

**UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO
CENTRO TECNOLÓGICO
DEPARTAMENTO DE ENGENHARIA ELÉTRICA
PROJETO DE GRADUAÇÃO**



Pâmela Catrinque Martins

**Modelagem da deflexão de agulhas em tecidos
heterogêneos usando redes neurais**

Vitória-ES

Julho/2017

Pâmela Catrinque Martins

Modelagem da deflexão de agulhas em tecidos heterogêneos usando redes neurais

Parte manuscrita do Projeto de Graduação da aluna Pâmela Catrinque Martins, apresentada ao Departamento de Engenharia Elétrica do Centro Tecnológico da Universidade Federal do Espírito Santo, como requisito parcial para a obtenção do grau de Engenheiro Eletricista.

Universidade Federal do Espírito Santo

Centro Tecnológico

Departamento de Engenharia Elétrica

Projeto de Graduação

Orientador: Prof. Dr. Patrick Marques Ciarelli


Vitória-ES

Julho/2017


Pâmela Catrinque Martins

Modelagem da deflexão de agulhas em tecidos heterogêneos usando redes neurais


Parte manuscrita do Projeto de Graduação da aluna Pâmela Catrinque Martins, apresentada ao Departamento de Engenharia Elétrica do Centro Tecnológico da Universidade Federal do Espírito Santo, como requisito parcial para a obtenção do grau de Engenheiro Eletricista.



Prof. Dr. Patrick Marques Ciarrelli
Orientador



Prof. Dr. André Ferreira
Universidade Federal do Espírito Santo



Prof. Dr. Evandro Ottoni Teatini
Salles
Universidade Federal do Espírito Santo

Vitória-ES

Julho/2017

AGRADECIMENTOS

Os agradecimentos principais são direcionados ao meu orientador, o Professor Doutor Patrick Marques Ciarelli, pelo apoio e aprendizado recebidos ao longo deste projeto, e pela confiança em mim depositada.

Um forte agradecimento a minha família, que se fez presente durante toda a minha formação como pessoa e engenheira, e fez dos meus sonhos os seus sonhos.

Também agradeço a todos os meus amigos queridos pelos momentos compartilhados e a todos os professores com os quais eu tive a honra de conviver e aprender.

Finalmente, um agradecimento especial a toda equipe do Laboratório de Sistemas de Telerobótica e Biorobótica da Universidade de Alberta no Canadá pelo seu acolhimento e prestatividade.

RESUMO

A inserção de agulhas percutâneas está entre os procedimentos clínicos mais prevalentes. Dentre eles, a braquiterapia é um tratamento eficaz em pacientes com câncer localizado, como o câncer de próstata. Altas doses de radiação são administradas no tecido canceroso da próstata utilizando longas agulhas de ponta chanfrada com sementes radioativas em seu interior. A eficácia deste tratamento é intrinsecamente dependente da precisão da agulha em atingir o alvo. Entretanto, a interação da agulha com o tecido que a circunda ocasiona uma deflexão da mesma em relação à trajetória desejada. Para superar este problema, muitas pesquisas têm sido realizadas no intuito de desenvolver sistemas robóticos para guiar automaticamente as agulhas por vias percutâneas, sendo necessário métodos para estimar a deflexão das mesmas em tecidos moles. Neste trabalho é analisado o uso de redes neurais para a modelagem da deflexão de agulhas. Os dados da interação entre agulha e tecido foram obtidos a partir de medições coletadas de várias inserções em tecidos *ex-vivo*. As variáveis medidas são a profundidade de inserção, velocidade, as rotações, forças e os torques medidos na base da agulha, e as deflexões são estimadas nas 3 coordenadas do espaço. Os resultados obtidos foram comparados com os de outro modelo usado na literatura.

Palavras-chave: inserção de agulhas, câncer de próstata, modelagem, redes neurais.

ABSTRACT

The insertion of percutaneous needles is one of the most prevalent clinical procedures. Among them, brachytherapy is an effective treatment in patients with localized cancer, such as prostate cancer. High doses of radiation are applied on the cancerous tissue of the prostate using long bevelled tip needles with radioactive seeds inside. The effectiveness of this treatment is intrinsically dependent on the precision of needle insertion to reach the desired target. However, the interaction of the needle with the surrounding tissue causes a deflection thereof in relation to the desired trajectory. To overcome this problem, many researches have been performed on the purpose of developing robotic systems to guide automatically the needles by percutaneous routes, with the necessity to estimate the deflexion of it in soft tissues. In this work, the use of neural networks to model the needle deflection is analysed. The data of the needle-tissue interaction was obtained from measurements collected from various insertions in ex-vivo tissues. The measured variables are the insertion depth, velocity, the rotations, forces and torques measured at the base of the needle, and the deflexions are estimated in 3 space coordinates. The obtained results were compared with another model used in the literature.

Keywords: needle insertion, prostate cancer, modeling, neural networks.

LISTA DE FIGURAS

Figura 1 – Volume de cirurgias minimamente invasivas realizadas no mundo entre os anos de 2005 à 2014, em milhares.	14
Figura 2 – Um esquema da inserção de agulha na braquiterapia. O cirurgião insere uma agulha longa através do períneo do paciente para depositar as sementes radioativas na próstata.	15
Figura 3 – As sementes radioativas para implantação próximas à uma moeda. . . .	20
Figura 4 – Vista do procedimento de PPB durante execução. O médico insere manualmente a agulha em direção à próstata.	20
Figura 5 – Exemplo de agulha utilizada para o procedimento de PPB.	21
Figura 6 – Forças de interação entre a agulha e o tecido durante a inserção. (a) Força de perfuração no ponto de contato entre a ponta da agulha e a superfície do tecido. (b) Força de corte incluindo a propagação da rachadura do tecido em resposta ao deslocamento da agulha. (c) Força de atrito aplicada tangencialmente ao eixo da agulha. (d) Força de deformação aplicada perpendicularmente à superfície de contato entre o eixo da agulha e o tecido.	22
Figura 7 – Forças atuando ao longo da agulha. As setas grossas são as forças de compressão durante a inserção da agulha, e as setas finas são as forças de atrito.	23
Figura 8 – Inserção de agulha em tecido mole. F_x , F_y são as forças medidas na base da agulha, na direção x e y , e F_z é a força de inserção da agulha. M_x , M_y são os torques medidos na base da agulha em torno de x e y , respectivamente. A posição da ponta da agulha no plano (y, z) e (x, z) são denotados u_y e u_x	24
Figura 9 – Neurônio biológico.	27
Figura 10 – Modelo de um neurônio de McCulloch e Pitts.	27
Figura 11 – Exemplo de uma rede de propagação para frente de múltiplas camadas com n entradas e m saídas e duas camadas escondidas de m neurônios.	30
Figura 12 – Exemplo de uma rede GRNN.	32
Figura 13 – Sistema robótico utilizado para coleta dos dados.	37

LISTA DE TABELAS

Tabela 1 – Erros RMSE, MAE, MAAPE e SMAPE obtidos para a variável $\mathbf{u_x}$ com os métodos MLP , GRNN e JIT para os quatro cenários de teste, para os 3 casos.	48
Tabela 2 – Erros RMSE, MAE, MAAPE e SMAPE obtidos para a variável $\mathbf{u_y}$ com os métodos MLP , GRNN e JIT para os quatro cenários de teste, para os 3 casos.	51
Tabela 3 – Erros RMSE, MAE, MAAPE e SMAPE obtidos para a variável $\mathbf{F_z}$ com os métodos MLP , GRNN e JIT para os quatro cenários de teste, para os 3 casos.	53

LISTA DE QUADROS

Quadro 1 – Os quatro cenários de teste utilizados para as redes MLP e GRNN. . .	41
Quadro 2 – Os três casos de estudo utilizados para as redes MLP e GRNN. . . .	41

LISTA DE ABREVIATURAS E SIGLAS

PPB	<i>Permanent prostate brachytherapy</i>
RNA	Rede neural artificial
MLP	<i>Multi-layer perceptron</i>
GRNN	<i>Generalized regression neural networks</i>
RBF	<i>Radial Basis Function</i>
GDL	Graus de liberdade
PID	Proporcional Integral Derivativo
JIT	<i>Just-In-Time</i>
RMSE	<i>Root Mean Square Error</i>
MAE	<i>Mean Absolute Error</i>
MAAPE	<i>Mean Arctangent Absolute Percentage Error</i>
SMAPE	<i>Symmetric Mean Absolute Percentage Error</i>

SUMÁRIO

1	INTRODUÇÃO	12
1.1	Contextualização	12
1.2	Justificativa	13
1.3	Objetivos	16
1.3.1	Objetivo Geral	16
1.3.2	Objetivos Específicos	17
1.4	Metodologia da Pesquisa	17
1.5	Estrutura do Trabalho	18
2	EMBASAMENTO TEÓRICO	19
2.1	A braquiterapia de próstata permanente	19
2.1.1	Procedimento	19
2.2	Interação entre agulha e tecido	21
2.2.1	Estimando a deflexão de agulhas	22
2.2.2	Controle e dirigibilidade de agulhas	23
2.2.2.1	Modelagem	24
2.3	Redes Neurais	26
2.3.1	Inspiração na neurociência	26
2.3.2	O neurônio artificial e a rede neural	26
2.3.3	Métodos de aprendizagem	28
2.3.3.1	Aprendizado supervisionado	29
2.4	Perceptron de múltiplas camadas – MLP	29
2.4.1	Treinamento da rede MLP	30
2.4.1.1	Algoritmo de retropropagação	31
2.5	Rede neural de regressão generalizada – GRNN	31
2.5.1	Arquitetura	32
2.5.2	Treinamento da rede GRNN	33
2.5.2.1	Função de base radial – RBF	33
2.5.2.2	Algoritmo	34
3	METODOLOGIA DOS EXPERIMENTOS	35
3.1	Modelagem <i>Just-In-Time</i>	35
3.2	Base de dados	36
3.2.1	Experimento e coleta de dados	36
3.3	Definição das variáveis	38
3.3.1	Configuração das variáveis	39

3.4	Cenários de teste	40
3.5	Configuração das redes MLP	41
3.6	Configuração das redes GRNN	42
3.7	Validação experimental	43
3.7.1	Validação cruzada	43
3.7.2	Medidas de avaliação	44
4	RESULTADOS	47
4.1	Deflexão da agulha no plano $(x, z) - u_x$	47
4.2	Deflexão da agulha no plano $(y, z) - u_y$	50
4.3	Força de inserção da agulha – F_z	52
5	CONCLUSÃO	55
	REFERÊNCIAS BIBLIOGRÁFICAS	58

1 INTRODUÇÃO

1.1 Contextualização

O câncer de próstata é o quarto tipo de câncer mais comum no mundo, e o segundo tipo de câncer mais comum nos homens. Em 2012, estimou-se que 1,1 milhão de homens foram diagnosticados com câncer de próstata (IARC, 2012). Este tipo de câncer se desenvolve comumente em homens mais velhos, por isso espera-se que com o envelhecimento da população mundial, 1 a cada 7 homens sejam diagnosticados com câncer de próstata (ACS, 2016).

Uma das opções amplamente adotadas para o tratamento do câncer é a braquiterapia de próstata permanente transperineal (do inglês, PPB – *Permanent Prostate Brachytherapy*). Este procedimento é minimamente invasivo e apresenta nível favorável de toxicidade, especialmente quando comparada a outras técnicas, como a radioterapia externa e a prostatectomia radical.

Na PPB, altas doses de radiação são administradas no tecido canceroso por meio da implantação de uma grande quantidade de sementes radioativas dentro da próstata, utilizando agulhas longas com as pontas chanfradas.

As sementes são distribuídas ao longo do tecido de forma a erradicar o câncer, preservando as estruturas saudáveis adjacentes. Portanto, a precisão do posicionamento das sementes nos alvos cancerosos é um fator decisivo para o bom resultado do tratamento (ROSSA et al., 2016a).

A localização das sementes na próstata é determinada previamente ao procedimento, em uma fase de pré-planejamento. Idealmente, as sementes são dispostas de forma equidistante nas proximidades do tumor, a fim de se obter uma distribuição consistente da radiação e maximizar a eficácia do tratamento. Nesta fase de pré-planejamento, assume-se que a agulha permanece reta durante toda a inserção (LEHMANN et al., 2016).

Entretanto, devido às forças de interação entre a agulha e o tecido, na prática a agulha sofre uma curvatura em sua forma defletindo assim da trajetória original desejada. Este efeito compromete significativamente a qualidade do implante das sementes no tecido canceroso e pode levar a efeitos colaterais indesejados (OKAMURA; SIMONE; O'LEARY,

2004). Assim, o sucesso da PPB se torna dependente da habilidade e experiência dos cirurgiões.

Problemas como este têm impulsionado o aumento do uso de sistemas robóticos em vários procedimentos médicos que seriam complexos de serem realizados utilizando os meios convencionais. O mercado mundial de robótica médica - incluindo cirurgias robóticas e robôs de reabilitação - foi avaliado em US\$ 1,7 bilhões em 2016 e a previsão é de que este número chegue a US\$ 2,8 bilhões em 2021 (RESEARCH; MARKETS, 2016).

Os sistemas robóticos não são empregados com o intuito de substituir o cirurgião, mas sim a fim de estender suas capacidades, oferecendo alto nível de destreza e precisão em diagnósticos e tratamentos. Assim, muitas vezes os robôs cirúrgicos são tratados como assistentes que trabalham em conjunto com os cirurgiões (TAYLOR et al., 2008).

Dado este cenário do investimento na área de cirurgias robóticas, e o problema abordado da deflexão de agulhas no tratamento do câncer de próstata, a inserção de agulhas assistida por robôs para melhorar a precisão da implantação de sementes tem sido o foco de muitas pesquisas na última década, como em Khadem et al. (2016c) e Patriciu et al. (2007).

Neste contexto, este trabalho propõe o uso de dois tipos de redes neurais artificiais para modelar a interação entre o tecido e a agulha, com o intuito de prever a deflexão da mesma, bem como a força de inserção empregada. A motivação para o uso de redes neurais é o fato da sua capacidade de realizar diversas tarefas, como de regressão e classificação, com um desempenho muitas vezes considerado aceitável.

Os dados foram obtidos em parceria com o Laboratório de Sistemas de Telerobótica e Biorobótica da Universidade de Alberta, Canadá. As medições foram coletadas a partir de várias inserções em tecidos *ex-vivo*¹ e as variáveis medidas são a profundidade de inserção, velocidade, as rotações, forças e torques medidas na base da agulha.

1.2 Justificativa


A utilização de sistemas robóticos na medicina tem crescido significativamente nos últimos anos devido às vantagens da cirurgia minimamente invasiva, e a consequente melhora nos resultados dos tratamentos. O aumento da demanda de cirurgias minimamente invasivas

¹ O termo *ex-vivo* significa que as amostras a serem utilizadas foram extraídas do organismo original, com alteração mínima das condições naturais.

pode ser atribuído à adoção de novas tecnologias por profissionais de saúde, bem como a aceitação do paciente para cirurgias robóticas (GVR, 2012).

A Figura 1 mostra a forte evolução do volume de cirurgias minimamente invasivas realizadas no mundo entre os anos de 2005 a 2014, em relação às cirurgias abertas tradicionais, em milhares. Como pode ser observado, o número de cirurgias minimamente invasivas em 2014 foi em torno de 9 vezes maior que o número de cirurgias abertas, e a tendência é que essa diferença aumente nos próximos anos.

Figura 1 – Volume de cirurgias minimamente invasivas realizadas no mundo entre os anos de 2005 à 2014, em milhares.



Fonte: Grand View Research, 2012


Um dos tipos de cirurgias minimamente invasivas, a braquiterapia de próstata permanente transperineal é amplamente utilizada no tratamento de pacientes com câncer de próstata localizados.

Esta técnica expõe os tumores à radiação através da implantação de sementes radioativas nas proximidades do tecido canceroso, utilizando agulhas longas de ponta chanfrada. Apesar do procedimento apresentar bons resultados na maioria dos casos, uma observação minuciosa da braquiterapia de próstata indica que há muitos aspectos a serem aprimorados.

A Figura 2 ilustra a inserção da agulha na braquiterapia. O cirurgião insere uma agulha longa através do períneo do paciente para depositar as sementes radioativas na próstata, e uma sonda de ultrassom transretal é utilizada para visualização durante o procedimento.

O maior desafio que pode comprometer a qualidade do tratamento é o posicionamento errôneo das sementes radioativas na próstata, ocasionado pela deflexão das agulhas e pelo deslocamento do tecido, ambos os quais são efeitos difíceis de serem controlados durante

Figura 2 – Um esquema da inserção de agulha na braquiterapia. O cirurgião insere uma agulha longa através do períneo do paciente para depositar as sementes radioativas na próstata.



Fonte: Khadema et al., 2016c

uma inserção manual. Estudos anteriores mostraram que as sementes são inseridas com uma precisão média absoluta de 5 mm, o que corresponde a um erro substancial de mais de 10% do diâmetro da próstata (TASCHEREAU et al., 2000).

Devido à baixa precisão do posicionamento das sementes, a prática atual da braquiterapia limita-se em tratar a próstata inteira uniformemente, mesmo para casos de pacientes com tumores localizados e bem definidos. Ao invés disto, a melhor opção para o tratamento seria depositar uma quantidade maior de doses de radiação apenas nos alvos cancerosos específicos.

Esta problemática tem evidenciado a necessidade da melhoria da precisão e dirigibilidade das agulhas, aspectos fundamentais para minimizar o risco de exposição indesejada à radiação dos tecidos saudáveis adjacentes. Muitos pesquisadores implementaram sistemas robóticos para inserir automaticamente uma agulha em um tecido e realizar as ações corretivas necessárias para controlar sua trajetória em direção a um alvo.

Uma das soluções usualmente empregada para prever e corrigir o posicionamento das agulhas baseia-se na utilização de imagens de ultrassom. Em (KHADEM et al., 2016c) é proposto a utilização de um modelo preditivo de controle baseado em imagens de ultrassom. Entretanto, modelos como este são difíceis de serem implementados pois além de contarem com um campo de visão muito estreito, as imagens de ultrassom contêm detalhes complexos a serem interpretados e distinguidos dos alvos. Deve-se levar em consideração ainda que, a sonda de ultrassom deve se mover em sincronia com a agulha, para evitar a deformação

indesejada do tecido adjacente e o deslocamento da posição do alvo (DOBLER et al., 2006).

Outra alternativa que tem ganhado destaque nas pesquisas recentes é a modelagem das interações entre o tecido e a agulha. Asadian, Kermani e Patel (2011) e Misra et al. (2010) desenvolveram modelagens mecânicas para prever o comportamento das agulhas quando inseridas no corpo humano. Embora estas modelagens físicas apresentem bons resultados para alguns casos, trata-se de um modelo com limitações, pois assume-se que o tecido é rígido em relação à agulha. Na prática, quando uma agulha é inserida no tecido, o mesmo é comprimido e sofre deslocamentos, o que, em contrapartida, provoca uma deflexão na agulha, alterando sua trajetória e curvatura.

Uma abordagem alternativa para levar em consideração estes fatos, é construir um modelo baseado em dados obtidos de observações empíricas das interações entre tecidos e agulhas. Estes modelos oferecem a possibilidade de estimar o comportamento final das agulhas sem um conhecimento da complexa dinâmica física do sistema.

Sob esta perspectiva, este trabalho visa o desenvolvimento de uma nova modelagem para as interações entre a agulha e o tecido, durante inserções percutâneas. Com a utilização de dados coletados a partir de vários testes de inserções em tecidos *ex-vivo*, é proposto o uso de redes neurais artificiais para prever a deflexão da agulha.

Rede neural artificial é um modelo computacional inspirado nas operações biológicas dos neurônios. Ela tem sido cada vez mais utilizada na área de biomedicina devido à sua habilidade de aprendizado e generalização, e ainda a capacidade de lidar com grandes volumes de dados referentes a processos complexos (FOSTER; KOPROWSKI; SKUFCIA, 2014).

1.3 Objetivos

1.3.1 Objetivo Geral

Este trabalho tem por objetivo modelar e aplicar redes neurais para prever a deflexão de agulhas no espaço 3D quando inseridas no corpo humano, para o tratamento de câncer de próstata.

1.3.2 Objetivos Específicos

- Determinar, a partir do conjunto de dados existente, as variáveis necessárias à previsão da deflexão das agulhas.
- Modelar o problema e configurar as redes neurais a serem utilizadas.
- Avaliar o desempenho das redes implementadas e comparar os resultados com um método utilizado na literatura.

1.4 Metodologia da Pesquisa

O desenvolvimento deste trabalho pode ser discriminado em duas etapas. Primeiramente, será feita uma revisão bibliográfica sobre as técnicas atuais de PPB, e as pesquisas recentes acerca da utilização de sistemas robóticos no tratamento do câncer de próstata.

Na sequência, serão apresentadas duas propostas baseadas em redes neurais: a primeira utilizará redes neurais perceptron de múltiplas camadas (do inglês, *Multi-layer perceptron* - MLP) e, a segunda, utilizará redes neurais de regressão generalizada (do inglês, *Generalized Regression Neural Networks* - GRNN).

O desempenho de ambas as propostas de redes neurais será avaliado e comparado também com os resultados apresentados por Rossa et al. (2016b) que utilizou o mesmo conjunto de dados em seus experimentos.

Para a execução deste trabalho será utilizado um conjunto de dados obtido em parceria com o Laboratório de Sistemas de Telerobótica e Biorrobótica da Universidade de Alberta, Canadá.

Para o desenvolvimento da proposta será utilizado o software Matlab, por permitir prototipagens rápidas e fáceis, além de possuir diversas bibliotecas que serão úteis para o desenvolvimento deste trabalho. Com o auxílio do *software* Matlab será feito o processamento dos dados, a seleção das variáveis utilizadas e posterior implementação das redes neurais, seu treinamento, teste e validação.

1.5 Estrutura do Trabalho

Este documento está dividido em cinco capítulos a fim de sintetizar todas as etapas de maneira sequencial e garantir melhor compreensão do trabalho.

No primeiro capítulo é feita uma introdução ao objeto de estudo, e a relevância deste trabalho é apresentada. Em seguida é feito um detalhamento dos objetivos gerais e específicos do projeto, e como o mesmo será desenvolvido.

O segundo capítulo fornece o embasamento teórico necessário para a compreensão deste trabalho. São apresentados o procedimento para o tratamento do câncer de próstata e a problemática da deflexão de agulhas. Em seguida é feito um estudo sobre as redes neurais e suas principais características.

O terceiro capítulo detalha como foi dado o desenvolvimento deste trabalho, explicando a base de dados e como a mesma foi obtida. Ainda são abordadas as configurações das variáveis de entrada e saída do problema, as configurações das redes neurais e os métodos de validação empregados.

No quarto capítulo são mostrados os resultados obtidos pelas redes neurais em diversos cenários de teste. Estes resultados são em seguida analisados e discutidos.

Finalmente, o quinto capítulo traz as conclusões com base nos resultados encontrados, adicionando-se as ações de continuidade e possibilidades de trabalhos futuros.

2 EMBASAMENTO TEÓRICO

2.1 A braquiterapia de próstata permanente

A braquiterapia (da palavra Grega *brachys*, que significa “curta distância”), trata-se de um procedimento médico minimamente invasivo, utilizado geralmente no tratamento do câncer cervical, de próstata, mama e câncer de pele.

No caso do tratamento do câncer de próstata, existem dois métodos de braquiterapia: a temporária e a permanente. A escolha do tratamento a ser adotado pelo médico depende de diversos fatores, incluindo o estágio do câncer, possíveis efeitos colaterais, a preferência do paciente e sua saúde geral.

Na braquiterapia temporária, também conhecida por braquiterapia de Taxa de Dose Alta (do inglês HDR – *High Dose Rate*), fontes radioativas são posicionadas próximas ao tumor por um tempo específico (alguns minutos) e em seguida são retiradas.

Por sua vez, a braquiterapia de próstata permanente transperineal, foco deste trabalho, é conhecida do inglês como PPB – *Permanent Prostate Brachytherapy*. Neste procedimento, sementes radioativas são implantadas permanentemente no tecido canceroso. A dose de radiação emitida pelas sementes decai à valores próximos de zero em algumas semanas ou meses, e finalmente as sementes permanecem inativas dentro da próstata.

2.1.1 Procedimento

Antes da PPB ser executada, é necessário que ocorra uma fase de planejamento pré-operatório. Nesta etapa, uma sonda de ultrassom é inserida no reto do paciente e são feitas várias imagens em profundidades equidistantes da próstata, afim de se visualizar várias camadas da mesma. Com as imagens de ultrassom coletadas é feita a identificação de toda a próstata e suas fronteiras são delimitadas. Estas fronteiras indicam os limites para a implantação das sementes e servem como referência para os médicos durante o procedimento cirúrgico (LEHMANN, 2013).

Em seguida, dá-se início à próxima etapa: a cirurgia. Neste momento, novamente é inserida uma sonda de ultrassom no reto do paciente para a visualização da próstata, agulha e das

sementes. Como o ultrassom fornece apenas imagens em duas dimensões, é necessário que o cirurgião alterne as camadas de visualização a fim de observar a trajetória da agulha e verificar se as sementes estão sendo inseridas na posição correta.

A agulha utilizada na braquiterapia pode conter várias sementes radioativas, desta forma, várias destas podem ser depositadas em uma única inserção. Durante o procedimento, são implantadas de 50 a 100 sementes e o tamanho de cada uma delas é comparado ao tamanho de um grão de arroz, com um diâmetro de aproximadamente um milímetro. Na Figura 3 é possível ver o tamanho das sementes quando comparadas à uma moeda. Elas são usualmente feitas de Iodo-125 – um radioisótopo do Iodo – e isoladas dentro de cápsulas de titânio.

Figura 3 – As sementes radioativas para implantação próximas à uma moeda.



Fonte: Lehmann, 2013

A Figura 4 mostra a inserção da agulha durante a execução da braquiterapia. A agulha contendo o material radioativo é inserida manualmente pelo cirurgião em direção aos locais planejados, aonde serão depositadas as sementes. Com o auxílio da sonda de ultrassom transretal, o cirurgião acompanha o posicionamento das sementes (LEHMANN, 2013).

Figura 4 – Vista do procedimento de PPB durante execução. O médico insere manualmente a agulha em direção à próstata.



Fonte: Lehmann, 2013

Durante a implantação das sementes, um médico é encarregado de interpretar e reportar as informações planejadas ao cirurgião. Ainda, ele deve fornecer instruções verbais sobre as coordenadas da agulha e a distância desta em relação ao plano de referência (YU et al., 1999).

Como resultado das técnicas manuais de inserção das agulhas, a PPB é capaz de posicionar as sementes com uma precisão de 5 milímetros, o que constitui um erro substancial de mais de 10% do tamanho da próstata. Desta forma, o tratamento não apresentará o resultado necessário da radiação sobre as células cancerosas, e ainda poderá ocasionar um dano aos tecidos saudáveis adjacentes (TASCHEREAU et al., 2000).

Tipicamente, assume-se que a agulha segue um caminho reto em direção ao alvo quando inserida no corpo humano. Entretanto, a agulha deflete durante sua inserção e o tecido adjacente sofre uma deformação. Ambos são as causas predominantes da baixa precisão durante o implante das sementes radioativas e estão relacionados à diversos fatores, os quais serão introduzidos na próxima seção.

2.2 Interação entre agulha e tecido

Uma das principais causas da baixa precisão do posicionamento das sementes durante a PPB advém da interação entre a agulha e o tecido: a deformação sofrida pela agulha durante sua inserção, bem como a deformação do tecido ao seu redor são efeitos acoplados e, portanto, influenciam um no outro (ROSSA et al., 2016b).

As agulhas utilizadas na braquiterapia são flexíveis e longas – podem ter 200 mm de comprimento – e apresentam uma ponta chanfrada. A Figura 5 mostra um modelo de agulha utilizado no procedimento de PPB. Por um lado, estas características intrínsecas da agulha levam à sua deflexão, mas em contrapartida, sua flexibilidade também pode ser usada para criar curvaturas durante sua trajetória, evitando obstáculos e atingindo o alvo.

Figura 5 – Exemplo de agulha utilizada para o procedimento de PPB.



Fonte: Site da Cook[®] medical

As próximas seções tratam dos fatores determinantes para o comportamento da agulha durante sua inserção, e como eles podem ser utilizados na aplicação estratégica de controle.


2.2.1 Estimando a deflexão de agulhas

As forças de interação que surgem durante a inserção da agulha em um tecido mole podem ser divididas em quatro fases distintas, a saber (KHADEM et al., 2016a):

- *Força de perfuração, F_p* : a força de perfuração surge no contato inicial da ponta da agulha com o tecido. Ela começa deformando o tecido e continua até a força de contato atingir seu máximo, dando origem à um rachadura no tecido.
- *Força de corte, F_c* : o corte é um evento dinâmico que começa quando a rachadura iniciada se propaga no tecido em resposta ao deslocamento da ponta da agulha.
- *Força de Atrito, F_f* : o atrito é aplicado tangencialmente ao eixo da agulha e fornece resistência ao movimento da agulha.
- *Força de deformação, F_s* : a força de reação de tecido é aplicada perpendicularmente à superfície de contato entre o eixo da agulha e o tecido.

A Figura 6 mostra as forças de interação mencionadas acima.

Figura 6 – Forças de interação entre a agulha e o tecido durante a inserção. (a) Força de perfuração no ponto de contato entre a ponta da agulha e a superfície do tecido. (b) Força de corte incluindo a propagação da rachadura do tecido em resposta ao deslocamento da agulha. (c) Força de atrito aplicada tangencialmente ao eixo da agulha. (d) Força de deformação aplicada perpendicularmente à superfície de contato entre o eixo da agulha e o tecido.




Fonte: Khadem et al., 2016a

Devido à natureza chanfrada da ponta das agulhas utilizadas na braquiterapia, ela possui uma característica assimétrica, grande responsável pela deflexão da agulha.

Como resultado da assimetria da ponta da agulha, o deslocamento do tecido durante a inserção também é assimétrico e uma quantidade maior de tecido é deslocada no lado do bisel (chanfro). Consequentemente, a agulha sofre a deflexão na direção do chanfro, devido às forças atuantes em sua ponta (ABOLHASSANI; PATEL, 2006), como é ilustrado na Figura 7.

Figura 7 – Forças atuando ao longo da agulha. As setas grossas são as forças de compressão durante a inserção da agulha, e as setas finas são as forças de atrito.



Fonte: Abolhassani; Patel, 2006

2.2.2 Controle e dirigibilidade de agulhas

Do ponto de vista do controle, a ponta chanfrada possui efeitos antagonísticos: enquanto ela facilita o corte e a penetração no tecido, ela também aumenta a deflexão da agulha à medida que ela avança. Assim, torcionando a base da agulha a direção de seu chanfro muda, oferecendo capacidade de dirigibilidade. A combinação adequada de profundidade de inserção e rotação podem ser então utilizadas para controlar a trajetória da ponta da agulha.

O termo dirigibilidade implica em controle da deflexão da ponta da agulha e variação de sua direção da trajetória enquanto a mesma é inserida, por meio de rotações axiais, manipulação lateral e controle da velocidade de inserção. Um modelo de dirigibilidade de agulha prediz a sua trajetória dentro do tecido com base nas entradas acima mencionadas (KHADEM et al., 2016b).

Vários dispositivos de dirigibilidade de agulhas foram desenvolvidos para guiar as agulhas e depositar as sementes radioativas, como em Fallahi et al. (2017), Lehmann et al. (2016) e Rossa et al. (2016b).

Estes sistemas podem ser classificados em três categorias principais, dependendo do grau de automação empregado: inserção totalmente automática, inserção semi-automática e inserção totalmente manual. Na primeira categoria, a inserção da agulha é feita automaticamente por um robô (PATRICIU et al., 2007). Na segunda categoria, o sistema

robótico atua como um manuseador da agulha que pode rotacioná-la axialmente, com o médico sendo responsável pela inserção da agulha (ZHANG et al., 2006). Finalmente, a terceira categoria consiste de tecnologias designadas à fornecer ao médico informações acerca das manobras necessárias e mantê-lo em controle da inserção e da dirigibilidade do procedimento (MAGEE et al., 2007).


O foco deste trabalho está na previsão da deflexão de agulhas utilizando redes neurais, com base nos testes realizados com um dispositivo de inserção totalmente automático e a modelagem necessária para o desenvolvimento do projeto é abordada na próxima seção.

2.2.2.1 Modelagem

O comportamento mecânico da agulha durante sua inserção depende da combinação dos efeitos da sua deflexão e da deformação do tecido adjacente. Primeiramente, é importante definir os parâmetros observáveis durante a inserção da agulha, que influenciam na deflexão da mesma, e que podem ser utilizados como variáveis de entrada de um modelo.

A Figura 8 representa esquematicamente uma agulha com ponta chanfrada inserida em um tecido mole. u_y e u_x denotam a deflexão da ponta da agulha nos planos (y, z) e (x, z) , respectivamente.

Figura 8 – Inserção de agulha em tecido mole. F_x , F_y são as forças medidas na base da agulha, na direção x e y , e F_z é a força de inserção da agulha. M_x , M_y são os torques medidos na base da agulha em torno de x e y , respectivamente. A posição da ponta da agulha no plano (y, z) e (x, z) são denotados u_y e u_x .



Fonte: Rossa et al., 2016

Enquanto a ponta da agulha avança e corta o tecido, um desequilíbrio de forças é desenvolvido sobre a mesma, levando a agulha a desviar de sua trajetória original. O eixo da agulha defletido comprime o tecido circundante imediatamente, que por sua vez exerce forças sobre a agulha.

Vários fatores influenciam a magnitude e a direção destas forças que, para uma determinada agulha, podem ser classificadas em duas categorias principais: parâmetros específicos do perfil de inserção e características específicas do tecido, como detalhado abaixo.

Parâmetros específicos do perfil de inserção incluem a profundidade à qual a agulha é inserida, a velocidade de inserção da agulha e a posição angular do bisel durante a inserção.

Profundidade de inserção (d): A deflexão da agulha aumenta à medida que a ponta avança mais no tecido. Assim, a profundidade em que a agulha é inserida é um fator chave que determina a quantidade de deflexão observada.

Orientação do chanfro: Uma vez que a força aplicada na ponta da agulha é normal ao ângulo do chanfro, alterar a orientação do chanfro fazendo rodar a base da agulha leva a agulha a defletir em diferentes direções. Uma combinação adequada da profundidade de inserção da agulha e a orientação do ângulo do bisel é tipicamente usada na inserção de agulhas assistida por robôs para forçar a ponta da agulha a seguir uma trajetória desejada.

Velocidade de inserção da agulha (v): Considerando o tecido como viscoelástico, a velocidade de inserção da agulha aumentará as forças de fricção entre a agulha e o tecido e afetam a força de inserção da agulha.

Além dos parâmetros específicos de inserção listados acima, a deflexão da agulha também depende das propriedades mecânicas do tecido. Em vez de caracterizar o tecido e utilizar esta informação como entrada, considera-se as forças e torques que atuam na base da agulha, que estão diretamente relacionados com as características dos tecidos e com a magnitude e direção da deflexão da agulha.

Forças laterais na base da agulha (F_x , F_y): As forças verticais e horizontais na base da agulha, chamadas F_x e F_y , são diretamente proporcionais à deflexão da agulha nos planos (x, z) e (y, z) , respectivamente. Essas forças representam a integral de todas as cargas aplicadas ao longo do eixo da agulha.

Momentos laterais na base da agulha (M_x , M_y): os torques são medidos na base da agulha e carregam informação sobre como esta deforma o tecido circundante durante a inserção uma vez que dependem da distribuição das cargas aplicadas no eixo da agulha. Assim, os torques também dependem da quantidade de deflexão da agulha em cada plano.

Tendo definido todo o embasamento teórico acerca da braquiterapia de próstata, da interação entre a agulha e o tecido e também do controle e modelagem do problema, as

próximas seções abordarão as redes neurais e suas principais características.

2.3 Redes Neurais

Os sistemas robóticos têm sido amplamente empregados na medicina nos últimos anos devido às vantagens da cirurgia minimamente invasiva, e a consequente melhora nos resultados dos tratamentos. A rede neural artificial é um modelo computacional inspirado nas operações biológicas dos neurônios, e tem sido cada vez mais utilizada na área de biomedicina – Amato et al. (2013); Parveen et al. (2016) – devido à sua habilidade de aprendizado e generalização, e ainda a capacidade de lidar com grandes volumes de dados referentes à processos complexos. Sob esta perspectiva, este trabalho visa o uso de uma rede neural artificial para resolver o problema apresentado.


2.3.1 Inspiração na neurociência

O processamento local de informação no cérebro efetua-se em cerca de 10^{11} unidades que têm uma estrutura relativamente simples: os neurônios. Na Figura 9 apresenta-se o modelo simplificado de um único neurônio real. O neurônio é uma célula com núcleo e corpo (soma), onde reações químicas e elétricas representam o processamento de informação. A saída da informação do soma é realizada por impulsos elétricos que se propagam através do axônio. No final do axônio existem inúmeras ramificações que distribuem a informação para outros neurônios vizinhos. A ligação com outros neurônios é realizada através de sinapses que estão conectadas a um dendrite do neurônio receptor. A sinapse dispara uma substância química quando for excitada pelo impulso do axônio. A substância se transmite entre sinapse e dendrite realizando a conexão entre dois neurônios vizinhos. Conforme as excitações (ou inibições) que células vizinhas transmitem para a célula em consideração ela processa a informação novamente e a transmite via seu axônio (RAUBER, 1997).

2.3.2 O neurônio artificial e a rede neural

Assim como o sistema nervoso é composto por bilhões de células nervosas, a rede neural artificial é formada por unidades de processamento que simulam o funcionamento de uma rede neural. Essas unidades devem funcionar de acordo com os elementos em que foram inspirados, recebendo e retransmitindo informações.

Figura 9 – Neurônio biológico.




Fonte: Rauber, T. W., 1997

A operação de uma unidade de processamento, proposta em McCulloch e Pitts (1943), pode ser resumida da seguinte maneira:

- Sinais são apresentados à entrada;
- Cada sinal é multiplicado por um número, ou peso, que indica a sua influência na saída da unidade;
- É feita a soma ponderada dos sinais que produz um nível de atividade;
- Se este nível de atividade exceder um certo limite (*threshold*) a unidade produz uma determinada resposta de saída.

A Figura 10 mostra este modelo de neurônio artificial.

Figura 10 – Modelo de um neurônio de McCulloch e Pitts.



Fonte: Rauber, T. W., 1997

A informação proveniente de D neurônios é fornecida às x_j entradas do neurônio processador. O processamento consiste de uma combinação linear das entradas, onde cada entrada

está associada a um peso w_j que reflete a importância de sua respectiva entrada x_j . O resultado dessa combinação linear é o valor net , como exibido na Equação 2.1.

$$net = \sum_{j=1}^D w_j x_j \quad (2.1)$$

Se o valor de net ultrapassar o limiar μ , o neurônio “dispara” o valor $y = 1$ na saída binária, e se não ultrapassar o limiar a saída fica em $y = 0$. No exemplo da Figura 10 a comparação de net com o limiar μ é realizada pela função de *Heaveside* (função de escada), mas existem outras funções que são comumente utilizadas e não apresentam uma transição tão abrupta de valores, como a função linear e sigmoidal.

Uma rede neural artificial tem uma característica fundamental: os métodos de aprendizagem, os quais são discutidos na seção seguinte.

2.3.3 Métodos de aprendizagem

Assim como existem diversas formas de aprendizagem para os seres humanos a partir do meio ao seu redor, assim acontece com as RNAs. O processo de aprendizagem de uma rede neural, como o próprio nome sugere, consiste em sua habilidade de aprender de seu ambiente e assim executar as tarefas desejadas.

O aprendizado ocorre quando a rede neural atinge uma solução generalizada para uma classe de problemas. Entretanto, para tal, é necessário que a rede seja treinada. O termo *treinamento* de uma rede neural implica em um processo iterativo de ajustes de seus pesos baseados em suas amostras de entrada, de modo que qualquer outra amostra futura apresentada à ela seja corretamente classificada.

De maneira geral, os processos de aprendizagem através dos quais as redes neurais funcionam podem ser categorizados em aprendizado supervisionado e não supervisionado. Neste trabalho a rede neural empregada utilizará o processo de aprendizado supervisionado, descrito a seguir.

2.3.3.1 Aprendizado supervisionado

Uma RNA possui um processo de aprendizado supervisionado quando se conhece um conjunto de exemplos de estímulo-resposta, ou algum outro tipo de informação, que represente o comportamento que deve ser apresentado pela rede neural. Para melhor compreensão deste processo, será exemplificado o procedimento do aprendizado supervisionado, a saber:

- Seja $d_j(k)$ a resposta desejada para o neurônio j no instante k ;
- Seja $y_j(k)$ a resposta observada do neurônio j no instante k , obtida através de um estímulo $x(k)$ presente na entrada da rede neural;
- $x(k)$ e $d_j(k)$ constituem um exemplo de par estímulo-resposta apresentado ao neurônio no instante k ;
- $e_j(k) = d_j(k) - y_j(k)$ é o sinal de erro observado na saída do neurônio j no instante k ;

O processo de aprendizado supervisionado tem por objetivo corrigir este erro $e_j(k)$ observado (em todos os neurônios). Para tanto, ele busca minimizar um critério (função objetivo, usualmente se usa o erro quadrático médio) baseado em $e_j(k)$, $j = 1, 2, \dots, p$, onde p é o número de neurônios da rede neural, de maneira que, para k suficientemente alto, as saídas observadas $y_j(k)$, $j = 1, 2, \dots, p$, estejam próximas das saídas desejadas $d_j(k)$, $j = 1, 2, \dots, p$.

2.4 Perceptron de múltiplas camadas – MLP

Existem diversas maneiras de processar a informação nos neurônios, assim como também existem várias formas de se conectar os neurônios uns aos outros. Estas possibilidades dão origem à RNAs de arquiteturas distintas.


As redes de propagação para frente – também conhecidas do inglês como *feedforward*, são redes cujo fluxo de informação é unidirecional através de suas camadas. Por sua vez, as camadas podem ser entendidas como o conjunto dos neurônios que recebem a informação simultaneamente (HAYKIN, 2009).

As redes perceptron de múltiplas camadas são redes de propagação para frente caracterizadas pela presença de uma ou mais camadas escondidas (ou ocultas), cujos nós

computacionais nestas camadas são denominados neurônios escondidos ou unidades escondidas. O termo “escondido” refere-se ao fato de que esta parte da RNA não é vista diretamente pela camada de entrada e pela de saída.

A Figura 11 ilustra uma rede neural de propagação para frente com duas camadas escondidas, com n entradas, m saídas e n neurônios na camada escondida. Os quadrados representam os x_n nós computacionais da camada de entrada, os círculos representam os y_m nós da camada de saída, e n_1 e n_2 representam os n neurônios da primeira e segunda camada oculta, respectivamente. Os neurônios na camada de entrada da rede constituem os sinais de entrada aplicados aos neurônios da segunda camada (que é a primeira camada escondida). Os sinais de saída desta segunda camada são então utilizados como entrada para a terceira camada, e assim por diante (LIMA et al., 2016).

Figura 11 – Exemplo de uma rede de propagação para frente de múltiplas camadas com n entradas e m saídas e duas camadas escondidas de m neurônios.



Fonte: LIMA et al., 2016.

2.4.1 Treinamento da rede MLP

É na fase do treinamento (ou aprendizagem) que a rede neural aprende o problema. Durante o processo de aprendizagem de uma RNA os pesos devem percorrer uma modificação iterativa para serem ajustados, até que o padrão final corresponda ao que se deseja associar como resposta ao de entrada. A forma como os pesos da rede serão modificados é determinada pelo algoritmo de aprendizagem empregado.

Nesta fase de treinamento, além do algoritmo de aprendizagem, também são escolhidos outros parâmetros de aprendizado, como a taxa de aprendizado (do inglês, *learning rate*), taxa de momento (do inglês, *momentum*), critérios de parada e forma de treinamento.

2.4.1.1 Algoritmo de retropropagação

O algoritmo de aprendizagem de retropropagação (do inglês, *backpropagation*) é um dos métodos mais empregados para a implementação de tarefas de aprendizado supervisionado em redes de propagação para a frente multicamadas (BRAGA; CARVALHO; LUDERMIR, 2007).

O método de aprendizagem por retropropagação consiste, basicamente, em dois passos: um passo para frente, que é a propagação, e um passo para trás, a retropropagação. No passo para frente, um vetor é apresentado aos nós de entrada da rede e seu efeito se propaga através desta, da esquerda para a direita e de camada em camada. Um conjunto de saídas é produzido como resposta da rede.

Durante este processo, os pesos sinápticos da rede são todos fixos. A resposta da rede é subtraída da resposta desejada e, então, determina-se o sinal de erro. Este sinal de erro é propagado para trás através da rede, contra a direção das conexões sinápticas. Os pesos são então ajustados de modo a se minimizar o sinal de erro (SILVA, 2005a).

Neste trabalho foi utilizado o algoritmo de Levenberg-Marquardt, que é um tipo de algoritmo de retropropagação desenvolvido a partir dos trabalhos de Levenberg (1944) e Marquardt (1963). Sua complexidade aumenta com o número de variáveis, tornando-o computacionalmente trabalhoso para ordem de milhares de variáveis. Porém, quando o número de variáveis é da ordem de centenas, o algoritmo é muito mais rápido que os demais (REYNALDI; LUKAS; MARGARETHA, 2012).

2.5 Rede neural de regressão generalizada – GRNN

As redes neurais de regressão generalizada foram propostas por Specht (1991) e têm sido o alvo de diversos trabalhos recentes. As suas aplicações podem variar de modelagem (JOSHI; GANJIGATTI, 2017), predição (SONG et al., 2017), análise de dados (TALELE et al., 2016), entre outras.


Estas redes são capazes de realizar a estimação de uma variável dependente a partir de uma independente por meio de um conjunto finito de variáveis. Seu treinamento é supervisionado e é realizado em apenas uma apresentação dos padrões de treinamento, e sua estrutura é do tipo *feedforward*.

As redes GRNN podem apresentar um esforço computacional menor quando comparadas as redes MLP, além de possuir uma quantidade menor de parâmetros, o que facilita suas configurações. Ainda, sua ideia básica de funcionamento se aproxima da ideia básica do método utilizado no artigo de Rossa et al. (2016b), como será explicado adiante.

2.5.1 Arquitetura

A GRNN possui uma estrutura fixa, disposta em quatro camadas: uma de entrada, duas intermediárias e uma de saída. As duas camadas intermediárias são chamadas de camada padrão e camada de soma. Esta configuração é mostrada na Figura 12, para x_n variáveis preditoras.

Figura 12 – Exemplo de uma rede GRNN.



Fonte: SONG et al., 2017

Camada de entrada: nesta camada existe um neurônio para cada variável preditora e estes neurônios se conectam à próxima camada: a camada padrão.

Camada padrão: quando um vetor de entradas de teste da camada de entrada é apresentado, os neurônios da camada padrão calculam a distância euclidiana entre os dados de teste e os dados de treino, e então estas distâncias são penalizadas com pesos, de acordo com a função de base radial, descrita na seção seguinte.

Camada de soma: esta camada é composta de apenas dois neurônios, e cada neurônio da camada padrão é conectado à ambos. O primeiro neurônio (S) é a unidade de soma do numerador, e o segundo neurônio (D) é a unidade de soma do denominador. O neurônio S realiza o somatório de cada uma das saídas ponderadas dos neurônios da camada padrão multiplicadas pelos respectivos valores reais da variável prevista. Por sua vez, o neurônio D realiza somente o somatório de cada uma das saídas ponderadas dos neurônios da camada padrão.

Camada de saída: esta camada contém um único neurônio que calcula a saída por meio da divisão da saída da unidade de soma do numerador (S) pela saída da unidade de soma do denominador (D).

2.5.2 Treinamento da rede GRNN

A ideia básica da GRNN é que a saída estimada para um dado conjunto de teste será provavelmente mais parecida com a saída das variáveis preditoras mais próximas. Partindo deste princípio, calcula-se a distância do ponto avaliado à cada um dos outros pontos do conjunto de treinamento, e a função de base radial (do inglês, *Radial Basis Function* – *RBF* ou também chamada de função Kernel) é aplicada à distância calculada para ponderar a influência de cada ponto do conjunto de treinamento sobre a variável de saída.

2.5.2.1 Função de base radial – RBF

A função de base radial é assim chamada pois a distância radial entre dois pontos é o próprio argumento da função, assim, quanto mais longe o ponto avaliado estiver dos outros pontos, menos influência ele terá. Esta ideia pode ser traduzida simplificada pela Equação 2.2: o *Peso* é a ponderação dada à *distância* calculada, por meio da função *RBF*.

$$Peso = RBF(distância) \quad (2.2)$$

Diferentes tipos de funções podem ser usadas para o cálculo da RBF, mas a mais comum é a função Gaussiana $\phi(x)$, que possui a forma mostrada na Equação 2.3, sendo: R a distância radial entre dois pontos, e σ o desvio padrão, também chamado de espalhamento.

$$\phi(r) = \exp\left(-\frac{R^2}{2\sigma^2}\right) \quad (2.3)$$

O valor de σ determina o espalhamento da função RBF, ou seja, quão rápido a função declina à medida que a distância do pico aumenta. Com valores de σ maiores, a função possui um espalhamento maior e pontos mais distantes têm uma influência maior. Por outro lado, com valores de σ menores, os pontos mais distantes passam a ter influência menor. Assim, dada uma rede neural GRNN é importante determinar qual será o valor ótimo para σ .

2.5.2.2 Algoritmo

O algoritmo da GRNN baseia-se na Equação 2.4. O resultado para a i – ésima variável prevista $\hat{y}_i$ é obtido por meio da divisão do somatório das n variáveis esperadas y_i do conjunto de treinamento ponderada por meio da função RBF, pelo somatório das n ponderações. R_i^2 é a i – ésima distância euclidiana calculada entre a variável de entrada x e cada uma das n variáveis correspondentes x_i do conjunto de treino, conforme a Equação 2.5.

$$\hat{y}_i(x) = \frac{\sum_{i=1}^n y_i \exp\left(-\frac{R_i^2}{2\sigma^2}\right)}{\sum_{i=1}^n \exp\left(-\frac{R_i^2}{2\sigma^2}\right)} \quad (2.4)$$

$$R_i^2 = (x - x_i)^T (x - x_i) \quad (2.5)$$

O termo $\exp\left(-\frac{R_i^2}{2\sigma^2}\right)$ reflete quanto a i – ésima amostra contribui para a saída:

- Se R_i^2 é um valor pequeno, então o termo $\exp\left(-\frac{R_i^2}{2\sigma^2}\right)$ retornará um valor grande.
- Se R_i^2 é um valor grande, então o termo $\exp\left(-\frac{R_i^2}{2\sigma^2}\right)$ retornará um valor pequeno.

O processo de treinamento consiste em ajustar a constante de espalhamento σ à um valor tal que o erro médio quadrático obtido seja mínimo.

3 METODOLOGIA DOS EXPERIMENTOS

Neste capítulo é apresentada a base de dados utilizada bem como o experimento pelo qual estes dados foram coletados. Em seguida são discutidas as configurações das redes neurais MLP e GRNN, suas entradas e saídas, e as métricas utilizadas para validação dos resultados.

Vale ressaltar que a metodologia adotada neste trabalho para a determinação das variáveis e treinamento da rede neural é baseada na metodologia adotada em Rossa et al. (2016b), que utilizou a mesma base de dados, de maneira que os resultados obtidos em ambos os trabalhos serão comparados no final.

Rossa et al. (2016b) utilizou o método de aprendizagem conhecido do inglês como *Just-In-Time* (JIT), ou, “na hora certa”, capaz de estimar variáveis de saída de um sistema com base num algoritmo de atribuição de pesos aos dados de entrada, de acordo com um critério de similaridade.

3.1 Modelagem *Just-In-Time*

A modelagem *Just-In-Time* usada em Rossa et al. (2016b) estima a saída do modelo baseada nas amostras de treinamento mais próximas da amostra de teste. Neste modelo, quando uma nova variável de entrada (amostra de teste) é disponibilizada para o sistema, ela é comparada com a base de dados de treinamento. Então, é selecionado apenas um subconjunto das amostras de treinamento mais relevantes à entrada avaliada de acordo com critérios de similaridade e funções de ponderação. Os critérios de similaridade quantificam a proximidade de cada amostra de dados para a variável de entrada, enquanto a função de ponderação atribui pesos às amostras mais semelhantes. Em Rossa et al. (2016b) é usado um algoritmo heurístico conhecido com *Particle Swarm Optimazation* para encontrar os pesos associados às amostras.

Uma vez que o subconjunto de dados é selecionado, um modelo linear local é aplicado aos pontos selecionados e a saída do sistema pode ser determinada. Após a atualização da entrada, o modelo local é descartado e o processo é repetido em torno do novo ponto de operação, resultando em um modelo rápido que muda a cada entrada do sistema (FUJIWARA; KANO; HASEBE, 2008).

3.2 Base de dados

Para a execução deste trabalho será utilizado um conjunto de dados obtido em parceria com o Laboratório de Sistemas de Telerobótica e Biorobótica da Universidade de Alberta, Canadá.

As medições foram coletadas a partir de 212 testes de inserção de agulhas em tecidos *ex-vivo*. Para cada inserção foram obtidas 250 amostras independentes e igualmente espaçadas em relação à profundidade da agulha no tecido. O banco de dados possui 15 testes sem qualquer rotação axial da agulha, 49 testes com apenas uma rotação axial, e 148 testes com duas rotações axiais, totalizando os 212 testes.

As variáveis medidas são:

- Profundidade de inserção
- Velocidade de inserção
- Rotações axiais
- Forças nos eixos x , y e z
- Torques nos eixos x , y e z
- Deflexão da agulha em dois planos


O experimento realizado para a obtenção destes dados é detalhado na seção seguinte.

3.2.1 Experimento e coleta de dados

O sistema robótico de 2 graus de liberdade (GDL) mostrado na Figura 13 foi utilizado para executar a inserção da agulha no tecido heterogêneo *ex-vivo* e coletar os dados. Uma agulha para braquiterapia de 1,3 mm de diâmetro externo e 200 mm de comprimento é conectada a um sensor de torque/força de 6-GDL (JR3, Inc. Woodland, EUA) em sua base.

O sensor de torque/força e a agulha podem ser rotacionados axialmente por um motor (Motor DC 1) de forma a alterar a orientação do chanfro da agulha. Estes equipamentos são montados sobre um trilho linear (Trilho linear 1) transladado manualmente em direção

Figura 13 – Sistema robótico utilizado para coleta dos dados.



Fonte: Adaptado de Rossa et al. (2016b)

ao tecido biológico. Em todas as inserções o chanfro da agulha começou na mesma posição apontando para cima, assim a agulha deflete para baixo.

Para acompanhar a trajetória da agulha durante sua inserção foi utilizado uma sonda de ultrassom (Utrasonix, Richmond, Canadá) na superfície do tecido e foram adquiridas imagens 2D à 30 Hz no plano perpendicular ao eixo da agulha (plano (z, y) da Figura 8).

A sonda de ultrassom é conectada à um segundo trilho linear (Trilho linear 2) cuja posição horizontal é medida por um potenciômetro linear (Midori Precisions, Tokyo, Japão) e corrigida por um controlador PID (Proporcional Integral Derivativo) que regula a posição da sonda de ultrassom para que esta acompanhe a trajetória da agulha. Para cada inserção, as coordenadas da ponta da agulha e bem como as deflexões nos planos (y, z) e (x, z) foram determinadas utilizando o método de processamento de imagens descrito em Waine et al. (2016).

As inserções foram realizadas em cinco amostras diferentes de tecidos, todos preparados a partir da inserção de um pedaço de lombo bovino numa mistura de 150 gramas de gelatina industrial também feita à partir de tecidos, por quilograma de água. Assim, cada amostra de tecido foi composta por três camadas: duas de gelatina e uma de tecido *ex-vivo*, como foi mostrado na Figura 13. Esta composição de tecido bovino e gelatina industrial visa representar características que se assemelham às do tecido humano.

Para todos os experimentos a máxima profundidade de inserção foi fixada em 140 mm, adotando-se o seguinte procedimento: a agulha é inicialmente inserida nos 15 – 20 mm

da primeira camada de gelatina, até atingir e penetrar os 100 – 110 mm da camada de tecido biológico. Este tecido apresenta várias camadas de gordura e músculo, tornando-o altamente heterogêneo. Tendo percorrido toda a camada de tecido biológico, a agulha atinge e percorre 15 – 20 mm da segunda e última camada de gelatina. À medida que a agulha é inserida, sua base pode ser girada axialmente em 180 graus em até duas profundidades de inserção predefinidas.

3.3 Definição das variáveis

A partir dos dados coletados nos experimentos pode-se definir as variáveis a serem utilizadas pela rede neural. A base de dados é composta de 212 inserções do tipo $(\mathbf{x}_i, \mathbf{y}_i)$, sendo cada inserção composta por 250 amostras ($1 \leq i \leq 250$), exceto algumas poucas exceções que possuem um número ligeiramente menor de amostras. O vetor $\mathbf{x}_i$ é formado pelas variáveis de entrada que levam às saídas correspondentes $\mathbf{y}_i$.

Assim, para cada uma das inserções, o vetor de entrada da i – ésima amostra pode conter até 8 variáveis, conforme a Equação 3.1:

$$\mathbf{x}_i = [z_i \quad \theta_{1i} \quad \theta_{2i} \quad F_{xi} \quad F_{yi} \quad M_{xi} \quad M_{yi} \quad v_i] \quad (3.1)$$

onde, z é a profundidade de inserção da agulha, θ_1 é a distância da profundidade atual z à profundidade em que a agulha sofreu a primeira rotação de 180° e θ_2 é a distância da profundidade da segunda rotação. Se a agulha não sofreu nenhuma rotação, então $\theta_1 = \theta_2 = 0$. Se a agulha foi rotacionada, por exemplo, aos 20 mm e a profundidade atual da mesma é 45 mm, então $\theta_1 = 25$ mm. F_x e F_y são as forças medidas na base da agulha nas direções x e y , conforme ilustrado na Figura 8, e M_y e M_x são os torques resultantes gerados por F_x e F_y , respectivamente. Finalmente, v é a velocidade de inserção da agulha.

A saída do sistema $\mathbf{y}_i$ associada à $\mathbf{x}_i$, é definida na Equação 3.2, e contém justamente as variáveis que se deseja prever utilizando a rede neural.

$$\mathbf{y}_i = [u_{xi} \quad u_{yi} \quad F_{zi}] \quad (3.2)$$

Sendo u_x e u_y as deflexões da agulha nos planos (y, z) e (x, z) (definidos na Figura 8), respectivamente. F_z é a força de inserção da agulha. A previsão da força de inserção da agulha F_z é importante para a implementação em trabalhos futuros de controladores de força para atuação sobre as deflexões das agulhas.

3.3.1 Configuração das variáveis

Uma vez conhecidos os dados do problema, dá-se prosseguimento com a configuração das variáveis. Neste trabalho, o objetivo é ser capaz de prever, com a melhor precisão possível, as 3 variáveis: u_x , u_y e F_z , a partir das 8 variáveis disponíveis: z , θ_1 , θ_2 , F_x , F_y , M_x , M_y e v , como foi mostrado nas Equações 3.2 e 3.1, respectivamente.

Dada as características intrínsecas distintas das variáveis que se deseja prever, optou-se, também de acordo com a metodologia adotada em Rossa et al. (2016b), estimar cada uma destas saídas independentemente, levando ao uso de três redes neurais: uma para cada uma destas variáveis.

Como já foi discutido na Seção 2.2.2.1, nem todas as 8 variáveis de entrada afetam as saídas do problema, a saber:

- Todas as saídas do modelos são influenciadas pela profundidade de inserção da agulha (z) e rotação (θ_1 e θ_2);
- Para a saída u_x , além de z , θ_1 e θ_2 , a força F_x e o torque M_y a influenciam.
- Para a saída u_y , além de z , θ_1 e θ_2 , a força F_y e o torque M_x a influenciam.
- Para a saída F_z , além de z , θ_1 e θ_2 , a velocidade v a influencia.

Assim, para cada rede neural utilizada, podemos definir as matrizes de entrada $\mathbf{X}_{\mathbf{u}_x}$, $\mathbf{X}_{\mathbf{u}_y}$, $\mathbf{X}_{\mathbf{F}_z}$ e suas respectivas saídas $\mathbf{Y}_{\mathbf{u}_x}$, $\mathbf{Y}_{\mathbf{u}_y}$ e $\mathbf{Y}_{\mathbf{F}_z}$ conforme as Equações 3.3 à 3.5.

$$\mathbf{X}_{\mathbf{u}_x} = \begin{bmatrix} z_1 & \theta_{1_1} & \theta_{2_1} & F_{x1} & M_{y1} \\ z_2 & \theta_{1_2} & \theta_{2_2} & F_{x2} & M_{y2} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ z_{250} & \theta_{1_{250}} & \theta_{2_{250}} & F_{x250} & M_{y250} \\ z_{251} & \theta_{1_{251}} & \theta_{2_{251}} & F_{x251} & M_{y251} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ z_{500} & \theta_{1_{500}} & \theta_{2_{500}} & F_{x500} & M_{y500} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ z_N & \theta_{1_N} & \theta_{2_N} & F_{xN} & M_{yN} \end{bmatrix}, \quad \mathbf{Y}_{\mathbf{u}_x} = \begin{bmatrix} u_{x1} \\ u_{x2} \\ \vdots \\ u_{x250} \\ u_{x251} \\ \vdots \\ u_{500} \\ \vdots \\ u_N \end{bmatrix} \quad (3.3)$$

$$\mathbf{X}_{\mathbf{u}_y} = \begin{bmatrix} z_1 & \theta_{1_1} & \theta_{2_1} & F_{y1} & M_{x1} \\ z_2 & \theta_{1_2} & \theta_{2_2} & F_{y2} & M_{x2} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ z_{250} & \theta_{1_{250}} & \theta_{2_{250}} & F_{y250} & M_{x250} \\ z_{251} & \theta_{1_{251}} & \theta_{2_{251}} & F_{y251} & M_{x251} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ z_{500} & \theta_{1_{500}} & \theta_{2_{500}} & F_{y500} & M_{x500} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ z_N & \theta_{1_N} & \theta_{2_N} & F_{yN} & M_{xN} \end{bmatrix}, \quad \mathbf{Y}_{\mathbf{u}_y} = \begin{bmatrix} u_{y1} \\ u_{y2} \\ \vdots \\ u_{y250} \\ u_{y251} \\ \vdots \\ u_{y500} \\ \vdots \\ u_{yN} \end{bmatrix} \quad (3.4)$$

$$\mathbf{X}_{\mathbf{F}_z} = \begin{bmatrix} z_1 & \theta_{1_1} & \theta_{2_1} & v_1 \\ z_2 & \theta_{1_2} & \theta_{2_2} & v_2 \\ \vdots & \vdots & \vdots & \vdots \\ z_{250} & \theta_{1_{250}} & \theta_{2_{250}} & v_{250} \\ z_{251} & \theta_{1_{251}} & \theta_{2_{251}} & v_{251} \\ \vdots & \vdots & \vdots & \vdots \\ z_{500} & \theta_{1_{500}} & \theta_{2_{500}} & v_{500} \\ \vdots & \vdots & \vdots & \vdots \\ z_N & \theta_{1_N} & \theta_{2_N} & v_N \end{bmatrix}, \quad \mathbf{Y}_{\mathbf{F}_z} = \begin{bmatrix} F_{z1} \\ F_{z2} \\ \vdots \\ F_{z250} \\ F_{z251} \\ \vdots \\ F_{z500} \\ \vdots \\ F_{zN} \end{bmatrix} \quad (3.5)$$

Os subíndices de 1 à N indicam as amostras de cada inserção. Logo, subíndices de 1 à 250 correspondem às 250 amostras da primeira inserção, 251 à 500 correspondem às amostras da segunda inserção, e assim sucessivamente até a última inserção de número 212, com amostras até $N = 250 \times 212 = 53.000$.

3.4 Cenários de teste

Tanto para as redes MLP quando para as redes GRNN consideram-se quatro cenários para os testes, de acordo com os experimentos realizados. É considerado, portanto: toda a base de dados, as inserções da agulha sem nenhuma rotação, com apenas uma rotação axial e com duas rotações axiais. Estes quatro cenários de testes são descritos no Quadro 1.

Ainda são realizados três casos de estudo, tanto para as redes MLP quanto para as GRNN. Os três casos distinguem-se pelo número de variáveis de entrada considerado.

Quadro 1 – Os quatro cenários de teste utilizados para as redes MLP e GRNN.

Cenário	Descrição
Todas as inserções	É utilizado todo o conjunto de dados das 212 inserções pela rede neural.
Sem rotação	É utilizado apenas o conjunto de dados das 18 inserções que não sofreram nenhuma rotação axial.
Uma rotação	É utilizado apenas o conjunto de dados das 49 inserções que sofreram apenas uma rotação axial.
Duas rotações	É utilizado apenas o conjunto de dados das 145 inserções que sofreram duas rotações axiais.

No primeiro caso, considera-se apenas as variáveis de entrada que supostamente influenciam suas respectivas saídas, conforme definido em Rossa et al. (2016b) e descrito na Seção 3.3.1. No segundo caso, considera-se que apenas as três variáveis influenciam as saídas do sistema: a profundidade de inserção da agulha (z) e as rotações axiais (θ_1 e θ_2). No terceiro e último caso, considera-se todas as 8 variáveis disponíveis como entradas para as redes neurais. Estes casos são mostrados no Quadro 2.

Quadro 2 – Os três casos de estudo utilizados para as redes MLP e GRNN.

Casos	Descrição
Caso 1	Apenas as variáveis de entrada que pressupõem-se influenciarem as saídas, como descrito na Seção 3.3.1.
Caso 2	Apenas as três variáveis de entrada comuns à todas as redes: z , θ_1 e θ_2 .
Caso 3	Todas as 8 variáveis disponíveis são utilizadas como entrada para as redes neurais.

Vale ressaltar que os quatro cenários de teste apresentados no Quadro 1 e os casos de estudo 1 e 2 apresentados no Quadro 2 também foram considerados na metodologia de Rossa et al. (2016b), e servirá de base de comparação para os resultados obtidos.

3.5 Configuração das redes MLP

Todas as três redes neurais MLP utilizadas são redes de propagação para frente com uma camada escondida, treinadas com o algoritmo de aprendizado de retropropagação de Levenberg-Marquardt. As redes para previsão de u_x , u_y possuem 5 neurônios na camada de entrada, enquanto a rede de F_z possui 4 neurônios na camada de entrada; todas possuem um único neurônio na camada de saída.

A configuração das redes neurais e suas posteriores validações, foram realizadas por meio de *scripts* desenvolvidos no *software* Matlab. Para melhor compreensão, o procedimento adotado pode ser detalhado conforme as etapas a seguir:

Etapas 1: Leitura e formatação dos dados da base de dados para criação das variáveis de entrada e saída.

Etapa 2: Divisão dos dados de maneira aleatória para criação dos conjuntos de treino, validação e teste. Este processo é repetido usando a validação cruzada, detalhada na seção 3.7.1.

Etapa 3: Normalização dos dados de entrada. Para cada variável de entrada, seus valores foram normalizados em relação a norma infinita do conjunto de treino correspondente. Por exemplo, dado o vetor $\mathbf{x}_z$ cujos dados de treinamentos correspondentes são $\mathbf{x}_z^{\text{treino}}$, o vetor normalizado $\mathbf{x}_z^{\text{norm}}$ é dado pela Equação 3.6. Este mesmo procedimento foi realizado em Rossa et al. (2016b).

$$\mathbf{x}_z^{\text{norm}} = \frac{\mathbf{x}_z}{\max|\mathbf{x}_z^{\text{treino}}|} \quad (3.6)$$

Etapa 4: Treino e validação da rede neural para cada uma das combinações dos parâmetros testados: foram feitos testes com números de neurônios da camada escondida iguais a 5, 10, 15 e 20; épocas iguais a 50, 100 e 200 e taxas de aprendizagem iguais a 0.01 e 0.05. As configurações que resultam na menor raiz do erro quadrático médio (do inglês, *Root Mean Square Error – RMSE*) são guardadas.

Etapa 5: Teste da rede neural com os melhores parâmetros encontrados na etapa anterior e cálculo das métricas de avaliação utilizadas.

3.6 Configuração das redes GRNN

Assim como para as redes MLP, também utilizou-se três redes GRNN, uma para cada variável estimada. As redes para previsão de u_x e u_y possuem 5 neurônios na camada de entrada, enquanto a rede de F_z possui 4 neurônios na camada de entrada. Como é próprio da arquitetura fixa das redes GRNN, elas possuem duas camadas ocultas: a camada padrão (cujo número de neurônios é igual ao número de amostras de treinamento) e a camada de soma (2 neurônios); e todas as três redes possuem um único neurônio na camada de saída.

A configuração destas redes neurais e suas validações também foram feitas com *scripts* desenvolvidos no *software* Matlab, e os procedimentos são detalhados a seguir:

Etapa 1: Leitura e formatação dos dados da base de dados para criação das variáveis de entrada e saída.

Etapa 2: Divisão dos dados de maneira aleatória para criação dos conjuntos de treino, validação e teste. Este processo é repetido usando a validação cruzada, detalhada na seção 3.7.1.

Etapa 3: Normalização dos dados de entrada. Para cada variável de entrada, seus valores foram normalizados em relação a norma infinita do conjunto de treino correspondente, por exemplo, dado o vetor $\mathbf{x}_z$ cujos dados de treinamentos correspondentes são $\mathbf{x}_z^{\text{treino}}$, o vetor normalizado $\mathbf{x}_z^{\text{norm}}$ é dado pela Equação 3.7. Este mesmo procedimento foi realizado em Rossa et al. (2016b).

$$\mathbf{x}_z^{\text{norm}} = \frac{\mathbf{x}_z}{\max|\mathbf{x}_z^{\text{treino}}|} \quad (3.7)$$

Etapa 4: Treino e validação da rede neural para valores de σ iguais à: 0,001, 0,01, 0,05, 0,10, 0,15, 0,20, 0,25, 0,40, 0,60, 0,80, 1,00, 2,00, 5,00, 10,00. O valor de σ que resulta na menor raiz do erro quadrático médio (do inglês, *Root Mean Square Error – RMSE*) é guardado.

Etapa 5: Teste da rede neural com o valor selecionado de σ encontrado na etapa anterior e cálculo das métricas de avaliação utilizadas.

3.7 Validação experimental

Nesta seção são detalhados os métodos utilizados para validar as redes neurais utilizadas e mensurar os seus respectivos desempenhos quanto à acurácia da previsão dos dados.

3.7.1 Validação cruzada

A validação cruzada (do inglês, *cross-validation – CV*) é uma técnica estatística clássica (SILVA, 2005b) que é útil em determinar, durante o treinamento, a capacidade de generalização de uma rede neural.

Neste trabalho utilizou-se o método de validação cruzada conhecido por *k-fold*. Neste processo, a base de dados é dividida aleatoriamente em k partições (*folds*) mutuamente exclusivas, com aproximadamente o mesmo número de amostras. Em seguida, $k - 1$ partições são usadas para treinar uma técnica e uma partição é usada para testar seu desempenho. Esse processo é repetido k vezes, onde cada partição é usada uma única vez para testar a técnica. Ao final, o desempenho médio da técnica para cada métrica é calculado. A repetição do processo permite atenuar o efeito de amostras de treinamento não representativas e obter uma medida de desempenho mais confiável (CIARELLI, 2012).

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 o fenômeno denominado *overtraining* (treinamento excessivo) da rede neural, que leva a uma péssima capacidade de generalização.

Tanto para as redes MLP quanto para as redes GRNN utilizadas, a base de dados foi dividida em igualmente em $k = 3$ conjuntos e foi feito um processo iterativo. Em cada iteração, um subconjunto foi utilizado como conjunto de teste, e os outros dois subconjuntos restantes foram utilizados como conjunto de treino. Este processo foi repetido 3 vezes. Por último, foram tiradas as médias dos erros dos modelos para todos os *folds*, para cada uma das redes neurais. O valor de k e o método de validação cruzada foram os mesmos usados em Rossa et al. (2016b).

Para encontrar a melhor calibração de cada rede neural para cada teste, o conjunto de treinamento é dividido em dois conjuntos, sendo um usado para treinar a rede e outro usado para validar (testar) a configuração da rede (parâmetros). Assim, a melhor calibração para cada teste é encontrada. Na próxima seção é apresentada todas as métricas utilizadas para avaliação do desempenho das redes.

3.7.2 Medidas de avaliação

Com a finalidade de quantificar a eficácia das redes neurais utilizadas para prever a deflexão de agulhas, foram utilizadas quatro métricas para o cálculo do erro entre uma variável esperada y_i e sua variável prevista $\hat{y}_i$ correspondente, onde $1 \leq i \leq n$, a saber:

- **RMSE** (do inglês, *Root Mean Square Error*):

A raiz do erro quadrático médio, ou RMSE, é uma métrica comumente utilizada e pode ser entendida como uma medida análoga ao desvio padrão, e expressa o erro do modelo de saída em unidades da variável de interesse. Seu cálculo é dado conforme a Equação 3.8. Como os erros são elevados ao quadrado antes do cálculo da média, o RMSE penaliza erros maiores.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3.8)$$

- **MAE** (do inglês, *Mean Absolute Error*):

O erro médio absoluto, ou MAE, é usado em um conjunto de predições para medir a magnitude média dos erros, não leva em conta se um erro foi sobrestimado ou

subestimado, conforme a Equação 3.9. Esta é a métrica usada em Rossa et al. (2016b).

$$MAE = \frac{1}{n} \sum_{i=1}^n |(y_i - \hat{y}_i)| \quad (3.9)$$

- **MAAPE** (do inglês, *Mean Arctangent Absolute Percentage Error*):

O erro percentual arco tangente absoluto médio, ou MAAPE, é uma métrica alternativa ao MAPE (do inglês, *Mean Absolute Percentage Error* ou erro médio absoluto percentual). O MAPE é uma medida amplamente empregada para a quantificação da precisão em previsões, porém, ele apresenta uma grande desvantagem: ele produz valores que tendem ao infinito quando os valores desejados (ou valores reais) são iguais ou muito próximos de zero. Ainda, se os valores desejados forem menores que 1, o MAPE poderá produzir valores de erro extremamente altos.

Desta forma, é proposto em Kim e Kim (2016) a métrica MAAPE como uma alternativa para o cálculo do erro percentual com o uso da função arco tangente, e ela é calculado conforme a Equação 3.10. O intervalo limitado da função arco tangente (calculada usando radianos), supera a limitação de valores infinitos.

$$MAAPE = \frac{100}{n} \sum_{i=1}^n \arctan \left(\left| \frac{y_i - \hat{y}_i}{y_i} \right| \right) \quad (3.10)$$

Entretanto, o resultado obtido na Equação 3.10 só pode ser considerado expresso em erro percentual para pequenos valores de desvio (até aproximadamente 20%). Isto pois, dada as características da função arco tangente, para pequenos valores a função permanece em uma região linear, fazendo com que o arco tangente tenha valores quase idênticos ao do próprio ângulo ($\theta \cong \arctan \theta$, para θ pequeno). Entretanto, se não houver um desvio padrão significativo em relação a média calculada, a tangente da média vai retornar um valor próximo ao erro percentual, pois estará em uma região localmente quase linear (em uma análise experimental foi observado que um desvio padrão de até 15% não causa uma grande diferença). Assim, neste trabalho é utilizada uma versão modificada do MAAPE com uma aproximação, de forma a evitar a distorção dos resultados que poderia ocorrer para grandes desvios percentuais, mas que possuem um baixo desvio padrão. O cálculo da MAAPE passa então a ser feito conforme a Equação 3.11.

$$MAAPE = 100 \times \tan \left(\frac{1}{n} \sum_{i=1}^n \arctan \left(\left| \frac{y_i - \hat{y}_i}{y_i} \right| \right) \right) \quad (3.11)$$

- **SMAPE** (do inglês, *Symmetric Mean Absolute Percentage Error*):

O erro simétrico médio absoluto percentual, ou SMAPE, é outra métrica alternativa ao MAPE para um conjunto de predições com valores zeros ou próximos de zeros. Os resultados do SMAPE estão entre os limites de 0% a 200%, e podem ser calculados pela Equação 3.12.

$$SMAPE = \frac{100\%}{n} \sum_{i=1}^n \frac{|(y_i - \hat{y}_i)|}{(|y_i| + |\hat{y}_i|)/2} \quad (3.12)$$

4 RESULTADOS

Esta seção dedica-se a exibição dos resultados alcançados após a implementação das redes neurais expostas nos capítulos anteriores. Optou-se por apresentar os resultados separadamente para cada uma das três variáveis a serem estimadas pelas redes neurais: deflexão da agulha no plano $(x, z) - (u_x)$, deflexão da agulha no plano $(y, z) - (u_y)$, e a força de inserção (F_z) .

Para cada uma destas três saídas, são exibidos os erros obtidos entre as variáveis esperadas e as previstas com as redes MLP e GRNN. Estes resultados são apresentados comparando-se os 4 cenários de testes e os 3 casos de estudo para as redes neurais, com base nas quatro métricas utilizadas.

Também são exibidos os erros encontrados com o método JIT do trabalho de Rossa et al. (2016b), que só utilizou a métrica MAE, e considerou apenas os casos de estudo 1 e 2, para os 4 cenários de teste.

4.1 Deflexão da agulha no plano $(x, z) - u_x$

Na Tabela 1 são exibidos os erros obtidos para a previsão da deflexão da agulha no plano $(x, z) - u_x$. Considera-se os métodos MLP, GRNN e JIT, os três casos de estudo e os quatro cenários de teste. São destacados em negrito os melhores resultados para cada cenário de teste.

Como resultado das técnicas para previsão da deflexão de agulhas, pode-se observar, da Tabela 1, que para os Casos 1 e 2, o método JIT é capaz de posicionar as sementes com um erro absoluto médio (MAE) menor do que as redes MLP e GRNN, atingindo um mínimo de $0,69 \text{ mm}$. Entretanto, este resultado não está tão distante do que foi encontrado no Caso 2, onde se alcançou um erro mínimo de $0,87 \text{ mm}$ utilizando as redes MLP.

Tabela 1 – Erros RMSE, MAE, MAAPE e SMAPE obtidos para a variável $\mathbf{u}_x$ com os métodos **MLP**, **GRNN** e **JIT** para os quatro cenários de teste, para os 3 casos.

Caso 1				
		MLP	GRNN	JIT
RMSE	Todas inserções	2,17 $\pm$ 0,26	2,15 $\pm$ 0,38	-
	Sem rotação	5,36 $\pm$ 1,43	3,79 $\pm$ 1,86	-
	1 rotação	2,09 $\pm$ 0,59	2,01 $\pm$ 0,47	-
	2 rotações	1,55 $\pm$ 0,39	2,26 $\pm$ 0,71	-
MAE	Todas inserções	1,15 $\pm$ 0,10	1,17 $\pm$ 0,18	0,81 $\pm$ 0,38
	Sem rotação	2,30 $\pm$ 0,88	2,29 $\pm$ 0,77	0,70 $\pm$ 0,40
	1 rotação	1,22 $\pm$ 0,15	1,32 $\pm$ 0,36	1,01 $\pm$ 0,49
	2 rotações	0,89 $\pm$ 0,11	1,36 $\pm$ 0,65	0,69 $\pm$ 0,38
MAAPE	Todas inserções	57,48 $\pm$ 1,64	59,64 $\pm$ 2,74	-
	Sem rotação	69,92 $\pm$ 9,53	61,90 $\pm$ 11,77	-
	1 rotação	59,02 $\pm$ 4,31	63,89 $\pm$ 15,33	-
	2 rotações	51,05 $\pm$ 1,74	65,15 $\pm$ 16,27	-
SMAPE	Todas inserções	67,26 $\pm$ 2,75	68,89 $\pm$ 5,04	-
	Sem rotação	80,93 $\pm$ 10,05	65,46 $\pm$ 12,38	-
	1 rotação	69,37 $\pm$ 9,33	78,47 $\pm$ 21,79	-
	2 rotações	62,43 $\pm$ 2,52	77,30 $\pm$ 22,64	-
Caso 2				
		MLP	GRNN	JIT
RMSE	Todas inserções	2,35 $\pm$ 0,30	2,60 $\pm$ 0,40	-
	Sem rotação	3,42 $\pm$ 2,12	3,74 $\pm$ 1,94	-
	1 rotação	4,00 $\pm$ 1,19	2,64 $\pm$ 0,50	-
	2 rotações	1,48 $\pm$ 0,07	1,88 $\pm$ 0,57	-
MAE	Todas rotações	1,28 $\pm$ 0,12	1,60 $\pm$ 0,40	0,94 $\pm$ 0,44
	Sem rotação	1,83 $\pm$ 0,93	2,22 $\pm$ 0,73	0,76 $\pm$ 0,36
	1 rotação	2,79 $\pm$ 1,64	1,62 $\pm$ 0,24	1,29 $\pm$ 0,71
	2 rotações	0,87 $\pm$ 0,02	1,12 $\pm$ 0,40	0,82 $\pm$ 0,47
MAAPE	Todas inserções	60,78 $\pm$ 1,17	73,02 $\pm$ 10,37	-
	Sem rotação	50,13 $\pm$ 4,68	57,62 $\pm$ 4,58	-
	1 rotação	88,86 $\pm$ 24,87	63,73 $\pm$ 2,33	-
	2 rotações	50,31 $\pm$ 0,69	58,93 $\pm$ 12,71	-
SMAPE	Todas inserções	74,07 $\pm$ 0,73	83,61 $\pm$ 12,89	-
	Sem rotação	58,39 $\pm$ 11,19	63,04 $\pm$ 1,22	-
	1 rotação	92,59 $\pm$ 17,35	87,88 $\pm$ 2,44	-
	2 rotações	60,46 $\pm$ 2,59	69,05 $\pm$ 14,11	-
Caso 3				
		MLP	GRNN	JIT
RMSE	Todas inserções	1,99 $\pm$ 0,31	1,94 $\pm$ 0,25	-
	Sem rotação	4,35 $\pm$ 1,56	3,92 $\pm$ 1,84	-
	1 rotação	2,12 $\pm$ 0,80	1,58 $\pm$ 0,29	-
	2 rotações	1,77 $\pm$ 0,38	2,21 $\pm$ 0,75	-
MAE	Todas inserções	1,02 $\pm$ 0,09	1,02 $\pm$ 0,03	-
	Sem rotação	2,28 $\pm$ 0,82	2,22 $\pm$ 0,95	-
	1 rotação	1,16 $\pm$ 0,19	1,01 $\pm$ 0,14	-
	2 rotações	0,88 $\pm$ 0,09	1,33 $\pm$ 0,61	-
MAAPE	Todas inserções	54,22 $\pm$ 1,03	55,09 $\pm$ 6,12	-
	Sem rotação	60,46 $\pm$ 8,64	58,39 $\pm$ 5,72	-
	1 rotação	56,11 $\pm$ 2,62	54,55 $\pm$ 3,09	-
	2 rotações	50,51 $\pm$ 1,23	65,90 $\pm$ 12,30	-
SMAPE	Todas inserções	63,90 $\pm$ 1,59	65,50 $\pm$ 6,16	-
	Sem rotação	77,66 $\pm$ 8,89	66,45 $\pm$ 8,53	-
	1 rotação	66,33 $\pm$ 4,74	66,89 $\pm$ 6,51	-
	2 rotações	61,72 $\pm$ 0,96	76,85 $\pm$ 17,39	-

Comparando-se a relevância dos cenários de teste utilizados, observa-se que a separação da base de dados considerando a existência ou não de rotações das agulhas influencia os resultados. Os melhores resultados gerais para os métodos foram obtidos utilizando-se o conjunto de dados formado por amostras contendo duas rotações axiais, que corresponde à aproximadamente 70% de todos os experimentos.

Por outro lado, os piores resultados evidenciaram a influência tanto da separação dos conjuntos de dados em cenários de teste, quanto da quantidade de variáveis de entrada. Por exemplo, para os casos de estudo 1 e 3, que contêm maiores números de variáveis de entrada, os piores desempenhos foram obtidos em geral para o conjunto de dados sem nenhuma rotação axial, que corresponde à apenas 7% de todos os experimentos. Entretanto, para o caso de estudo 2, que contém apenas 3 variáveis de entrada, a rede MLP apresentou piores resultados com os dados contendo apenas uma rotação axial, que corresponde aos 23% restante da base de dados.

Portanto, embora tenha-se feito o pressuposto de que a deflexão da agulha no plano (x, z) seria influenciada não só pela profundidade de inserção e rotações, mas também pela força e torque correspondente, e que ainda, a velocidade de inserção e a força e torque das componentes y não influenciaram o modelo, observa-se que a utilização de mais ou menos variáveis pode ser benéfico para as redes, pois em paralelo à quantidade de variáveis deve-se considerar o efeito dos cenários de teste e o tamanho do conjunto de dados disponíveis.

Embora o Caso 2 tenha apenas as 3 variáveis de entrada, em determinados cenários de testes (sem rotação, duas rotações) seu desempenho foi melhor do que para os demais casos. Logo, embora o Caso 3 utilize todas as 8 variáveis de entrada disponíveis, seu desempenho no cenário sem rotação foi inferior ao desempenho do Caso 2 correspondente. Talvez o aumento na quantidade de variáveis e a diminuição na quantidade de amostras de treinamento podem ter afetado o desempenho das redes.

Ressalta-se ainda que os erros percentuais em relação à deflexão da agulha no plano (x, z) obtidos com o MAAPE foram em média melhores para as redes MLP em detrimento às redes GRNN, atingindo um erro mínimo de 50,13%. Com a métrica SMAPE o melhor erro percentual obtido foi de 58,39%. Embora os erros percentuais obtidos não pareçam tão baixos, o MAAPE e o SMAPE possuem uma característica assimétrica que penaliza mais os erros negativos (quando a variável esperada é menor do que a prevista). Além disso, quando se compara os erros mínimos obtidos pelas redes MLP e GRNN em mm (que chegaram à 0,69 mm e 0,87 mm respectivamente) com o erro atual das técnicas manuais de inserção de agulha de 5 mm , nota-se que apesar dos erros percentuais mais elevados, os resultados encontrados são ainda bem superiores às técnicas manuais atuais.

4.2 Deflexão da agulha no plano $(y, z) - u_y$

Na Tabela 2 são exibidos os erros obtidos para a previsão da deflexão da agulha no plano (y, z) . Considera-se os métodos MLP, GRNN e JIT, os três casos de estudo e os quatro cenários de teste. São destacados em negrito os melhores resultados para cada cenário de teste.

A Tabela 2 mostra que, a rede GRNN superou o resultado do método JIT e da rede MLP no Caso 1 no cenário de duas rotações, no qual ela apresentou um desvio médio em relação à posição correta (métrica MAE) de 0,95 *mm* para o posicionamento das sementes radioativas na próstata. Nos demais cenários o método JIT apresentou resultados ligeiramente melhores que as duas redes.

Esta situação mudou para o caso de estudo utilizando apenas 3 variáveis de entrada: as redes MLP tiveram melhor desempenho geral do que as redes GRNN e o método JIT utilizado por Rossa et al. (2016b), com exceção do cenário sem rotações, onde a rede GRNN foi ligeiramente melhor. As redes MLP conseguiram prever a deflexão da agulha no plano (y, z) com um erro mínimo de 1,01 *mm* com a base de dados formada por amostras contendo duas rotações axiais. Estes resultados evidenciam um bom desempenho das redes desenvolvidas.

Ainda da Tabela 2, o menor MAE obtido para a previsão da deflexão das agulhas foi de 0,87 *mm* obtido com as redes MLP para o Caso 3 (com 8 variáveis de entrada), com o conjunto de dados formado por amostras contendo duas rotações axiais, que como já foi dito, corresponde à maior parte dos experimentos.

Com base nestes resultados observados, destaca-se a influência das variáveis de entrada para a previsão correta do modelo utilizado: foram obtidos erros médios menores com o aumento da quantidade de variáveis de entrada, considerando o mesmo cenário de teste.

Observa-se ainda que as redes MLP apresentaram melhor desempenho geral para a estimativa da deflexão da agulha no plano (y, z) no posicionamento das sementes radioativas na próstata; resultado observado também para os erros percentuais, que atingiram um valor mínimo de até 72,47% (MAAPE) contra os 73,76% obtidos com as redes GRNN.

Tabela 2 – Erros RMSE, MAE, MAAPE e SMAPE obtidos para a variável $\mathbf{u}_y$ com os métodos **MLP**, **GRNN** e **JIT** para os quatro cenários de teste, para os 3 casos.

Caso 1				
		MLP	GRNN	JIT
RMSE	Todas inserções	2,04 ± 0,19	2,17 ± 0,04	-
	Sem rotação	4,27 ± 0,58	2,85 ± 0,51	-
	1 rotação	3,19 ± 0,45	2,30 ± 0,13	-
	2 rotações	1,83 ± 0,38	1,62 ± 0,15	-
MAE	Todas inserções	1,31 ± 0,12	1,42 ± 0,09	1,22 ± 0,66
	Sem rotação	3,19 ± 0,55	1,89 ± 0,18	1,70 ± 0,88
	1 rotação	1,81 ± 0,31	1,43 ± 0,10	1,26 ± 0,81
	2 rotações	1,11 ± 0,17	0,95 ± 0,06	0,96 ± 0,57
MAAPE	Todas inserções	99,58 ± 1,74	106,64 ± 6,22	-
	Sem rotação	120,21 ± 1,56	98,39 ± 8,23	-
	1 rotação	80,24 ± 1,64	79,34 ± 5,68	-
	2 rotações	92,47 ± 2,26	80,80 ± 0,86	-
SMAPE	Todas inserções	125,58 ± 0,64	142,64 ± 13,93	-
	Sem rotação	144,85 ± 10,83	139,01 ± 8,64	-
	1 rotação	95,08 ± 9,46	100,00 ± 4,58	-
	2 rotações	112,14 ± 3,45	105,20 ± 0,86	-
Caso 2				
		MLP	GRNN	JIT
RMSE	Todas inserções	2,09 ± 0,02	2,32 ± 0,29	-
	Sem rotação	2,90 ± 0,94	2,81 ± 0,77	-
	1 rotação	2,02 ± 0,36	2,28 ± 0,37	-
	2 rotações	1,57 ± 0,11	1,84 ± 0,12	-
MAE	Todas rotações	1,37 ± 0,02	1,53 ± 0,16	1,42 ± 0,54
	Sem rotação	2,00 ± 0,73	1,93 ± 0,45	1,99 ± 0,96
	1 rotação	1,26 ± 0,19	1,48 ± 0,30	1,46 ± 0,90
	2 rotações	1,01 ± 0,01	1,16 ± 0,11	1,08 ± 0,79
MAAPE	Todas inserções	102,74 ± 1,57	114,92 ± 0,42	-
	Sem rotação	90,16 ± 2,61	107,73 ± 10,45	-
	1 rotação	72,47 ± 1,80	82,65 ± 12,88	-
	2 rotações	92,30 ± 1,58	98,83 ± 4,39	-
SMAPE	Todas inserções	135,83 ± 1,52	157,87 ± 6,27	-
	Sem rotação	141,85 ± 14,71	146,68 ± 13,11	-
	1 rotação	94,41 ± 4,06	100,69 ± 11,30	-
	2 rotações	118,06 ± 3,62	146,85 ± 18,00	-
Caso 3				
		MLP	GRNN	JIT
RMSE	Todas inserções	1,67 ± 0,31	2,14 ± 0,07	-
	Sem rotação	3,09 ± 0,45	2,85 ± 1,02	-
	1 rotação	2,59 ± 0,63	2,06 ± 0,34	-
	2 rotações	1,41 ± 0,16	1,82 ± 0,30	-
MAE	Todas inserções	1,07 ± 0,04	1,38 ± 0,06	-
	Sem rotação	2,01 ± 0,31	2,07 ± 0,72	-
	1 rotação	1,47 ± 0,19	1,32 ± 0,20	-
	2 rotações	0,87 ± 0,05	1,08 ± 0,18	-
MAAPE	Todas inserções	89,83 ± 1,80	104,23 ± 2,79	-
	Sem rotação	99,60 ± 16,10	111,45 ± 6,67	-
	1 rotação	75,41 ± 2,70	73,76 ± 11,20	-
	2 rotações	87,76 ± 3,60	92,51 ± 8,13	-
SMAPE	Todas inserções	110,50 ± 1,09	150,89 ± 12,85	-
	Sem rotação	109,53 ± 16,09	139,28 ± 9,42	-
	1 rotação	90,03 ± 5,26	92,65 ± 14,10	-
	2 rotações	105,99 ± 2,89	118,10 ± 17,02	-

4.3 Força de inserção da agulha – F_z

Na Tabela 3 são exibidos os erros obtidos para a previsão da força de inserção da agulha no tecido. Considera-se os métodos MLP, GRNN e JIT, os três casos de estudo e os quatro cenários de teste. São destacados em negrito os melhores resultados para cada cenário de teste.

Como pode ser observado na Tabela 3, as redes MLP apresentaram um desempenho geral muito próximo e às vezes ligeiramente superior em relação ao método JIT proposto na literatura de referência, e também em relação às redes GRNN. Notoriamente para o Caso 1, onde são utilizadas como entrada a profundidade de inserção, as rotações axiais e a velocidade de inserção, obteve-se um desvio médio em relação à posição correta de apenas 0,37 N . Este resultado utiliza o conjunto de dados contendo amostras com somente uma rotação axial, que, como dito anteriormente, corresponde à 23% da base de dados.

As redes GRNN, por sua vez, destacaram-se com bons resultados também no cenário que utiliza apenas o conjunto de dados contendo amostras com somente uma rotação axial, alcançando um desvio médio mínimo (MAE) em relação à força correta de 0,38 N , resultado próximo do descrito acima com a rede MLP.

Consequentemente, assim como foi constatado para a estimativa da agulha no plano (y, z) , as redes MLP e GRNN utilizadas neste trabalho apresentaram melhores resultados do que o método JIT utilizado em Rossa et al. (2016a).

Embora tenha-se partido do pressuposto que a força de inserção seria influenciada apenas pela profundidade de inserção, pelas duas rotações axiais e pela velocidade, observa-se da Tabela 3 que para os diferentes conjuntos de variáveis de entrada os resultados permaneceram muito próximos, e com baixos erros percentuais, sendo obtido os valores mínimos de 14,14% com o MAAPE e 14,43% com o SMAPE.

Tabela 3 – Erros RMSE, MAE, MAAPE e SMAPE obtidos para a variável $\mathbf{F}_z$ com os métodos **MLP**, **GRNN** e **JIT** para os quatro cenários de teste, para os 3 casos.

Caso 1				
		MLP	GRNN	JIT
RMSE	Todas inserções	0,66 ± 0,07	0,72 ± 0,02	-
	Sem rotação	0,52 ± 0,09	0,58 ± 0,10	-
	1 rotação	0,50 ± 0,05	0,51 ± 0,01	-
	2 rotações	0,75 ± 0,21	1,06 ± 0,28	-
MAE	Todas inserções	0,47 ± 0,03	0,51 ± 0,02	0,46 ± 0,06
	Sem rotação	0,41 ± 0,06	0,45 ± 0,07	0,42 ± 0,04
	1 rotação	0,37 ± 0,03	0,38 ± 0,01	0,52 ± 0,06
	2 rotações	0,47 ± 0,05	0,76 ± 0,28	0,43 ± 0,03
MAAPE	Todas inserções	23,37 ± 2,25	26,71 ± 2,25	-
	Sem rotação	26,91 ± 5,35	29,82 ± 6,49	-
	1 rotação	13,75 ± 0,50	15,38 ± 0,23	-
	2 rotações	24,95 ± 3,26	35,51 ± 8,20	-
SMAPE	Todas inserções	25,96 ± 2,25	28,95 ± 2,43	-
	Sem rotação	34,91 ± 10,28	35,52 ± 10,74	-
	1 rotação	14,43 ± 0,23	16,01 ± 0,47	-
	2 rotações	27,41 ± 3,78	37,68 ± 8,87	-
Caso 2				
		MLP	GRNN	JIT
RMSE	Todas inserções	0,73 ± 0,04	0,74 ± 0,08	-
	Sem rotação	0,51 ± 0,04	0,59 ± 0,07	-
	1 rotação	0,53 ± 0,03	0,50 ± 0,03	-
	2 rotações	0,70 ± 0,03	1,09 ± 0,24	-
MAE	Todas rotações	0,49 ± 0,00	0,52 ± 0,04	0,50 ± 0,07
	Sem rotação	0,40 ± 0,03	0,46 ± 0,07	0,44 ± 0,09
	1 rotação	0,39 ± 0,02	0,38 ± 0,03	0,57 ± 0,08
	2 rotações	0,46 ± 0,01	0,81 ± 0,24	0,46 ± 0,08
MAAPE	Todas inserções	23,93 ± 1,56	27,65 ± 1,87	-
	Sem rotação	26,63 ± 7,96	30,62 ± 11,44	-
	1 rotação	14,14 ± 1,58	15,09 ± 1,91	-
	2 rotações	24,46 ± 1,38	37,79 ± 7,29	-
SMAPE	Todas inserções	26,62 ± 1,83	28,95 ± 1,55	-
	Sem rotação	33,14 ± 12,32	35,55 ± 14,15	-
	1 rotação	15,08 ± 1,19	15,82 ± 1,69	-
	2 rotações	27,41 ± 1,55	39,63 ± 7,70	-
Caso 3				
		MLP	GRNN	JIT
RMSE	Todas inserções	0,71 ± 0,07	0,69 ± 0,12	-
	Sem rotação	0,91 ± 0,20	0,49 ± 0,03	-
	1 rotação	0,74 ± 0,24	0,56 ± 0,01	-
	2 rotações	0,92 ± 0,26	0,76 ± 0,11	-
MAE	Todas inserções	0,45 ± 0,02	0,50 ± 0,05	-
	Sem rotação	0,69 ± 0,15	0,70 ± 0,02	-
	1 rotação	0,51 ± 0,10	0,42 ± 0,00	-
	2 rotações	0,50 ± 0,09	0,51 ± 0,02	-
MAAPE	Todas inserções	22,14 ± 1,40	26,60 ± 1,82	-
	Sem rotação	36,22 ± 1,64	27,68 ± 4,55	-
	1 rotação	16,74 ± 1,48	16,05 ± 0,71	-
	2 rotações	24,41 ± 2,33	28,14 ± 2,19	-
SMAPE	Todas inserções	24,60 ± 2,07	28,48 ± 2,20	-
	Sem rotação	42,78 ± 5,55	33,41 ± 9,24	-
	1 rotação	18,31 ± 2,18	16,79 ± 1,06	-
	2 rotações	26,62 ± 3,06	30,14 ± 2,49	-

Considerando os resultados obtidos nesse trabalho para as três medidas estimadas, observou-se que as redes MLP e GRNN propostas apresentaram bons desempenhos no geral. Para a previsão da deflexão da agulha no plano (x, z) , o melhor resultado foi obtido com o método JIT que apresentou um erro mínimo de até $0,69\text{ mm}$. Entretanto, valores muito próximos foram alcançados tanto com as redes MLP ($0,87\text{ mm}$), quanto para as redes GRNN ($1,01\text{ mm}$). Ainda foi possível observar que o desempenho das redes neurais foram influenciados pela separação da base de dados em diferentes cenários de teste, e a utilização de diferentes quantidades de variáveis de entrada.

Por sua vez, a deflexão da agulha no plano (y, z) foi melhor prevista com as redes MLP, que apresentaram na média resultados ligeiramente superiores aos demais métodos, atingindo um resultados de até $0,87\text{ mm}$. Situação semelhante ocorreu para a previsão da força de inserção da agulha, que também apresentou melhor desempenho com as redes MLP, com um valor de erro absoluto médio de até $0,37\text{ N}$.

Os erros percentuais observados não apresentaram valores muito satisfatórios para alguns casos, porém, esses resultados são aceitáveis quando comparados com a precisão das técnicas atuais de inserção de agulha. Observou-se por fim que para os diferentes casos e cenários, os melhores resultados foram obtidos com diferentes técnicas. Portanto, a escolha da melhor técnica depende da medida que se pretende estimar, do conjunto de dados considerado e das variáveis de entrada que se utiliza.

5 CONCLUSÃO

Um dos procedimentos mais adotados para o tratamento do câncer, a braquiterapia de próstata consiste na inserção de longas agulhas percutâneas para depositar sementes radioativas no tecido canceroso. Entretanto, a eficácia deste tratamento é ainda intrinsecamente dependente da habilidade do médico em acertar os alvos com a agulha, que sofre uma deflexão em relação a trajetória desejada devido sua interação com o tecido que a circunda. Neste contexto, surgem os sistemas robóticos aplicados à medicina. Eles buscam estender as capacidades dos cirurgiões, oferecendo alto nível de destreza e precisão na implantação de sementes.

Sob esta perspectiva, nesse trabalho foram apresentadas duas propostas baseadas em redes neurais para estimar a deflexão de agulhas em tecidos *ex-vivos*. A primeira proposta consistiu no uso das redes *multi-layer perceptrons* (MLP), e a segunda no uso das redes neurais de regressão generalizada (GRNN).

Para avaliação das redes utilizadas, foram realizados vários testes considerando uma série de configurações e cenários possíveis, tais como a separação da base de dados em subconjuntos de tamanhos distintos levando em consideração a existência de rotações axiais da agulha e a utilização de diferentes conjuntos de variáveis de entrada do sistema.

A metodologia adotada neste trabalho para a determinação das variáveis e treinamento das redes neurais foi baseada na metodologia adotada em Rossa et al. (2016b), que usou a modelagem *Just-in-Time* (JIT) para resolver o mesmo problema, de maneira que seus resultados também são utilizados como base de comparação para os resultados obtidos com esse trabalho. Os testes foram realizados sobre uma base de dados do Laboratório de Sistemas de Telerobótica e Biorobótica da Universidade de Alberta, Canadá, obtida a partir de experimentos realizados em laboratório para simular a inserção de agulhas durante um procedimento de braquiterapia.

Constatou-se que as redes MLP e GRNN propostas neste trabalho apresentaram bons desempenhos individuais, e também quando comparadas ao método JIT proposto na literatura. Como mencionado em Taschereau et al. (2000), as técnicas manuais atuais empregadas pelos cirurgiões durante o procedimento de braquiterapia são capazes de posicionar as sementes com uma precisão de 5 milímetros, o que constitui um erro substancial de mais de 10% do tamanho da próstata. Embora a base de dados utilizada neste trabalho tenha sido obtida em um ambiente controlado utilizando tecidos bovinos,

os resultados indicam que com o emprego das redes utilizadas nesse trabalho, conseguiu-se atingir um desvio médio para a deflexão da agulha no plano (x, z) de até $0,87\text{ mm}$ com as redes MLP e de $1,01\text{ mm}$ com as redes GRNN. Para este caso, o método JIT teve um resultado de até $0,69\text{ mm}$. Já para a deflexão da agulha no plano (y, z) foram obtidos desvios mínimos de $0,87\text{ mm}$ com as redes MLP e de $0,95\text{ mm}$ com as redes GRNN. O método JIT teve um resultado de até $0,96\text{ mm}$ neste caso. Em nenhum caso avaliado o desvio médio das redes foi superior a $3,5\text{ mm}$. Ainda, para a força de inserção da agulha, obteve-se um erro médio mínimo de $0,37\text{ N}$ com as redes MLP, $0,38\text{ N}$ com as redes GRNN e $0,42\text{ N}$ com o método JIT.

Embora para a estimativa de deflexão da agulha no plano (x, z) o método JIT tenha apresentado melhores resultados, as redes MLP apresentaram na média resultados ligeiramente superiores, tanto para a deflexão da agulha no plano (y, z) quanto para a força de inserção da agulha. Entretanto, de maneira geral os resultados encontrados pelas redes GRNN não foram muito distantes dos obtidos com as redes MLP, e ainda, em alguns cenários de teste eles foram até melhores. Os resultados também indicaram que não existe uma técnica que vence em todos os casos e cenários. Portanto, a escolha da melhor técnica vai depender do tipo de medida que se pretende estimar e das variáveis de entrada que se tem a disposição.

Acerca dos pressupostos que foram considerados para a modelagem da deflexão da agulha e as variáveis de entrada que influenciariam as variáveis de saída correspondentes, pôde-se notar que o desempenho das redes neurais melhorou em alguns casos utilizando mais ou menos variáveis de entrada, pois em paralelo à quantidade de variáveis os resultados das redes também foram influenciados pelos cenários de teste considerados, que possuíam diferentes tamanhos de conjunto de dados disponíveis.

Observou-se ainda que a utilização de uma base de dados maior, composta por todo o conjunto de experimentos, não resultou necessariamente em um desempenho melhor das redes neurais. Para vários testes os melhores resultados foram obtidos utilizando-se o conjunto de dados formado por amostras contendo duas rotações axiais, que corresponde à aproximadamente 70% da base de dados. Isto pode ser entendido sabendo que, dependendo do conjunto de treino selecionado, as redes podem não ter dados suficientemente representativos de uma tarefa, diminuindo sua capacidade de generalização.

Os resultados obtidos neste trabalho indicam que é possível obter resultados mais precisos para posicionar as sementes do que de forma manual, mesmo embora os experimentos tenham sido realizados em uma situação controlada. Mesmo a porcentagem do erro percentual sendo um tanto alta quando analisadas as métricas MAAPE e SMAPE, os resultados são ainda superiores aos oriundos das técnicas manuais de braquiterapia. Ainda

assim, trabalhos futuros poderiam avaliar a utilização de outros métodos para estimar as grandezas de deflexão e força.

REFERÊNCIAS BIBLIOGRÁFICAS

ABOLHASSANI, N.; PATEL, R. V. Deflection of a flexible needle during insertion into soft tissue. *Proceedings of the 28th IEEE EMBS Annual International Conference*, v. 1, p. 3858–3861, 2006. Citado na página 23.

ACS. *American Cancer Society: Prostate Cancer Statistics*. 2016. Disponível em: <<https://www.cancer.org/cancer/prostate-cancer.html>>. Acesso em: 23 de abril de 2017. Citado na página 12.

AMATO, F. et al. Artificial neural networks in medical diagnosis. *Journal of APPLIED BIOMEDICINE*, 2013. Citado na página 26.

ASADIAN, A.; KERMANI, M. R.; PATEL, R. V. An analytical model for deflection of flexible needles during needle insertion. *Conference on Intelligent Robots and Systems*, 2011. Citado na página 16.

BRAGA, A. de P.; CARVALHO, A. P.; LUDERMIR, T. B. *Redes neurais artificiais: Teoria e aplicações*. 2. ed. Rio de Janeiro: LTC, 2007. Citado na página 31.

CIARELLI, P. M. *Modelo de aprendizado incremental baseado em uma rede neural com arquitetura adaptativa*. Tese (Doutorado) — Universidade Federal do Espírito Santo, Vitória, 2012. Citado na página 43.

DOBLER, B. et al. Evaluation of possible prostate displacement induced by pressure applied during transabdominal ultrasound image acquisition. *Strahlentherapie und Onkologie*, v. 182, n. 04, p. 240—246, 2006. Citado na página 16.

FALLAHI, B. et al. Sliding-based image-guided 3d needle steering in soft tissue. *Control Engineering Practice*, v. 63, p. 34–43, 2017. Citado na página 23.

FOSTER, K. R.; KOPROWSKI, R.; SKUFCA, J. D. Machine learning, medical diagnosis, and biomedical engineering research - commentary. *BioMedical Engineering OnLine*, 2014. Citado na página 16.

FUJIWARA, K.; KANO, M.; HASEBE, S. Correlation-based just-in-time modeling for soft-sensor design. *18th European Symposium on Computer Aided Process Engineering – ESCAPE 18*, 2008. Citado na página 35.

GVR. Grand view research, ethicon endo-surgery inc. report. 2012. Citado na página 14.

HAYKIN, S. *Neural networks and learning machines*. 3. ed. Nova Jersey: Pearson Prentice Hall, 2009. Citado na página 29.

IARC. *International Agency for Research on Cancer: prostate cancer*. 2012. Disponível em: <<http://gco.iarc.fr/today/fact-sheets-cancers?cancer=19&type=0&sex=1>>. Acesso em: 23 de abril de 2017. Citado na página 12.

JOSHI, S. R.; GANJIGATTI, J. Application of general regression neural networks for forward and reverse modeling of aluminum alloy aa5083. 2017. Citado na página 31.

- KHADEM, M. et al. Mechanics of tissue cutting during needle insertion in biological tissue. *IEEE Robotics and Automation Letters*, v. 1, p. 800–807, 2016. Citado na página 22.
- KHADEM, M. et al. A two-body rigid/flexible model of needle steering dynamics in soft tissue. *IEEE/ASME Transactions on Mechatronics*, v. 21, n. 5, p. 2352–2364, 2016. Citado na página 23.
- KHADEM, M. et al. Ultrasound-guided model predictive control of needle steering in biological tissue. *Medical Robotics Research*, v. 01, n. 01, p. 1–17, 2016. Citado 2 vezes nas páginas 13 e 15.
- KIM, S.; KIM, H. A new metric of absolute percentage error for intermittent demand forecasts. *International Journal of Forecasting*, v. 32, p. 669–679, 2016. Citado na página 45.
- LEHMANN, T. *Development of a Surgical Assistant System for Needle Adjustment in Prostate Brachytherapy*. Dissertação (Mestrado) — University of Alberta e Hochschule Furtwangen University, Canadá, 2013. Citado 2 vezes nas páginas 19 e 20.
- LEHMANN, T. et al. A real-time estimator for needle deflection during insertion into soft tissue based on adaptive modeling of needle-tissue interactions. 2016. Citado 2 vezes nas páginas 12 e 23.
- LEVENBERG, K. A method for the solution of certain non-linear problems in least squares. *Quarterly of Applied Math*, v. 2, p. 164–168, 1944. Citado na página 31.
- LIMA, M. A. et al. Uso de redes neurais artificiais (rna) do tipo multilayer perceptrons (mlp) modificado com processamento estatístico em paralelo para estudo do problema de classificação da origem de vinho tinto. *Revista Brasileira de Agropecuária Sustentável*, v. 6, n. 2, p. 58–65, 2016. Citado na página 30.
- MAGEE, D. et al. An augmented reality simulator for ultrasound guided needle placement training. *IMedical and biological engineering and computing*, v. 45, n. 10, p. 957–967, 2007. Citado na página 24.
- MARQUARDT, D. W. An algorithm for least-squares estimation of nonlinear parameters. *Journal of the Society for Industrial and Applied Mathematics*, v. 11, n. 2, p. 431–441, 1963. Citado na página 31.
- MCCULLOCH, W. S.; PITTS, W. a. A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, 1943. Citado na página 27.
- MISRA, S. et al. Mechanics of flexible needles robotically steered through soft tissue. *The International Journal of Robotics Research*, v. 29, n. 13, p. 1640–1660, 2010. Citado na página 16.
- OKAMURA, A. M.; SIMONE, C.; O’LEARY, M. D. Force modeling for needle insertion into soft tissue. 2004. Citado na página 13.
- PARVEEN, R. et al. A review and survey of artificial neural network in medical science. *Journal of Advanced Research in Computing and Applications*, v. 3, n. 1, p. 7–16, 2016. Citado na página 26.

- PATRICIU, A. et al. Automatic brachytherapy seed placement under mri guidance. *IEEE Transactions on Biomedical Engineering*, v. 54, n. 8, p. 1499–1506, 2007. Citado 2 vezes nas páginas 13 e 23.
- RAUBER, T. W. Redes neurais artificiais. *ERI '97 – Encontro regional de informática. Mini - curso*, 1997. Citado na página 26.
- RESEARCH; MARKETS. *Healthcare Robotics: Global Market Analysis and Forecasts*. 2016. Disponível em: <<http://www.researchandmarkets.com/research/r4wwg6/healthcare>>. Acesso em: 23 de abril de 2017. Citado na página 13.
- REYNALDI, A.; LUKAS, S.; MARGARETHA, H. Backpropagation and levenberg-marquardt algorithm for training finite element neural network. *EMS '12 Proceedings of the 2012 Sixth UKSim/AMSS European Symposium on Computer Modeling and Simulation*, p. 89–94, 2012. Citado na página 31.
- ROSSA, C. et al. Constrained optimal control of needle deflection for semi-manual steering. 2016. Citado 2 vezes nas páginas 12 e 52.
- ROSSA, C. et al. A data-driven soft sensor for needle deflection in heterogeneous tissue using just-in-time modelling. *Medical and Biological Engineering and Computing*, 2016. Citado 14 vezes nas páginas 17, 21, 23, 32, 35, 39, 41, 42, 43, 44, 45, 47, 50 e 55.
- SILVA, L. M. O. da. *Uma Aplicação de Árvores de Decisão, Redes Neurais e KNN para a Identificação de Modelos ARMA Não-Sazonais e Sazonais*. Tese (Doutorado) — Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2005. Citado na página 31.
- SILVA, R. M. *Redes Neurais Artificiais aplicadas à Detecção de Intrusão em Redes TCP/IP*. Dissertação (Mestrado) — Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2005. Citado na página 43.
- SONG, J. et al. A globally enhanced general regression neural network for on-line multiple emissions prediction of utility boiler. *Knowledge-Based Systems*, v. 118, p. 4–14, 2017. Citado na página 31.
- SPECHT, D. A generalized regression neural network. *IEEE Transactions on Neural Networks*, v. 02, p. 568–576, 1991. Citado na página 31.
- TALELE, K. et al. Facial expression recognition using general regression neural network. In: IEEE. *Bombay Section Symposium (IBSS), 2016 IEEE*. [S.l.], 2016. p. 1–6. Citado na página 31.
- TASCHEREAU, R. et al. Seed misplacement and stabilizing needles in transperineal permanent prostate implants. 2000. Citado 3 vezes nas páginas 15, 21 e 55.
- TAYLOR, R. H. et al. Medical robotics and computer integrated surgery. 2008. Citado na página 13.
- WAINE, M. et al. Needle tracking and deflection prediction for robot-assisted needle insertion using 2d ultrasound images. *Journal of Medical Robotics Research*, v. 01, n. 1, p. 1640001, 2016. Citado na página 37.

YU, Y. et al. Permanent prostate seed implant brachytherapy: Report of the american association of physicists in medicine. *Medical Physics*, v. 26, n. 10, p. 2054–2076, 1999. Citado na página 21.

ZHANG, Y. et al. Semi-automated needling and seed delivery device for prostate brachytherapy. *Intelligent Robots and Systems - IEEE/RSJ International Conference*, p. 1279–1284, 2006. Citado na página 24.