial no que diz respeito ao treinamento, validação e o teste de múltiplos neurônios interconectados, como as redes aprendem e o método de validação cruzada. O capítulo seguinte, abordará a RNA proposta neste trabalho, responsável pela parametrização do simulador de ventilação mecânica, analisando sua arquitetura em termos de camadas, número de neurônios em cada camada, dados de entrada e saída, algoritmo de ativação e aprendizado.

---

<sup>9</sup> Média da diferença entre o valor do estimador e do parâmetro ao quadrado.



## 5 PROJETO DE SIMULAÇÃO

Este capítulo abordará as fases do projeto desenvolvido nesta dissertação, com relação ao programa simulador de ventilação mecânica, capaz de ajustar os parâmetros de um ventilador mecânico a nível de software, detalhando sua arquitetura, iniciando com a proposta da RNA, parte essencial do programa, analisando os dados de entrada da rede que irão gerar as possíveis saídas ajustadas do ventilador, bem como o número de camadas, as funções de ativação, os parâmetros de treinamento, assim como a implementação da interface em termos de botões, funções e funcionamento.

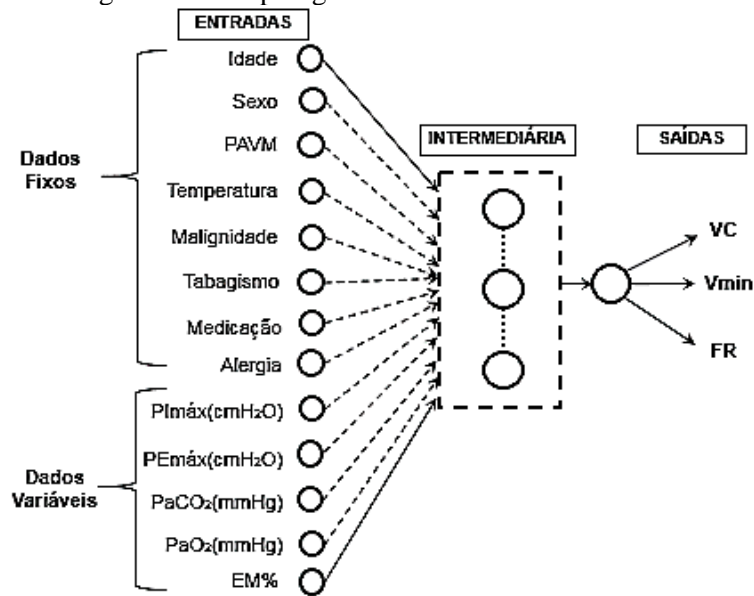
### 5.1 NÚMERO DE CAMADAS, ENTRADAS E SAÍDAS DA REDE NEURAL

A configuração para o número de camadas de entrada (*input layer*), intermediária ou escondida (*hidden layer*) e de saída (*output layer*), numa RNA, é de fundamental importância para o bom desempenho do projeto. Neste trabalho, a camada de entrada (*input layer*) da RNA proposta, consta de 13 neurônios. Estes neurônios correspondem a dados específicos, anteriormente apresentados no Capítulo 2, ou seja, os dados que o especialista, encarregado de ajustar o ventilador mecânico, observa no prontuário<sup>10</sup> do paciente e também por meio de dispositivos sensores ligados a este. Estes dados foram analisados, conforme suas características, e separados em duas classes: fixos e variáveis, como ilustrado na Figura 5.1.

---

<sup>10</sup> Documento que orienta médicos e outros profissionais na prestação de cuidados de saúde.

Figura 5.1 - Topologia da rede neural



Fonte: Elaboração própria do autor desta dissertação (2019).

Na ilustração da figura 5.1, observa-se que na entrada da rede há dois conjuntos de dados, ou seja, 8 *dados fisiológicos fixos*: idade, sexo, pneumonia associada a ventilação mecânica (PAVM), temperatura, malignidade<sup>11</sup>, tabagismo<sup>12</sup>, uso de medicamentos e alergia respiratória; e 5 *dados variáveis*: pressão inspiratória máxima (PImáx(cmH<sub>2</sub>O)), pressão expiratória máxima (PEmáx(cmH<sub>2</sub>O)), pressão arterial de gás carbônico (PaCO<sub>2</sub>(mmHg)), pressão arterial de oxigênio (PaO<sub>2</sub>(mmHg)) e espaço morto (EM%). A camada intermediária (*hidden layer*), é composta de 10 neurônios, que foram definidos de forma empírica após diversos testes. Segundo Souza (2012), a determinação de tal fator é subjetivo e depende exclusivamente de quem trabalha no projeto.

A camada de saída (*Output*), consiste de 3 neurônios, que correspondem aos 3 parâmetros ventilatórios ajustáveis do ventilador mecânico, a saber: o volume corrente (VC), a frequência respiratória (FR) e o volume minuto (Vmin). A escolha destes 3 parâmetros como saída da RNA, diz respeito a uma avaliação eficaz da impressão clínica do paciente para a indicação da VM (CARVALHO; TOUFEN; FRANÇA, 2007).

<sup>11</sup> É a característica de uma lesão que a classifica como câncer.

<sup>12</sup> Ato de se consumir cigarros ou outros produtos que contenham tabaco, cuja droga ou princípio ativo é a nicotina.

## 5.2 DOMÍNIO DOS DADOS DE ENTRADA E SAÍDA NA RNA

Para o uso dos dados, pela RNA, os mesmos foram divididos em fixos e variáveis, como vistos anteriormente e quantificados/valorados. Tal quantificação dos dados tornou-se necessário, pois a RNA não aceita, em suas entradas, letras do alfabeto e nem valores alfanuméricos. Sendo assim, para dados com atributos multivalorados, valores inteiros variando de 0 a 2, foram atribuídos, como por exemplo: o paciente é tabagista? Se a resposta for *sim* ( $s = 1$ ), *não* ( $n = 0$ ) e nenhuma das anteriores, cessação<sup>13</sup> ( $c = 2$ ). Os Quadros 5.1 e 5.2, ilustram os 13 dados de entrada, separados, com as suas respectivas quantificações em fixos e variáveis.

Quadro 5. 1 - Valores quantitativos: dados fixos

<b>Atributos</b>	<b>Domínio</b>
Idade	Anos (0 a 99)
Sexo	(0) masculino, (1) feminino
PAVM	Dias (1 a 30)
Temperatura	(0) normal, (1) alterada
Malignidade	(0) não, (1) sim
Tabagismo	(0) não fumante, (1) fumante, cessação (2)
Medicação	(0) não usa, (1) usa
Alergia	(0) não alérgico, (1) alérgico

Fonte: Sachetti *et al.* (2014).

Quadro 5. 2 - Valores quantitativos: dados variáveis

<b>Atributos</b>	<b>Domínio</b>
PImáx(cmH <sub>2</sub> O)	-70 a +70
PEmáx(cmH <sub>2</sub> O)	0 a 100
PaCO <sub>2</sub> (mmHg)	35 a 45
PaO <sub>2</sub> (mmHg)	0 a 100
EM%	25 a 40

Fonte: Sachetti *et al.* (2014).

<sup>13</sup> Indivíduo que deixou de ser tabagista.

Para a camada de saída (*Output*), os 3 neurônios, analisados anteriormente, possuem valores numéricos que variam da seguinte forma, conforme o Quadro 5.3:

Quadro 5.3 - Valores quantitativos: dados de saída

Atributos	Domínio
VC	0 a 2500mL
FR	12 a 22rpm
Vmin	5 a 8L/min

Fonte: Morato, Sandri e Guimarães (2015).

### 5.3 ESPECIFICAÇÕES DA RNA

A RNA proposta nesta dissertação é do tipo MLP, com algoritmo *backpropagation* e otimização *Levenberg-Marquadt*<sup>14</sup>, ou seja, um método que potencializa a eficiência do processo de treinamento visando diminuir o esforço computacional requerido (SILVA; SPATTI; FLAUZINO, 2010). A escolha da rede como sendo MLP, e do algoritmo *backpropagation*, se deve ao fato do supervisionamento, isto é, para cada amostra dos dados de entrada obtém-se a respectiva saída (resposta) desejada, que é uma característica comum neste tipo de arquitetura de rede, estudado no Capítulo 4, o qual é bastante utilizado em exemplos de aprendizado de máquina (SILVA, 2017).

O treinamento da rede neural proposta contou com o emprego das funções de ativação sigmoidais (*logsig*), nas camadas intermediárias, necessárias para obter a não-linearidade, ou seja, uma técnica que torna a RNA mais eficiente com relação a dados de entrada com grandes variações de valores (HAYKIN, 2001). Na camada de saída, foram utilizadas funções de ativação lineares (*purelin*), que segundo Morais (2011), são funções ideais para variáveis contínuas<sup>15</sup>, como exemplo da FR.

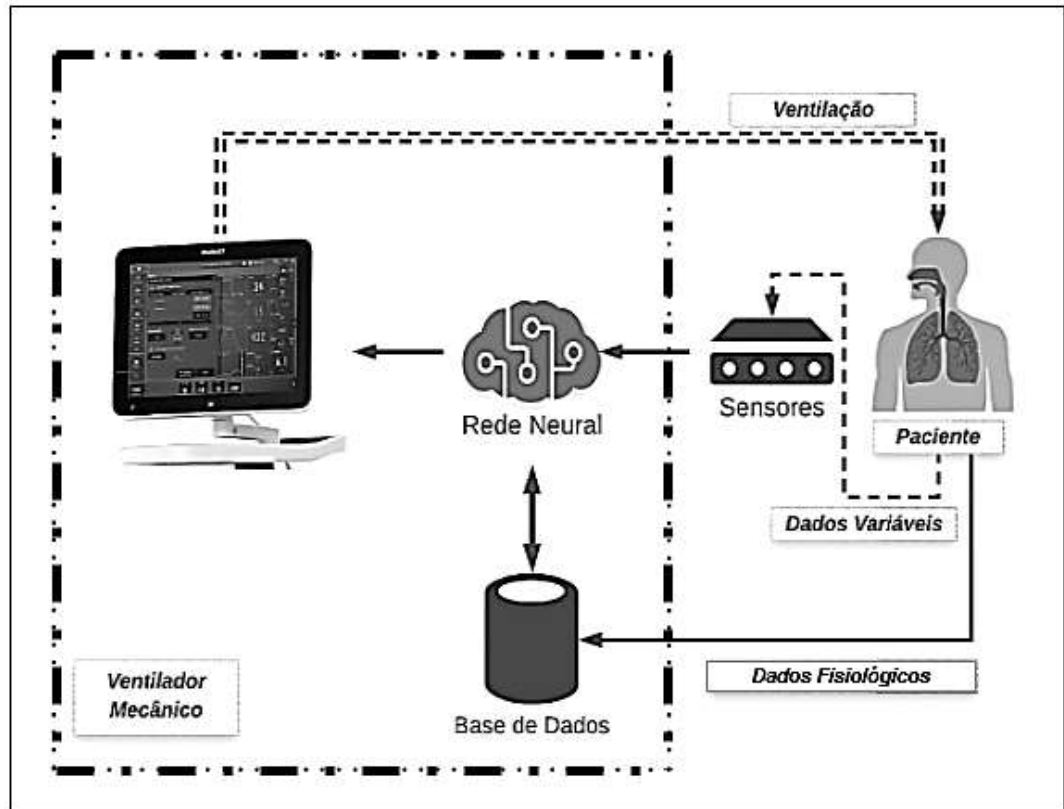
<sup>14</sup> Método que passa continuamente do método de máxima descida para o método de Gauss Newton.

<sup>15</sup> Características mensuráveis que assumem valores em uma escala contínua (na reta real), para as quais valores fracionais fazem sentido.

#### 5.4 ARQUITETURA DO PROJETO

A Figura 5.2, ilustra o esquema do projeto proposto neste trabalho, através de um diagrama em que se observa um paciente unido a um ventilador mecânico, cujo funcionamento é automatizado exclusivamente por uma RNA.

Figura 5. 2 - Projeto do ventilador automatizado



Fonte: Elaboração própria do autor desta dissertação (2019).

Na arquitetura proposta, esquematizada na figura 5.2, a automatização do ventilador (linha traço ponto), ocorre quando os dados fisiológicos de um determinado paciente, sob VM, são enviados para uma base de dados. Estes dados, posteriormente, são analisados pela RNA, já treinada anteriormente, a qual recebe também os dados variáveis, ou seja, os sinais obtidos, em tempo real, por meio dos dispositivos sensores conectados ao paciente. A RNA ao receber estes dados, fisiológicos e variáveis, por meio dos seus pesos ajustados, definirá qual a melhor configuração do ventilador para aquele paciente específico,

com base no treinamento anterior que recebeu, auxiliando a necessidade respiratória deste.

Cabe destacar que, a proposta de automatização do ventilador mecânico, não exclui a necessária supervisão de sua operação por um especialista, visto que, o tratamento dos dados clínicos, obtidos do paciente, necessários para a performance da RNA, depende do olhar crítico, dos conhecimentos, habilidades e técnicas de profissionais de saúde.

## 5.5 FERRAMENTA PARA DESENVOLVIMENTO DO PROGRAMA

A implementação do programa, baseado em Inteligência Artificial (IA), utilizando-se das técnicas de redes neurais artificiais (RNA), consistiu no planejamento de um projeto inicial em termos de interface, usabilidade e resultados.

O desenvolvimento do programa foi concebido no MATLAB<sup>®16</sup>, versão 9.4.0 R2018a. O MATLAB é uma linguagem moderna de programação de alto desempenho e ambiente de programação, para computação técnica. MATLAB inclui ferramentas de edição e depuração integrais, e suporta estruturas de dados complexas e programação orientada a objetos, em que as estruturas de dados tornam-se objetos que incluem dados e funções ou operações.

O *App Designer* foi a ferramenta do MATLAB utilizada na implementação do programa, o qual permite criar aplicativos profissionais. O mesmo integra as duas principais tarefas de criação de aplicativos, apresentando os componentes visuais de uma interface gráfica do usuário (GUI), e o comportamento do aplicativo de programação.

As especificações de hardware para este trabalho, contam com um computador com processador Intel<sup>®</sup> 17 Core™ 2 Duo CPU<sup>18</sup> T9400 de 2,53 GHz com 4,00 GB de memória RAM<sup>19</sup> DDR2, e sistema operacional de 64 Bits.

---

<sup>16</sup> © 1994-2019 The MathWorks, Inc. <https://www.mathworks.com/products/matlab.html>

<sup>17</sup> © Intel Corporation.

<sup>18</sup> Unidade central de processamento.

<sup>19</sup> *Random Access Memory*.

## 5.6 NÚMERO DE NEURÔNIOS DA CAMADA OCULTA DA RNA

O MATLAB disponibiliza algumas funções para a criação de RNA, das quais pode-se destacar:

```
net = cascadeforwardnet(hiddenSizes, trainFcn);
```

```
net = fitnet(hiddenSizes, trainFcn);
```

```
net = patternnet(hiddenSizes, trainFcn, performFcn);
```

```
net = feedforwardnet(hiddenSizes, trainFcn);
```

Dentre estas funções, a *feedforwardnet* foi utilizada na implementação do programa, visto que o funcionamento da mesma é por meio do algoritmo *backpropagation*, estudado no Capítulo 4, e por ter obtido excelente performance durante os testes. O parâmetro ‘hiddenSizes’ cria a RNA com determinado número de neurônio(s) na(s) camada(s) oculta(s), e o parâmetro ‘trainFcn’, que é opcional, determina o modelo de treinamento da rede.

Este trabalho analisou a performance do programa, de acordo com a resposta gerada para cada uma das funções citadas anteriormente. Para isto, buscou-se analisar o Erro Quadrado Médio (EQM), de cada rede criada, com a devida função estabelecida. A análise de cada função, foi importante para observar os requisitos de velocidade, respostas adequadas ao problema proposto nesta dissertação e escolha da função de criação da rede neural.

Segundo Suzuki (2013), o EQM é usado como uma função de erro, para calcular o erro em cada iteração, usando a saída de destino e a saída final, calculada do aprendizado em cada iteração. Se o erro ainda for maior que o valor de erro aceitável predefinido, o processo de treinamento continuará para a próxima iteração. O EQM, próximo de zero, indica uma boa precisão em determinada análise (CAVALCANTE, 2018). As Tabelas 5.1 e 5.2, ilustram os valores do EQM encontrados para cada rede analisada, por meio da função estabelecida, com determinado número de neurônios na camada intermediária, escolhidos de forma empírica.

Tabela 5. 1 - Valores do EQM com 10 neurônios

Função	Nº Neurônios	EQM
--------	--------------	-----

<i>cascaforwardnet</i>	10	4.024
<i>feedforwardnet</i>	10	0.2532
<i>fitnet</i>	10	1.113
<i>patternnet</i>	10	22.65

Fonte: Elaboração própria do autor desta dissertação (2019).

Tabela 5. 2 - Valores do EQM com 30 neurônios

<b>Função</b>	<b>Nº Neurônios</b>	<b>EQM</b>
<i>cascaforwardnet</i>	30	4.26e – 15
<i>feedforwardnet</i>	30	–1.3e – 12
<i>fitnet</i>	30	2.4e – 13
<i>patternnet</i>	30	17.67

Fonte: Elaboração própria do autor desta dissertação (2019).

Com base nestas duas tabelas, a função *feedforwardnet* alcançou o menor EQM, mas alguns fatores podem influenciar nos valores do EQM como, por exemplo, o número de camadas e número de neurônios.

## 5.7 INTERFACE DO PROGRAMA, ENTRADA E SAÍDA DE DADOS

Como já explicado anteriormente, os parâmetros de entrada da rede foram quantificados para uso no simulador. Conforme a Figura 5.3, a 1ª interface do programa simulador de ventilação mecânica, implementada no MATLAB, consta de 13 entradas que são os parâmetros de *Input*, da rede neural (lado esquerdo), ou seja, referente aos dados fisiológicos fixos e variáveis, e as 3 saídas (respostas), ou *Outputs* da RNA, que são os ajustes do ventilador mecânico (lado direito), a saber: volume corrente (VC), o volume por minuto (Vmin) e a frequência respiratória (FR).

Figura 5. 3 - Interface da simulação



The screenshot shows a software window titled "Tela Paciente" with a standard Windows-style title bar. The main content area is organized into four quadrants and a right-hand sidebar. The top-left quadrant, "Parâmetros Fixos", contains eight input fields with dropdown menus for "Idade", "Sexo", "PAVM", "T°", "Patologia", "Tabagista", "Medicação", and "Alergia", each with a range of options. The top-right quadrant, "Empregar a RNA", features a blue button with a right-pointing arrow and a small box containing the number "2". The bottom-left quadrant, "Parâmetros Variáveis", includes five input fields for "PImax(cmH2O)", "PEmax(cmH2O)", "PaCO2(mmHg)", "PaO2(mmHg)", and "EM(%)" with their respective ranges. The bottom-right quadrant, "Treinar Rede Neural", has a similar blue button and a box with the number "1". The right sidebar, set against a dark background, displays three large digital readouts: "Vol. Control." (yellow "0"), "Vol. Minuto" (green "0"), and "F. Resp. resp/min" (cyan "0"). To the right of each display are smaller numerical values: 2500 and 5 for the first, 40.0 and 3.5 for the second, and 100 and 4 for the third.

Fonte: Elaboração própria do autor desta dissertação (2019).

Observa-se pela figura, que alguns dados ao serem preenchidos, com exceção da idade, possuem atributos multivalorados, determinados intuitivamente, cabendo ao usuário escolher entre duas opções ou mais. Esses dados são os '*Parâmetros Fixos*' (lado superior esquerdo), a exemplo do atributo '*sexo*', com duas opções: *masculino* (M) ou *feminino* (F), e '*tabagista*' que possui três opções: *sim* (S), *não* (N) e *cessação* (C). Esta configuração foi estabelecida para evitar que dados inseridos, de forma incorreta ou ambígua, prejudiquem a resposta do sistema.

Para os dados variáveis em '*Parâmetros Variáveis*' (lado inferior esquerdo), que são coletados em tempo real, por meio de dispositivos sensores<sup>20</sup> acoplados ao corpo de um paciente, tal preenchimento é realizado de forma instantânea pelo sistema em seu funcionamento.

<sup>20</sup> Vide Capítulo 2.


## 5.8 FUNCIONAMENTO

A 1ª interface do programa possui dois botões. Um botão para empregar a RNA e outro para treinamento da RNA. O programa, no geral, é implementado com duas telas (interfaces): uma para treinamento da RNA e outra para empregar a rede neural.

### 5.8.1 Treinamento da RNA

Conforme a figura da 1ª interface, vista anteriormente, o funcionamento do programa tem seu início com o treinamento da rede neural, acionando o botão conforme ilustrado na Figura 5.4, em 5.4(1), chamando a tela de treinamento (2ª interface).

Figura 5. 4 - Botão tela de treinamento



Fonte: Elaboração própria do autor desta dissertação (2019).

O código responsável em chamar a tela de treinamento, após o acionamento do botão, pode ser visualizado na Figura 5.5.

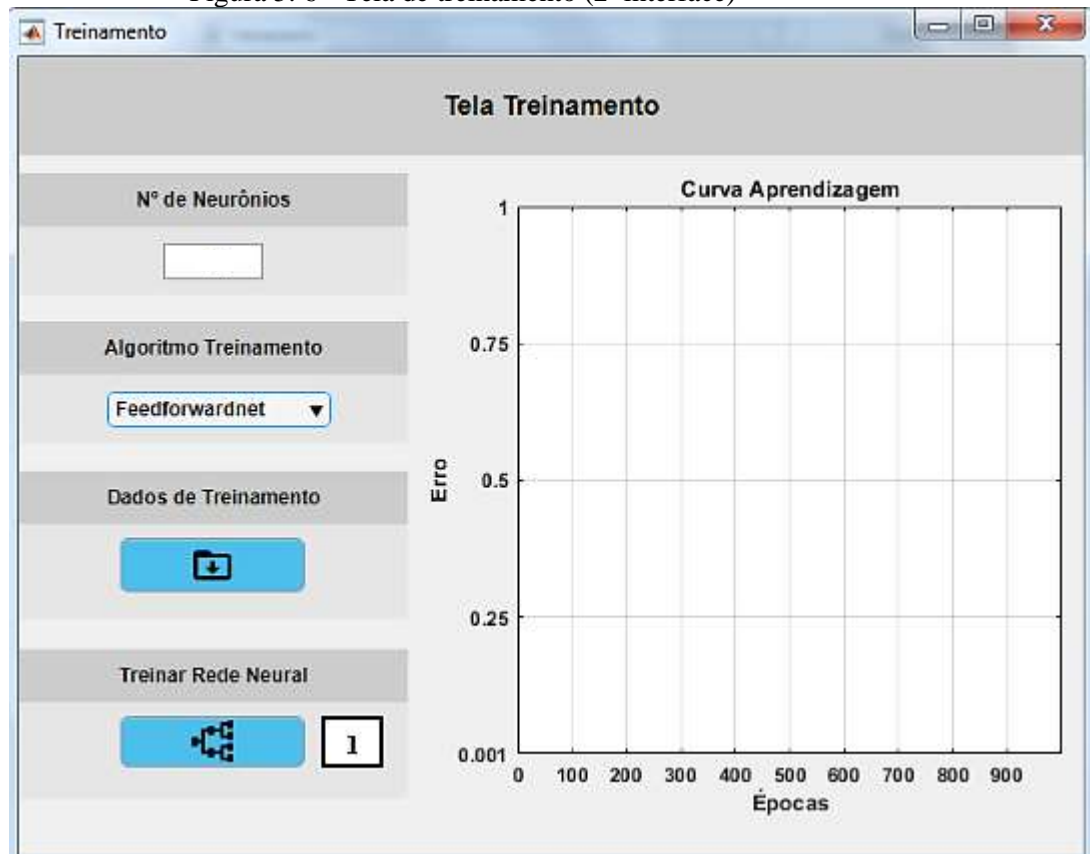
Figura 5. 5 - Código que chama a 2ª interface (tela de treinamento)

```
% Button pushed function: TreinarRedeNeuralButton
function TreinarRedeNeuralButtonPushed(app, event)
    % Desabilita botão Treina Rede Neural
    app.TreinarRedeNeuralButton.Enable = 'off';
    % Chama a Tela de Treinamento
    app.Call_Train = Tela_Treinamento;
end
```

Fonte: Elaboração própria do autor desta dissertação (2019).

Nesta figura, é possível observar que dentro da função ‘TreinarRedeNeural ButtonPushed(app, event)’, tem-se a linha de código: ‘*app.Call\_Train = Tela\_Treinamento;*’ a qual tem a função de abrir/chamar a 2ª interface, ou seja, a tela de treinamento, conforme a Figura 5.6.

Figura 5. 6 - Tela de treinamento (2ª interface)



Fonte: Elaboração própria do autor desta dissertação (2019).

A tela da 2ª interface, é implementada com as opções de: número de neurônios na camada intermediária e escolha do algoritmo de treinamento, que são importantes para o ajuste dos pesos e configuração da RNA, se o administrador do sistema assim o desejar. Nesta tela também consta um gráfico para a visualização da curva de aprendizagem da rede e mais dois botões, ou seja, um botão para o carregamento dos dados e outro para o treinamento da rede.

O código da função de treinamento da rede, após o acionamento do botão em 5.6(1), pode ser visualizado na Figura 5.7.

Figura 5. 7 - Código de treinamento da rede

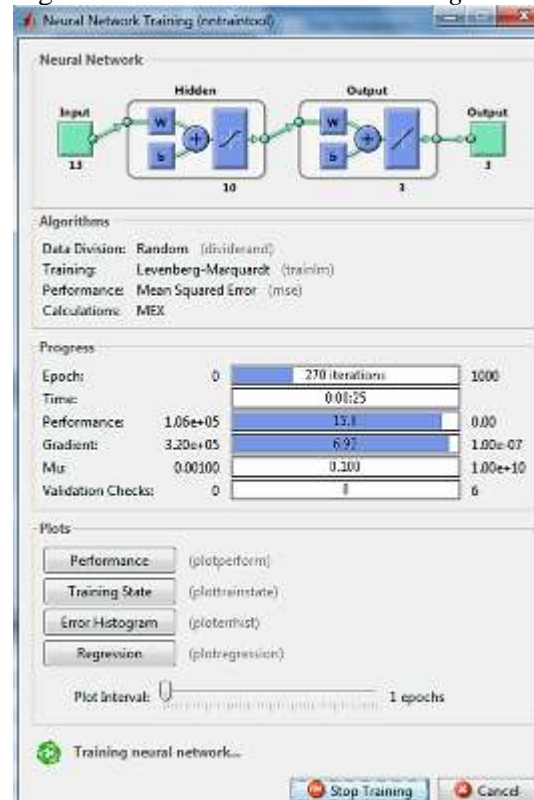
```

%***** Função para treinar a RN *****
function [net] = TreinarRN(app)
    app.i = Dados_Input(app);
    app.t = Dados_Target(app);
    net = feedforwardnet(10);
    net = train(net, app.i, app.t);
    [net,tr] = train(net,app.i ,app.t);
    nntraintool    % exibe a tela de treinamento
    plotperform(tr) % exibe gráfico de performance
    view(net)      % exibe a rede
end

```

Fonte: Elaboração própria do autor desta dissertação (2019).

Nesta figura, observa-se dentro da função ‘TreinarRN(app)’, além dos dados de entrada ( $app.i = \text{Dados\_Input}(app)$ ) e dados de saída ( $app.t = \text{Dados\_Target}(app)$ ), a função *feedforwardnet* com o número de 10 neurônios. Ao iniciar o treinamento da RNA, a linha ‘*nntraintool*’ automaticamente executa o *Neural Network Training*, uma aplicação do MATLAB que exibe em tempo real o treinamento da rede, conforme a Figura 5.8.

Figura 5. 8 - *Neural Network Training*

Fonte: Elaboração própria do autor desta dissertação (2019).

Vários são os dados exibidos na tela do *Neural Network Training*, como por exemplo, a estrutura da rede criada; algoritmos de treinamento; botões para plotagem dos gráficos de performance, estágios de treinamento, histograma de erros e regressão.

### 5.8.2 Emprego da RNA na 1ª interface

Após o treinamento da RNA na 2ª interface, ocorre na 1ª interface a inserção/admissão dos dados fixos e variáveis pelo usuário, vistos anteriormente neste capítulo, por meio do preenchimento dos campos de parâmetros. As respostas geradas pela RNA, após o preenchimento dos campos, inicia-se com a ativação do botão ‘*Empregar a RNA*’, conforme a Figura 5.9(2), gerando os resultados de saída que são os ajustes do ventilador mecânico.

Figura 5. 9 - Botão para empregar a RNA



Fonte: Elaboração própria do autor desta dissertação (2019).

A função que simula os resultados de saída do programa, conforme o padrão gerado pela RNA, pode ser visualizado na Figura 5.10.

Figura 5. 10 - Função que emprega a RNA

```

%***** Função Emprega RNA *****
function EmpregaRN(app, net)
    app.i = InserePaciente(app);
    app.a = sim(net, app.i');
    app.VolControlado.Value = app.a(3);
    app.VolMinuto.Value = app.a(2);
    app.FreqResp.Value = app.a(1);
    app.TreinarRedeNeuralButton.Enable = 'on';
end

```

Fonte: Elaboração própria do autor desta dissertação (2019).

Conforme esta figura, na função ‘*EmpregaRN(app, net)*’, a linha de código ‘*InserePaciente(app)*’ contém o vetor onde todos os dados de um paciente foram inseridos e o armazena na variável ‘*app.i*’. A função ‘*sim(net, app.i)*’ simula os dados do vetor conforme o padrão estabelecido pelo treinamento da RNA ocorrido na 2ª interface. Os valores obtidos após

a simulação são armazenados na variável ‘*app.a*’ e, finalmente, as saídas geradas pelo programa, correspondentes aos parâmetros ventilatórios FR, Vmin e VC, constituem os valores encontrados pelas linhas de código: ‘*app.FreqResp.Value = app.a(1)*’, ‘*app.VolMinuto.Value = app.a(2)*’ e ‘*app.VolControlado.Value = app.a(3)*’.

A Figura 5.11, ilustra um exemplo prático que resume todas as fases do programa descritas até aqui, ou seja, após o treinamento da RNA, os dados fixos (lado superior esquerdo), e variáveis (lado inferior esquerdo), de um paciente, são inseridos na 1ª interface do programa.

Figura 5. 11 - Exemplo da Simulação

The screenshot shows a software interface titled 'Tela Paciente' with the following sections:

- Parâmetros Fixos:**
  - Idade: 45 (range 0 - 100)
  - Sexo: M (dropdown, options M, MF)
  - PAVM: 5 (dropdown, options 5, Dias)
  - T<sup>o</sup>: S (dropdown, options S, S/N)
  - Patologia: N (dropdown, options N, S/N)
  - Tabagista: S (dropdown, options S, S/N/C)
  - Medicação: N (dropdown, options N, S/N)
  - Alergia: N (dropdown, options N, S/N)
- Empregar a RNA:** A blue button with a right-pointing arrow.
- Parâmetros Variáveis:**
  - P<sub>lmáx</sub>(cmH<sub>2</sub>O): -21 (range -70 a +70)
  - P<sub>Emáx</sub>(cmH<sub>2</sub>O): 32 (range 0 a 100)
  - PaCO<sub>2</sub>(mmHg): 51 (range 0 a 150)
  - PaO<sub>2</sub>(mmHg): 51 (range 0 a 150)
  - EM(%): 68 (range 1 a 100%)
- Treinar Rede Neural:** A blue button with a right-pointing arrow.
- Results (Right Panel):**
  - Vol. Control:** 546 (range 2500, 5)
  - Vol. Minuto:** 7 (range 40.0, 3.5)
  - F. Resp. resp/min:** 17 (range 100, 4)

Fonte: Elaboração própria do autor desta dissertação (2019).

Conforme a figura: um paciente com idade: 45, masculino, PAVM (5 dias), apresenta hipertermia, não apresenta malignidade, tabagista; não medicado, não alérgico, P<sub>imáx</sub> = -21, P<sub>emáx</sub> = 32, PaCO<sub>2</sub> = 51, PaO<sub>2</sub> = 51 e EM (68%); após a simulação, apresenta como resultados ventilatórios (lado direito do programa): Frequência Respiratória (FR) = 17; Volume por minuto (Vmin) = 7 e Volume Corrente (VC) = 546.

## 5.9 CONSIDERAÇÕES FINAIS DO CAPÍTULO

As fases da implementação de um programa, capaz de simular os ajustes dos parâmetros de um ventilador mecânico, a nível de software, utilizando-se de redes neurais artificiais (RNA), foi o assunto deste capítulo; o qual abordou a arquitetura da RNA do projeto, em termos de dados de entrada e saída, assim como o número de camadas, algoritmo de treinamento e funções de ativação; a ferramenta utilizada na criação do programa, no caso o MATLAB, detalhando a função de criação da rede neural, assim como as interfaces, no que diz respeito aos seus parâmetros de entrada, suas funções e suas respectivas saídas. No próximo capítulo, serão detalhados os resultados alcançados, por meio dos experimentos realizados no simulador proposto.

## 6 RESULTADOS E DISCUSSÃO

Este capítulo apresenta os resultados do programa simulador de ventilação mecânica, proposto neste trabalho. Por meio de diversos testes e análises, a RNA que é parte do programa, será discutida com base nas respostas produzidas, por meio dos dados obtidos, gráficos gerados e a análise de entrevistas.

### 6.1 AQUISIÇÃO DOS DADOS E TREINAMENTO DA RNA

Para este estudo, foram coletados dados a partir de uma base de registros de 94 pacientes, da UTI do Hospital São Vicente de Paulo, na região norte do Estado do Rio Grande do Sul, em 2011, e foram cedidos por um membro<sup>21</sup> da equipe para este trabalho.

Foram obtidos dados ventilatórios e fisiológicos dos pacientes, no momento da admissão e, em especial, de pacientes adultos e com pneumonia. O estudo foi aprovado pelo Comitê de Ética da Universidade de Passo Fundo, sob o parecer 453/2011, sem a necessidade de consentimento informado do paciente (SACHETTI *et al.*, 2014).

Sendo 94 pacientes, tem-se um total de  $94 \times 13 = 1222$  dados de entrada (*Input*), e  $94 \times 3 = 282$  dados de saída (*Output*) da RNA, Quadro A.1 (Apêndice A). Esses dados foram analisados e quantificados, conforme visto no Capítulo 5.

Para realização do treinamento da RNA, foi definido o aprendizado supervisionado *off-line*<sup>22</sup> com validação cruzada por amostragem aleatória (*random subsampling cross-validation*), em que o conjunto total de dados (amostras) disponíveis é aleatoriamente dividido em duas partes: o subconjunto de treinamento (70%) e o subconjunto de teste/validação (30%), conforme sugerido por Silva, Spatti e Flauzino (2010). Para o teste de generalização da rede, ou seja, a capacidade de resposta da rede para dados nunca utilizados, foi separado um conjunto com os dados inéditos de 10 pacientes, Tabela B.1 (Apêndice B), tomados um a um, cujos parâmetros de cada um deles foram inseridos na rede, e as saídas geradas foram analisadas por

---

<sup>21</sup> Profa. Dra. Viviane Rech, professora do Departamento de Fisioterapia, União Metropolitana de Educação e Cultura, UNIME, Brasil.

<sup>22</sup> Um grande volume de dados é examinado uma única vez, induzindo um único modelo de predição, o qual não é mais revisado por novos dados.



um grupo de pessoas que foram entrevistadas por meio de um questionário. O número máximo de épocas de treinamento foi estabelecido em 1000.

O conjunto de treinamento é utilizado no ajuste dos pesos, o conjunto de validação é utilizado para estimar a capacidade de generalização da rede durante o processo de aprendizagem e o conjunto de testes, responsável pela avaliação dos modelos (CAVALCANTE, 2018).

## 6.2 DESEMPENHO DA RNA (ABORDAGEM QUANTITATIVA)

A validação do simulador ocorreu depois de inúmeros testes, iniciando a partir de entradas já conhecidas com suas devidas saídas, para determinar se a RNA estava, de fato, ‘aprendendo’. O número de neurônios, da camada intermediária da rede, foi modificado empiricamente, mudando gradativamente seu valor para encontrar a performance ideal, ficando estabelecido em 10 neurônios.

A análise das simulações com os 10 pacientes<sup>23</sup>, pode ser visualizada na Tabela C.1 (Apêndice C). Nesta tabela, estão os possíveis parâmetros ajustáveis do ventilador mecânico, a saber: frequência respiratória (FR), o volume por minuto (Vmin) e o volume corrente (VC), gerados pelo programa para cada paciente, de acordo com os dados fisiológicos destes, contidos na Tabela B.1 (Apêndice B).

Inicialmente foi estabelecido, empiricamente, um número de 4 simulações para analisar as respostas da RNA, após treinada, com os 94 pacientes. Ao iniciar a primeira simulação, os resultados obtidos não demonstraram valores aceitáveis, que deveriam estar dentro de determinada faixa com relação aos parâmetros ventilatórios<sup>24</sup>, como por exemplo, a FR e VC muito elevados Pac07 (FR = 31; VC = 1188), Tabela C.1 (Apêndice C). Sendo assim, aumentou-se o número de dados de treinamento com pequenos ajustes e passou-se para segunda simulação, a qual também não demonstrou êxito em determinados resultados como, por exemplo, o Pac02 (FR = 30; VC = 617). Após um novo acréscimo nos dados de treinamento, com o mesmo tratamento feito na simulação anterior, observou-se resultados satisfatórios com a terceira simulação. Na quarta simulação, os procedimentos feitos nas simulações anteriores

---

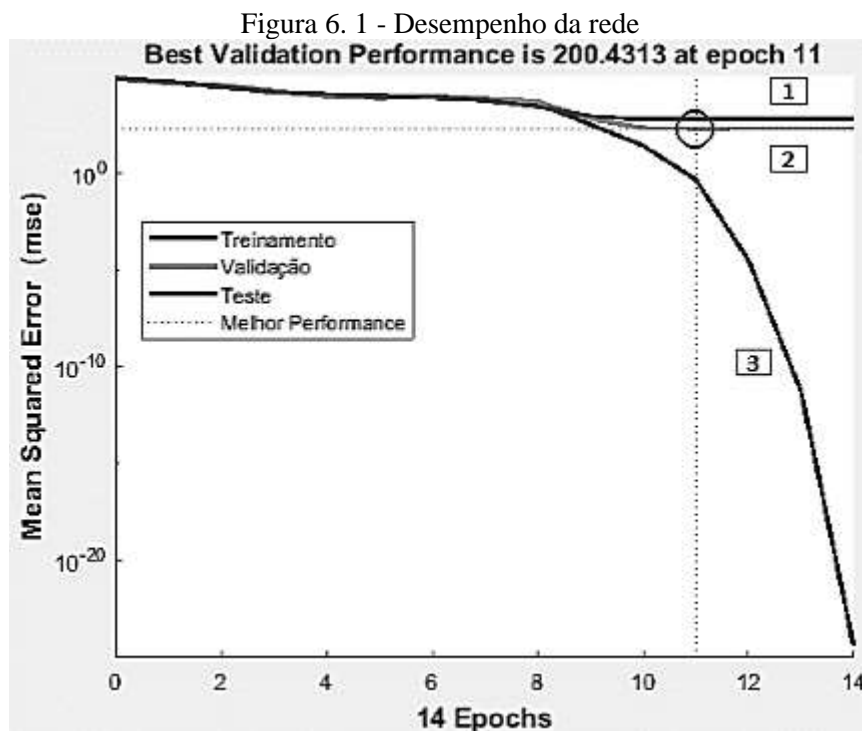
<sup>23</sup> Vide seção 7.1.

<sup>24</sup> Vide Capítulo 2.

foram repetidos e os valores gerados já se encontravam dentro de valores aceitáveis em ventilação mecânica, cabendo a validação destes por especialistas. Os resultados obtidos nas simulações foram observados por meio da geração de gráficos como performance, regressão, erro e matriz de confusão.

### 6.2.1 Gráfico de Performance

Na análise do gráfico de performance, conforme ilustra a Figura 6.1, nota-se que as curvas de teste (1), e validação (2) são bastante semelhantes, o que demonstra um treinamento adequado.



Fonte: Elaboração própria do autor desta dissertação (2019).

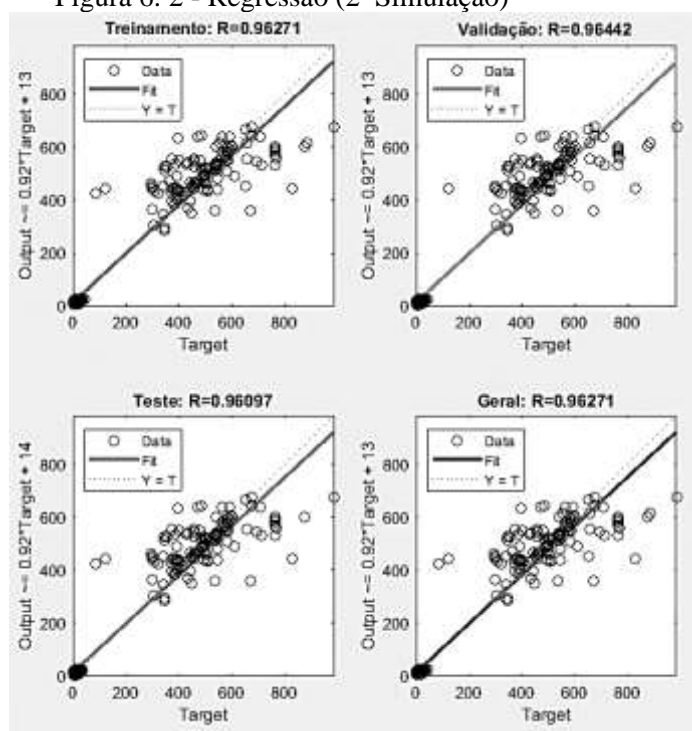
Na análise deste gráfico, se a curva de teste tivesse aumentado bruscamente, afastando-se da curva de validação, então possivelmente algum *overfitting*<sup>25</sup> poderia ter ocorrido (BEALE; HAGAN; DEMUTH, 2017).

<sup>25</sup> Deficiências na capacidade de generalização de um classificador.

## 6.2.2 Gráficos de Regressão

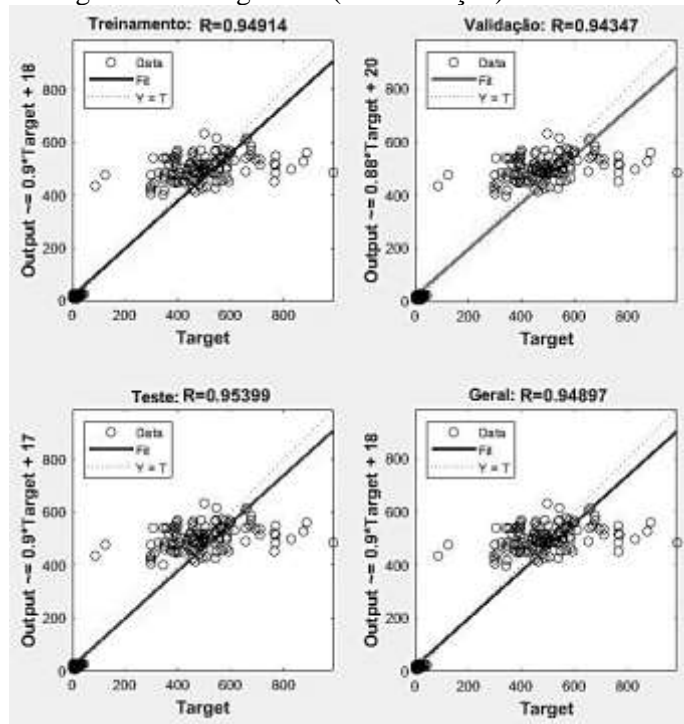
As Figuras 6.2, 6.3 e 6.4, que representam gráficos de regressão, referem-se aos dados de treinamento, teste e validação das simulações 2, 3 e 4 da Tabela C.1 (Apêndice C), escolhidos aleatoriamente como exemplos. Esses gráficos destacam a relação entre as saídas (*Outputs*) da RNA, e os alvos desejados (*Targets*). Quando o treinamento é eficiente, as saídas da rede e os alvos são exatamente iguais, mas, na prática, esta relação raramente acontece. A linha tracejada, em cada plotagem, representa o resultado eficiente, ou seja,  $Outputs = Targets$ .

Figura 6. 2 - Regressão (2ª Simulação)



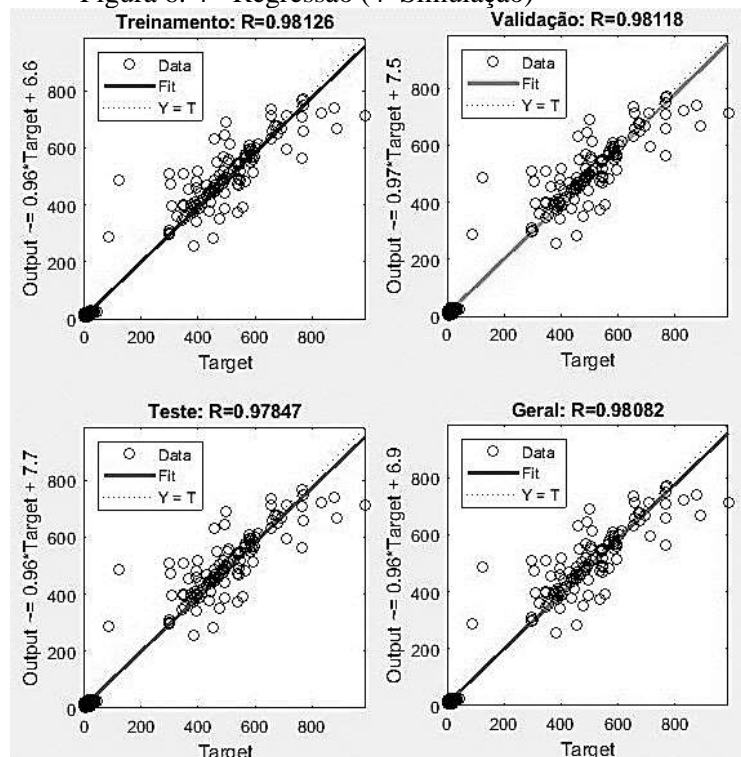
Fonte: Elaboração própria do autor desta dissertação (2019).

Figura 6. 3 - Regressão (3ª Simulação)



Fonte: Elaboração própria do autor desta dissertação (2019).

Figura 6. 4 - Regressão (4ª Simulação)



Fonte: Elaboração própria do autor desta dissertação (2019).

A linha sólida de ajuste (*Fit*), representa a regressão linear de melhor ajuste, entre as saídas e os alvos desejados. No gráfico da figura 6.4, por exemplo, observa-se que os dados estão menos dispersos e mais alinhados ao longo da linha *Fit*, em comparação aos gráficos das figuras 6.2 e 6.3, demonstrando um ajuste adequado. O valor *R* é uma indicação da relação entre as saídas e os alvos desejados. Se  $R = 1$ , isso indica que existe uma relação linear exata entre as saídas e os alvos. Se *R* estiver próximo de zero, não haverá relação linear entre as saídas e os alvos (BEALE; HAGAN; DEMUTH, 2017). A Tabela 6.1, ilustra os valores de *R* para as fases de treinamento, validação, teste e geral, das simulações 2, 3 e 4 da Tabela C.1 (Apêndice C).

Tabela 6. 1 - Valores de R

Fases	Simulação 2	Simulação 3	Simulação 4
<b>Treinamento</b>	0.96271	0.94914	0.98126
<b>Validação</b>	0.96442	0.94347	0.98118
<b>Teste</b>	0.96097	0.95399	0.97847
<b>Geral</b>	0.96271	0.94897	0.98082


Fonte: Elaboração própria do autor desta dissertação (2019).

Os resultados observados na Tabela 6.1, indicam que na ‘Simulação 4’, os valores de *R* para treinamento, validação e teste aproximam-se de 1, o que pode ser constatado como um ajuste satisfatório. Segundo Morais (2011), um valor alto de *R* não implica, necessariamente, que o modelo de regressão é adequado. O gráfico de dispersão é útil para mostrar que certos pontos de dados têm ajustes ruins e que, se a RNA não for suficientemente precisa, pode ser necessário um novo treinamento da mesma.

### 6.2.3 Gráfico de Erro

A verificação do histograma de erros, auxilia numa verificação adicional do desempenho da RNA. A Figura 6.5, representa o histograma de erro da 4ª simulação da Tabela C.1 (Apêndice C). Nesta figura tem-se as barras de treinamento, validação, teste e zero erro.

Figura 6.5 - Histograma de erro (4ª Simulação)



Fonte: Elaboração própria do autor desta dissertação (2019).

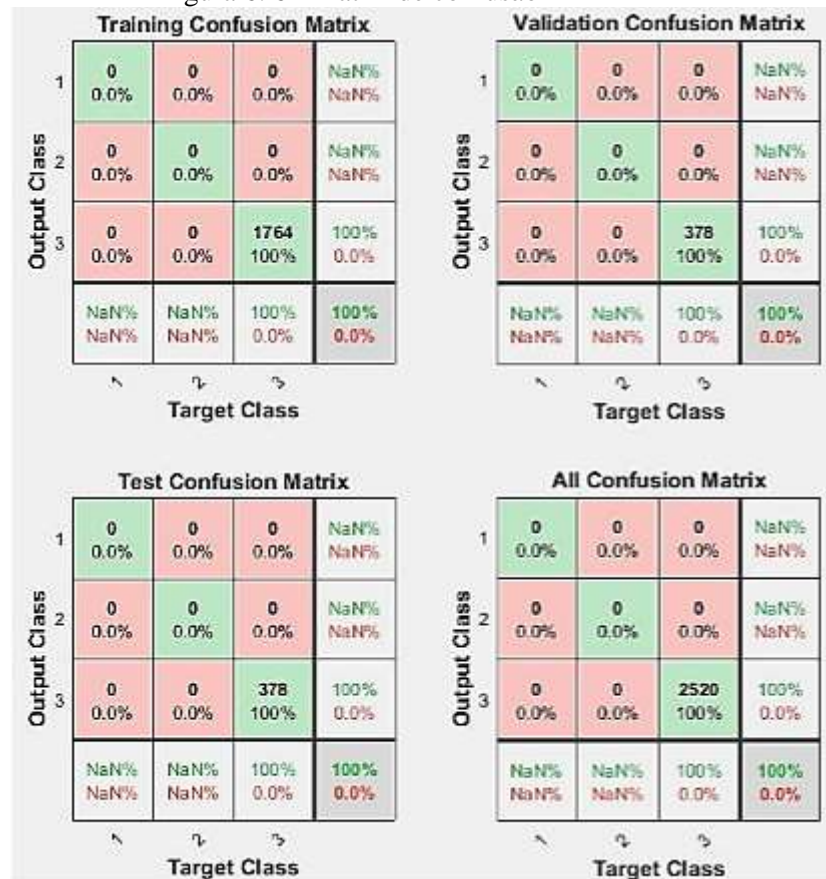
Este histograma pode fornecer uma indicação de *outliers*, ou seja, pontos de dados em que o ajuste é significativamente pior que a maioria dos dados. Nesse caso, é possível ver que, embora a maioria dos erros esteja aproximadamente entre -9 e 9, há um ponto de treinamento com um erro de aproximadamente -10, e pontos de validação com erros de -16 e 11. Esses valores discrepantes também são visíveis no gráfico de regressão, de teste, no gráfico da figura 6.4. O primeiro corresponde ao ponto com um alvo de 800 e saída próxima a 600. É sempre necessário verificar os *outliers* para determinar se os dados estão inconsistentes, ou se esses pontos de dados são diferentes do resto do conjunto de dados (BEALE; HAGAN; DEMUTH, 2017). Se os *outliers* forem pontos de dados válidos, mas forem diferentes do resto dos dados, a rede está extrapolando para esses pontos. Sendo assim, é imprescindível coletar mais dados parecidos com os pontos discrepantes e treinar novamente a rede.

#### 6.2.4 Matriz de Confusão

Uma matriz de confusão é a forma objetiva de avaliar o desempenho de uma classificação quantitativamente (PASSO, 2013). No gráfico da matriz de confusão, as linhas correspondem à classe prevista (classe de saída), e as colunas correspondem à classe verdadeira (classe de destino). A Figura 6.6, ilustra a resposta quantitativa em relação ao desempenho da RNA. As células diagonais correspondem às observações classificadas corretamente como, por

exemplo, na figura a fase de treinamento ocorreu com uma classificação de 1764, com 100% de precisão; na fase de validação e teste, ambas obtiveram 378 e também 100% de precisão. As células fora da diagonal correspondem a observações classificadas incorretamente, o que segundo a figura não houve. O número de observações e a porcentagem do número total de observações são mostrados em cada célula.

Figura 6. 6 - Matriz de confusão



Fonte: Elaboração própria do autor desta dissertação (2019).

A coluna na extrema direita do gráfico mostra as porcentagens de todos os exemplos previstos para pertencer a cada classe que são classificados correta e incorretamente. Essas métricas costumam ser chamadas de precisão (ou valor preditivo positivo) e taxa de descoberta falsa, respectivamente. A linha na parte inferior do gráfico, mostra as porcentagens de todos os exemplos pertencentes a cada classe que são classificados correta e incorretamente. Essas métricas são frequentemente chamadas de *recall* (ou taxa positiva verdadeira) e taxa de falso negativo, respectivamente.

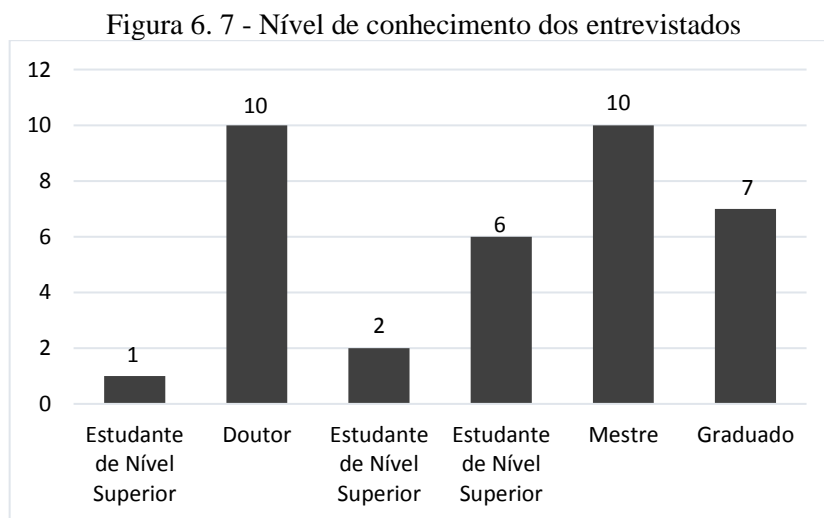
### 6.3 DESEMPENHO DA RNA (ABORDAGEM QUALITATIVA)

A validação do programa simulador de ventilação mecânica, além das respostas adquiridas por meio dos testes de performance, regressão e erro; contou com a opinião de estudantes e especialistas da área de fisioterapia, por meio de uma pesquisa com caráter de amostragem não-probabilística intencional (LAKATOS, MARCONI, 2002).

#### 6.3.1 Análise de Especialistas e Estudantes

Para este trabalho, um grupo de seis pessoas, entre estudantes e especialistas da área de saúde, ou seja, um doutor Ph.D., um mestre, três estudantes de nível superior e um graduado, todos do ramo da fisioterapia e com diferentes níveis de conhecimento, foram convidados para uma pesquisa de opinião acerca do projeto desta dissertação. Um formulário com cinco questões foi desenvolvido no Google Forms<sup>26</sup> e enviado aos entrevistados.

Antes de responder as cinco perguntas, no questionário constava uma enquete que visava saber o grau de conhecimento de cada um acerca de ventilação mecânica. Dependendo do nível de conhecimento e especialização, um determinado peso foi atribuído visando uma acurácia melhor dos resultados. Na Figura 6.7, estão os percentuais de conhecimento conforme informado no questionário.



Fonte: Elaboração própria do autor desta dissertação (2019).

<sup>26</sup> <https://www.google.com/forms/about/>



O questionário consta de 5 casos escolhidos da Tabela B.1 (Apêndice B), de forma aleatória, dentre os 10 pacientes inéditos mencionados anteriormente.

Para cada caso, foram levantados questionamentos sobre as saídas geradas pela simulação, no caso a 4ª Simulação da Tabela C.1 (Apêndice C), escolhida conforme a seção 6.2 deste Capítulo. Os entrevistados deveriam examinar se as saídas, a saber: a frequência respiratória (FR), o volume por minuto (Vmin) e o volume corrente (VC), estariam dentro dos valores ventilatórios considerados aceitáveis em ventilação mecânica, conforme os dados inseridos nas entradas do programa, ou seja, os parâmetros de cada paciente.

### 6.3.2 Questionário Para os Entrevistados

As perguntas para cada caso, foram tratadas da seguinte forma, conforme o Quadro 6.1, supondo um paciente X após a análise de seus dados.

Quadro 6. 1 - Questionário da simulação

Considerando os dados do paciente X citados, a configuração automática sugerida pelo simulador e sua experiência pessoal, avalie:
A) É coerente para este paciente a frequência respiratória (FR) = Y?
B) É coerente para este paciente o volume por minuto (Vmin) = W?
C) É coerente para este paciente o volume corrente (VC) = Z?
D) É coerente para este paciente a combinação: Frequência respiratória (FR) = Y; Volume por Minuto (Vmin) = W; Volume Corrente (VC) = Z?

Fonte: Elaboração própria do autor desta dissertação (2019).

Com base em cada pergunta do quadro, os entrevistados tinham que responder sua opinião numa escala *Likert*, dentro de uma faixa de 1 a 7, concordando ou discordando dos dados apresentados. Conforme o Quadro 6.2, as faixas da escala possuem as seguintes legendas.

Quadro 6. 2 - Faixas e legendas da escala

Faixa	Legenda
1	Discordo totalmente
2	Discordo parcialmente
3	Discordo
4	Neutro
5	Concordo
6	Concordo parcialmente
7	Concordo totalmente

Fonte: Elaboração própria do autor desta dissertação (2019).

Segundo Cunha (2007, p. 24) “a escala tipo Likert é composta por um conjunto de frases (itens) em relação a cada uma das quais se pede ao sujeito que está a ser avaliado para manifestar o grau de concordância desde o *discordo totalmente* (nível 1), até ao *concordo totalmente* (nível 5, 7 ou 11).”

Os entrevistados tinham a opção de fazer observações acerca de cada caso, se assim o desejassem. Tais observações foram importantes para a análise e validação das simulações, no que tange aos valores encontrados e comparados a dados clínicos reais.

### 6.3.3 Respostas aos Resultados Obtidos

Cada caso analisado pelos entrevistados, foram apresentados em quadros com os devidos dados do paciente. Em cada quadro, os pacientes são identificados por um código PacXX, ou seja, Pac significa ‘paciente’, ‘XX’ uma numeração de 1 a 10, seus dados fisiológicos e respiratórios. Os resultados obtidos na pesquisa foram expressos por meio de gráficos que mostram a avaliação para cada questão levantada na simulação, por todos os entrevistados.

#### 6.3.3.1 Caso 1

O primeiro caso analisa um paciente de 45 anos, sexo masculino, com PAVM de 5 dias, apresentando alteração de temperatura e tabagista, conforme o Quadro 6.3. O questionário para este caso consta no Quadro 6.4.

Quadro 6. 3 - Dados do paciente Pac01

Paciente	Idade	Sexo	PAVM	T°	Tabagista	Pimáx	Pemáx	PaCO <sub>2</sub>	PaO <sub>2</sub>	EM%
Pac01	45	M	5	S	S	-21	32	51	51	68

Fonte: Elaboração própria do autor desta dissertação (2019).

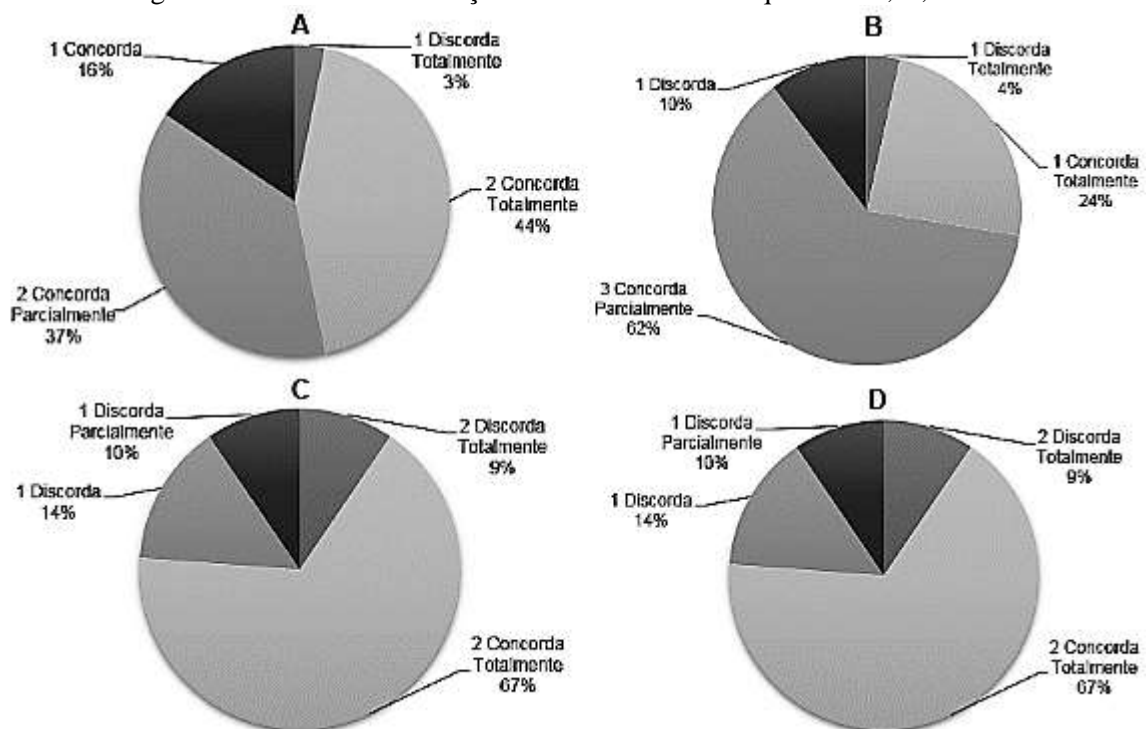
Quadro 6. 4 - Questionário do Caso 1

Considerando os dados do paciente Pac01, anteriormente citados, a configuração automática sugerida pelo simulador e sua experiência pessoal, avalie:
A) É coerente para este paciente a frequência respiratória (FR) = 17?
B) É coerente para este paciente o volume por minuto (Vmin) = 7?
C) É coerente para este paciente o volume corrente (VC) = 546?
D) É coerente para este paciente a combinação: Frequência respiratória (FR) = 17; Volume por Minuto (Vmin) = 7; Volume Corrente (VC) = 546?

Fonte: Elaboração própria do autor desta dissertação (2019).

As avaliações feitas por cada entrevistado, foram quantificadas e ilustradas por meio de 4 gráficos A, B, C e D, ou seja, com relação às 4 perguntas do questionário, e constam na Figura 6.8, que contém o somatório do percentual de opinião de cada um deles sobre as questões.

Figura 6. 8 - Caso 1 – Avaliação dos entrevistados às questões A, B, C e D



Fonte: Elaboração própria do autor desta dissertação (2019).

Com base no caso 1, algumas observações foram feitas pelas especialidades doutor e mestre, mais especificamente no valor para a  $FR = 17$ , a qual se encontra num nível aceitável o que, segundo a figura 6.8(A), contabiliza 44% (2 Concorde totalmente), mas para um melhor diagnóstico deveria adequá-lo ao peso do paciente. Quanto ao  $V_{min} = 7$  em 6.8(B), o mesmo encontra-se no valor correto cuja variação é de 5 a 8 L/min, o que pode ser visto como 24% (1 Concorde totalmente), conforme visto no Capítulo 2.

A análise feita pelos entrevistados, com relação ao primeiro caso, demonstrou que o sistema atendeu de forma ideal, com a combinação dos parâmetros  $FR$ ,  $V_{min}$  e  $VC$ , visto que o somatório das análises contabilizaram 67% (2 Concorde totalmente), o que pode ser constatado no gráfico, figura 6.8(D).

### 6.3.3.2 Caso 2

O caso 2 refere-se a um paciente com 59 anos, sexo masculino, PAVM de 9 dias, tabagista, uso de medicação e alérgico no trato respiratório, conforme o Quadro 6.5.

Quadro 6. 5 - Dados do paciente Pac03

Paciente	Idade	Sexo	PAVM	Tab.	Med.	Alerg.	Pimáx	Pemáx	PaCO <sub>2</sub>	PaO <sub>2</sub>	EM%
Pac03	59	M	9	S	S	S	-35	54	120	43	68

Fonte: Elaboração própria do autor desta dissertação (2019).

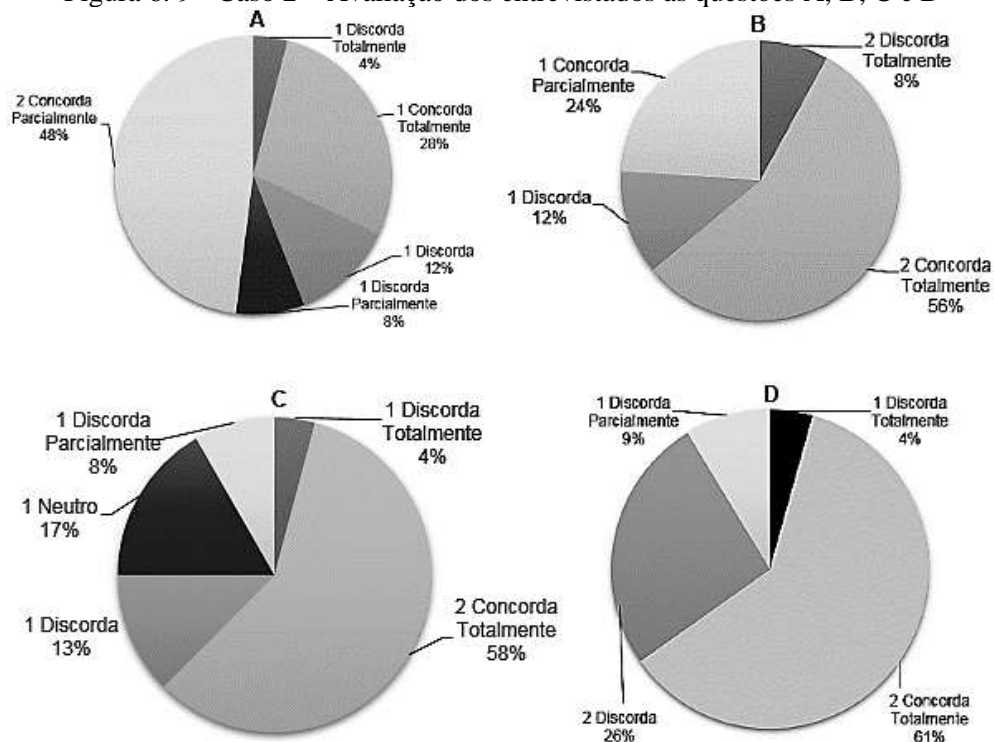
Quadro 6. 6 - Questionário do Caso 2

Considerando os dados do paciente Pac03, anteriormente citados, a configuração automática sugerida pelo simulador e sua experiência pessoal, avalie:
A) É coerente para este paciente a frequência respiratória (FR) = 20?
B) É coerente para este paciente o volume por minuto (Vmin) = 8?
C) É coerente para este paciente o volume corrente (VC) = 518?
D) É coerente para este paciente a combinação: Frequência respiratória (FR) = 20; Volume por Minuto (Vmin) = 8; Volume Corrente (VC) = 518?

Fonte: Elaboração própria do autor desta dissertação (2019).

Idem ao caso 1, as avaliações feitas por cada entrevistado, conforme as questões do Quadro 6.6, constam na Figura 6.9.

Figura 6. 9 - Caso 2 – Avaliação dos entrevistados às questões A, B, C e D



Fonte: Elaboração própria do autor desta dissertação (2019).

Conforme a observação do entrevistado na modalidade doutor em 6.9(A), o valor da  $FR = 20$  está num nível elevado, pois devido a concentração de oxigênio baixa do paciente, ou seja, a  $PaO_2 = 43$ , torna-se necessário uma demanda maior de oxigênio para o mesmo voltar à normalidade, conforme visto no Capítulo 2.

O somatório dos percentuais de satisfação contabilizam 61% (2 Concorde totalmente), conforme o gráfico, figura 6.9(D).

### 6.3.3.3 Caso 3

O terceiro caso trata-se de um paciente de 67 anos, sexo feminino, PAVM de 3 dias e uso de medicamentos, conforme o Quadro 6.7.

Quadro 6. 7 - Dados do paciente Pac06

Paciente	Idade	Sexo	PAVM	Med.	Pimáx	Pemáx	PaCO <sub>2</sub>	PaO <sub>2</sub>	EM%
Pac06	67	F	3	S	-23	37	34	45	84

Fonte: Elaboração própria do autor desta dissertação (2019).

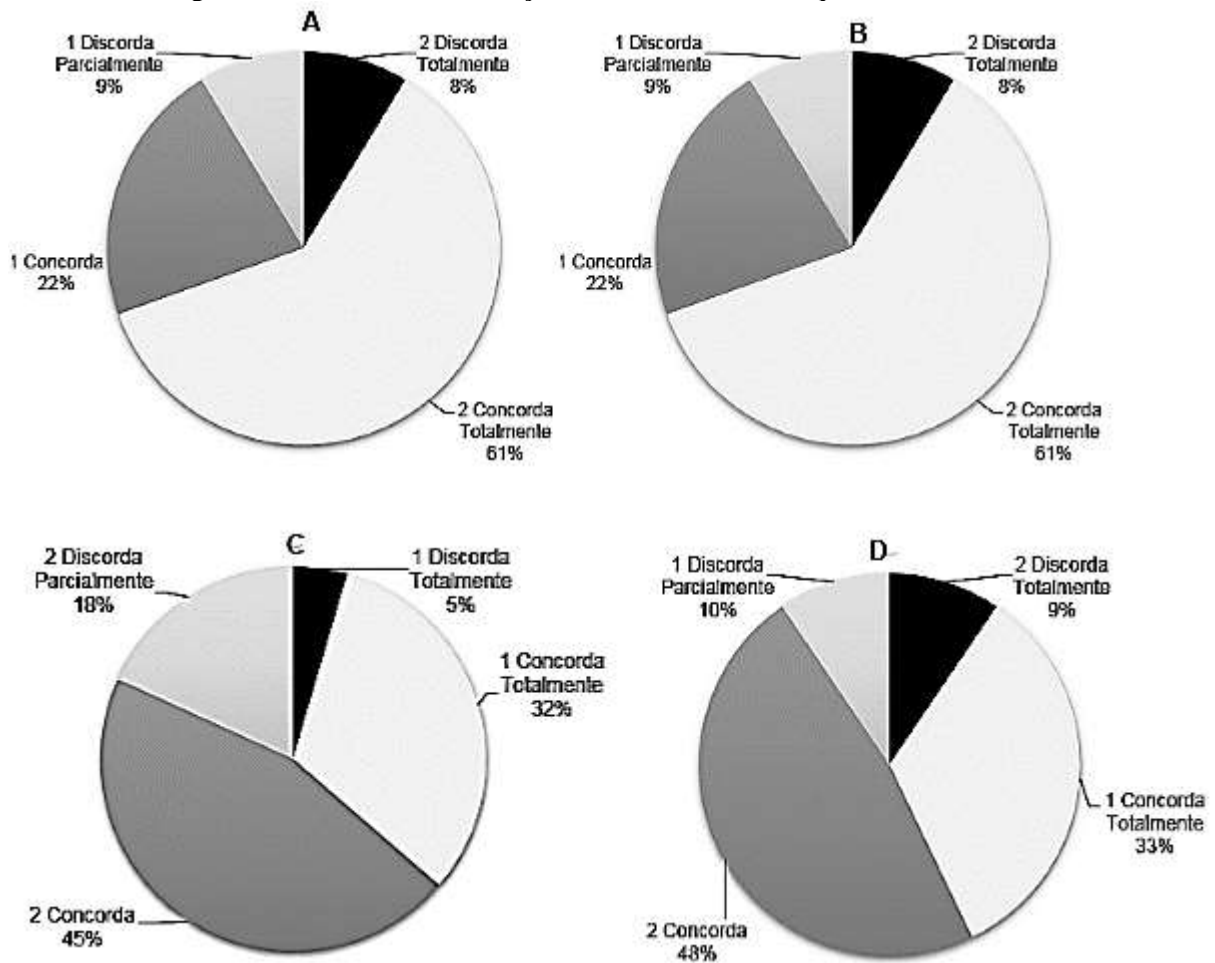
Quadro 6. 8 - Questionário do Caso 3

Considerando os dados do paciente Pac06, anteriormente citados, a configuração automática sugerida pelo simulador e sua experiência pessoal, avalie:
A) É coerente para este paciente a frequência respiratória ( $FR = 21$ )?
B) É coerente para este paciente o volume por minuto ( $V_{min} = 8$ )?
C) É coerente para este paciente o volume corrente ( $VC = 470$ )?
D) É coerente para este paciente a combinação: Frequência respiratória ( $FR = 21$ ); Volume por Minuto ( $V_{min} = 8$ ); Volume Corrente ( $VC = 470$ )?

Fonte: Elaboração própria do autor desta dissertação (2019).

Idem aos casos 1 e 2, as avaliações feitas por cada entrevistado, conforme as questões do Quadro 6.8, constam na Figura 6.10.

Figura 6. 10 - Caso 3 – Avaliação dos entrevistados às questões A, B, C e D



Fonte: Elaboração própria do autor desta dissertação (2019).

Neste caso 3, a análise feita pelos entrevistados constatou que os valores FR, Vmin e VC estão dentro dos valores ideais no tratamento do paciente. A avaliação do gráfico, figura 6.10(D), permite afirmar que a simulação correspondeu com 81% (2 Concorde, 1 Concorde totalmente), conforme as avaliações de um estudante de nível superior, do mestre e doutor.

#### 6.3.3.4 Caso 4

O quarto caso refere-se a um paciente de 73 anos, sexo feminino, PAVM de 8 dias, apresentando hipertermia, tabagista e utilizou antibiótico e antifúngico, conforme o Quadro 6.9.

Quadro 6. 9 - Dados do paciente Pac08

Paciente	Idade	Sexo	PAVM	T°	Tabagista	Med.	Pimáx	Pemáx	PaCO <sub>2</sub>	PaO <sub>2</sub>	EM%
Pac08	73	F	8	S	S	S	-23	25	98	25	69

Fonte: Elaboração própria do autor desta dissertação (2019).

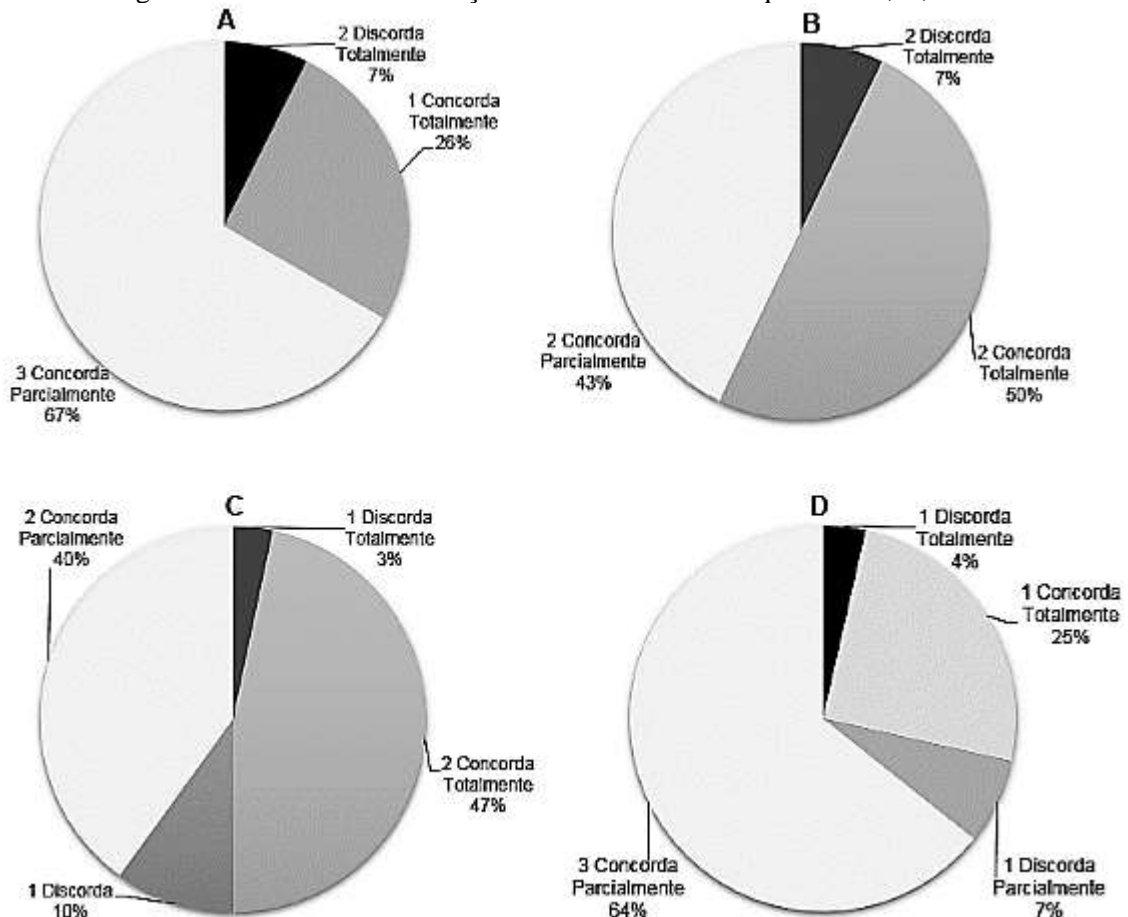
Quadro 6. 10 - Questionário do Caso 4

Considerando os dados do paciente Pac08, anteriormente citados, a configuração automática sugerida pelo simulador e sua experiência pessoal, avalie:
A) É coerente para este paciente a frequência respiratória (FR) = 20?
B) É coerente para este paciente o volume por minuto (Vmin) = 8?
C) É coerente para este paciente o volume corrente (VC) = 518?
D) É coerente para este paciente a combinação: Frequência respiratória (FR) = 20; Volume por Minuto (Vmin) = 8; Volume Corrente (VC) = 518?

Fonte: Elaboração própria do autor desta dissertação (2019).

Idem aos casos 1, 2 e 3, as avaliações feitas por cada entrevistado, conforme as questões do Quadro 6.10, constam na Figura 6.11.

Figura 6. 11 - Caso 4 – Avaliação dos entrevistados às questões A, B, C e D



Fonte: Elaboração própria do autor desta dissertação (2019).

Na análise do caso 4, os valores da FR e Vmin se encontram nas faixas de normalidade assim como o VC. Na ilustração do gráfico, figura 6.11(D), o somatório dos percentuais de dois alunos de nível superior, mestre e doutor contabilizaram 89% (3 Concorde parcialmente, 1 Concorde totalmente).

### 6.3.3.5 Caso 5

No caso 5, tem-se um paciente com 87 anos, sexo masculino, PAVM de 2 dias e alergia no trato respiratório, conforme o Quadro 6.11.

Quadro 6. 11 - Dados do paciente Pac10

Paciente	Idade	Sexo	PAVM	Alergia	Pimáx	Pemáx	PaCO <sub>2</sub>	PaO <sub>2</sub>	EM%
Pac10	87	M	2	S	-22	25	34	24	57

Fonte: Elaboração própria do autor desta dissertação (2019).

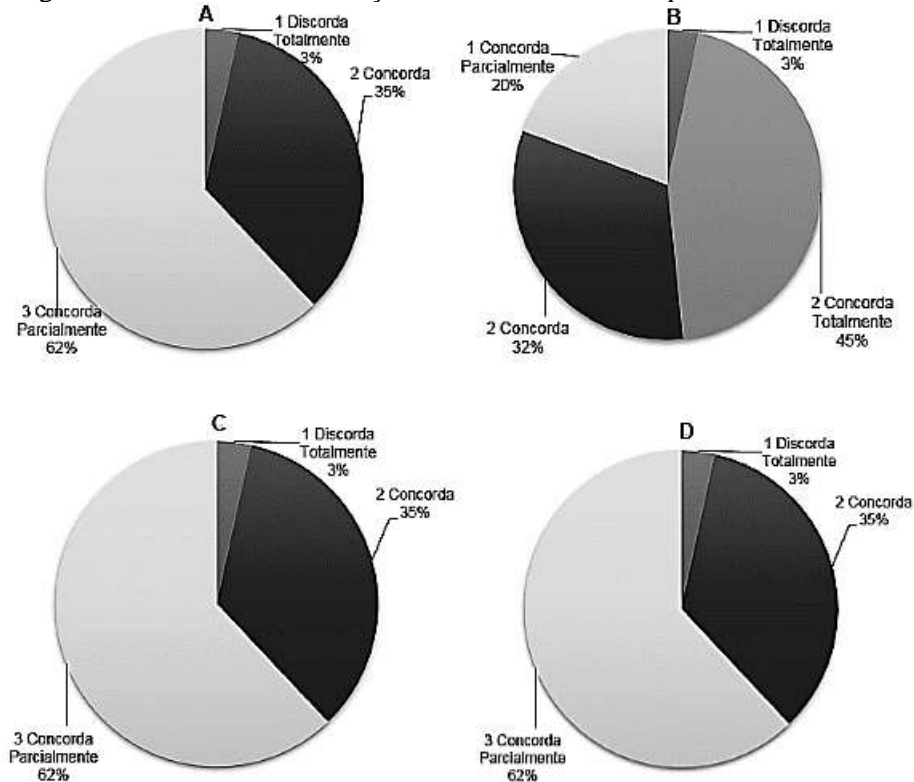
Quadro 6. 12 - Questionário do Caso 5

Considerando os dados do paciente Pac10, anteriormente citados, a configuração automática sugerida pelo simulador e sua experiência pessoal, avalie:
A) É coerente para este paciente a frequência respiratória (FR) = 21?
B) É coerente para este paciente o volume por minuto (Vmin) = 8?
C) É coerente para este paciente o volume corrente (VC) = 450?
D) É coerente para este paciente a combinação: Frequência respiratória (FR) = 21; Volume por Minuto (Vmin) = 8; Volume Corrente (VC) = 450?

Fonte: Elaboração própria do autor desta dissertação (2019).

Idem aos casos 1, 2, 3 e 4 as avaliações feitas por cada entrevistado, conforme as questões do Quadro 6.12, constam na Figura 6.12.

Figura 6. 12 - Caso 5 – Avaliação dos entrevistados às questões A, B, C e D




Fonte: Elaboração própria do autor desta dissertação (2019).



As considerações acerca da figura, mais precisamente no gráfico, figura 6.12(C) com relação ao VC = 450, conforme o entrevistado na modalidade doutor, relata que seriam necessários o peso e da altura do paciente para calcular o valor exato do VC, mas em princípio, considerando outras variáveis, está próximo do padrão. A avaliação geral acerca do gráfico, figura 6.12(D), teve 97% (3 Concorda parcialmente, 2 Concorda), de satisfação para com os valores simulados.

#### 6.4 AVALIAÇÃO GERAL DOS RESULTADOS

As respostas obtidas por meio das simulações e as avaliações dos entrevistados, ao responderem o questionário, puderam inferir que o programa simulador de ventilação mecânica, proposto nesta dissertação, atendeu de forma adequada para uma grande parte dos casos anteriores, conforme ilustra o gráfico da Figura 6.13.



Fonte: Elaboração própria do autor desta dissertação (2019).

Nesta figura, com relação ao que foi tratado em cada caso particularmente, observa-se que os percentuais de aceitação dos entrevistados, relacionados aos valores preditos pela RNA, ou seja, a avaliação de cada um conforme a escala *Likert*, mais precisamente aos conceitos de: ‘5 Concordo’, ‘6 Concordo parcialmente’ e ‘7 Concordo totalmente’, apresentam valores bastante expressivos. A média geral de todos os valores do gráfico contabiliza 79%, o que pode ser considerado como um valor significativo para uma possível validação do programa.

## 6.5 CONSIDERAÇÕES FINAIS DO CAPÍTULO

Este capítulo tratou sobre os resultados obtidos, por meio de simulações feitas no programa desenvolvido nesta dissertação, com o propósito de ensaiar um aparelho de ventilação mecânica (VM). A rede neural proposta, que é parte fundamental do programa, mostrou-se dinâmica, consoante as análises de desempenho, em termos de velocidade, gráficos gerados e respostas ao problema levantado. A participação dos entrevistados, ao analisar os resultados gerados pelo programa, mostrou-se bastante relevante, pois o projeto final pôde ser avaliado e validado. O capítulo seguinte abordará sobre as conclusões finais deste projeto e os trabalhos futuros.

## 7 CONCLUSÃO E TRABALHOS FUTUROS

A ventilação mecânica (VM), embora seja uma técnica eficiente e largamente empregada na terapia intensiva de pacientes com insuficiência respiratória aguda, requer o emprego de pessoal especializado e dedicado continuamente nos ajustes dos parâmetros do ventilador. Neste contexto, esta pesquisa teve por objetivo propor um programa simulador de ventilação mecânica, baseado em Inteligência Artificial (IA), utilizando-se Redes Neurais Artificiais (RNA), capaz de realizar, de forma automática, os ajustes dos parâmetros do ventilador mecânico.

Inicialmente, uma revisão da literatura com relação à ventilação mecânica tornou-se necessário para analisar quais os parâmetros mais importantes no momento da monitoração de um paciente sob um ventilador mecânico, assim como a modalidade ventilatória mais utilizada, bem como as consequências de uma má monitoração. A modalidade escolhida para este estudo, dentre muitas, foi a Ventilação Controlada a Volume (VCV).

Dentre os parâmetros analisados, entre fisiológicos e ventilatórios, 13 deles foram importantes para o desenvolvimento deste trabalho, assim como os parâmetros ajustáveis do ventilador mecânico que foram estabelecidos em 3.

Um amplo estudo sobre redes neurais também foi importante, pois faria parte do programa proposto neste trabalho, analisando assim a topologia da rede em termos de camadas, dados de entrada e saída, algoritmo de aprendizagem e funções de ativação.

Em relação à arquitetura da RNA, proposta na solução do problema levantado, esta foi implementada com 13 entradas que são os parâmetros ventilatórios do paciente, e 3 saídas que são os parâmetros ajustáveis do ventilador.

A ferramenta escolhida para a construção do programa, foi o MATLAB versão 9.4.0 R2018a, o qual possui ótima interatividade, performance para diversos cálculos matemáticos e construção de interfaces gráficas diversas.

Após a implementação do programa, testes diversos foram realizados para analisar quantitativamente o desempenho do sistema, assim como as respostas obtidas por meio da RNA proposta, o que pôde ser constatado por meio dos gráficos obtidos alcançando resultados com 100% de acerto da rede, e também através de comparações dos resultados com dados clínicos reais. Neste cenário, uma pesquisa envolvendo estudantes e especialistas da área de saúde foi

proposta por meio de um questionário composto de cinco casos, de diferentes pacientes e situações, para avaliar qualitativamente o programa.

Ao final da pesquisa, gráficos para cada caso, em particular, foram gerados e seus valores contabilizados percentualmente, o que correspondeu 67%, 61%, 81%, 89% e 97%, respectivamente, para os casos 1, 2, 3, 4 e 5.

Os resultados obtidos por meio das diversas simulações realizadas, juntamente com a avaliação dos entrevistados, puderam comprovar que o programa respondeu de forma satisfatória a todos os casos podendo, possivelmente, ser validado.

As limitações deste trabalho dizem respeito ao reduzido número de amostras de dados que foram utilizados para o treinamento, validação e teste da RNA, ou seja, 94. Com um número maior de amostras, a generalização da rede poderia ser mais significativa e com respostas mais exatas, ou seja, alcançando padrões para analisar também outras patologias.

Como contribuição, este trabalho apresentou um modelo que pôde ser implementado computacionalmente e, uma vez validado, permitirá otimizar o emprego de recursos de pessoal especializado na operação do ventilador mecânico, sem prejuízo da adequada ventilação do paciente.

Como sugestões para trabalhos futuros, espera-se:

- a) Desenvolver o equipamento de VM com redes neurais artificiais;
- b) Validar os seus resultados por meio da ampliação das bases de dados disponíveis para treinamento;
- c) Empregar avançados manequins simuladores<sup>27</sup>;
- d) Implementar uma plataforma simuladora de ventilação mecânica, baseada em redes neurais, para uso na educação.

---

<sup>27</sup> Manequins conectados a um computador que conseguem representar situações clínicas de risco.

## 8 PUBLICAÇÕES VINCULADAS À PESQUISA

SILVA, R. M.; NUNES, E. O.; RECH, V.; Redes Neurais Aplicadas na Parametrização da Ventilação Mecânica de Pacientes com Insuficiência Respiratória Aguda. **Revista de Sistemas e Computação – RSC**. Salvador, BA. v. 9, n. 2, 2019. Disponível em: <https://revistas.unifacs.br/index.php/rsc/article/view/6073> Acesso em: 1 jan. 2020.

## REFERÊNCIAS

- AGÊNCIA NACIONAL DE VIGILÂNCIA SANITÁRIA (ANVISA). **Abordagem de Vigilância Sanitária de Produtos para Saúde Comercializados no Brasil: Ventilador Pulmonar**. Brasília: Anvisa; 2011.
- ALLEROD, C. **A decision support system for mechanical ventilation: description and retrospective clinical evaluation**. [S.l.]: River Publishers, 2012.
- AKBULUT, F.P; AKKUR, E; AKAN, A. *et al.* A decision support system to determine optimal ventilator settings. **BMC Medical Informatics and Decision Making**, v.14, n.3, 2014. doi:10.1186/1472-6947-14-3.
- AMORIM, M. M.; GOMES, S. R. Ações de enfermagem para prevenção de infecções associadas à ventilação mecânica na unidade de terapia intensiva neonatal. **Revista Interdisciplinar do Pensamento Científico**, v, 1, n.2, jul./dez. 2015.
- BARBAS, C. S. V. *et al.* Recomendações brasileiras de ventilação mecânica 2013. Parte I. **Revista brasileira de terapia intensiva**, São Paulo, v. 26, n. 2, p. 89-121, jun. 2014. Disponível em: [http://www.scielo.br/scielo.php?script=sci\\_arttext&pid=S0103-507X2014000200089&lng=en&nrm=iso](http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0103-507X2014000200089&lng=en&nrm=iso). Acesso em: 12 jul. 2019.
- BEALE, M. H.; HAGAN, M. T.; DEMUTH, H. B. **Neural Network Toolbox™ User's Guide** [S.l.]: The MathWorks, Inc, 2017.
- CARVALHO, C. R. R.; TOUFEN, J. C.; FRANCA, S. A. Ventilação mecânica: princípios, análise gráfica e modalidades ventilatórias. **Jornal brasileiro de pneumologia**, São Paulo, v. 33, supl. 2, p. 54-70, jul. 2007. Disponível em: [http://www.scielo.br/scielo.php?script=sci\\_arttext&pid=S1806-37132007000800002&lng=en&nrm=iso](http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1806-37132007000800002&lng=en&nrm=iso). Acesso em: 12 mar. 2019.
- CAVALCANTE, W. M. **Redes neurais artificiais como ferramenta de auxílio na operação e controle da estação de tratamento de água de Palmeira dos Índios**. Salvador: [s.n.], 2018, 76 f.
- CORREA, R. A. *et al.* Diretrizes brasileiras para pneumonia adquirida na comunidade em adultos imunocompetentes. **Jornal brasileiro de pneumologia**, São Paulo, v. 35, n. 6, p. 574-601, jun. 2009. ISSN 1806-3713. Disponível em: [http://www.scielo.br/scielo.php?script=sci\\_arttext&pid=S1806-37132009000600011&lng=en&nrm=iso](http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1806-37132009000600011&lng=en&nrm=iso). Acesso em: 23 abr. 2018.
- COSTA, D. *et al.* Novos valores de referência para pressões respiratórias máximas na população brasileira. **Jornal brasileiro de pneumologia**, São Paulo, v. 36, n. 3, p. 306-312, Jun. 2010. ISSN 1806-3713. Disponível em: [http://www.scielo.br/scielo.php?script=sci\\_arttext&pid=S1806-37132010000300007&lng=pt&nrm=iso](http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1806-37132010000300007&lng=pt&nrm=iso). Acesso em: 23 fev. 2019.
- CUNHA, L. M. A. **Modelos Rasch e Escalas de Likert e Thurstone na medição de atitudes**. 2008. Dissertação (Mestrado)- Universidade de Lisboa, Faculdade de Ciências, Departamento de Estatística e Investigação Operacional, Lisboa, 2008. Disponível em: [https://reposit.orio.ul.pt/bitstream/10451/1229/1/18914\\_ULFC072532\\_TM.pdf](https://reposit.orio.ul.pt/bitstream/10451/1229/1/18914_ULFC072532_TM.pdf). Acesso em: 10 ago. 2019.

- CUNHA, B. A. **Fundamentos em pneumonia**. 3. ed. Porto Alegre: ArtMed, 2012.
- DUDA, R. O. *et al.* **Pattern classification**. 2. nd. New York: [s.n.], 2001.
- FONTELA, P. C. *et al.* Ventilação mecânica variável. **Revista brasileira de terapia intensiva**, São Paulo, v. 29, n. 1, p. 77-86, 2016. Disponível em: [http://www.scielo.br/scielo.php?script=sci\\_arttext&pid=S0103-507X2017000100077&lng=en&nrm=iso](http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0103-507X2017000100077&lng=en&nrm=iso). Acesso em: 12 jun. 2019.
- HAYKIN, S. **Redes neurais: princípios e prática**. Porto Alegre: Bookman, 2001.
- HESS, D. R. Noninvasive Ventilation for Acute Respiratory Failure. **Respiratory Care**, v.58, n.6, p. 950–969, 2013.
- KARBING, D. S. *et al.* Retrospective evaluation of a decision support system for controlled mechanical ventilation. **Medical & Biological Engineering & Computing**, v.50, p. 43-51, 2011.
- LAKATOS, E. M.; MARCONI, M. A. **Técnicas de pesquisas, elaboração, análise e interpretação de dados**. 5. ed. São Paulo: Atlas, 2002.
- MALBOUISSON, L. M. S.; OLIVEIRA, R. A. G. Ventilação mecânica protetora intraoperatória: o que há de novo? **Revista brasileira de terapia intensiva**, São Paulo, v. 29, n. 4, p. 404-407, 2017. ISSN 0103-507X. Disponível em: [http://www.scielo.br/scielo.php?script=sci\\_arttext&pid=S0103-507X2017000400404&lng=en&nrm=iso](http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0103-507X2017000400404&lng=en&nrm=iso). Acesso em: 12. out. 2018.
- MANZAN, J. R. G. **Análise de desempenho de redes neurais artificiais do tipo multilayer perceptron por meio do distanciamento dos pontos do espaço de saída**. 2016. 129 f. Tese (Doutorado em Ciências), Universidade Federal de Uberlândia, Uberlândia, 2016. Disponível em: <http://clyde.dr.ufu.br/handle/123456789/17967>. Acesso em: 7 jul. 2019.
- MAQUET Critical Care. **Ventilador Pulmonar Servo-s. v. 6.1**. Rontgenvagen 2, SE-171 95, Solna Suécia: [s.n.], 2012. 291p.
- MARTINIANO, A. *et al.* Utilizando uma rede neural artificial para aproximação da função de evolução do sistema de Lorentz. **Revista Produção e Desenvolvimento**, v.2, p.26-38, 2016. 10.32358/rpd.2016.v2.94.
- MATSUNAGA, V. Y. **Curso de redes neurais utilizando o Matlab**. Belém do Pará, 2012. Disponível em: <https://docplayer.com.br/15733073-Curso-de-redes-neurais-utilizando-o-matlab.html>. Acesso em: 7 abr. 2019.
- MIRANDA, A. P. *et al.* Sistema de análise de ativos através de Redes Neurais de Múltiplas Camadas. **Revista de Administração da UFSM**, v. 5, n. 1, p. 145-162, 2012. Disponível em: <http://www.spell.org.br/documentos/ver/7941/sistema-de-analise-de-ativos-atraves-de-redes-neurais-de-multiplas-camadas/i/pt-br>. Acesso em 7 jul. 2019.
- MORAIS, J. T. G. **Análise de componentes principais integrada a redes neurais artificiais para predição de matéria orgânica**. 67p. 2011. (Dissertação de Mestrado)– Universidade Federal da Bahia – UFBA. Escola Politécnica. Salvador, 2011. Disponível em: <http://repositorio.ufba.br/ri/handle/ri/18678>. Acesso em: 7 abr. 2019.

MORATO, J. B.; SANDRI, P.; GUIMARÃES, H. P. **ABC da Ventilação Mecânica**. v. 2. São Paulo: Atheneu, 2015.

PARRECO, J. *et al.* Using artificial intelligence to predict prolonged mechanical ventilation and tracheostomy placement. **The Journal of surgical research**, n. 228, p. 179-187, 2018. 10.1016/j.jss.2018.03.028.

PASSO, D. P. **Análise da qualidade de classificadores para identificação de alvos urbanos em imagens de alta resolução espacial: uma aplicação com as imagens do satélite Worldview II**. 2013. xvi, 106 f., il. Dissertação (Mestrado em Geociências)- Universidade de Brasília - UNB, Brasília, 2013.

PERALES, T. R. **Utilização de Redes Neurais Artificiais no Diagnóstico de Cardiopatias**. 168p. Dissertação (Mestrado)– Universidade Estadual de Londrina. Departamento de Engenharia Elétrica, Londrina, 2011.

PASCHOARELLI, L.; MEDOLA, F.; BONFIM, G. H. Características Qualitativas, Quantitativas de Abordagens Científicas: estudos de caso na subárea do Design Ergonômico. **Revista de Design, Tecnologia e Sociedade**, v. 2, n. 1, p. 65-78. 2018. Disponível em: <http://periodicos.unb.br/index.php/design-tecnologia-sociedade/article/view/15699>. Acesso em: 7 jul. 2019.

REES, S.E. *et al.* The Intelligent Ventilator Project: Application of Physiological Models in Decision Support. Artificial Intelligence in Medicine. **AIME 2011. Lecture Notes in Computer Science**, v. 6747, 2011.

REFAEILZADEH *et al.* Cross-Validation. **Encyclopedia of Database Systems.**, v.532–538, p. 532-538, 2009. 10.1007/978-0-387-39940-9\_565.

REICH, D. **Monitoring in Anesthesia and Perioperative Care**. Cambridge: Cambridge University Press. 2011.

RODRIGUES, A. N. *et al.* Impactos e fatores determinantes no bundle de pneumonia associada à ventilação mecânica. **Revista Brasileira de Enfermagem**, Brasília, v. 69, n. 6, p. 1108-1114, dez. 2016. Disponível em: [http://www.scielo.br/scielo.php?script=sci\\_arttext&pid=S0034-71672016000601108&lng=en&nrm=iso](http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0034-71672016000601108&lng=en&nrm=iso). Acesso em: 7 jul. 2019.

SACHETTI, A. *et al.* Adesão às medidas de um bundle para prevenção de pneumonia associada à ventilação mecânica. **Revista brasileira de terapia intensiva**, v.26, n.4, p.355-359, 2014. ISSN 0103-507X. Disponível em: <http://www.scielo.br/scielo.php?script=sciarttext&pid=S0103-507X2014000400355&lng=en&nrm=iso>. Acesso em: 7 jul. 2019.

SANTANA, J. C. B.; MELO, C. L.; DUTRA, B. S. **Monitorização Invasiva e Não Invasiva: Fundamentação para o Cuidado**. São Paulo: Atheneu, 2013, cap. 5. p. 67-77.

SANTOS, R. M. G. *et al.* Manovacuometria realizada por meio de traqueias de diferentes comprimentos. **Fisioterapia e Pesquisa**, São Paulo, v.24, n. 1, p. 9-14, Mar. 2017. ISSN 2316-9117. Disponível em: [http://www.scielo.br/scielo.php?script=sci\\_arttext&pid=S1809-29502017000100009&lng=en&nrm=iso](http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1809-29502017000100009&lng=en&nrm=iso). Acesso em: 7 ago. 2019.



SARMENTO, G. J. V. **Princípios e práticas de ventilação mecânica em pediatria e neonatologia**. Barueri, SP: Manole, 2011.

SCHENEKENBERG, C. N. M. *et al.* Redes bayesianas para eleição da ventilação mecânica no pós-operatório de cirurgia cardíaca. **Fisioterapia em movimento**, Curitiba, v. 24, n. 3, p. 481-492, 2011. ISSN 1980-5918. Disponível em: [http://www.scielo.br/scielo.php?script=sci\\_arttext&pid=S0103-51502011000300013&lng=en&nrm=iso](http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0103-51502011000300013&lng=en&nrm=iso). Acesso em: 7 jan. 2019.

SILVA, A. Q. B. **Implementação e aplicação de algoritmos de aprendizado em um sistema neuro-simbólico**. 89f. Dissertação (Mestrado em Engenharia Elétrica e de Computação) - Centro de Tecnologia, Universidade Federal do Rio Grande do Norte, Natal, 2017. Disponível em: <https://repositorio.ufrn.br/jspui/handle/123456789/22563>. Acesso em: 7 jun. 2018.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes neurais artificiais: para engenharia e ciências aplicadas**. São Paulo: Artliber, 2010.

SOUZA, A. B. G. **Enfermagem Neonatal cuidado integral ao recém-nascido**. São Paulo: Martinari, 2011.

SOUZA, F. A. A. **Análise de desempenho da rede neural artificial do tipo multilayer perceptron na era multicore**. 62 f. 2012. Dissertação (Mestrado em Automação e Sistemas; Engenharia de Computação; Telecomunicações), Universidade Federal do Rio Grande do Norte, Natal, 2012. Disponível em: <https://repositorio.ufrn.br/jspui/handle/123456789/15447>. Acesso em: 12 dez. 2018.

SUZUKI, K. Artificial Neural Networks. **Architectures and Applications**, p. 262, 2013.

TURRIN, B. B. **Projeto e Desenvolvimento de um Sistema de Controle para um Dispositivo de Ventilação Mecânica Pulmonar**. 2011. Dissertação (Mestrado)- Departamento de Engenharia de Telecomunicações e Controle. Escola Politécnica da Universidade de São Paulo, São Paulo, 2011. Disponível em: [http://www.teses.usp.br/teses/disponiveis/3/3139/tde03052012122930/publico/Dissertacao\\_Bruno\\_Bestle\\_Turrin.pdf](http://www.teses.usp.br/teses/disponiveis/3/3139/tde03052012122930/publico/Dissertacao_Bruno_Bestle_Turrin.pdf). Acesso em: 7 nov. 2018.

VERON, H. L. *et al.* Implicações da respiração oral na função pulmonar e músculos respiratórios. **Revista CEFAC**, São Paulo, v. 18, n. 1, p. 242-251, 2016. ISSN 1516-1846. Disponível em: [http://www.scielo.br/scielo.php?script=sci\\_arttext&pid=S1516-1846201600100242&lng=en&nrm=iso](http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1516-1846201600100242&lng=en&nrm=iso). Acesso em: 7 mar. 2019.

VIANA, A. P. P.; MACHADO, F. R.; SOUZA, J. L. A. **Sepse, um problema de saúde pública: a atuação e colaboração da enfermagem na rápida identificação e tratamento da doença**. São Paulo: COREN-SP, 2017.

WEST, John B. **Respiratory physiology: the essentials**. 9th ed. Philadelphia: [s.n.], 2013.

WUERGES, A. F. E.; BORBA, J. A. Redes neurais, lógica nebulosa e algoritmos genéticos: aplicações e possibilidades em finanças e contabilidade. **JISTEM J.Inf.Syst. Technol. Manag.** (Online), São Paulo, v.7, n. 1, p. 163-182, 2010. Disponível em: <http://dx.doi.org/10.4301/S1807-17752010000100007>. Acesso em: 21 jan. 2018.

YOKOYAMA, T. *et al.* Noninvasive ventilation in acute exacerbation of idiopathic pulmonary fibrosis. **Internal medicine**, v. 49, n.15, p. 1509-14, 2010.

## APÊNDICE A – SUBCONJUNTO DE TREINAMENTO/TESTE E VALIDAÇÃO

Quadro A. 1 - Base para treinamento (Continua)

Paciente	Inputs													Target		
Pac01	59	0	12	0	1	2	1	1	-25	26	100	49	51	33	20	543
Pac02	16	0	2	1	1	0	0	1	-21	58	54	54	60	21	8	678
Pac03	63	0	3	0	0	1	1	1	-44	25	56	35	68	24	7	523
Pac04	85	1	5	0	0	1	1	1	-67	24	85	25	51	18	8	547
Pac05	76	1	3	0	1	1	1	1	-23	97	98	36	24	26	12	678
Pac06	18	1	4	1	0	0	1	1	-12	82	25	82	44	31	13	712
Pac07	67	1	5	0	0	0	1	1	-32	48	98	71	71	32	20	765
Pac08	91	1	7	0	1	1	1	1	-34	24	84	10	48	26	6	365
Pac09	56	0	2	1	0	0	0	0	-45	25	32	98	57	28	8	376
Pac10	44	0	4	1	0	-1	1	1	-34	34	98	52	77	21	8	587
Pac11	43	1	5	1	0	1	0	0	0	0	27	54	42	13	5	536
Pac12	69	1	8	0	0	0	1	1	-23	81	55	88	24	30	21	437
Pac13	79	0	10	0	0	0	0	0	-43	97	22	41	68	12	4	465
Pac14	87	0	8	0	0	0	0	0	-17	93	24	24	57	26	7	376
Pac15	65	0	4	0	0	0	1	1	-16	83	15	39	92	27	0	482
Pac16	76	0	7	0	0	0	0	0	-15	68	68	74	34	31	6	409
Pac17	62	1	16	0	0	1	1	1	-19	59	48	48	54	24	5	537
Pac18	60	1	11	0	1	1	0	0	-28	72	42	54	15	22	8	375
Pac19	49	1	7	1	0	0	1	1	0	0	98	98	49	21	5	397
Pac20	63	1	2	0	0	0	1	1	-12	12	77	41	75	0	9	694
Pac21	65	0	3	0	0	1	1	1	-39	31	25	38	88	31	13	765
Pac22	61	1	5	0	0	0	1	0	-27	95	87	28	74	0	17	587
Pac23	69	-1	4	0	0	0	1	1	-21	25	93	74	64	28	15	487
Pac24	70	1	7	0	0	0	0	0	-25	67	84	38	57	21	5	396
Pac25	65	1	3	0	1	1	1	1	-32	85	54	31	51	25	7	487
Pac26	62	0	2	0	0	0	0	1	-24	24	98	22	54	22	6	491
Pac27	59	0	9	0	0	1	0	0	-41	85	80	54	53	12	8	393
Pac28	78	0	8	0	1	1	1	1	-28	25	75	58	61	24	7	399
Pac29	65	0	2	0	0	0	0	0	-17	84	84	56	67	23	5	469
Pac30	67	0	14	0	0	0	0	0	-50	15	97	24	61	12	4	298
Pac31	69	0	4	0	0	0	0	0	-19	92	35	57	49	36	17	710
Pac32	78	1	6	0	0	0	0	1	-20	58	58	51	27	25	6	489
Pac33	67	1	8	0	0	0	0	0	-21	34	59	35	58	23	7	578
Pac34	65	0	5	0	1	1	0	0	-20	39	25	23	48	22	6	387
Pac35	69	1	2	0	0	0	1	1	-38	29	48	18	96	22	5	402

Quadro A.1: Base para treinamento (Continua)

Pac36	73	0	13	0	0	1	1	1	-31	21	98	97	35	22	5	308
Pac37	54	1	-1	1	0	1	1	1	-28	28	35	83	54	24	4	498
Pac38	58	1	2	1	0	1	1	1	-10	0	89	25	74	21	5	376
Pac39	89	0	5	0	0	1	1	1	-19	26	78	54	25	18	4	509
Pac40	67	0	4	0	0	0	0	0	-16	25	74	54	28	23	6	418
Pac41	73	0	5	0	0	0	1	1	-34	26	68	45	54	22	6	490
Pac42	69	1	2	0	0	1	1	1	-38	37	94	68	39	19	4	496
Pac43	89	0	2	0	0	0	0	1	-27	98	58	21	85	16	6	455
Pac44	73	1	9	0	0	0	1	1	-31	64	84	41	54	32	18	539
Pac45	57	1	8	1	0	0	1	1	-41	74	56	43	68	34	19	398
Pac46	66	0	3	0	0	0	1	1	-31	82	67	26	60	22	8	429
Pac47	-1	0	2	0	0	0	1	1	-29	26	37	38	73	21	8	547
Pac48	73	0	5	0	0	0	0	0	-30	51	99	39	54	19	8	446
Pac49	46	0	4	1	0	0	1	1	-32	36	101	85	68	18	8	594
Pac50	19	0	7	1	1	2	0	0	-52	48	97	54	35	13	8	498
Pac51	26	0	-1	1	0	1	1	1	-34	25	87	68	25	32	17	602
Pac52	69	1	6	0	0	0	0	0	-29	48	68	24	41	24	5	444
Pac53	56	0	5	1	0	0	1	1	-23	96	48	41	33	23	5	498
Pac54	85	1	8	0	1	1	0	0	-19	87	98	49	68	18	4	659
Pac55	87	0	4	0	0	0	1	1	-21	24	78	48	64	16	4	541
Pac56	75	1	2	0	0	0	0	0	-21	22	51	57	43	32	10	503
Pac57	67	0	-1	0	0	0	1	1	0	19	48	82	61	14	6	437
Pac58	79	1	9	0	1	1	0	0	-21	52	52	48	58	18	8	354
Pac59	55	1	8	1	1	1	0	0	-27	25	85	35	49	23	8	384
Pac60	65	0	7	0	1	2	1	1	-25	36	87	26	62	28	13	581
Pac61	76	0	2	0	1	1	1	1	-24	25	96	55	63	26	14	487
Pac62	68	0	8	0	0	0	0	0	-23	52	48	34	49	27	6	584
Pac63	81	0	5	0	1	1	0	0	-29	45	15	28	43	25	7	543
Pac64	48	1	2	1	0	0	0	1	-47	48	78	35	44	27	8	395
Pac65	87	1	13	0	1	1	0	0	-16	96	96	53	77	22	8	545
Pac66	63	0	3	0	1	1	1	1	-32	58	25	15	45	21	8	385
Pac67	80	0	5	0	0	0	1	1	-17	54	85	52	50	23	8	473
Pac68	71	1	8	0	1	2	1	1	-11	65	28	41	77	24	8	540
Pac69	56	1	7	1	0	0	1	1	-28	24	78	46	41	22	8	475
Pac70	78	0	4	0	0	1	1	1	-26	34	25	35	40	30	13	593
Pac71	63	1	6	1	0	1	1	0	-27	33	64	39	40	26	7	493
Pac72	66	1	5	0	0	0	1	1	-29	25	22	84	36	21	8	298
Pac73	76	1	8	0	0	0	1	1	-25	25	48	15	55	13	7	493
Pac74	87	0	4	0	1	1	1	1	0	36	41	25	56	14	5	563
Pac75	69	0	5	0	0	0	1	1	-18	15	58	45	68	17	8	299
Pac76	67	1	3	0	0	0	0	0	-85	30	48	85	69	30	9	297
Pac77	83	0	2	0	0	0	0	0	-19	32	31	36	47	22	10	584
Pac78	45	0	5	1	0	2	1	1	-17	27	23	52	62	18	4	487

Quadro A.1: Base para treinamento (Conclusão)

Pac79	60	0	9	0	0	1	1	1	-28	91	46	54	43	19	6	430
Pac80	45	0	3	1	1	0	0	0	-21	20	24	16	75	33	13	542
Pac81	68	0	2	0	0	1	0	0	-28	25	65	53	71	22	5	505
Pac82	74	1	3	0	1	2	1	1	-16	26	0	0	66	35	10	584
Pac83	90	1	6	0	1	1	0	0	-27	41	34	25	54	24	8	497
Pac84	86	0	5	0	1	1	1	1	-15	23	23	72	40	20	6	395
Pac85	88	0	8	0	0	1	-1	0	-28	17	30	56	24	27	7	546
Pac86	75	1	4	0	-1	2	1	1	-29	25	32	55	97	23	6	395
Pac87	23	0	7	0	1	1	1	1	-34	102	44	80	100	13	8	456
Pac88	45	0	8	0	0	0	0	0	-32	43	34	87	35	31	7	767
Pac89	67	1	9	1	1	2	0	0	-21	55	55	68	65	23	6	568
Pac90	54	1	4	0	1	1	0	0	-43	32	46	78	77	43	8	657
Pac91	34	1	1	1	0	2	1	0	-12	47	49	90	68	22	9	459
Pac92	47	0	12	0	0	1	0	0	-32	45	35	76	76	33	8	325
Pac93	45	1	2	0	0	0	0	0	-32	66	33	56	56	13	10	567
Pac94	13	0	10	1	0	0	1	1	-43	71	22	76	77	23	6	87

Fonte: Sachetti *et al.* (2014).

## APÊNDICE B – SUBCONJUNTO DE TESTE E GENERALIZAÇÃO

Tabela B. 1 - Subconjunto de teste e generalização

Paciente	Idade	Sexo (M/F)	PAVM (Dias)	T <sup>o</sup> (S/N)	Malignidade (S/N)	Tabagista (S/N/C)	Medicação (S/N)	AR (S/N)	Pimáx (cmH <sub>2</sub> O)	Pemáx (cmH <sub>2</sub> O)	PaCO <sub>2</sub> (mmHg)	PaO <sub>2</sub> (mmHg)	EM (%)
Pac01	45	M	5	S	N	S	N	N	-21	32	51	51	68
Pac02	56	M	4	S	N	N	S	S	-18	72	68	47	25
Pac03	59	M	9	N	N	S	S	S	-35	54	120	43	68
Pac04	63	F	3	S	N	N	S	N	-29	84	58	45	58
Pac05	65	M	1	N	N	S	S	S	-41	29	17	48	77
Pac06	67	F	3	N	N	N	S	N	-23	37	34	45	84
Pac07	69	F	2	N	S	N	N	S	-23	41	34	59	76
Pac08	73	F	8	N	N	S	S	S	-23	25	98	25	69
Pac09	76	F	9	N	N	N	S	S	-25	25	37	120	58
Pac10	87	M	2	N	N	N	S	S	-22	25	34	24	57

Fonte: Própria do autor desta dissertação (2019).

## APÊNDICE C – SIMULAÇÕES

Tabela C. 1 - Saídas simuladas do ventilador mecânico

Paciente	Simulação 1			Simulação 2			Simulação 3			Simulação 4		
	FR	Vmin	VC	FR	Vmin	VC	FR	Vmin	VC	FR	Vmin	VC
<b>Pac01</b>	24	8	125	17	7	772	22	6	517	17	7	546
<b>Pac02</b>	18	10	197	30	11	617	23	7	520	23	10	550
<b>Pac03</b>	11	9	380	23	6	213	23	8	435	20	8	518
<b>Pac04</b>	23	9	914	25	6	707	22	8	597	21	8	508
<b>Pac05</b>	27	9	872	25	9	832	21	9	455	21	8	390
<b>Pac06</b>	10	6	587	21	5	124	21	6	513	21	8	470
<b>Pac07</b>	31	11	1188	18	5	420	23	10	638	23	8	527
<b>Pac08</b>	21	11	975	21	6	334	17	9	504	20	8	518
<b>Pac09</b>	33	6	102	21	7	411	21	7	365	22	6	432
<b>Pac10</b>	26	8	524	20	7	429	17	8	471	21	8	450

Fonte: Própria do autor desta dissertação (2019).