

Risk Factor Forecasting System for Pressure Injuries Through Artificial Neural Network

B. M. Pedroso, J. V. S. Guazzelli, A. P. Silva, S. R. M. S. Boschi, S. C. Martini and T. A. Scardovelli

Abstract—The appearance of pressure injuries is very common in patients bedridden for a long time due to a surgical procedure or a recovery process caused by an accident. Many studies have been carried out to monitor and prevent this condition, but the methodology used requires the direct or indirect intervention of a health professional to classify the risk of wound development. This study aims to demonstrate the development of a system capable of predicting the risk factor for the development of pressure injuries through the analysis of the Braden Scale parameters inserted by a health professional on an electronic interface, where through an algorithm based on artificial neural networks, which is responsible for processing, it will be possible to carry out the classification of the risk factor for pressure injuries. To acquire the friction and shear parameters, force sensors were used in a matrix architecture, together with a signal conditioning circuit as well as a control and communication drive via USB with the computer for sending data, as well as a graphical interface for entry of other parameters by the health professional.

Index Terms—Artificial Neural Network, Braden Scale, Embedded Electronics, Pressure Injuries

I. INTRODUÇÃO

LESÕES por pressão (LPP), também conhecidas como Escaras, são lesões ocasionadas no tecido devido a ausência de fluxo sanguíneo, responsável por nutrir e oxigenar as células, ocasionando em sua morte e apresentando como consequência a necrose do tecido [1]. Cerca de 39% dos pacientes restritos ao leito desenvolvem lesões por pressão [2].

Existem alguns fatores que acarretam o aparecimento das lesões por pressão, porém o fator de maior relevância é a pressão de interface [3]. Outros fatores como a temperatura da pele e umidade também apresentam um papel determinante no desenvolvimento de lesões por pressão, podendo iniciar com

B. M. Pedroso, Aluno de Doutorado em Engenharia Biomédica e docente no departamento de Engenharia Elétrica na Universidade de Mogi das Cruzes, Mogi das Cruzes, São Paulo, Brasil (e-mail: brunomedina@umc.br)

J. V. S. Guazzelli, Aluno da graduação em Engenharia Elétrica na Universidade de São Paulo, São Paulo, Brasil (e-mail: joao.guazzelli@usp.br)

A. P. Silva, Pesquisador e docente do departamento de Engenharia Elétrica na Universidade de Mogi das Cruzes, Mogi das Cruzes, São Paulo, Brasil (e-mail: alessandrops@umc.br)

S. R. M. S. Boschi, Pesquisadora e docente do departamento de Engenharia Elétrica na Universidade de Mogi das Cruzes, Mogi das Cruzes, São Paulo, Brasil (e-mail: boschi@umc.br)

S. C. Martini, Pesquisadora e docente do departamento de Engenharia Elétrica na Universidade de Mogi das Cruzes, Mogi das Cruzes, São Paulo, Brasil, (e-mail: silviac@umc.br)

T. A. Scardovelli, Pesquisador e docente do departamento de Engenharia Elétrica na Universidade de Mogi das Cruzes, Mogi das Cruzes, São Paulo, Brasil (e-mail: terigi@gmail.com)

um eritema, até atingir seu nível mais crítico que é o acometimento da estrutura óssea [4].

Uma classificação dos níveis de comprometimento das lesões por pressão foi estabelecida por alguns órgãos internacionais, tais como a European Pressure Ulcer Advisory Panel (EPUAP), o National Pressure Ulcer Advisory Panel (NPUAP), recomendado pela Agency Health Care Policy and Research (AHCPR), como segue:

Estado I: Vermelhidão de pele (Eritema), sem o retorno aos padrões normais após o cessar da pressão de interface.

Estado II: Existe uma Perda parcial de pele, sendo que a lesão é considerada superficial, sendo acompanhada de bolhas.

Estado III: Perda da pele superficial com necrose do tecido subcutâneo.

Estado IV: Perda total da pele superficial, com necrose em tecidos subcutâneos e danos aos músculos, tendões e estrutura óssea. [5]

Para quantificação da probabilidade de um paciente ser acometido por lesões por pressão durante a internação em ambiente hospitalar, algumas escalas são adotadas pela equipe médica, como por exemplo a escala de Gosnell que avalia as condições mentais, mobilidade, nutrição, etc; a escala de Ek que analisa índices como ingestão de alimentos e ingestão de líquidos; a escala de Waterlow a qual analisa a relação peso - altura, continência, idade e sexo; e a escala de Braden que efetua uma pontuação dos níveis de progressão das lesões por pressão [6].

Na área de dispositivos eletrônicos existem equipamentos que realizam o monitoramento remoto de sinais fisiológicos, como por exemplo, os sinais do eletrocardiograma, que podem ser enviados de um módulo de controle e monitoramento a um roteador e enviados pela internet a um computador remoto ou equipamento que torna possível a medição de temperatura, pressão de interface e umidade através de um colete com sensores, enviando estes dados ao usuário [7][8]. Existe equipamento que foi elaborado para diminuir a pressão de interface em determinada área através da movimentação de um sistema mecânico, responsável por movimentar e alterar o decúbito do paciente. [9]

Alguns sistemas foram construídos para monitoramento “in loco”, como um estudo realizado para monitorar os pontos de pressão de um indivíduo deitado, sendo enviados via bluetooth para um tablet para análise [10].

Um outro campo com grande volume de estudo é o da Inteligência Artificial, sendo esta além do processamento de variáveis, também é empregada para monitoramento a distância de pacientes para melhoria de qualidade de vida [11].

Já outras aplicações envolvem a utilização de técnicas de Machine Learning no processamento de imagens de raio X retiradas do cérebro a fim de detectar possíveis doenças desde o Acidente vascular encefálico (AVE) até a detecção de padrões para a doença de Alzheimer [12]. Aplicações de Deep Learning também são usuais na área médica, como por exemplo, para reconhecimento de dados e informações referentes ao quadro de diabetes retinopática em imagens médicas, situação que se torna complexa com a utilização de parâmetros convencionais de diagnóstico [13]. As redes neurais convolucionais também podem ser utilizadas para, por exemplo, efetuar o processamento de imagens obtidas por câmeras de lesões por pressão para avaliar o grau da ferida, bem como o comprometimento dos tecidos da região [14].

Tendo em vista o cenário apresentado, este trabalho tem como princípio a elaboração de um equipamento eletrônico que atue como sistema de aquisição dos parâmetros de um conjunto de sensores, bem como de informações inseridas por um profissional de saúde, para o acompanhamento do estado clínico de um paciente em relação a probabilidade do desenvolvimento de lesões por pressão. Sendo assim, o objetivo é desenvolver um sistema para monitoramento da carga aplicada em uma determinada região do corpo (calcâneo), ligada ao parâmetro de fricção e cisalhamento da Escala de Braden e os parâmetros de Percepção Sensorial, Mobilidade, Atividade, Nutrição e Umidade inseridos em um display. Os dados são processados em um computador através de um algoritmo de Redes Neurais Artificiais (RNA), com intuito de entregar como resposta o fator de risco e a acurácia da rede, bem como os parâmetros instantâneos da aquisição em um software supervisorio desenvolvido em linguagem Python por meio de bibliotecas específicas. As técnicas de monitoramento e processamento demonstradas neste artigo poderão auxiliar pesquisas futuras sobre a aplicação da Inteligência Artificial na área médica.

II. METODOLOGIA

As características técnicas empregadas no projeto serão descritas nesta seção a fim de apresentar a metodologia de aplicação. Este estudo apresenta características longitudinais, onde as variáveis foram testadas e analisadas em função do tempo.

Na Fig. 1, pode ser observado a divisão do sistema de medição de força, responsável por efetuar a aquisição dos dados do sensor de carga e condicioná-lo para envio ao controlador; do sistema de entradas de dados manuais, no qual consiste na utilização de um display TFT para inserção manual dos parâmetros da Escala de Braden pelo profissional de saúde; do banco de dados para armazenamento das variáveis preditivas enviadas pelo sistema eletrônico embarcado via protocolo RS-232 (Percepção Sensorial, Mobilidade, Atividade, Nutrição, Umidade e Fricção/Cisalhamento); do processamento através de redes neurais que é responsável por analisar os parâmetros lidos e entregar a resposta referente ao fator de risco para lesões por pressão; o sistema de visualização dos dados que consiste em apresentar de maneira gráfica todo o processo de aquisição, treinamento e execução

de rede, bem como a manipulação do banco de dados, para leitura e limpeza das informações armazenadas.

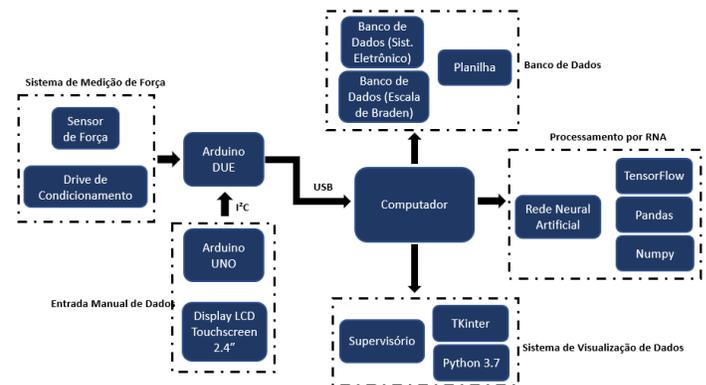


Fig. 1. Diagrama de blocos do sistema de previsão de lesões por pressão.

A. Sistema de Medição de Força

Este bloco é constituído por quatro sensores de força do tipo FSR (*Force Sensor Resistor*) responsáveis por efetuar a aquisição da carga aplicada pela região do corpo do paciente acamado sobre a superfície de repouso. Foi utilizada a arquitetura matricial para aumento do range de medição. Esta aplicação é responsável por encaminhar os parâmetros de Cisalhamento e Fricção da Escala de Braden. O sensor FSR apresenta dimensões de 3,81cm x 3,81cm, totalizando uma área útil para medição de 14,51cm², já para a matriz 2X2 a área útil para medição é de 58,04cm². Esta aplicação tem como foco a aplicação na região calcânea do paciente. Na Fig. 2 é possível observar a arquitetura de montagem dos sensores:

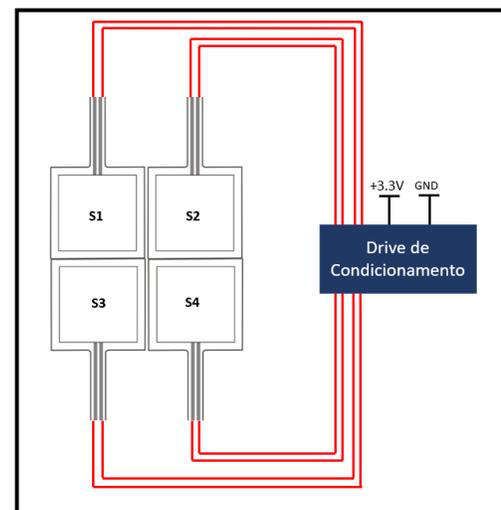


Fig. 2. Esquema de montagem da matriz de carga com os sensores FSR.

Após implementação do sensor de carga FSR, foi realizado o teste para levantamento da curva característica do sensor em função das cargas aplicadas com valores conhecidos. Na Fig. 3 é possível observar os dados referentes a variação de carga em função do valor de resistência elétrica no sensor.

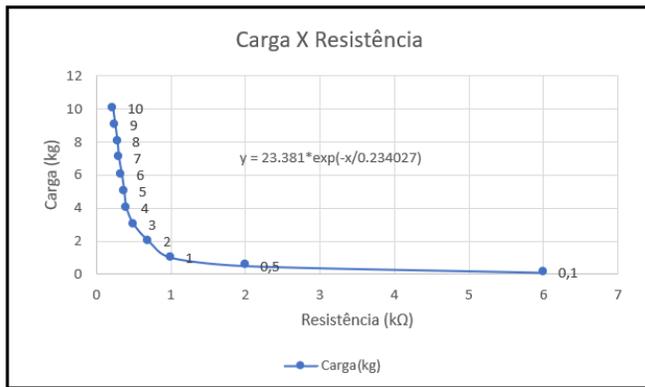


Fig. 3. Equação característica do sensor FSR.

Como circuito de condicionamento foi utilizado um divisor de tensão para cada sensor, ajustando o sinal de saída para o módulo de controle. Para cálculo da tensão de saída de cada sensor, foi adotada a relação matemática observada na equação 1:

$$V_{out} = \frac{RB}{RA+RB} * V_{in} \quad (1)$$

Onde RA é o sensor FSR, RB o resistor de ajuste para saída de tensão compatível com o controlador, V_{in} a tensão de entrada do circuito e V_{out} a tensão de saída do módulo de controle.

Para uma melhor adequação à leitura dos sensores da matriz de pressão 2X2, foi utilizada a leitura em função dos valores decodificados do conversor Analógico / Digital, que para esta aplicação foi configurado para atuar com 12 bits de resolução. A equação 2 foi utilizada para determinar o valor de tensão lida pelo conversor A/D nas entradas das portas analógicas:

$$V_{dig} = \frac{V_{in} - V_{refL}}{\left(\frac{V_{refH} - V_{refL}}{2^{n-1}}\right)} \quad (2)$$

Onde V_{in} é o valor de entrada analógico, proveniente do sensor; V_{refH} e V_{refL} são os valores de referência de tensão do conversor, que para esta aplicação foram definidos em 3,3V e 0V; V_{dig} o valor resultante da conversão analógico / digital e n o número de bits do conversor, configurado para 12 bits. Os valores digitais, provenientes da conversão são retornados pela função *AnalogRead()* do Arduino Due, obtidos para cada medição do sensor.

Em função dos valores resultantes do conversor A/D, foi possível gerar o gráfico de resposta do sensor, utilizado para geração do código fonte para conversão de parâmetros, como observado na Fig. 4:

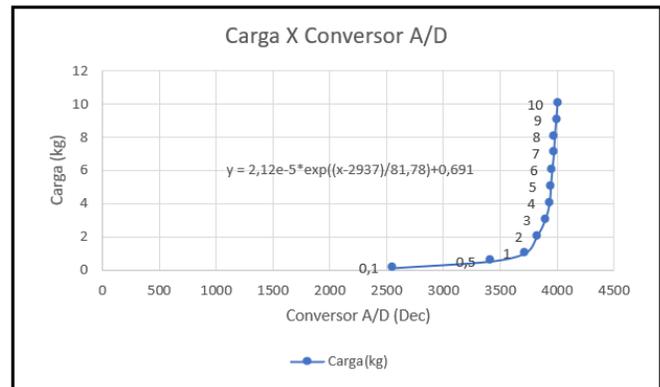


Fig. 4. Resposta gráfica do sensor FSR após conversão do Arduino Due.

B. Sistema para Entrada Manual de Dados

Este sistema é responsável por enviar os outros parâmetros previstos pela Escala de Braden, como Percepção Sensorial, Umidade, Atividade, Mobilidade e Nutrição, que são inseridos manualmente pelo profissional de saúde após avaliação clínica do paciente. Para controle das informações inseridas no display TFT, foi utilizado a plataforma eletrônica Arduino Uno, com comunicação I²C com o display TFT, no qual consiste em dois barramentos para troca de informações de forma serial, sendo um barramento para tráfego de informações e um barramento de clock para sincronismo do protocolo de comunicação [15].

Os parâmetros do display TFT, bem como os sinais da matriz de sensores de carga são enviados a um controlador central baseado na arquitetura da plataforma Arduino Due para envio destas informações ao computador via comunicação USB, abastecendo o banco de dados da Rede Neural Artificial.

C. Banco de Dados do Sistema Eletrônico

Neste projeto foram criados dois bancos de dados distintos, sendo o primeiro banco baseado em todas as possibilidades de combinações com os parâmetros para treinamento da rede neural referentes à Escala de Braden, totalizando 3075 combinações, com os índices de Percepção Sensorial, Umidade, Mobilidade, Atividade, Nutrição e Fricção/Cisalhamento. O algoritmo de treino da rede utiliza este banco de dados em formato de planilha para ajuste dos pesos das conexões da rede, permitindo a possibilidade de previsão para o desenvolvimento de lesões por pressão em função das entradas. Um segundo banco foi criado com os dados obtidos através do sistema de aquisição eletrônica, constituído de um módulo de controle com a plataforma Arduino Due responsável por enviar através do protocolo RS-232 os dados dos sensores e parâmetros inseridos no display TFT a uma planilha eletrônica que será utilizada pela rede neural na execução para obter o fator de risco para lesões por pressão.

Os fatores preditivos são classificados com pontuação entre 1 à 4 para percepção sensorial, umidade, atividade, mobilidade e nutrição. Já o fator de fricção e cisalhamento é pontuado de 1 à 3, sendo a classificação do risco considerada como risco muito alta para pontuação total entre 6 e 9, risco alto para pontuação entre 10 e 12, risco moderado com

pontuação entre 13 e 14, risco baixo para pontuação entre 15 e 18 e sem risco para lesões por pressão com pontuação entre 19 e 23 [16].

D. Processamento por RNA

Um algoritmo que apresenta como objetivo imitar a estrutura cerebral, onde encontramos um número conhecido de entradas e saídas de informações. Estes parâmetros são processados por uma cadeia de neurônios que apresentam como saídas as respostas preditivas ou classificatórias para uma determinada situação. Através do ajuste de pesos é possível que este tipo de algoritmo possa aprender a cada interação no treinamento [17].

A estrutura de um neurônio, bem como seu modelo matemático pode ser observados na Fig. 5 e equação 3:

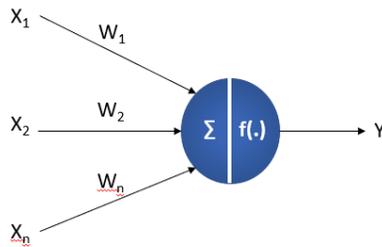


Fig. 5. Arquitetura de um neurônio artificial.

$$v_j(n) = \sum_{i=0}^m w_{ji}(n)y_i(n) \quad (3)$$

Onde m é o número de entradas, w_j são os pesos sinápticos, v_j é o sinal de saída e y_i é o sinal funcional.

Para criação dos algoritmos de treino da RNA bem como para execução da RNA, foram utilizadas bibliotecas comerciais como o TensorFlow, que conta com o auxílio das Interfaces de Programação Aplicada como o Keras e o Scikit-learn que são responsáveis por criar a RNA e gerar métricas para análise dos resultados de saída da rede. Após a verificação do número de entradas, saídas e camadas ocultas necessárias para criação da RNA, foram elaborados os modelos para teste do tipo MLP (*Multi Layer Perceptron*), observado na Fig. 6:

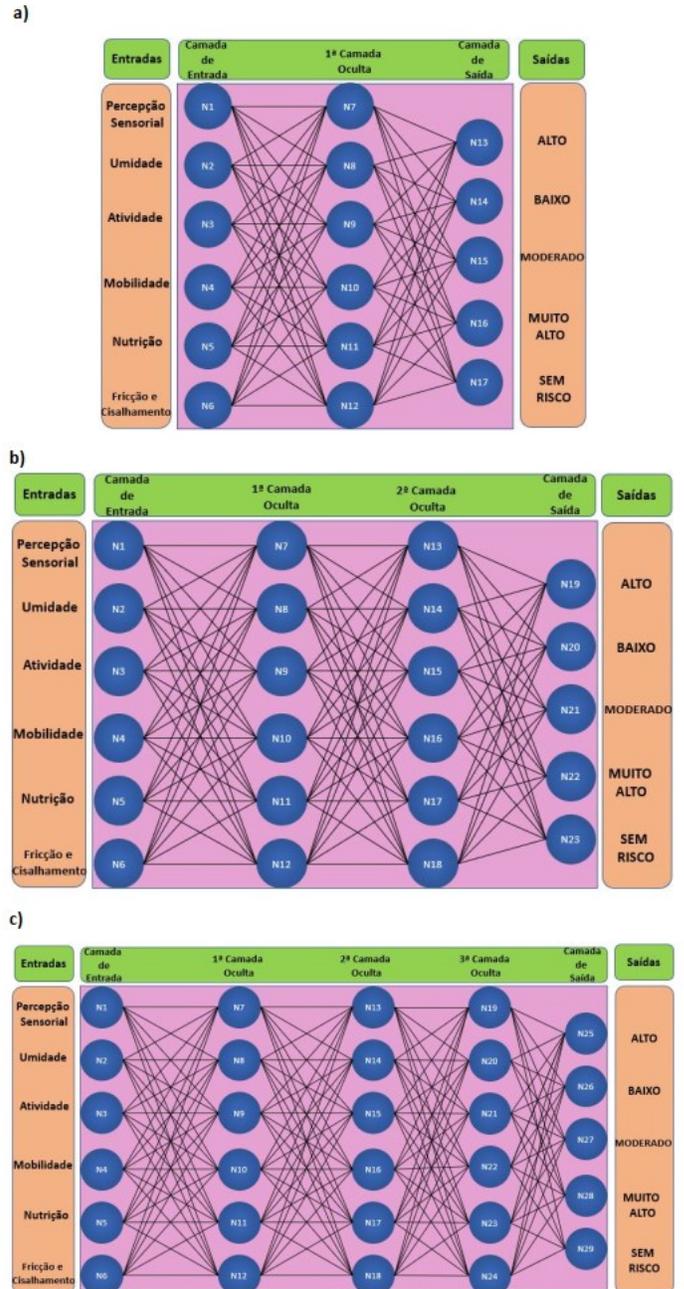


Fig. 6. a) Arquitetura da RNA de 3 camadas b) Arquitetura da RNA de 4 camadas c) Arquitetura da RNA de 5 camadas

As estruturas de Rede utilizadas contam com 17, 23 e 29 neurônios divididos em uma, duas e três camadas ocultas respectivamente; contando ainda com uma camada de entrada e uma camada de saída.

E. Sistema Supervisor

Para facilitar a visualização dos parâmetros do sensor matricial, bem como dos resultados da Rede Neural Artificial, foi criado uma interface gráfica em linguagem de programação Python onde é possível efetuar a execução do processo de aquisição de dados pelo sistema de controle, enviando os parâmetros à planilha de aquisição, bem como o processo de aprendizagem da rede neural e sua execução, apresentando o valor da acurácia, o número de dados da

aquisição e o fator de risco equivalente. Na Fig. 7 é possível observar o software para interface gráfica:

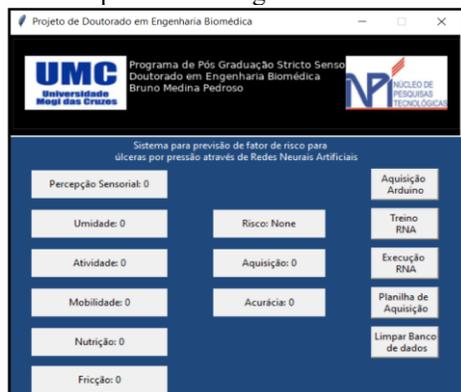


Fig. 7. Tela do software de supervisão com os parâmetros lidos do sensor, a resposta da RNA e os botões de execução.

O botão “*Aquisição Arduino*” é responsável por iniciar a comunicação via porta USB para armazenamento dos dados em um planilha de teste. Já o elemento “*Treino RNA*” foi disposto para efetuar o treino da Rede Neural Artificial após a coleta dos dados do dispositivo eletrônico; já o botão “*Execução RNA*” foi criado para executar o algoritmo de aplicação da Rede Neural Artificial para gerar o fator de risco bem como o valor da Acurácia da RNA. Ainda constam no *software* os botões de “*Planilha de dados*” e “*Limpar banco de dados*”, responsáveis pelo acesso as informações capturadas e apagar os dados aquisitados, respectivamente.

III. RESULTADOS E DISCUSSÃO

Para realização dos experimentos práticos, foi adotado o protocolo de testes que consistem em analisar cada etapa do equipamento de maneira individual, finalizando com o teste geral de equipamento.

A. Teste dos Sensores de Carga

Para validar a utilização do sensor FSR para aquisição dos dados referentes a carga aplicada na região de interface entre a pele e a superfície do colchão, foram realizados os ensaios de precisão e exatidão. No ensaio de precisão, o objetivo é analisar o grau de repetibilidade do sensor. Já no ensaio de exatidão, busca-se verificar a concordância do valor lido com um valor de referência conhecido. Os ensaios de precisão e exatidão podem ser observados na Tabela I e Tabela II respectivamente:

TABELA I
ENSAIO DE PRECISÃO DO SENSOR DE CARGA FSR.

Medição	Leitura de Carga Aplicada (kg)	Erro (kg)	Erro Percentual (%)
1	5,95	0,35	5,88
2	6,00	0,40	6,67
3	5,80	0,20	3,45
4	5,98	0,38	6,35
5	5,90	0,30	5,08
6	5,90	0,30	5,08
7	6,00	0,40	6,67
8	5,95	0,35	5,88
9	6,00	0,40	6,67
10	5,80	0,20	3,45

O experimento foi realizado utilizando a região calcânea que em média apresenta cerca de 6,17% à 6,30% do peso corporal total do indivíduo, que neste projeto está em torno de 89kg [18]. O intervalo de leitura foi de 30 segundos para que não ocorressem problemas com a flutuação do sinal do sensor. De acordo com os dados obtidos, foi possível determinar o valor do desvio padrão, compreendido em 0,077kg, bem como a média de leituras em 5,92kg, confirmando a característica da repetibilidade nas leituras conforme dados da Tabela I. A carga aplicada de referência neste ensaio esta compreendida em 5,60kg.

TABELA II
ENSAIO DE EXATIDÃO DO SENSOR DE CARGA FSR.

Medição	Carga de Referência (kg)	Carga de Leitura (kg)	Erro (kg)	Erro Percentual (%)
1	1	1,28	0,28	28,0
2	2	2,20	0,20	10,0
3	3	3,15	0,15	5,00
4	4	4,25	0,25	6,25
5	5	5,30	0,30	6,00
6	6	6,22	0,22	3,67
7	7	7,33	0,33	4,71
8	8	8,21	0,21	2,63
9	9	9,12	0,12	1,33
10	10	10	0	0

Na Tabela II, com os dados obtidos no ensaio de exatidão, é possível observar média nos erros de leitura em 0,21kg com desvio padrão 0,097kg, justificando a utilização deste modelo de sensor para esta aplicação.

B. Teste para o Algoritmo de Aquisição de Dados

Para efetuar a aquisição dos dados do sistema eletrônico embarcado via protocolo *I²C*, foi ajustado o tempo de 10 segundos para atualização do banco de dados para aplicação da RNA. O tempo de atualização e envio dos dados foi cronometrado e comprovado experimentalmente em formato de observação direta do comportamento do sistema. Esta configuração foi definida empiricamente em função da observação do comportamento do protocolo de comunicação.

C. Teste do Algoritmo de Treino da RNA

No algoritmo de treino da RNA foram considerados a divisão dos dados, sendo 70% para treino e 30% para teste da rede, bem como o número de épocas a ser configurado para que a rede atinja uma acurácia de 100%. Foram realizados testes com 10 variações no valor nominal das épocas para treino, analisando os parâmetros de acurácia, sensibilidade e especificidade. Foram utilizadas 3 arquiteturas distintas de RNA, sendo a primeira com 3 camadas ocultas, a segunda com 4 camadas ocultas e a configuração com 5 camadas ocultas, definidas aleatoriamente em função no número de entradas e saída. Os dados de desempenho das arquiteturas foram comparados e ilustrados na Tabela III, Tabela IV e Tabela V respectivamente:

TABELA III

ENSAIO PARA AJUSTE DO Nº DE ÉPOCAS PARA RNA – 3 CAMADAS

Nº de Épocas	Época	Acurácia (%)	Sensibilidade (%)	Especificidade (%)	Tempo (seg)
50	50 ^a	90	85,1	100	11
100	100 ^a	98,8	98	100	20
150	150 ^a	99,9	100	100	31
200	158 ^a	100	100	100	43
250	171 ^a	100	100	100	52
300	155 ^a	100	100	100	64
350	227 ^a	100	100	100	79
400	228 ^a	100	100	100	90
450	252 ^a	100	100	100	102
500	252 ^a	100	100	100	120

TABELA IV

ENSAIO PARA AJUSTE DO Nº DE ÉPOCAS PARA RNA – 4 CAMADAS

Nº de Épocas	Época	Acurácia (%)	Sensibilidade (%)	Especificidade (%)	Tempo (seg)
50	50 ^a	99,6	98,3	100	11
100	67 ^a	100	100	100	20
150	67 ^a	100	100	100	31
200	74 ^a	100	100	100	43
250	74 ^a	100	100	100	52
300	106 ^a	100	100	100	64
350	86 ^a	100	100	100	79
400	177 ^a	100	100	100	90
450	89 ^a	100	100	100	102
500	52 ^a	100	100	100	120

TABELA V

ENSAIO PARA AJUSTE DO Nº DE ÉPOCAS PARA RNA – 5 CAMADAS

Nº de Épocas	Época	Acurácia (%)	Sensibilidade (%)	Especificidade (%)	Tempo (seg)
50	50 ^a	99,9	100	100	17
100	43 ^a	100	100	100	31
150	132 ^a	100	100	100	48
200	51 ^a	100	100	100	63
250	80 ^a	100	100	100	81
300	62 ^a	100	100	100	99
350	82 ^a	100	100	100	118
400	105 ^a	100	100	100	88
450	115 ^a	100	100	100	94
500	74 ^a	100	100	100	120

O experimento de treino da RNA foi realizado em um computador com processador Intel(R) Core(TM) i5-7200U CPU 2.50GHz, memória RAM de 16 GB e placa de vídeo NVIDIA GeForce 940MX. A análise comparativa do rendimento das arquitetura de RNA adotadas são observadas na Fig. 8:

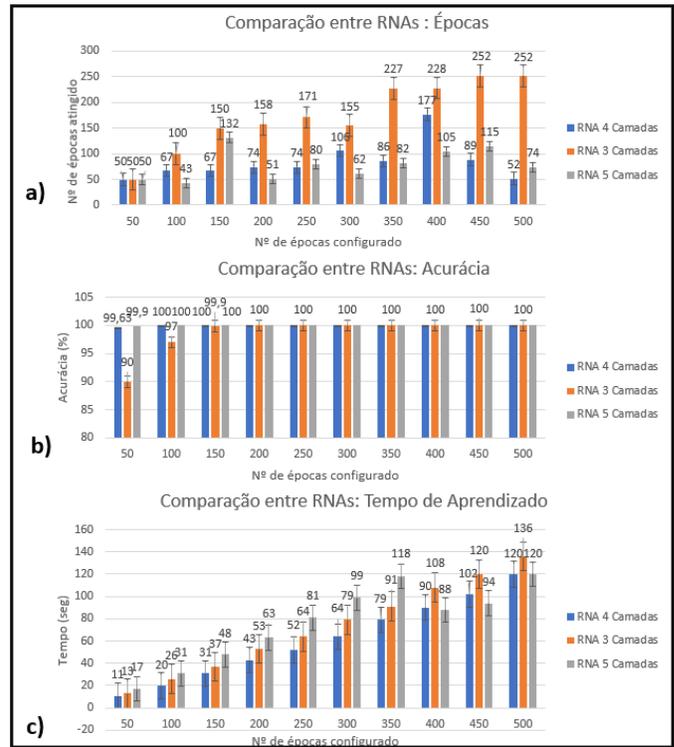


Fig. 8. a) Análise do nº de épocas. b) Análise da Acurácia. c) Análise do Tempo de Aprendizado.

D. Teste do Algoritmo de Execução da RNA

Para analisar o comportamento da RNA na execução do sistema de previsão com os dados coletados pelo sistema eletrônico embarcado, foram elaboradas as matrizes de confusão para cada arquitetura testada, que consiste em um método de verificação da predição do algoritmo. Pode ser obtida através da acurácia, que consistem na análise classificatória correta das classes de saída da rede; da sensibilidade, no qual consiste no percentual de dados verdadeiros calssificados como verdadeiros e na especificidade que é a caracteristica do percetual de dados negativos classificados corretamente como negativos. Para cálculo da acurácia, sensibilidade e especificidade, devem ser utilizadas a equação 4, equação 5 e equação 6 respectivamente [19] [20] [21]:

$$Acurácia = \frac{VP+VN}{VP+FP+FN+VN} * 100\% \tag{4}$$

$$Sensibilidade = \frac{VP}{VP+FN} * 100\% \tag{5}$$

$$Especificidade = \frac{VN}{FP+VN} * 100\% \tag{6}$$

Sendo *VP* - o número de predições positivas corretas; *VN* – o número de predições negativas corretas; *FP* – o número de previsões positivas incorretas; *FN* – o número de predições negativas incorretas.

Para comprovar a acurácia, sensibilidade e especificidade das configurações de RNA adotadas para teste, foram

utilizadas as matrizes de confusão para cada arquitetura. Nesta matriz constam as saídas reais da RNA, localizadas nos índices das linhas da tabela, bem como os parâmetros que deveriam estar contidos na resposta da rede, ou seja, dados preditivos estão localizados nos índices das colunas da tabela. Desta forma torna-se possível analisar graficamente o rendimento de uma RNA. Para as três configurações definidas para teste neste projeto, foram geradas as matrizes observadas na Fig. 9:

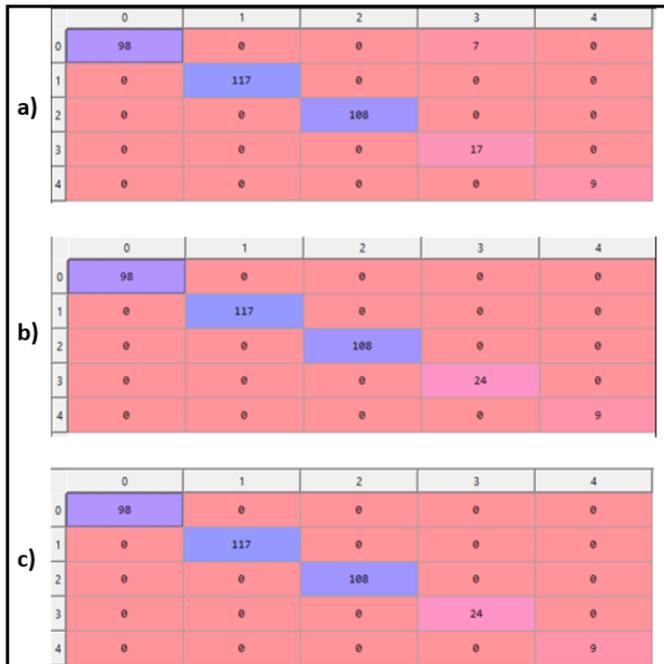


Fig. 9. Análise da matriz de confusão para as RNAs: a) 3 camadas; b) 4 camadas; c) 5 camadas. para 100 épocas.

Nas matrizes de confusão para as configurações de RNA de 4 e 5 camadas é possível confirmar 100% para acurácia, sensibilidade e especificidade para ajuste na aprendizagem da rede para 100 épocas. Para a RNA de 3 camadas, é possível observar acurácia em 98,8%, sensibilidade em 98% e especificidade em 100%.

E. Teste do Software Supervisor

Para finalizar a análise do comportamento do sistema, foi realizado o teste no software supervisor, onde todo o processo de aquisição, treinamento e execução da RNA foram integrados a fim de validar o funcionamento de todo o sistema. O sistema de aquisição foi configurado a realizar 200 aquisições e os dados salvos em uma planilha para execução da RNA. Para treino, foi utilizada a planilha com os dados referentes a Escala de Braden. Algumas janelas foram inseridas para visualização do fator de risco para lesões por pressão, número de aquisições realizadas e acurácia da RNA. Na Fig. 10 é possível observar o funcionamento do sistema com os resultados comparados com a base de dados da Escala de Braden.

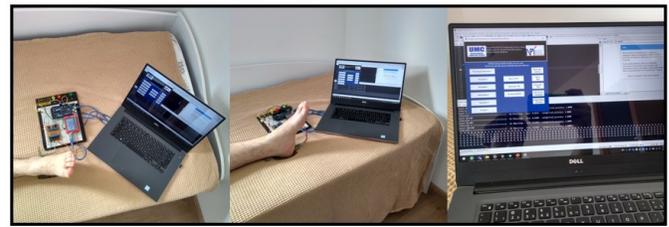


Fig 10. Montagem do equipamento para teste completo do sistema.

IV. CONCLUSÃO

Atualmente, os sistemas baseados em algoritmos de inteligência artificial são elaborados e ajustados em detectar padrões para previsão de situações que envolvam previsão de dados, sendo que boa parte deste processo é devido o correto funcionamento de sistemas e aquisição de dados, bem como de classificação [22]. Sendo assim, a aplicação de ferramentas de Inteligência Artificial na área biomédica é de grande importância, pois torna-se possível a classificação de fatores médicos, bem como a previsão do estado clínico de um paciente de acordo com a doença.

O sensor de carga aplicado neste trabalho mostrou-se eficaz para medição do parâmetro de fricção e cisalhamento da Escala de Braden, já que apresentou nos testes experimentais desvio padrão de 0,077kg para precisão e 0,097kg para exatidão, efetivando estas características em seu comportamento, e com erro médio percentual para precisão em 5,52%, bem como erro médio percentual para exatidão em 6,76%, demonstrando sua confiabilidade na utilização.

Os ensaios para as configurações de RNA adotadas para esta aplicação, também se mostraram eficazes para prever o fator de risco para lesões por pressão, sendo que a arquitetura escolhida para aplicação no equipamento, após a análise dos testes experimentais, foi a de 4 camadas, que apresentou acurácia de 100% com 100 épocas definidas, diminuindo o tempo computacional para geração do resultado final, bem como sensibilidade e especificidade em 100%, garantido a eficácia para classificação do fator de risco com baixo gasto de processamento computacional. A configuração de 3 camadas apresentou rendimento inferior para 100 épocas e a RNA de 5 camadas apresentou tempo computacional um pouco superior para processamento. De acordo com todos os parâmetros obtidos nos ensaios experimentais, é possível afirmar que torna-se extremamente viável a utilização de Redes Neurais Artificiais para realizar a classificação de lesões por pressão em pacientes acamados com intuito de auxiliar a equipe médica multidisciplinar a propor um tratamento adequado para o diagnóstico de cada paciente. Com esta pesquisa, espera-se que outros estudos na área de inteligência artificial sejam aplicados à medicina para auxiliar os profissionais de saúde no diagnóstico e na proposta de tratamentos mais eficazes e individualizados.

Como proposta e melhoria a pesquisas futuras, sugerimos a substituição do sistema eletrônico embarcado utilizado (Arduino Due) por um módulo do Raspberry Pi 4, com o objetivo de embarcar o código referente à criação de redes neurais artificiais, excluindo a utilização de um computador convencional para processar as informações. O sistema de entradas de dados *Touchscreen* também pode ser substituído

por uma interface mais eficiente quanto à comunicação com o módulo de processamento. Em relação à matriz de sensores, um sistema intercambiável pode ser implementado para medição de pressão de interface em outras regiões do corpo.

REFERÊNCIAS

- [1] M. J. Carvalho, “Úlceras por pressão: proposta de prevenção por meio de um colchão de látex natural (*Hevea Brasiliensis*) sensorizado”, Dissertação de Mestrado, Universidade de Brasília, Distrito Federal – Brasil. 2014.
- [2] N. M. B. Rogenski and V. L. C. G. Santos, “Estudo sobre a incidência de úlceras por pressão em um hospital universitário. Revista Latino-Americana de Enfermagem”, vol. 13, no.4, p. 474-480, 2005.
- [3] L. Blanes, I. S. Duarte, J. A. Calil and L. M. Ferreira, “Avaliação clínica e epidemiológica das úlceras por pressão em pacientes internados no Hospital São Paulo”. *Rev Assoc Med Bras*, vol. 50, no. 2, pp. 182-7, 2004.
- [4] F. G. Marchione, L. M. Q. Araújo and L. V. Araújo, “Approaches that use software to support the prevention of pressure ulcer: a systematic review”. *International journal of medical informatics*, vol. 84, no. 10, p. 725-736, 2015.
- [5] C. L.A. Santos, “Sistema automático de prevenção de úlceras por pressão”. 62 f. Tese de Doutorado. Universidade da Madeira, Ilha da Madeira - Portugal. 2009.
- [6] M. C. Mishu and J. W. Schroeder, “Modelling of Pressure Ulcer (PU) Risk Prediction System”. *Science and Information Conference*, 2015.
- [7] J. Ling and W. Yingin, “Wireless ECG monitoring system based on OMAP. In: *Computational Science and Engineering*”. *International Conference on IEEE*, pp. 1002-1006. 2009.
- [8] J. Mcneil, D. Sen, Y. Mendelson, et al. Wearable wireless sensor patch for continuous monitoring of skin temperature, pressure, and relative humidity. *Proceedings - IEEE International Symposium on Circuits and Systems*, pp. 7–10, 2017.
- [9] A. F. Filho, M. A. Fumagalli, N. E. M. T. Theodório and F. Rubio, “Desenvolvimento de um dispositivo para a prevenção de úlceras por pressão em cadeirantes”. *Revista Brasileira de Inovação Tecnológica em Saúde*, ISSN: 2236-1103, vol. 3, no. 1, 2013.
- [10] D. Hay, M. Falgenhauer, J. Morak, K. Wipfler, V. Willner, W. Liebhart and G. Schreier, “An eHealth System for Pressure Ulcer Risk Assessment Based on Accelerometer and Pressure Data”. *Journal of Sensors*, vol. 2015, 2015.
- [11] J. Lioret, A. Canovas, S. Sendra and L. Parra, “A smart communication architecture for ambient assisted living”. *IEEE Communications Magazine*, vol. 53, no. 1, pp. 26-33, 2015.
- [12] A. Dermirhan, “Neuroimage-based clinical prediction using machine learning tools.” *International Journal of Imaging Systems and Technology*, vol. 27, no. 1, pp. 89–97, 2017.
- [13] S. Dutta, B. C. S. Manideep, S. Rai, V. Vijayarajan. A comparative study of deep learning models for medical image classification. *IOP Conference Series: Materials Science and Engineering*, vol. 263, no. 4, pp. 0–9, 2017.
- [14] M. Elmogy, B. Garcia-Zapiran, A. S. Elmaghraby, A. El-Baz. “An Automated Classification Framework for pressure ulcer tissues based on 3d Convolutional Neural Network.” *Proceedings - International Conference on Pattern Recognition, ICPR*, pp. 20-24, 2018.
- [15] A. N. Miyadaira. “Microcontroladores PIC18: Aprenda e programe em linguagem C” 3rd ed. São Paulo, Érica, 2012, sec XXI, pp. 1-400.
- [16] Y. W. Paranhos, V. L. C. G. Santos. Avaliação de risco por risco para úlceras por pressão por meio da escala de Braden, na língua portuguesa. *III Congresso Brasileiro de Estomatologia*. vol 33. 1999.
- [17] A. P. Braga, A. C. P. L. F. Carvalho. and T. Bernarda. “Redes Neurais Artificiais: Teoria e Aplicações”. 2nd ed. Rio de Janeiro, LTC, 2016, sec. XXI, pp. 3-226.
- [18] M. C. Mishu, J. W. Schroeder. Modelling of pressure ulcer (PU) risk prediction system. *Proceedings of the 2015 Science and Information Conference, SAI 2015*, pp. 650–656, 2015.
- [19] H. Chen, B. Yang, D. Liu, et al. Using Blood Indexes to Predict Overweight Statuses : An Extreme Learning Machine- Based Approach. *Journal Plos One* pp. 1–18, 2015.
- [20] C. G. Raji, S. S. V. Chandra. Long-Term Forecasting the Survival in Liver Transplantation Using Multilayer Perceptron Networks. *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 47, no. 8, pp. 2318–2329, 2017.
- [21] B. Ramsay, E. V. D. Knaap. Confusion Matrix-based Feature Selection Sofia Visa Algorithm for Confusion Matrix-based. *Proceedings of the Twenty-second Midwest Artificial Intelligence and Cognitive Science Conference*. pp. 120–127, 2011.
- [22] J. Vives, E. Quiles, E. Garcia. AI Techniques Applied to Diagnosis of Vibrations Failures in Wind Turbines. *IEEE Latin America Transactions*, vol.18. no.8. August. 2020.



Bruno Medina Pedroso. Possui graduação em Tecnologia em Automação Industrial (2009) pela Universidade de Mogi das Cruzes, Licenciatura em Eletrônica (2010) pela Faculdade de Tecnologia de São Paulo, Pós-graduação em Automação Industrial (2012) pela Faculdade Senai Armando de Arruda Pereira, Extensão em Sistemas Eletrônicos para Controle (2016) pela Faculdade Senai Anchieta, Mestrado em Engenharia Biomédica (2015) pela Universidade de Mogi das Cruzes, atualmente é Doutorando em Engenharia Biomédica com linha de pesquisa na área de Inteligência Artificial aplicada à Bioengenharia. Possui experiência na área de controle e automação, programação aplicada e sistemas inteligentes. Email: brunomedina@umc.br



João Vitor Sartori Guazzelli. Aluno de graduação da Escola Politécnica da Universidade de São Paulo, em formação em Engenharia Elétrica (2021) Possui formação de nível técnico em Mecatrônica (2019). Possui experiência na área de programação de sistemas eletrônicos embarcados em diversas linguagens.

Email: joao.guazzelli@usp.br



Alessandro Pereira da Silva Possui graduação em Engenharia da Computação (2003) pela Universidade de Mogi das Cruzes, Mestrado em Engenharia Biomédica (2007) pela Universidade de Mogi das Cruzes, Doutorado em Engenharia Biomédica (2009) pela Universidade de Mogi das Cruzes. Possui experiência na área de Engenharia Biomédica com ênfase em processamento de sinais e imagens médicas, atuando na subárea de tecnologia assistiva.



Silvia Regina Matos da Silva Boschi Possui graduação em Fisioterapia (1988) pela Pontifícia Universidade Católica de Campinas, Mestrado em Engenharia Biomédica (2003) pela Universidade de Mogi das Cruzes, Doutorado em Engenharia Biomédica (2011) pela Universidade de Mogi das Cruzes, Pós-doutorado em Engenharia Biomédica

(2016) pela Pontifícia Universidade Católica de São Paulo. Possui experiência na área de Fisioterapia com ênfase em Neurologia Infantil.



Silvia Cristina Martini Possui graduação em Matemática (1995) pela Universidade Federal de São Carlos, Mestrado em Engenharia Elétrica (1999) pela Universidade de São Paulo, Doutorado em Engenharia Elétrica (2004), Pós-doutorado em Engenharia Elétrica (2004) pela Universidade de São Paulo. Possui experiência com sistemas em ambiente virtual para ensino e aprendizagem, processamento de imagens médicas.



Terigi Augusto Scardovelli. Possui graduação em Engenharia da Computação (2003) pela Universidade de Mogi das Cruzes, Mestrado em Engenharia Biomédica (2007) pela Universidade de Mogi das Cruzes, Doutorado em Engenharia Biomédica (2010) pela Universidade de Mogi das Cruzes. Possui experiência na área de Engenharia Biomédica com ênfase em processamento de imagens, modelagem, animação e desenvolvimento de jogos computadorizados na subárea de tecnologia assistiva. Email: terigi@gmail.com