

UNIVERSIDADE FEDERAL DE ITAJUBÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

Desenvolvimento de um Sistema de Controle aplicado a uma Prótese Ativa de Joelho

Raíssa Ferraz Campos

Itajubá, Julho de 2020

UNIVERSIDADE FEDERAL DE ITAJUBÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

Raíssa Ferraz Campos

**Desenvolvimento de um Sistema de Controle
aplicado a uma Prótese Ativa de Joelho**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da UNIFEI (área de concentração: Automação e Sistemas Elétricos Industriais), como parte dos requisitos necessários para a obtenção do Título de Mestre em Ciências em Engenharia Elétrica.

Orientador: Prof. Dr. Luis Henrique de Carvalho Ferreira

Coorientador: Prof. Dr. Jeremias Barbosa Machado

Julho de 2020

Itajubá - MG

Campos, Raíssa Ferraz
Desenvolvimento de um Sistema de Controle
aplicado a uma Prótese Ativa de Joelho / Raíssa Ferraz Campos. – Itajubá - MG,
24 de Julho de 2020.

81 p. : il. (algumas color.).

Orientador: Prof. Dr. Luis Henrique de Carvalho Ferreira
Coorientador: Prof. Dr. Jeremias Barbosa Machado
Dissertação (Mestrado) – Universidade Federal de Itajubá – UNIFEI
Instituto de Engenharia de Sistemas e Tecnologias da Informação
Programa de Pós-Graduação em Engenharia Elétrica, 24 de Julho de 2020.

1. Próteses Transfemorais. 2. Joelho MR. 3. Controle Preditivo. 4. Redes
Neurais Recorrentes. 5. LSTM. I. Ferreira, Luis Henrique de Carvalho, orient. II.
Machado, Jeremias Barbosa, coorient. III. Universidade Federal de Itajubá. IV.
Desenvolvimento de um Sistema de Controle aplicado a uma Prótese Ativa de
Joelho.

UNIVERSIDADE FEDERAL DE ITAJUBÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

Raíssa Ferraz Campos

**Desenvolvimento de um Sistema de Controle
aplicado a uma Prótese Ativa de Joelho**

Dissertação aprovada por banca examinadora em 24 de julho de 2020, conferindo à autora o Título de Mestre em Ciências em Engenharia Elétrica.

Banca examinadora:

Prof. Dr. Luis Henrique de Carvalho Ferreira – UNIFEI
Prof. Dr. Jeremias Barbosa Machado – UNIFEI
Prof. Dr. Caio Fernandes de Paula – UNIFEI
Prof. Dr. Felipe Oliveira e Silva – UFLA

Julho de 2020
Itajubá - MG

Soli Deo Gloria.

Agradecimentos

Agradeço ao Cristo, à Virgem Maria, ao meu Santo Anjo da Guarda e ao meu amigo Venerável Carlo Acutis.

Aos meus pais, Olavo e Mirtes, e ao meu irmão pelo amor benévolo e incondicional, e por nunca deixarem de ser meu sustento. A vocês o meu amor profundo e eterna gratidão.

Ao meu namorado, sobretudo por me ajudar a caminhar firmemente em direção à Verdade; também pela paciência, compreensão, incentivo, esteio e amor. Amo-te!

Aos professores Luís Henrique de Carvalho Ferreira e Jeremias Barbosa Machado pela orientação. De forma especial ao professor Jeremias, por todo o tempo dedicado à realização deste trabalho, pelas ideias, sugestões e confiança; pelo auxílio e apoio; por todos os ensinamentos, conselhos e contribuições, não só no âmbito educacional.

Aos meus familiares e em memória dos meus avós Décio e Mirtes.

Aos amigos que me colocam constantemente diante da minha realidade, me fazendo lembrar que *"Eu sou eu e minha circunstância, e se não salvo a ela, não me salvo a mim"*, por serem cruciais para o meu crescimento e para a formação da minha personalidade.

À CAPES pelo apoio financeiro para a realização deste trabalho de pesquisa.

*“A vaidade da ignorância é um
abismo de miséria humana.”
(Olavo de Carvalho)*

Resumo

No Brasil o número de amputações de membros inferiores realizadas na rede pública de saúde é predominante entre as cirurgias deste tipo, sendo as amputações feitas entre o joelho e a articulação do quadril – designadas amputações transfemorais – as de maior incidência. Equilíbrio e estabilidade passam a ser novos obstáculos após uma cirurgia como esta. A tentativa de compensação da perda do membro faz com que a biomecânica corporal seja afetada; além disso, uma privação da mobilidade do paciente indubitavelmente ocorre, influenciando diretamente a sua qualidade de vida. Ao longo dos anos, as investidas na devolução da qualidade de vida aos pacientes amputados transfemorais ganharam mais forma. Vislumbrando suprir a perda do membro ou, ao menos, atenuar as influências na biomecânica corporal, inúmeras pesquisas têm sido realizadas no campo do desenvolvimento de próteses, inclusive de joelho. As próteses de membros podem ser de três tipos: passiva, semi-ativa e ativa. No fim, o que se pretende é que elas proporcionem ao indivíduo uma experiência próxima ao natural, tanto quanto possível; para tal finalidade, as próteses ativas são as mais eficientes. Os fluidos magneto-reológicos são uma classe de materiais inteligentes, cuja principal característica é passar do estado líquido para semi-sólido por meio da aplicação de um campo magnético. Suas vantagens fazem com que sua utilização seja bastante promissora em diversas aplicações, como nos dispositivos protéticos. O presente estudo traz a elaboração de um sistema de controle de um joelho magneto-reológico que, com a utilização de técnicas de controle preditivo e redes neurais, visa ser posteriormente implementado em uma prótese transfemural ativa. As habilidades de aprendizado, previsão e auto-organização, aliadas à capacidade de predição e garantia de comportamento do sistema dentro do horizonte de previsão, possibilitam o refinamento do controle do sistema. A fim de atestar seu correto funcionamento são feitos os controles de torque e de posição do joelho, que, atuando como sub-sistemas, são responsáveis por assegurar que o motor tenha condições de proporcionar torque suficiente para realização dos movimentos e que a perna possa ser adequadamente posicionada durante todo o ciclo de marcha. Os dois subsistemas, atuando simultânea e compassadamente, garantem que todos os requisitos do sistema sejam satisfeitos. Diferentes arranjos de redes são testados utilizando camadas *Long Short-Term Memory*, *Gated Recurrent Unit* e camadas recorrentes simples. Os resultados mostram que o controle do joelho é alcançado fazendo uso das técnicas apresentadas, demonstrando que sua aplicação em próteses é factível e promissora.

Palavras-chaves: próteses transfemorais. joelho magneto-reológico. controle preditivo. redes neurais recorrentes. lstm.

Abstract

In Brazil the number of lower limb ablations performed in the public health system is prevalent among surgeries of this type, with transfemoral amputations having the highest incidence. With the loss of a considerable part of a lower limb, body's balance and stability are drastically affected. The attempt to compensate the loss affects patients' body biomechanics and the deprivation of mobility directly influences its quality of life. Over the years, efforts to enlarge transfemural amputee patients' quality of life have grown and numerous researches have been carried out, benefiting prosthetic development that tries to compensate the limb loss or at least to mitigate the influences on body biomechanics. Limb prostheses can be passive, semi-active and active, being the last mentioned the most appropriate to provide an experience very close to the natural one to its users. Magneto-rheological fluids are a class of intelligent materials, whose main characteristic is to change from a liquid to a semi-solid state through the application of a magnetic field. Its advantages make its use very promising in several implementations, such as in the field of prosthetic devices. This study presents the development of a control system for a magneto-rheological knee that aims to be subsequently applied in an active transfemoral prosthesis. The system uses neural networks and predictive control techniques, that brings the skills of learning, forecasting, self-organization, the ability to predict and guarantee the behaviour of the system within the prediction horizon. Together these two techniques enable a refinement of the control system. In order to assure its correct functioning, torque and knee positioning controls are performed, which acting as sub-systems are responsible for ensuring that the engine is able to provide sufficient torque to perform the movements and the leg could be properly positioned during every gait cycle. The two sub-systems acting simultaneously and steadily can guarantee that all system requirements are met. Different network arrangements are tested using Long Short-Term Memory, Gated Recurrent Unit and simple recurrent layers. The results showed that the magneto-rheological knee can be controlled using the techniques presented, which demonstrates its application in real prostheses is feasible and promising.

Keywords: transfemural prostheses. magnetorheological knee. predictive control. recurrent neural networks. lstm.

Lista de ilustrações

Figura 1 – Distinção entre passo e passada.	12
Figura 2 – Fases e subfases da marcha.	14
Figura 3 – Fases, períodos, subfases e percentuais da marcha.	14
Figura 4 – Representação do controle preditivo.	19
Figura 5 – Representação das partes do neurônio e sinapse.	24
Figura 6 – Exemplo de estrutura das camadas de uma rede.	25
Figura 7 – Representação da matemática realizada no nó j	27
Figura 8 – Estrutura das camadas de uma rede neural recorrente.	29
Figura 9 – Estrutura de uma célula da camada oculta na RNR.	31
Figura 10 – Ilustração do funcionamento de um <i>gate</i>	33
Figura 11 – Estrutura de uma célula LSTM.	34
Figura 12 – Comparação de estados ocultos entre GRU e LSTM.	36
Figura 13 – Estrutura de funcionamento de uma célula GRU.	36
Figura 14 – Torque do joelho no ciclo de marcha.	42
Figura 15 – Modelo dinâmico do joelho MR.	42
Figura 16 – Modos de operação com base no controle preditivo híbrido.	43
Figura 17 – Diagrama de blocos do controle de torque do joelho MR.	45
Figura 18 – Torque de referência do joelho e torque do teste.	45
Figura 19 – Planos anatômicos do corpo humano.	48
Figura 20 – Representação do modelo de testes.	50
Figura 21 – Eixos no plano sagital.	51
Figura 22 – Referenciais angulares da coxa e da perna.	51
Figura 23 – Referencial dos ângulos do joelho.	52
Figura 24 – Resultado da aquisição J01.	53
Figura 25 – Resultado da aquisição J02.	54
Figura 26 – Resultado da aquisição J06.	54
Figura 27 – Resultado do ângulo do joelho segundo a aquisição J01.	55
Figura 28 – Resultado do ângulo do joelho segundo a aquisição J02.	55
Figura 29 – Resultado do ângulo do joelho segundo a aquisição J06.	56
Figura 30 – Modelo de curva do ângulo do joelho proposto por Kapti e Yucenur.	57
Figura 31 – Modelo de curva do ângulo do joelho proposto por Geng et al.	57
Figura 32 – Curvas dos ângulos do joelho previstas por uma rede LSTM 3 camadas e uma rede LSTM 5 camadas.	60
Figura 33 – Curva do ângulo do joelho prevista por uma rede LSTM 8 camadas.	61
Figura 34 – Curvas dos ângulos do joelho previstas por uma rede GRU 5 camadas e uma rede <i>SimpleRNN</i> 5 camadas.	62

Figura 35 – Diagrama de blocos do controle de posição do joelho MR. 63

Figura 36 – Curvas do ângulo do joelho segundo a referência do sistema de controle de posicionamento e a saída \hat{S} do sistema de controle de posicionamento. 64

Figura 37 – Curvas do ângulo do joelho referentes ao Padrão de Marcha II e à saída \hat{S} do sistema de controle de posicionamento. 64

Lista de tabelas

Tabela 1 – Erro Quadrático Médio.	46
---	----

Lista de abreviaturas e siglas

BPTT	<i>Backpropagation Through Time</i>
DAOP	Doença Arterial Obstrutiva Periférica
DM	Diabetes Mellitus
DMC	<i>Dynamic Matrix Control</i>
EQM	<i>Erro Quadrático Médio</i>
FIR	<i>Finite Impulse Response</i>
FT	Função de Transferência
GRU	<i>Gated Recurrent Unit</i>
HMPC	<i>Heuristic Model Predictive Control</i>
IBGE	Instituto Brasileiro de Geografia e Estatística
IP	<i>Internet Protocol</i>
LSTM	<i>Long Short-Term Memory</i>
MLD	<i>Mixed Logical Dynamical</i>
MPC	<i>Model (Based) Predictive Control</i>
MR	Magneto-reológico
PI	Proporcional Integral
PID	Proporcional Integral Derivativo
RN	Rede Neural
RNA	Rede Neural Artificial
RNR	Rede Neural Recorrente
SEA	<i>Series Elastic Actuator</i>
<i>SimpleRNN</i>	<i>Simple Recurrent Neural Network</i>
TBPTT	<i>Truncated Backpropagation Through Time</i>

TSR *Truncated Step Response*

UDP *User Datagram Protocol*

Lista de símbolos

Δt	Tempo de amostragem
λ	Fator de ponderação do erro
γ	Fator de ponderação da ação de controle
P	Horizonte de predição
M	Horizonte de controle
z^{-1}	Operador deslocamento para trás
τ	Torque
K_p	Parâmetro proporcional do controlador PI
K_i	Parâmetro integrativo do controlador PI
γ_s	Ângulo no plano sagital
g	Gravidade
G_x	Valor do vetor da gravidade no eixo x
G_y	Valor do vetor da gravidade no eixo y

Sumário

	INTRODUÇÃO	1
	Contextualização do Problema	1
	As Próteses	3
	Dispositivos Magneto-Reológicos	4
	Motivação	5
	Objetivos	6
	Organização do Trabalho e Contribuições	6
I	FUNDAMENTAÇÃO TEÓRICA	9
1	A MARCHA	11
1.1	Introdução	11
1.2	Modelo de Marcha	11
1.3	Conclusão	15
2	TÉCNICAS DE CONTROLE PREDITIVO	17
2.1	Introdução	17
2.2	Controle Preditivo Baseado em Modelo	18
2.2.1	Controle Preditivo Híbrido MLD	21
2.3	Conclusão	22
3	REDES NEURAIS	23
3.1	Introdução	23
3.2	Redes Neurais Artificiais	23
3.2.1	Redes Neurais Recorrentes	29
3.3	Conclusão	36
II	PROPOSTA	39
4	TRABALHO PROPOSTO E RESULTADOS	41
4.1	Introdução	41
4.2	Implementação do Controle Preditivo para Controle de Torque	41
4.2.1	Modelo	41
4.2.2	Resultados	44
4.3	Sistema de Rastreamento de Posição	46

4.3.1	Modelo	47
4.3.2	Resultados	52
4.4	Rede Neural para Modelar a Correlação entre os Ângulos da Coxa e do Joelho	58
4.4.1	Modelo	58
4.4.2	Resultados	60
4.5	Controle de Posição via Técnicas de Controle Preditivo	62
4.5.1	Modelo	63
4.5.2	Resultados	63
4.6	Sistema de Controle Geral	65
4.7	Considerações Finais	65
III	PARTE FINAL	67
5	CONCLUSÕES E TRABALHOS FUTUROS	69
6	TRABALHOS PUBLICADOS E EM ANDAMENTO	71
	REFERÊNCIAS	73

Introdução

Contextualização do Problema

A primeira coleta de dados sobre as pessoas com deficiência no Brasil foi ainda sob regência de Dom Pedro II, no ano de 1872, quando 0.89% da população apresentava algum tipo de deficiência. Foram feitas novas coletas nos anos de 1890, 1900, 1920 e 1940; depois disso houve um período sem que tivesse sido feito qualquer levantamento, até que em 1991 foi registrado um novo censo. Os resultados dos últimos três censos realizados expressam o crescente número de deficientes entre os brasileiros, com taxas de 1,14% para o ano de 1991, 14,48% em 2000 e 23,91% em 2010 (LENZI, 2016).

Em 1991 a falta de membros acometia aproximadamente 9% – sendo 7% homens e 2% mulheres – daqueles que manifestaram algum tipo de deficiência, ou 0,1% da população total da época (IBGE, 1991). Segundo Chagas e Viotti (2003), pode-se pressupor que por razões exógenas, como acidentes de trabalho e trânsito ou mesmo violência, as amputações de membros entre homens sejam muito mais numerosas.

De acordo com Jannuzzi, G.S.M. e Jannuzzi, N. (1994 apud TEIXEIRA; OLIVEIRA, 2004, p. 10), o percentual de deficientes apontado no Censo de 1991 é muitíssimo baixo; e, averiguando a metodologia utilizada àquela altura, os autores observaram algumas razões que poderiam explicar tal número (razões, estas, que teriam impactado de forma decisiva a qualidade das informações), sendo elas: a baixa fração amostral utilizada, as definições sobre deficiência adotadas pelo Instituto Brasileiro de Geografia e Estatística (IBGE) – englobando apenas as pessoas com lesões já diagnosticadas ou com grandes lesões –, o plausível ocultamento dos informantes e as dificuldades de identificação de deficiências por parte dos pesquisadores.

Tendo o IBGE superado algumas dificuldades conceituais ao longo da década de 90, para o Censo Demográfico de 2000 foi adotada uma definição mais ampliada do que vinha a ser deficiência, incluindo também os conceitos de incapacidade e desvantagem, compatíveis com a Classificação Internacional de Funcionalidade, Incapacidade e Saúde (TEIXEIRA; OLIVEIRA, 2004; JANNUZZI, G.S.M.; JANNUZZI, 2016). A partir dessa classificação, qualquer dificuldade ou limitação corporal, manifestada de forma permanente ou mesmo temporária, é apta a ser considerada como deficiência (CANTORANI et al., 2015). Ademais, com a adoção desta nova abordagem haveria uma garantia de comparabilidade dos dados a nível internacional (TEIXEIRA; OLIVEIRA, 2004).

Conforme apontaram os dados levantados pelo Censo Demográfico de 2000, os deficientes representavam 14,48% dos quase 170 milhões de habitantes residentes no

Brasil à época (IBGE, 2000). Com relação ao número total de pessoas com deficiência, os classificados como deficientes físicos por perda de membro ou parte dele foram 1,94% e os que apresentavam alguma deficiência motora chegaram a 32,27%. Assim como no Censo de 1991, os homens foram maioria em termos da perda de um membro ou parte dele; ao contrário, as mulheres foram maioria quando se trata de deficiência motora (IBGE, 2000; CHAGAS; VIOTTI, 2003). Entretanto, vê-se que, em ambas as classes, a maior parte dos deficientes tinha entre 15 e 64 anos.

O Censo de 2000 atingiu um progresso deveras satisfatório quanto à obtenção de novas informações a respeito das deficiências no Brasil, e os resultados obtidos foram reflexo da adesão de conceitos mais aperfeiçoados acerca do tema (TEIXEIRA; OLIVEIRA, 2004; CANTORANI et al., 2015). Dessa forma, com a reelaboração do questionário utilizado na coleta, pode-se ampliar a precisão com que se passou a mensurar e caracterizar o coletivo dos indivíduos com deficiência no nosso território (TEIXEIRA; OLIVEIRA, 2004).

Após outras adequações referentes ao conceito de deficiência, o Censo Demográfico de 2010, último realizado, apontou que 7% da população brasileira apresentava algum tipo de deficiência motora (IBGE, 2012; CANTORANI et al., 2015). Fazendo releitura dos resultados deste censo, aplicando a linha de corte sugerida pelo Grupo de Washington para análise dos dados, a porcentagem de indivíduos com deficiência motora é de 2,3% (IBGE, 2010). Segundo a Pesquisa Nacional de Saúde de 2013, 1,5% dos brasileiros acima de 14 anos apresentam algum tipo de deficiência motora, entre elas a perda de um membro ou parte dele (IBGE, 2010).

De acordo com o Ministério da Saúde, as amputações de membros inferiores são predominantes, atingindo 85% do número de amputações registradas no Brasil (MS, 2013). A partir do número de cirurgias de amputação catalogadas entre os anos de 2008 e 2015, calculou-se que foram realizados 12,35 procedimentos por 100.000 habitantes por ano (PEIXOTO et al., 2017). Este número condiz com os resultados obtidos por um estudo feito pelo *The Global Lower Extremity Amputation Study Group* em alguns países com mais de 200.000 habitantes – como Inglaterra, Japão, Itália –, onde o número de procedimentos varia de 2,8 a 43,9 por 100.000 habitantes por ano (UNWIN, 2000). Em 2011, 94% das cirurgias de amputação feitas pelo SUS foram de membros inferiores (MS, 2013). Entre 2011 e 2016 as amputações também corresponderam a este percentual, sendo que 70% dos pacientes apresentavam diabetes mellitus (DM) (SANTOS et al., 2018). A maior incidência de amputação é nos pacientes do sexo masculino e a ocorrência de amputação de membros inferiores em homens varia na casa dos 70% (AGNE et al., 2004; REIS; JÚNIOR; CAMPOS, 2012; MS, 2013).

Entre as causas de amputação, as doenças vasculares (incluindo diabetes, hipertensão) são predominantes, variando entre um percentual de 72 a 80% (CHAMLIAN et al., 2013; MS, 2013; GARLIPPE, 2014). Segundo Milech et al. (2016), a DM dobra as possibi-

lidades de o paciente desenvolver doença arterial obstrutiva periférica (DAOP); pacientes com DM e DAOP têm de 5 a 10 vezes mais chances de sofrer grande amputação. As causas traumáticas representam cerca de 20% das causas de amputação, incluindo acidentes domésticos, acidentes de trânsito e ferimentos com arma de fogo; já o restante é devido à outras causas, como consequências de tumores, complicações cirúrgicas e causas congênitas (AGNE et al., 2004; NESI, 2005; CHAMLIAN et al., 2013; MS, 2013; GARLIPPE, 2014). No Relatório Anual de 2018 a Associação Brasileira Beneficente de Reabilitação aponta que somente em seu Centro de Reabilitação foram realizadas 1068 consultas por amputações, sendo 62% delas decorrentes de problemas vasculares por diabetes e 15% por outros problemas vasculares, 18% traumáticas, 2% por causas infecciosas, outros 2% por causas tumorais e apenas 1% de amputações congênitas (ABBR, 2018).

Quanto ao nível de amputação de membros inferiores, o número maior é de amputações feitas entre a articulação do quadril e o joelho – conhecidas como amputações transfemorais (AGNE et al., 2004; LEITE et al., 2004; NESI, 2005; REIS; JÚNIOR; CAMPOS, 2012).

Com a perda de uma parte da perna ocorre o aumento da demanda de ajustes musculares do indivíduo para a manutenção de sua postura de pé e sua locomoção, uma vez que problemas de equilíbrio e estabilidade passam a ser desafios (PRADA, 2014). A pélvis e a coluna passam a correr maior risco de serem lesionadas, já que ocorre sobrecarga em ambas (ANDRADE, R. M., 2018). Além destas, há uma série de alterações funcionais na biomecânica corporal, que podem interferir no cotidiano do amputado e influenciar nos padrões de postura e de marcha para compensar a perda do membro (ANDRADE, R. M., 2018).

As Próteses

Para uma boa qualidade de vida é indispensável que o indivíduo tenha mobilidade. Entretanto, para uma pessoa amputada transfemoral isto torna-se mais difícil (FARJOD et al., 2009). Visando proporcionar a melhoria da qualidade de vida destes pacientes, no decorrer dos anos diversas pesquisas e estudos têm sido realizados no campo do desenvolvimento de próteses de joelho capazes de compensar a perda do membro e atenuar as influências na biomecânica corporal (ANDRADE, R. M., 2018).

As próteses de membros podem ser subdivididas em três tipos (ANDRADE, R. M., 2018):

- **Passiva:** sem controle do nível de amortecimento, não requer fonte de energia e não permite ajuste de desempenho.
- **Semi-ativa:** dissipa energia por meio de amortecedores controláveis, apresenta baixo

consumo de energia, baixa relação peso-torque e boa capacidade de controle.

- **Ativa:** dissipa e supre energia de forma controlada.

Ainda que próteses já tenham sido desenvolvidas e algumas delas comercializadas, há muito o que ser feito visando proporcionar ao indivíduo uma experiência cada vez mais parecida com o natural e saudável. A *Power Knee*® foi a primeira tentativa comercial de restaurar as características funcionais do indivíduo; apesar disso, não produz torque suficiente para ajudar o mesmo a se levantar de uma cadeira. Em 2006, Kapti e Yucenur (2006) projetaram uma prótese com atuador linear, motor e fuso de esferas recirculantes; ela reproduz bem o torque mas é pesada. No ano de 2009, Martinez-Villalpando e Herr (2009) fizeram uma prótese que utiliza dois atuadores elásticos em série com controle de impedância variável, visando a redução do consumo de energia. Já em 2013, Inoue et al. (2013) fizeram uma prótese passiva, que faz uso de um mecanismo com mola para armazenar energia e gerar momento de extensão do joelho suficiente para subir uma escada. Fite et al. (2007) e Geng et al. (2010) produziram próteses ativas para joelho, enquanto Lawson et al. (2011), Sup et al. (2011), Thatte e Geyer (2016) produziram próteses ativas para joelho e tornozelo. A *C-Leg (OttoBock)*® é semi-ativa e foi a primeira prótese de joelho disponível comercialmente a usar um controle através de microprocessador em ambas as fases de apoio e balanço, a *Rheo Knee*® usa um micro controlador e fluido magneto-reológico (MR) para controlar a resistência ao movimento na articulação do joelho; ambas não geram torque ativo para o amputado subir escadas e rampas ou levantar de cadeira (OTTOBOCK, s.d.; RHEO-KNEE, 2005; ANDRADE, R. M., 2018).

Dispositivos Magneto-Reológicos

Os fluidos magneto-reológicos são uma classe de materiais inteligentes que atualmente estão sendo amplamente utilizados em diversas aplicações, como para fazer estruturas adaptáveis e controláveis por um campo magnético (FARJOUR et al., 2009; GUDMUNDSSON; JONSDOTTIR; THORSTEINSSON, 2010; VICENTE; KLINGENBERG; HIDALGO-ALVAREZ, 2011; ASHTIANI; HASHEMABADI; GHAFARI, 2015).

Fluidos MR convencionais são preparados dispersando grande quantidade de micropartículas sólidas e altamente magnetizáveis em um fluido (óleo) transportador não magnetizável com aditivos estabilizadores (ZUBIETA et al., 2009; VICENTE; KLINGENBERG; HIDALGO-ALVAREZ, 2011; CAMACHO; ALBA, 2013; ASHTIANI; HASHEMABADI; GHAFARI, 2015). A principal característica destes fluidos é a sua habilidade de sair do estado líquido e se transformar em semissólido com tensão de cisalhamento controlável apenas alguns milissegundos após a aplicação de um campo magnético (VICENTE; KLINGENBERG; HIDALGO-ALVAREZ, 2011; ASHTIANI; HASHEMABADI; GHAFARI, 2015).

Na ausência do campo as suspensões têm uma viscosidade relativamente baixa; entretanto, na presença dele as partículas de ferro se alinham na direção em que ele é aplicado, formando cadeias e, assim, a viscosidade do fluido MR aumenta (FARJOUR et al., 2009; ZUBIETA et al., 2009; CHEN; LIAO, 2010; VICENTE; KLINGENBERG; HIDALGO-ALVAREZ, 2011). Para romper as estruturas em cadeias é preciso exercer uma tensão de cisalhamento, que deverá ser maior de acordo com que o campo magnético aumenta (CHEN; LIAO, 2010).

Como fluido inteligente, um fluido MR apresenta diversas vantagens, como alto rendimento, boa estabilidade e rápido tempo de resposta. Além disso, o efeito MR deve ser estável dentro de uma ampla faixa de temperatura (CHEN; LIAO, 2010; CAMACHO; ALBA, 2013). Tais recursos tornam este fluido promissor para inúmeras aplicações, como no ramo dos dispositivos protéticos, onde foram introduzidos de forma bem-sucedida (GUDMUNDSSON; JONSDOTTIR; THORSTEINSSON, 2010). Entre estes dispositivos está a prótese de joelho, objeto de estudo deste trabalho.

Motivação

Patologias motoras, como a amputação de membros, prejudicam a locomoção do paciente e, conseqüentemente, a qualidade de vida deste. É sabido que aparatos podem ser utilizados com a intenção de assistir o indivíduo e devolver a ele a oportunidade de deslocar-se de forma independente. Sabe-se também que o Instituto Nacional do Seguro Social é obrigado a fornecer prótese, órtese e outros instrumentos de auxílio para locomoção aos seus segurados e dependentes (Lei nº 8.213/91, artigos 89 e 90; Decreto nº 3048/99, Art. 137, IV, § 2º) e o Governo deve disponibilizar pelo Sistema Único de Saúde aparelhos ortopédicos e tratamento de reabilitação às pessoas com deficiência; entretanto, o tempo de espera é grande. Por outro lado, o custo das próteses é elevado, tornando-se inacessível para grande parte da população.

O estudo em questão foi motivado pela aspiração de contribuir para o desenvolvimento de um dispositivo de custo mais reduzido e de fácil manipulação, capaz de auxiliar o paciente em, pelo menos, suas necessidades mais básicas.

O que inspirou este trabalho foi o artigo *Evaluating Energy Consumption of an Active Magnetorheological Knee Prosthesis*, escrito por Andrade, R. M. et al. (2019), e a dissertação que deu origem a ele, intitulada *Joelho Magneto-Reológico para Próteses Transfemorais: Prototipagem Digital, Fabricação e Identificação Experimental* (ANDRADE, R. M., 2018).

Objetivos

Por objeto de estudo tem-se o sistema de controle de um joelho magneto-reológico a ser implementado em uma prótese transfemoral ativa.

O que sobretudo se deseja com o uso de toda e qualquer prótese é atingir tanto quanto possível a funcionalidade do membro que fora substituído. Sabendo-se que o cérebro humano coordena integralmente seus elementos estruturais – permitindo que o organismo seja capaz de realizar com primor inúmeras e concomitantes funções – e compreendendo-se que ele atua de forma preditiva, é certamente prolífero trazer para o desenvolvimento desta dissertação algumas técnicas que, embasadas no funcionamento do cérebro, podem colaborar para o melhor desempenho do sistema de controle a ser aqui elaborado.

Ainda que a maioria dos estudos neste ramo da engenharia faça uso de controladores do tipo proporcional-integral-derivativo (PID) e obtenha bons resultados, optou-se por aliar as técnicas de controle preditivo e a modelagem via redes neurais ao desenvolvimento deste trabalho.

Associando as habilidades de aprendizado, previsão e auto-organização à capacidade de predição e garantia de comportamento do sistema dentro do horizonte de previsão – advindas do uso de redes neurais e do controle preditivo, respectivamente –, pretende-se obter um controle mais refinado do movimento da prótese transfemoral, de forma a beneficiar o usuário final desta.

Organização do Trabalho e Contribuições

Após apresentada uma breve introdução ao assunto abordado neste trabalho, bem como sua motivação e os objetivos que se deseja alcançar, aqui pretende-se relatar como este está organizado.

A primeira parte consiste na fundamentação teórica, que é feita nos três primeiros capítulos e aborda assuntos fundamentais para o desenvolvimento do estudo.

Esta parte preliminar é fragmentada em três capítulos. No **Capítulo 1 - A Marcha** faz-se uma explanação do que é a marcha e apresenta-se seu modelo generalizado. Em seguida, no **Capítulo 2 - Técnicas de Controle Preditivo** aborda-se de forma sucinta o controle preditivo e uma de suas variantes que será aqui utilizada: o Controle Preditivo Híbrido. Ao longo do **Capítulo 3 - Redes Neurais** são apresentadas as redes neurais artificiais, com destaque às Redes Neurais Recorrentes.

Na segunda parte é apresentado o que, de fato, é o desenvolvimento deste trabalho. As proposições feitas, os modelos elaborados e os resultados atingidos são todos abordados no **Capítulo 4 - Trabalho Proposto e Resultados**, que é dividido nas subseções

descritas a seguir:

- **Implementação do Controle Preditivo para o Controle de Torque:** Aqui faz-se utilização das técnicas de controle preditivo para a resolução do problema de controle de torque em uma prótese, garantindo que durante todo o processo o motor é capaz de fornecer torque suficiente para o movimento da perna. Apresenta-se a metodologia utilizada e, por fim, os resultados alcançados.
- **Sistema de Rastreamento de Posição:** Demonstra-se que para o sistema de controle em questão não basta fazer o controle de torque, mas que é necessário também um controle de posição angular a fim de satisfazer os requisitos do problema. No entanto, antes de se pretender controlar o posicionamento, viu-se a necessidade da realização do rastreamento da posição angular da coxa e da perna. Tal necessidade se deu por conta de que, na literatura, as fases do ciclo de marcha descritas do Capítulo 1 são majoritariamente relacionadas ao ângulo do joelho. No entanto, para um amputado transfemural só se pode obter o ângulo do fêmur ou da coxa. Nesta seção, então, apresentam-se os modelos personalizados de marcha obtidos por meio dos rastreamentos, o método empregado para realizá-los e seus resultados.
- **Rede Neural para Modelar a Correlação entre os Ângulos da Coxa e do Joelho:** Antes ainda de se fazer o controle de posição foi preciso criar e treinar uma rede capaz de relacionar os ângulos da coxa de uma pessoa (dados de entrada) e os ângulos de resposta do joelho (dados de saída). Nesta parte do trabalho são expostos os resultados conseguidos com a utilização das melhores redes neurais recorrentes treinadas; também uma análise comparativa entre tais resultados e a seleção da melhor rede.
- **Controle de Posição via Técnicas de Controle Preditivo:** São aqui apresentados o sistema de controle de posição, cuja referência é a saída obtida pela rede neural elaborada na seção anterior, e seus respectivos resultados.
- **Sistema de Controle Geral:** Brevemente descreve-se como os dois sistemas de controle se relacionam, compondo um único sistema geral para controle do joelho magneto-reológico.
- **Considerações Finais:** Nesta seção faz-se um comentário final a respeito de todos os resultados atingidos no presente trabalho.

Finalmente, na terceira parte, o **Capítulo 5 - Conclusões e Trabalhos Futuros** expõe as contribuições feitas e as perspectivas quanto a futuros trabalhos e o **Capítulo 6 - Trabalhos Publicados e em Andamento** relata uma publicação já feita e a elaboração de um novo artigo.

A singularidade do estudo está em utilizar as técnicas de controle preditivo – em vez do controle PID – para realizar os controles de torque e posição do joelho magneto-reológico.

Parte I

Fundamentação Teórica

1 A Marcha

1.1 Introdução

Marcha é a repetição de sucessivas ações dos membros inferiores de forma a projetar o corpo para frente enquanto é mantida uma postura estável, ou seja, o andar (LOTERIO, 2015; ANDRADE, R. M., 2018). Para impulsionar o corpo para frente são necessárias forças, geradas por uma atividade coordenada de vários músculos; assim, a marcha requer a sincronia do sistema nervoso central, periférico e músculos para realizar movimentos ligeiros e complexos (LOTERIO, 2015). Como relata Andrade, R. M. (2018), um ciclo de marcha é o período entre dois acontecimentos análogos e sucessivos, dividido em duas fases: apoio (*stance phase*) e balanço (*swing phase*).

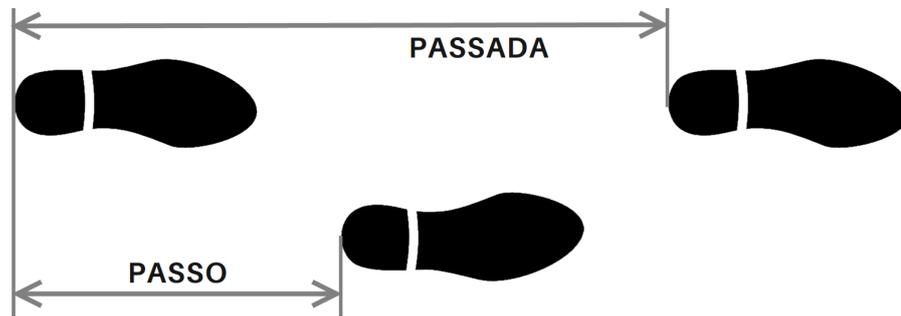
A análise da marcha humana é um dos principais recursos que podem ser utilizados no estudo e no tratamento de disfunções do aparelho locomotor ou que o envolvam (SAAD; BATTISTELLA; MASIERO, 1996; SANTANA, 2005). Os dados fornecidos por essa análise permitem que o profissional responsável determine o método de tratamento mais indicado – sendo ele um procedimento cirúrgico, fisioterapia, utilização de órteses, próteses ou outros auxiliares da marcha, ou mesmo um tratamento medicamentoso – e, além disso, a análise da marcha possibilita uma comparação pré e pós-tratamento em qualquer intervenção e também ajuda na orientação de desempenho para atletas de elite (SAAD; BATTISTELLA; MASIERO, 1996; SANTANA, 2005; MARÃES et al., 2014). Desta forma, a análise de marcha tornou-se objeto de estudo dentro da área de pesquisa em reabilitação.

1.2 Modelo de Marcha

A marcha humana é o movimento que se dá por sucessivos ciclos de marcha, divididos nas fases de apoio e balanço. A fase de apoio, que corresponde à 60% do ciclo, tem início quando ocorre o primeiro contato do pé com o solo e termina ao último contato entre eles; já a fase de balanço, que corresponde aos 40% restantes do ciclo, é a etapa na qual o pé está levantado e sua perna correlata desloca-se para frente, terminando quando o pé toca o chão novamente, completando uma passada, como mostra a Figura 1 (ANDRADE, L. M., 2002; SANTANA, 2005; SCAFETTA; MARCHI; WEST, 2009; LOTERIO, 2015).

Objetivando favorecer as análises acerca da marcha, o ciclo pode ser representado a partir de uma distribuição percentual. Como o tempo de duração de cada fase muda conforme a velocidade da marcha, convenientemente os valores percentuais respectivos

Figura 1 – Distinção entre passo e passada.



às fases são representados de acordo com uma velocidade natural (ANDRADE, L. M., 2002). Não há evento específico que marque o início do ciclo, no entanto, por convenção, na literatura encontra-se o contato inicial como evento primo; por conseguinte, é tido como 0% e o fim do ciclo – imediatamente antes de ocorrer o próximo contato inicial – como 100% (ANDRADE, L. M., 2002; CHAMBERS; SUTHERLAND, 2002).

Segundo Chambers e Sutherland (2002), os eventos que definem os períodos e, conseqüentemente, as fases funcionais do ciclo, são:

- **Contato inicial (*foot strike*):** é o início do ciclo e início da fase de apoio, quando o pé toca o solo.
- **Fim de contato do pé oposto (*opposite toe-off*):** quando o pé contralateral perde contato com o solo, iniciando sua fase de balanço.
- **Contato inicial do pé oposto (*opposite foot strike*):** quando o pé contralateral toca o solo, dando início à sua fase de apoio.
- **Fim de contato do pé (*toe-off*):** quando o pé perde contato com o solo, finalizando, então, a fase de apoio.
- **Progresso ou liberação do pé (*foot clearance*):** quando se dá início à fase de balanço, onde a perna é acelerada para frente.
- **Tíbia vertical (*tibia vertical*):** instante no qual a tíbia da perna em balanço fica na posição vertical
- **Contato inicial sucessivo (*successive foot strike*):** quando o pé toca o solo novamente, finalizando um ciclo de marcha e dando início ao ciclo seguinte.

Com base nas definições anteriores e de acordo com Andrade, L. M. (2002) e Torrealba et al. (2007), uma explanação sobre cada um dos períodos das fases de apoio e balanço será dada a seguir.

A fase de apoio consta de três períodos iniciais:

- **Primeiro apoio duplo:** O primeiro apoio duplo, caracterizado pela transferência de carga para o membro que inicia o ciclo de marcha, começa com o evento *foot strike* e termina com *opposite toe-off*. Neste instante ocorre o amortecimento do impacto do pé com o solo, realizando-se a função de manutenção da estabilidade do peso corporal e a preservação da progressão. As subfases que ocorrem no primeiro apoio duplo são o contato inicial e a resposta à carga.
- **Apoio simples:** Durante o apoio simples ocorre o balanço do membro inferior contralateral, com isso, o membro inferior em apoio tem a responsabilidade de suporte do peso corporal total durante sua progressão. É o período que inicia com *opposite toe-off* e termina com *opposite foot strike*. As subfases que ocorrem no apoio simples são o apoio médio e o apoio terminal.
- **Segundo apoio duplo:** O segundo apoio duplo ou pré-balanço tem início com *opposite foot strike* e finda quando se dá o evento *toe-off*. Tem como função, além da rápida transferência de peso para o membro inferior contralateral, o preparo para o balanço.

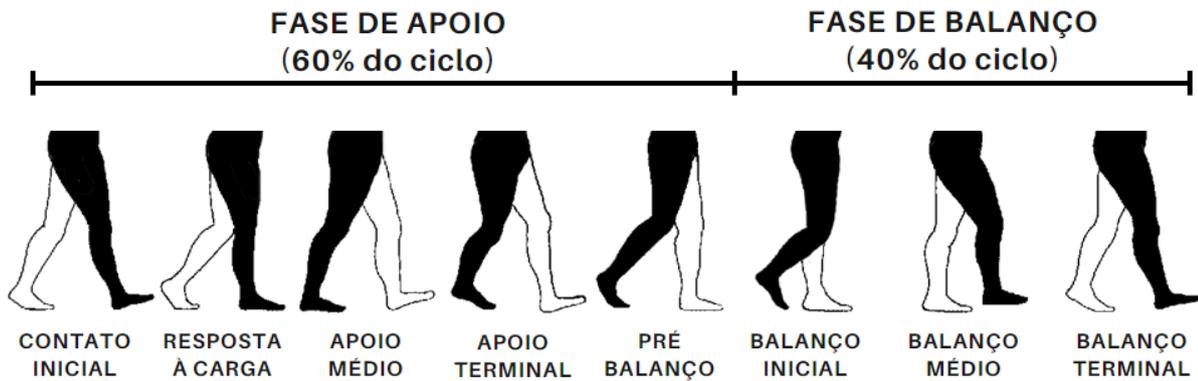
A fase de balanço consiste na retirada do pé do solo, no avanço do membro inferior e na progressão do corpo, e é dividida em três períodos – que são também subfases de balanço:

- **Balanço inicial:** O balanço inicial começa com a retirada do pé do solo, *toe-off*, e termina com o evento *foot clearance*, quando a coxa ultrapassa o membro inferior contralateral.
- **Balanço médio:** Tem início com *foot clearance* e termina quando a perna verticaliza em relação ao solo, com *tibia vertical*.
- **Balanço terminal:** Na última subfase, a de balanço terminal, se completa o avanço do membro inferior com o movimento da perna à frente da coxa e assim este membro inferior se prepara para o próximo contato inicial. Tem início quando a tibia está verticalizada em relação ao solo (*tibia vertical*) e termina com o *foot strike*, em 100% do ciclo de marcha.

Apoio e balanço e suas respectivas subfases estão retratadas na Figura 2.

As fases realizadas durante o ciclo da marcha têm como objetivo a progressão do corpo do indivíduo. As subfases de contato inicial e resposta à carga têm como propósito a aceitação do peso corporal, sendo necessário que haja absorção de choque, estabilidade inicial do membro e preservação da progressão. As subfases de apoio médio e apoio terminal estão relacionadas com o suporte de membro único, sendo que este terá a responsabilidade

Figura 2 – Fases e subfases da marcha.



Fonte: Adaptada de Andrade, L. M. (2002).

de suportar o peso corporal mantendo a progressão do corpo. A tarefa final envolve as subfases de pré-balanço (fase de apoio), balanço inicial, balanço médio e balanço terminal, que tem o objetivo de avanço do membro. Nessas fases o membro se levanta, avança e se prepara para a próxima fase de apoio (PERRY; BURNFIELD, 2010; LOTERIO, 2015).

Cada estudo adota um percentual diferente para as subfases do ciclo de marcha, como se pode ver nas publicações de Vaughan et al. (1999), Andrade, L. M. (2002), Torrealba et al. (2007), Lotério (2015) e Andrade, R. M. (2018). No trabalho em questão serão admitidos os valores conforme apresentado na Figura 3.

Figura 3 – Fases, períodos, subfases e percentuais da marcha.

FASE	PERÍODO	SUBFASE	PERCENTUAL	
APOIO	1º APOIO DUPLO	0 - 10%	CONTATO INICIAL	0%
		0 - 10%	RESPOSTA À CARGA	0 - 10%
	APOIO SIMPLES	10 - 50%	APOIO MÉDIO	10 - 30%
		30 - 50%	APOIO TERMINAL	30 - 50%
	2º APOIO DUPLO	50 - 60%	PRÉ BALANÇO	50 - 60%
BALANÇO			BALANÇO INICIAL	60 - 70%
			BALANÇO MÉDIO	70 - 85%
			BALANÇO TERMINAL	85 - 100%

1.3 Conclusão

Neste primeiro capítulo apresentou-se a marcha humana, o que se entende por este movimento, suas fases e subfases. Foi apontado também que durante o tratamento de patologias motoras e outras enfermidades que envolvam o sistema locomotor a análise da marcha é um dos artifícios mais utilizados como aliado.

O entendimento acerca de como funciona a marcha traz benefícios ao desenvolvimento deste trabalho, com o qual se pretende desenvolver o sistema de controle para uma prótese magneto-reológica de joelho. Compreendidas as funções exercidas pelos membros inferiores e como estes se comportam durante a marcha, entende-se quais os movimentos precisam ser reproduzidos e a importância deles.

Conhecidos estes pontos fundamentais a respeito da marcha humana pode-se começar a pensar em como reproduzir sua dinâmica e quais as técnicas a serem empregadas.

2 Técnicas de Controle Preditivo

2.1 Introdução

Diversas publicações foram feitas de forma relativamente independente e por volta da mesma época, tratando do que mais tarde seria chamado de *Model (Based) Predictive Control*¹ (MPC). Dessa forma, dificilmente a origem do MPC é atribuída a uma única pessoa (LEE, 2011).

Richalet et al. (1978) desenvolveram uma técnica denominada *Heuristic Model Predictive Control*² (HMPC) e relataram o sucesso de sua aplicação em processos industriais em larga escala. Logo depois, Cutler e Ramaker (1979) passaram a atrair as atenções quando relataram o uso do que nomearam *Dynamic Matrix Control*³ (DMC), um algoritmo de controle baseado em modelo multivariável. Enquanto no HMPC empregava-se um modelo de resposta ao impulso finito (FIR) e uma trajetória de referência junto com pontos de coincidência, no DMC era empregado um modelo de resposta em etapas truncadas (TSR) e minimização de erros por mínimos quadrados em relação a um ponto de ajuste constante. Em síntese, os principais ajustes para o HMPC eram feitos através das constantes de tempo das trajetórias de referência, enquanto para o DMC os parâmetros de peso na minimização de mínimos quadrados eram fundamentais (RICHALET et al., 1978; CUTLER; RAMAKER, 1979; LEE, 2011).

A publicação de Cutler e Ramaker, juntamente com artigos anteriores que expunham ideias equivalentes, gerou grande repercussão na comunidade de controle de processos, dando início à era do Controle Preditivo Baseado em Modelo (LEE, 2011). É importante ressaltar que diferentes siglas são utilizadas para representar as técnicas, no entanto o termo coletivo é MPC.

A primeira década dessa era foi marcada pela rápida adoção da tecnologia nas indústrias (especialmente nas de refino e setor petroquímico), ocasionando interesse por parte dos acadêmicos, que, ainda desorientados pela ausência de clareza em torno do assunto, cometeram equívocos – os quais, posteriormente, levaram a outras descobertas. Durante a segunda década viu-se a constante inserção dos algoritmos comerciais do MPC em inúmeros setores industriais; além disso, atingiu-se uma significativa compreensão do MPC, havendo a elaboração de uma base teórica sólida (LEE, 2011). No fim da segunda década houve o surgimento do MPC Híbrido, voltado para sistemas com regras lógicas e dinâmica contínua, cuja descrição matemática foi proposta por Bemporad e Morari

¹ Controle Preditivo Baseado em Modelo

² Controle Preditivo Heurístico de Modelo

³ Controle por Matriz Dinâmica

(1999). Desde então o foco tem sido o aperfeiçoamento das técnicas de MPC, com o desenvolvimento de algoritmos mais rápidos e melhorias no desempenho destes modelos (tanto os de computação *online* quanto os que funcionam de modo *offline*).

As técnicas de controle preditivo são aplicadas visando, resumidamente, prever e garantir o comportamento dinâmico de um sistema em um horizonte de previsão.

2.2 Controle Preditivo Baseado em Modelo

O objetivo próprio de um projeto de controle é o alcance da estabilidade do sistema em malha fechada. No entanto, uma solução fechada para o problema de controle ideal que descreve o *feedback* é, em geral, utópica. Uma alternativa para contornar este revés surge com a aplicação do MPC que, essencialmente, soluciona o controle ideal para o estado atual do sistema fazendo uso do modelo do próprio sistema. A cada instante ocorre o recálculo e o problema de controle ideal para o novo estado do sistema é resolvido, de forma que o que antes seria um problema insolucionável, torna-se resolvível (FINDEISEN, 2005).

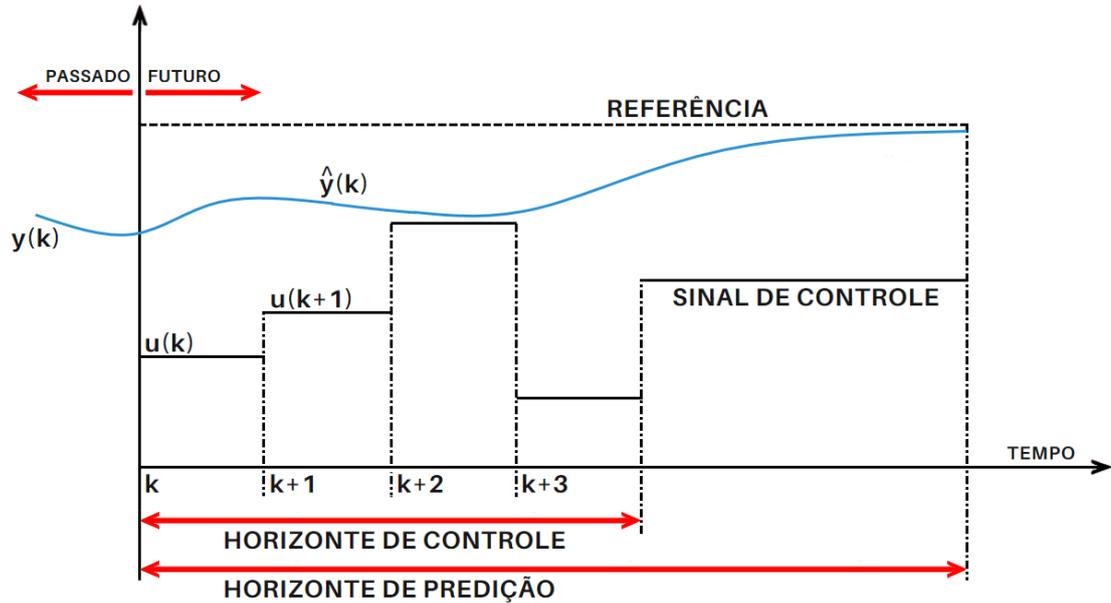
Conceitualmente, o MPC é uma técnica de controle que utiliza um modelo matemático do processo em questão para prever seu comportamento futuro (GARCIA; PRETT; MORARI, 1989; MAYNE et al., 2000; MA et al., 2011). Porém, um mesmo processo pode ser descrito por diversos modelos e, como é a partir de um modelo que todo cálculo de predição é feito, sua escolha interfere diretamente no desempenho do controle. O que caracteriza um bom modelo preditor é a sua eficácia em prever a evolução dinâmica do processo o qual representa (VALE, 2017).

Um MPC convencional baseia-se, ainda, nas restrições do modelo, nos horizontes de predição e controle, no tempo de amostragem e na minimização de função de custo a fim de sintetizar o sinal de controle do processo. Os parâmetros são adequados para cada tipo de problema segundo as exigências da aplicação (VALE, 2017).

Por horizonte de predição entende-se o intervalo de tempo no qual as saídas futuras são previstas; as saídas são calculadas a cada instante levando-se em conta as entradas, saídas e sinais de controle do passado (QIN; BADGWELL, 2003; BRAVO; NORMEY-RICO, 2009; VALE, 2017). Os sinais de controle futuros são definidos segundo a resposta que se obtém da função de custo, de forma a otimizar o processo. Estes sinais, ou ações, são executados sobre as variáveis de entrada do processo no período de tempo que recebe o nome de horizonte de controle, normalmente menor que o de predição (BRAVO; NORMEY-RICO, 2009; QIN; BADGWELL, 2003; VALE, 2017). A Figura 4 visualmente retrata o sinal de controle e os horizontes de controle e predição, representados no tempo discreto.

O controle torna-se mais suave quanto maior o horizonte de predição que se tem

Figura 4 – Representação do controle preditivo.



Fonte: Adaptada de Yousuf, Al-Duwaish e Hamouz (2010).

no processo. Embora os controladores modernos consigam trabalhar com um horizonte de predição infinito, geralmente horizontes finitos são suficientes para realizar boas predições. O horizonte de controle, quanto maior, faz com que o desempenho do sistema aumente; mas, para isso, é necessário um maior esforço computacional (QIN; BADGWELL, 2003).

Compreende-se por tempo de amostragem – ou *sample time* (Δt) – a taxa com que um sistema discreto coleta amostras de entrada. Ele deve ser escolhido de maneira bastante criteriosa, propiciando a descrição discreta do comportamento do sistema da forma mais acertada, tanto quanto possível. Se o sistema tiver uma dinâmica rápida, a escolha de um Δt alto pode levar à perda de informação e uma representação não fidedigna de seu comportamento (VALE, 2017). Em contrapartida, com a diminuição progressiva do valor de Δt nem sempre se consegue uma melhoria de performance; isso acontece quando são coletados mais dados do que o suficiente para sua representação, requerendo mais recursos computacionais do que o necessário.

O controle preditivo possui uma capacidade quase única de lidar com restrições simples e efetivas no controle e nos estados (GARCIA; PRETT; MORARI, 1989; YOUSUF; AL-DUWAISH; HAMOUZ, 2010). Pode-se considerar que na prática todos os processos apresentam restrições, sejam elas de origem construtiva, por motivos de segurança de operação ou por razões ambientais (FAVARO, 2012). Para que se consiga êxito no controle é preciso que o sistema esteja sempre antecipando as ações, mantendo a operação próxima às restrições do sistema e não permitindo que elas sejam violadas; de forma que situações críticas sejam impedidas ao máximo (GARCIA; PRETT; MORARI, 1989; VALE, 2017).

Quando as restrições são consideradas inicialmente, na fase de projeto do controlador, viabiliza-se uma operação ainda mais próxima do sistema real (VALE, 2017).

Definindo antecipadamente ações de controle ótimas ocorre a minimização de uma função de custo, como mostrada na equação (2.1):

$$J = \sum_{i=1}^P \lambda \|y(t+i|k) - y_r(t+i)\| + \sum_{i=1}^M \gamma \|\Delta u(t+i)\| \quad (2.1)$$

onde λ é o fator de ponderação do erro, γ é o fator de ponderação da ação de controle, P é o horizonte de predição, M é o horizonte de controle, $y(t+i)$ é a saída predita, $y_r(t+i)$ é o sinal de referência e $\Delta u(t+i)$ é a variação da ação de controle – ou seja, $u(t+i+1) - u(t+i)$ – (CAMACHO; ALBA, 2013).

Minimizar a função de custo significa agir concomitantemente minimizando o consumo de energia do sistema e atendendo as características dinâmicas esperadas para o sistema em malha fechada. O sistema dinâmico, por sua vez, é modelado através de um modelo preditor da forma (2.2) e representado em função do operador deslocamento para trás z^{-1} , onde $A(z^{-1})$ e $B(z^{-1})$ são polinômios dados por (2.3a) e (2.3b), nesta ordem, sendo a_1, \dots, a_{Na} e b_0, b_1, \dots, b_{Nb} parâmetros destes polinômios.

$$y(t) = \frac{B(z^{-1})}{A(z^{-1})} u(t-1) \quad (2.2)$$

$$A(z^{-1}) = 1 + a_1 z^{-1} + a_2 z^{-2} + \dots + a_{Na} z^{-Na} \quad (2.3a)$$

$$B(z^{-1}) = b_0 + b_1 z^{-1} + b_2 z^{-2} + \dots + b_{Nb} z^{-Nb} \quad (2.3b)$$

A atuação antecipativa é possível se as ações de controle são atualizadas a cada instante, de acordo com a disponibilidade de novos dados do processo.

A ação de controle $u(k)$ – da forma $u(k) = u(k-1) + \Delta u(k)$ – é obtida a partir da solução do problema de minimização da função de custo J (2.1). Se o problema a ser resolvido for irrestrito, e o sistema linear, há uma solução fechada para $\Delta u(k)$, conforme apresentado por Camacho e Alba (2013). Para sistemas mais complexos, com restrições ou sistemas não lineares, a solução é obtida por meio de algoritmos de otimização não-linear (CAMACHO; ALBA, 2013).

De acordo com Camacho e Alba (2013), estes controladores podem ser aplicados ao controle de uma ampla variedade de processos com modelo matemático conhecido, tanto os que possuem dinâmicas relativamente simples quanto as mais complexas. Também podem ser aplicados a sistemas com grandes atrasos de transporte, de fase mínima ou não-mínima, estáveis ou instáveis, monovariáveis ou multivariáveis, lineares ou não (BRAVO;

[NORMEY-RICO, 2009](#)). Eles compensam intrinsecamente os atrasos de transporte, são de simples implementação e seu custo computacional é reduzido ([FINDEISEN, 2005](#)). Podem levar em consideração limites da planta e dos atuadores e têm poucos parâmetros de ajuste. Sua sintonia é relativamente fácil e caso haja necessidade de inclusão de não linearidades e restrições no modelo do processo (tanto na saída quanto na ação de controle), isso pode ser feito com facilidade. Ademais, são bastante úteis quando os sinais de referência do processo são conhecidos durante toda a operação.

2.2.1 Controle Preditivo Híbrido MLD

Os sistemas dinâmicos híbridos são formados por componentes lógicos e analógicos – ou seja, discretos e contínuos –, atraindo os olhares dos estudiosos de controle e ciência da computação. A fim de analisá-los e controlá-los eles foram subdivididos em classes, já que por ora não há um método aplicável a todos os casos ([HEEMELS; SCHUTTER; BEMPORAD, 2001](#)). Sistemas de complementaridade linear, sistemas lógico-dinâmicos mistos (MLD), sistemas híbridos lineares de primeira-ordem com saturação e sistemas afins por partes são algumas das subclasses existentes, sendo cada uma delas possuidora de suas vantagens ([HEEMELS; SCHUTTER; BEMPORAD, 2001](#)).

MLDs são sistemas de tempo discreto que envolvem estados com valores contínuos e discretos, restrições, declarações lógicas e não linearidades ([KARAMAN; SANFELICE; FRAZZOLI, 2008](#)). Bemporad e Morari ([1999](#)) e Karaman, Sanfelice e Frazzoli ([2008](#)) representam os MLDs por meio de um conjunto de equações dinâmicas lineares, que podem conter desigualdades lineares que envolvem variáveis reais e inteiras (variáveis auxiliares contínuas e binárias, tanto lógicas quanto definidas por 0-1). Os números inteiros, por sua vez, podem ser usados para modelar não apenas os fatos lógicos do sistema, mas também várias não linearidades – como funções lineares por partes, restrições disjuntivas, saturação e outras ([KARAMAN; SANFELICE; FRAZZOLI, 2008](#)). Além disso, é relevante ressaltar que as regras lógicas, restrições de operação e leis físicas que os representam são vigorosamente dependentes entre si ([BEMPORAD; MORARI, 1999; COLMENARES et al., 2001](#)).

Os MLDs englobam algumas classes significativas de sistemas, como os sistemas lineares; os híbridos lineares; os lineares restritos; os não lineares cujas não-linearidades possam ser representadas (ou, ao menos, aproximadas de forma apropriada) por funções lineares por partes; os lógicos sequenciais (máquinas de estados finitos, autômatos) e algumas classes de sistemas de evento discreto ([BEMPORAD; MORARI, 1999](#)).

O componente discreto destes sistemas pode ser tratado de diversas maneiras, uma delas é a partir da determinação de níveis hierárquicos, de forma que as variáveis contínuas são fixadas nos níveis inferiores e as discretas (decisões) nos superiores ([COLMENARES et al., 2001](#)). A lógica proposicional envolvendo variáveis contínuas e discretas pode ser

transformada em desigualdades lineares; nessa estrutura, técnicas como MPC podem ser usadas para controlar o sistema (COLMENARES et al., 2001).

O controlador híbrido MLD, como ocorre na modelagem MLD, tem seu sinal de controle definido por meio de regras lógicas que incorporam previsões de modelos locais no processo de otimização. A solução para o problema de otimização é obtida numericamente através da minimização da função de custo (2.1), como mostrado por Bemporad e Morari (1999).

2.3 Conclusão

As aplicações ao setor industrial e as sucessivas pesquisas realizadas fizeram com que as técnicas de controle preditivo logo ganhassem visibilidade entre os cientistas de controle. Com a inserção no mercado industrial, os estudos realizados e os desacertos cometidos, muito pode ser aprendido acerca destas técnicas, permitindo uma primeira estruturação teórica. A partir daí muito já foi – e continua sendo – desenvolvido e otimizado, foram alcançados avanços nos algoritmos e melhor performance dos modelos.

Sua eficácia em prever comportamentos futuros proporciona que ações corretivas sejam tomadas de antemão, garantindo o comportamento do sistema dentro do horizonte de predição determinado. O ajuste de parâmetros com a finalidade de minimizar a função de custo faz com que o sistema economize energia à medida que atende às restrições existentes.

A possibilidade de utilizar o controle preditivo trabalhando com elementos discretos e contínuos trouxe vantagens, fazendo com que as técnicas de controle preditivo híbrido pudessem ser aplicadas a uma maior gama de sistemas.

Sendo assim, a aplicação desta técnica vem de encontro ao que se requer neste estudo: a predição de estados futuros associada à utilização de regras lógicas.

3 Redes Neurais

3.1 Introdução

O cérebro humano é um computador de demasiada complexidade, não linear e paralelo, que com maestria coordena seus elementos estruturais de modo a executar inúmeras e simultâneas funções (HAYKIN, 1994). Suykens, Vanderwalle e Moor (2012) defendem que da perspectiva da engenharia, deixar-se iluminar pela biologia é decerto um passo prolífero. Assim, as redes neurais (RNs) surgiram como uma representação matemática de modelos inspirados em redes neurais biológicas, imitando a arquitetura neural do homem e seus princípios de funcionamento (EKICI; AKSOY, 2009; SUYKENS; VANDEWALLE; MOOR, 2012; AMATO et al., 2013).

De forma sintetizada pode-se dizer que estas redes são processadores distribuídos, formados por diversas unidades simples de processamento e com paralelismo bastante intenso. Elas possuem uma disposição intrínseca para arquivar conhecimentos experimentais e viabilizar seu uso. Assim como ocorre com o cérebro humano, é através do aprendizado que as redes neurais adquirem conhecimento, sendo este armazenado pelas forças que interligam os neurônios (HAYKIN, 1994).

Um tipo especial de RN destaca-se por possuir atributos bastante interessantes para o desenvolvimento deste estudo – são as redes neurais recorrentes. Estas, além de realizarem o processamento de dados sequenciais, possuem a capacidade de reter informações sobre o passado.

Em suma, a utilização destas redes proporciona ao sistema a habilidade de lidar e aprender com informações primitivas, conservar os conhecimentos obtidos por meio delas e disponibilizá-los, por fim, para uma aplicação posterior.

3.2 Redes Neurais Artificiais

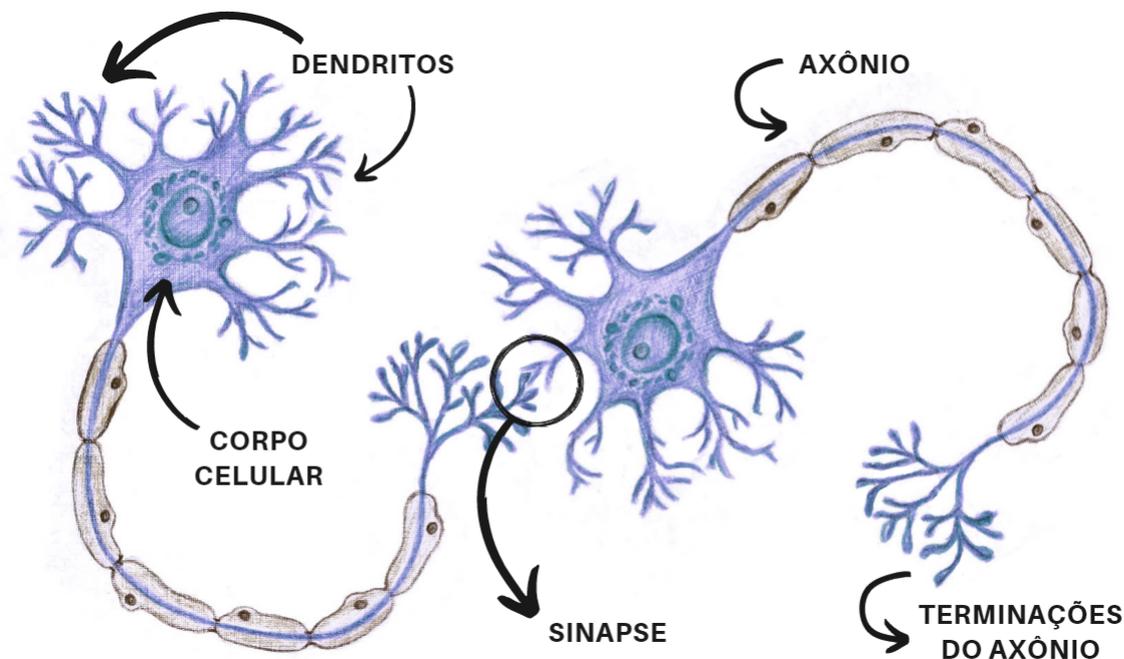
O desenvolvimento das redes neurais artificiais (RNAs) foi motivado pela capacidade que o cérebro humano tem de executar tarefas complexas e não lineares processando informações paralelamente, tudo isso de forma surpreendente (JAIN; MAO; MOHIUDDIN, 1996; KARAYIANNIS; VENETSANOPOULOS, 2013). Ainda que com arquiteturas altamente simplificadas, as redes artificiais herdaram as habilidades de aprendizado, previsão (ou generalização) e auto-organização provenientes das redes biológicas (EKICI; AKSOY, 2009; AMATO et al., 2013; KARAYIANNIS; VENETSANOPOULOS, 2013). Por esse motivo, as RNAs são consideradas pertencentes ao campo da inteligência artificial, uma

vez que esta pode ser compreendida como a capacidade de aprendizado, compreensão e pensamento dos computadores (EKICI; AKSOY, 2009; AMATO et al., 2013).

Para melhor entendimento da estrutura e do funcionamento de uma RNA, um breve conhecimento a respeito do sistema nervoso faz-se necessário.

A célula nervosa, chamada neurônio, é responsável por processar informações. Cada neurônio é composto por axônio, dendritos – transmissor e receptores de sinais, respectivamente – e um corpo celular. Assim, um neurônio recebe impulsos através de seus dendritos e transmite os sinais gerados por meio de seu axônio, cujas terminações são ramificadas. Jain, Mao e Mohiuddin (1996) relatam que cada neurônio se liga a outro através das sinapses, que são estruturas elementares ligadas às terminações dos dendritos de um neurônio e ao axônio de outro neurônio, como pode ser visto na Figura 5.

Figura 5 – Representação das partes do neurônio e sinapse.



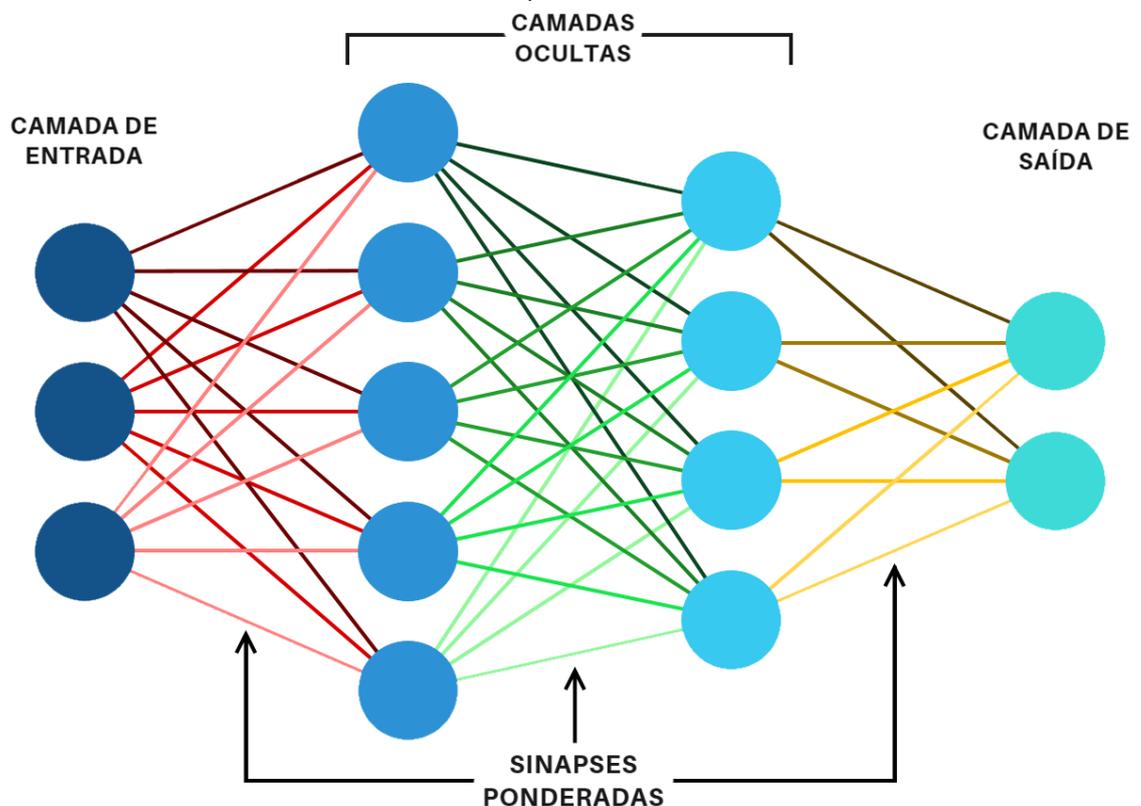
Fonte: Adaptada de Conceitos (c2019).

Um cérebro humano possui em média 15 bilhões de neurônios (JAIN; MAO; MOHIUDDIN, 1996; KARAYIANNIS; VENETSANOPOULOS, 2013). Ainda que sozinhos sejam relativamente simples, as redes neuronais são extremamente complexas pelo fato de os neurônios serem maciçamente conectados entre si, podendo um neurônio conectar-se a outros 10^3 ou 10^4 . Em números totais, o cérebro humano pode chegar a conter de 10^{14} a 10^{15} interconexões (JAIN; MAO; MOHIUDDIN, 1996). Normalmente os pulsos de comunicação têm duração de milissegundos. A mensagem é modulada na frequência de transmissão de pulsos, que pode variar entre poucas e várias centenas de Hertz – sendo cerca de um milhão de vezes mais lenta que a velocidade de comutação mais rápida nos circuitos eletrônicos (JAIN; MAO; MOHIUDDIN, 1996). No entanto, as informações

críticas não são transmitidas diretamente, mas capturadas e distribuídas entre os bilhões de neurônios interconectados – cada um continuamente enviando e recebendo informações –, fazendo com que as decisões perceptivas complexas (como o reconhecimento facial) sejam tomadas em algumas centenas de milissegundos (JAIN; MAO; MOHIUDDIN, 1996; KARAYIANNIS; VENETSANOPOULOS, 2013).

Possuindo a RNA uma estrutura como a do sistema nervoso, ela consiste em vários elementos computacionais simples, os neurônios, que são interconectados entre si e dispostos de forma massivamente paralela (EKICI; AKSOY, 2009; SUYKENS; VANDEWALLE; MOOR, 2012; KARAYIANNIS; VENETSANOPOULOS, 2013). Estes neurônios são organizados em camadas; sendo que cada neurônio de uma camada é conectado aos neurônios da próxima camada por meio de conexões (sinapses) ponderadas, conforme apresentado na Figura 6. A força destas interconexões é quantificada por meio de pesos adaptáveis, que precisam ser aprendidos a partir de um conjunto de exemplos. Estes pesos são dados da seguinte forma: w_{ij} indica a força da conexão existente entre o i -ésimo neurônio de uma camada e o j -ésimo neurônio da camada posterior. A arquitetura das RNAs foi assim projetada visando explorar simultaneamente inúmeras hipóteses concorrentes (SUYKENS; VANDEWALLE; MOOR, 2012; KARAYIANNIS; VENETSANOPOULOS, 2013).

Figura 6 – Exemplo de estrutura das camadas de uma rede.



As camadas de uma RNA são divididas deste modo: uma camada de entrada X (*input*), uma ou mais camadas ocultas H (*hidden layers*) e uma camada de saída Y

(*output*). Tal estrutura é exemplificada pela Figura 6, cujas camadas são representadas pelos vetores (3.1a), (3.1b), (3.1c) e (3.1d).

$$X = (x_1, x_2, x_3) \quad (3.1a)$$

$$H1 = (h_{11}, h_{12}, h_{13}, h_{14}, h_{15}) \quad (3.1b)$$

$$H2 = (h_{21}, h_{22}, h_{23}, h_{24}) \quad (3.1c)$$

$$Y = (y_1, y_2) \quad (3.1d)$$

Os neurônios pertencentes à camada de entrada recebem as informações e as transmitem, através das sinapses ponderadas, aos neurônios da primeira camada oculta; nesta acontece o processamento matemático dos dados, cujo resultado é enviado aos neurônios da próxima camada. O processo avança até que se chegue aos neurônios da última camada, que, por sua vez, fornecem a saída da rede (AMATO et al., 2013). É fundamental destacar que o número de neurônios em cada camada e o número de camadas da rede é dado de acordo com a complexidade do problema a ser estudado.

A matemática executada em um nó j da camada oculta consiste nos seguintes passos (AMATO et al., 2013):

- Cálculo do produto escalar de entradas e pesos, conforme (3.2), fornecendo P_j .
- Soma de P_j a um *bias* θ_j (cuja finalidade é modelar o *offset* do sinal) relativo ao nó, resultando em N_j , como aponta (3.3).
- Aplicação de uma função de ativação f (sendo a sigmoide a mais comum delas) ao termo N_j , gerando S_j , como dado por (3.4).

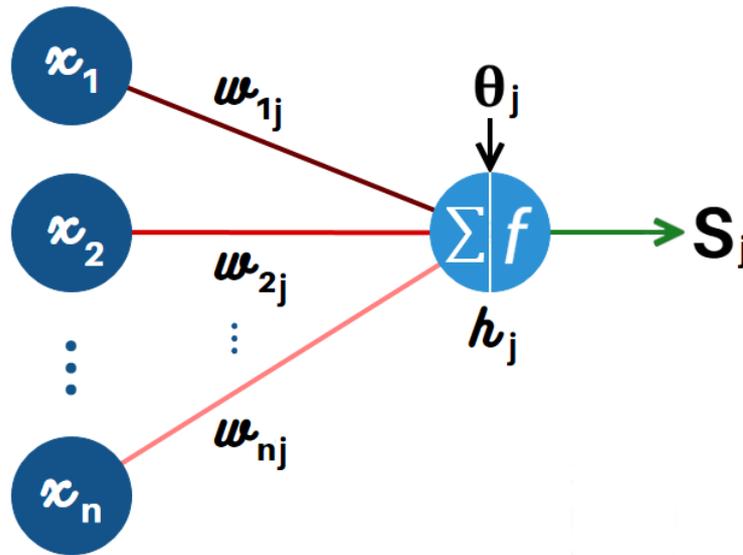
$$P_j = \sum_{i=1}^n x_i w_{ij} \quad j = (1, 2, \dots, m) \quad (3.2)$$

$$N_j = P_j + \theta_j; \quad (3.3)$$

$$S_j = f(N_j) \quad (3.4)$$

Sucedida a matemática, transfere-se o resultado (S_j) do nó aos neurônios da camada seguinte (AMATO et al., 2013). Tal processo encontra-se ilustrado na Figura 7.

O aprendizado da rede acontece no que é chamado processo de treinamento, que se dá por meio do que Amato et al. (2013) chamaram de banco de dados de treinamento. Este, por sua vez, é formado a partir uma série de dados de entrada e seus respectivos valores de saída. O objetivo da etapa de treinamento é encontrar a função g que aproxime

Figura 7 – Representação da matemática realizada no nó j .

Fonte: Adaptada de *A Medium Corporation* (2018).

um vetor de entrada X ao vetor de saída Y correspondente, de forma que Y possa ser representado pela equação (3.5).

$$Y_m = g(X_n) \quad (3.5)$$

A função g é obtida modificando-se iterativamente, segundo o algoritmo de treinamento, os valores que os pesos de conexão (w_{ij}) recebem. Tais valores são alterados a partir de um método chamado *steepest descent* – ou método de descida mais íngreme – para minimizar uma função usada como critério de parada do treinamento, adequada de acordo com cada caso.

Definida a arquitetura da rede a ser utilizada, o processo de treinamento é repetido até que o critério de parada seja atingido. Após treinada, a rede passa por um processo de verificação dos vetores de entrada e saída não utilizados na etapa anterior. Por fim, a etapa de testes: a rede pode ser usada a fim de prever saídas para novos vetores de entrada (AMATO et al., 2013).

Via de regra, a rede pode ser vista pelo usuário como uma caixa preta, que recebe um vetor X_n com n entradas e fornece um vetor Y_m com m saídas (AMATO et al., 2013).

A designação de um sistema pelo termo geral rede neural comumente indica qualquer arquitetura de computação que consista em interconexão massivamente paralela de neurônios simples, implicando em capacidade de aprender. A aprendizagem é entendida como o processo pelo qual um sistema neural é capacitado a realizar certas tarefas por meio do ajuste de parâmetros internos segundo algum esquema de aprendizado (KARAYIANNIS; VENETSANOPOULOS, 2013).

Embora as RNs possam servir de modelo para entender melhor as funções cerebrais

e possam ainda executar tarefas semelhantes ao cérebro humano – como reconhecimento de objetos e padrões, reconhecimento de fala ou memória associativa –, há um crescente interesse por parte dos engenheiros (e pesquisadores de forma geral) acerca do tema (SUYKENS; VANDEWALLE; MOOR, 2012; KARAYIANNIS; VENETSANOPOULOS, 2013). Isso porque estas redes apresentam diversos benefícios para a resolução de problemas, inclusive de engenharia (EKICI; AKSOY, 2009; KARAYIANNIS; VENETSANOPOULOS, 2013).

A vantagem da RNA sobre outros métodos – o que é um dos motivos pelos quais as RNAs são amplamente aplicadas em pesquisas – é o fato de que elas são capazes de modelar sistemas altamente não lineares, onde se desconhece a relação entre as variáveis ou ela é muito complexa (EKICI; AKSOY, 2009; AMATO et al., 2013). As RNAs são também extensamente utilizadas nas áreas de ciências e tecnologia, sendo empregadas em diversos ramos da química, física e biologia, como mostra Amato et al. (2013).

Na área da saúde, as RNAs auxiliaram na análise de amostras de sangue de pacientes diabéticos (CANETE; GONZALEZ-PEREZ; RAMOS-DIAZ, 2012), detecção de carcinoma (BARWAD; DEY; SUSHEILIA, 2012; MEHDY et al., 2017), previsão da categoria de um tumor (NASSER; ABU-NASER, 2019), diagnóstico e previsão da progressão de doenças cardiovasculares (YASNITSKY et al., 2015), diagnósticos de tuberculose (ER; TEMURTAS; TANRIKULU, 2010; ELVEREN; YUMUŞAK, 2011), problemas renais e doenças cardíacas (AL-SHAYEA, 2011; KUMAR; ABHISHEK, 2012; KHAN; ZOPE; SURALKAR, 2013).

Ademais, as RNAs viabilizaram que boas soluções fossem encontradas para muitos problemas em outros campos, como em processamento de sinais, modelagem e controle, robótica, previsão de séries temporais, otimização, sistemas especializados e aplicações financeiras (SUYKENS; VANDEWALLE; MOOR, 2012).

Karayiannis e Venetsanopoulos (2013) sugerem que as RNAs vistas como uma técnica de engenharia, por conta de sua natureza massivamente paralela, permitem o aumento da velocidade da computação; devido à natureza adaptativa, permitem a adequação às mudanças nos dados e aprendizagem das características dos sinais de entrada; por causa de sua natureza não linear, viabilizam a execução de operações de filtragem, indo além da filtragem linear convencional. As RNAs podem ainda ser utilizadas para classificação de padrões, sendo caracterizadas como dispositivos treináveis possuintes de uma capacidade ímpar de generalizar. Devido à habilidade de aprender e ao tipo de arquitetura paralela, elas também podem vencer algumas deficiências encontradas nos computadores convencionais (KARAYIANNIS; VENETSANOPOULOS, 2013).

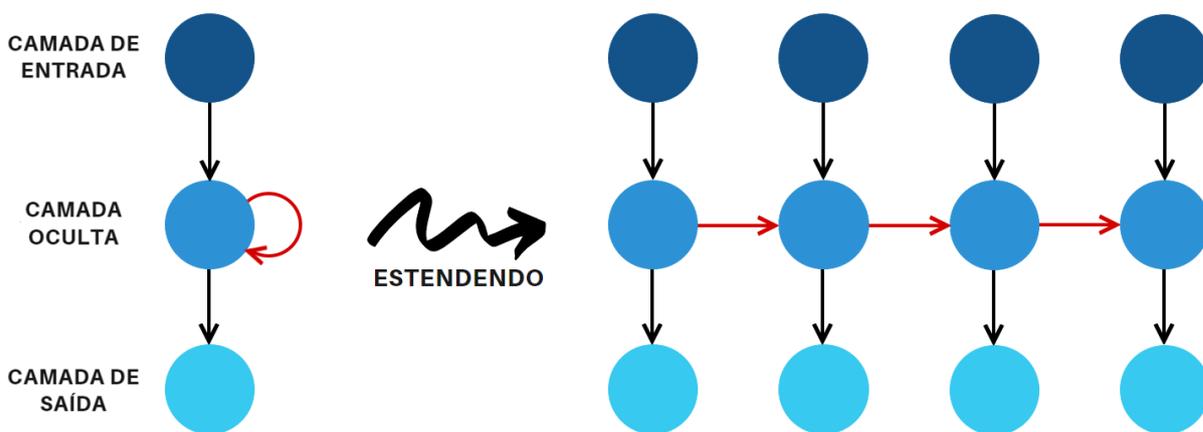
Apesar de todas as capacidades e habilidades únicas que redes neurais artificiais têm, ainda há uma enorme lacuna entre estas e as redes biológicas (SUYKENS; VANDEWALLE; MOOR, 2012).

3.2.1 Redes Neurais Recorrentes

As pesquisas que deram origem às redes neurais recorrentes (RNRs) surgiram na década de 80, e já em 1982 Hopfield propôs um modelo com capacidade de reconhecer padrões (PASCANU; MIKOLOV; BENGIO, 2013). Este modelo, útil para recuperar um padrão armazenado de uma versão corrompida, foi precursor das máquinas de Boltzmann e dos codificadores automáticos.

As RNRs surgiram de uma adaptação das redes *feed-forward* padrão e têm como finalidade modelar processos com características sequenciais (SUTSKEVER; MARTENS; HINTON, 2011; PASCANU; MIKOLOV; BENGIO, 2013; GOODFELLOW; BENGIO; COURVILLE, 2016). Elas permitem conexões – chamadas de arestas recorrentes – entre suas unidades ocultas e um atraso temporal; no entanto, assim como as redes *feed-forward*, podem não ter ciclos entre as arestas convencionais (PASCANU; MIKOLOV; BENGIO, 2013). A estrutura comum de uma RNR, representada pela Figura 8, conta com o arranjo padrão de uma RNA – que consta de uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída – acrescido da conexão típica das redes recorrentes.

Figura 8 – Estrutura das camadas de uma rede neural recorrente.



Fonte: Adaptada de WILDML - *Artificial Intelligence, Deep Learning, and NLP* (2015).

Com o uso das arestas recorrentes as informações podem circular dentro da rede por um tempo arbitrariamente longo, de tal forma que o modelo passa a ser capaz de reter informações sobre o passado, o que é a principal qualidade deste modelo de rede neural (MIKOLOV et al., 2010; PASCANU; MIKOLOV; BENGIO, 2013).

A capacidade da lembrança e do processamento de informações passadas decorre justamente de um estado oculto de alta dimensão com dinâmica não linear. Isso torna a rede recorrente um modelo poderoso, ainda que simples (pois as não linearidades de cada unidade não são sofisticadas). São as iterações que fazem com que seja alcançada uma dinâmica elaborada, tornando a rede potente na solução de problemas com características fortemente

temporais (SUTSKEVER; MARTENS; HINTON, 2011; PASCANU; MIKOLOV; BENGIO, 2013).

Em decorrência de seus atributos, as redes RNRs têm atingido ótima performance em trabalhos que envolvem modelagem de linguagem, reconhecimento de fala e tradução automática (GRAVES; MOHAMED; HINTON, 2013; ZAREMBA; SUTSKEVER; VINYALS, 2014). As melhorias alcançaram ainda a modelagem acústica, possibilitando um notável desempenho destas modelagens (GRAVES; MOHAMED; HINTON, 2013).

A fim de descrever uma rede recorrente, toma-se uma sequência de dados de entrada $x^{(t)}$ – com o índice de intervalo de tempo t variando de 1 a α –, uma ou mais camadas ocultas $h^{(t)}$ e um vetor de saída $\check{y}^{(t)}$ (GRAVES; MOHAMED; HINTON, 2013; LIPTON; BERKOWITZ; ELKAN, 2015). A cada instante de tempo uma nova entrada chega à rede, em seguida há a atualização do estado oculto, cujo funcionamento está mais detalhado na Figura 9, e depois a execução de uma previsão de saída (SUTSKEVER; MARTENS; HINTON, 2011). No momento t , cada nó com arestas recorrentes recebe um *input* com dados atuais proveniente de $x^{(t)}$ e os valores dos nós ocultos referentes ao estado anterior da rede, ou seja, a memória de trabalho $h^{(t-1)}$. O nó oculto atual $h^{(t)}$ é calculado de acordo com a Figura 9 e, por fim, o *output* $\check{y}^{(t)}$ é previsto a cada instante t (LIPTON; BERKOWITZ; ELKAN, 2015). Dessa forma, cada membro da saída é uma função das saídas anteriores; e assim como $h^{(t-1)}$, a entrada $x^{(t-1)}$ no tempo $t - 1$ pode influenciar a saída prevista no tempo t (e posteriormente) por meio das conexões recorrentes (LIPTON; BERKOWITZ; ELKAN, 2015; GOODFELLOW; BENGIO; COURVILLE, 2016).

Os vetores de $X^{(t)}$, $H^{(t)}$ e $\check{Y}^{(t)}$ que exprimem uma rede recorrente padrão estão representados respectivamente pelas equações (3.6), (3.7) e (3.8); já os cálculos de $h^{(t)}$ e $\check{y}^{(t)}$ pelas equações seguintes (3.9) e (3.10), de acordo com Graves, Mohamed e Hinton (2013).

$$X^{(t)} = (x^{(1)}, x^{(2)}, x^{(3)}, \dots, x^{(\alpha)}) \quad (3.6)$$

$$H^{(t)} = (h^{(1)}, h^{(2)}, h^{(3)}, \dots, h^{(\alpha)}) \quad (3.7)$$

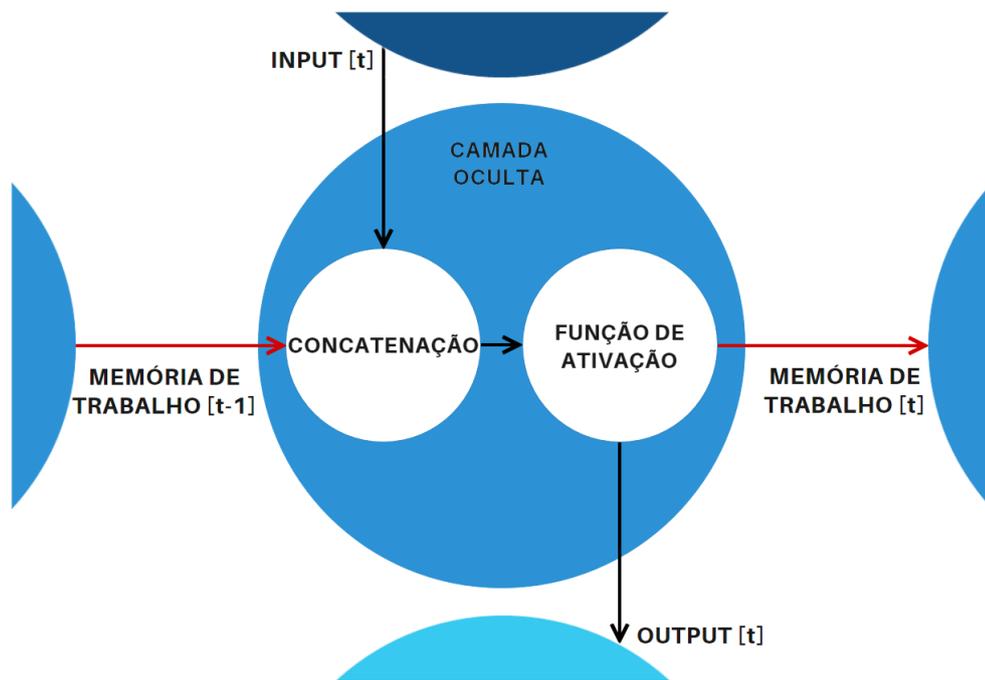
$$\check{Y}^{(t)} = (\check{y}^{(1)}, \check{y}^{(2)}, \check{y}^{(3)}, \dots, \check{y}^{(\alpha)}) \quad (3.8)$$

$$h^{(t)} = \mathcal{H}(W^{hx}x^{(t)} + W^{hh}h^{(t-1)} + \theta_h) \quad (3.9)$$

$$\check{y}^{(t)} = W^{yh}h^{(t)} + \theta_y \quad (3.10)$$

Os termos W denotam matrizes de peso: W^{hx} é a matriz de peso entre a entrada e a camada oculta, W^{hh} é a matriz de pesos recorrentes entre a camada oculta e ela mesma

Figura 9 – Estrutura de uma célula da camada oculta na RNR.



Fonte: Adaptada de Bouvet (2020).

em etapas adjacentes, W^{yh} é a matriz de peso entre a camada oculta e a saída; os termos θ denotam vetores de *bias* – θ_h é o vetor relativo à camada oculta e θ_y à camada de saída –, responsáveis por permitirem que cada nó aprenda um deslocamento (SUTSKEVER; MARTENS; HINTON, 2011; GRAVES; MOHAMED; HINTON, 2013; LIPTON; BERKOWITZ; ELKAN, 2015). \mathcal{H} é a função de ativação da camada oculta, sendo a sigmoide e a tanh as mais utilizadas (GRAVES; MOHAMED; HINTON, 2013; LIPTON; BERKOWITZ; ELKAN, 2015). A expressão indefinida $W^{hh}h^{(t-1)}$ no momento $t = 1$ é substituída por um vetor de polarização inicial especial h^{init} (SUTSKEVER; MARTENS; HINTON, 2011).

Em verdade, os períodos de tempo de operação das redes recorrentes nem sempre correspondem ao curso do tempo no mundo real, podendo somente referir-se ao posicionamento na sequência (GOODFELLOW; BENGIO; COURVILLE, 2016). Isso pode ocorrer uma vez que estas redes comumente operam em *minibatches* das sequências.

Para finalidades práticas, as RNRs fechadas são consideradas como os modelos de sequência mais eficientes. Entre os tipos de RNRs fechadas está a memória de longo prazo; a respeito dela, diz-se muito sobre o problema de suas dependências, que é uma das dificuldades básicas das RNRs padrão (GOODFELLOW; BENGIO; COURVILLE, 2016; PEDRYCZ; CHEN, 2019). Este problema aparece na etapa de treinamento, quando se faz necessária a propagação dos gradientes por muitos estágios – o que ocorre quando o comprimento da entrada ou da saída desejada é relativamente grande – e, dessa forma, tendem ao desaparecimento ou à explosão, sendo o segundo mais raro de acontecer que o primeiro, embora seja ele mais danoso à otimização (BENGIO; SIMARD;

FRASCONI, 1994; PEDRYCZ; CHEN, 2019). Estes problemas de gradientes, descritos por Bengio, Simard e Frasconi (1994) como problemas de fuga e explosão, decorrem de erros de retropropagação que vão se repetindo durante as várias etapas de tempo (MIKOLOV et al., 2010; SUTSKEVER; MARTENS; HINTON, 2011). Na prática, os gradientes de fuga agem como obstáculos, atrapalhando o entendimento de qual direção os parâmetros devem se mover a fim de melhorar a função de custo; os gradientes explosivos, no entanto, atuam como possível entrave ao aprendizado (GOODFELLOW; BENGIO; COURVILLE, 2016).

Como os gradientes da RNR são fáceis de calcular através da propagação reversa ao longo do tempo, pode parecer que as RNRs são de fácil treinamento a partir do gradiente de descida (SUTSKEVER; MARTENS; HINTON, 2011). Empiricamente vê-se a dificuldade em treinar adequada e efetivamente esse tipo de rede, porque a relação entre os parâmetros e a dinâmica dos estados ocultos é muito instável, tornando a descida do gradiente ineficaz e, conseqüentemente, o aprendizado difícil (PASCANU; MIKOLOV; BENGIO, 2013). Como a descida em gradiente era o principal algoritmo usado para treinar redes neurais na época, esses resultados teóricos e a dificuldade empírica de treinar RNRs levaram ao quase abandono da pesquisa (SUTSKEVER; MARTENS; HINTON, 2011).

Pascanu, Mikolov e Bengio (2012) fornecem um tratamento matemático completo dos problemas de gradiente de fuga e explosão, caracterizando as condições exatas sob as quais esses problemas podem ocorrer. Dadas essas condições, eles sugerem uma abordagem ao treinamento por meio de um termo de regularização que força os pesos a valores em que o gradiente não desaparece nem explode (LIPTON; BERKOWITZ; ELKAN, 2015). *Long Short-Term Memory*¹ (LSTM) e *Truncated Backpropagation Through Time*² (TBPTT) são variantes da arquitetura tradicional da RNN propostas para corrigir esses problemas (PEDRYCZ; CHEN, 2019).

A arquitetura LSTM, que dentre as arquiteturas de redes recorrentes é uma das que apresenta melhor desempenho, foi introduzida em 1997 por Hochreiter como uma solução para o problema dos gradientes de fuga (BENGIO; SIMARD; FRASCONI, 1994; LIPTON; BERKOWITZ; ELKAN, 2015; PEDRYCZ; CHEN, 2019). A rede LSTM é similar a uma rede RNR padrão com uma camada oculta, diferindo na presença de células de memória em vez de nós comuns na camada oculta. Estas células de memória são compostas, cada uma, por um nó com arestas recorrentes autoconectadas de peso fixo, responsáveis por assegurar o fluxo dos gradientes durante muitas etapas de tempo, de forma a evitar que eles explodam ou desapareçam (LIPTON; BERKOWITZ; ELKAN, 2015; PEDRYCZ; CHEN, 2019).

Desde a elaboração da arquitetura original LSTM, diversas variantes foram produzidas e encontram-se descritas em literatura (LIPTON; BERKOWITZ; ELKAN, 2015;

¹ Memória de Longo Prazo

² Retropropagação Truncada ao Longo do Tempo

PEDRYCZ; CHEN, 2019). Apesar de cada uma ter sua particularidade, todas elas seguem a mesma ideia: a manutenção de uma recorrência linear pela qual as informações podem ser propagadas por longos períodos de tempo. Ressalta-se ainda que o tempo de integração pode ser variado dinamicamente com o aumento do peso das autoconexões (BENGIO; SIMARD; FRASCONI, 1994).

Graças à capacidade de preservar informações, as redes LSTM têm atingido ótimos resultados quando utilizadas em aplicações de modelagem de sequência, como reconhecimento de escrita manual e de fala, geração de escrita manual, tradução automática, conversão de imagem em texto (legendas) e análise (BENGIO; SIMARD; FRASCONI, 1994; PEDRYCZ; CHEN, 2019).

Os projetos mais modernos, no entanto, têm utilizado uma variação arquitetônica bastante eficaz da LSTM, com a introdução de *gates* de esquecimento (*forget gates*) (LIP-TON; BERKOWITZ; ELKAN, 2015). Estes *gates*, quando aliados às células de memória, amplificam a capacidade da rede em modelar informações de sequência, fazendo com que a rede seja treinada para esquecer as informações desnecessárias enquanto mantém as informações importantes na célula de memória (PEDRYCZ; CHEN, 2019).

Além dos *gates* de esquecimento, uma rede LSTM possui ainda *gates* de entrada (*input gates*) e de saída (*output gates*), que filtram as informações que devem ser descartadas das que precisam ser retidas, como ilustra a Figura 10.

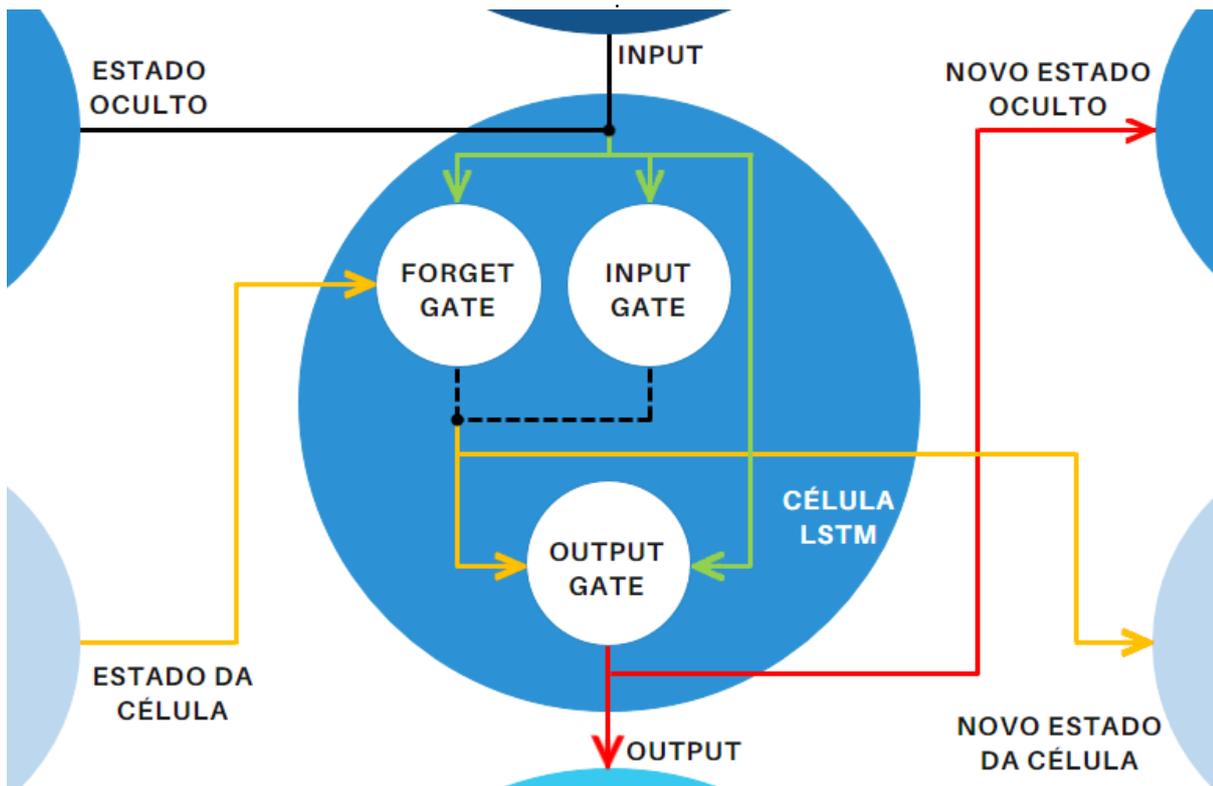
O funcionamento de uma célula LSTM se dá, em cada etapa, da seguinte forma: ela recebe o *input* atual, a memória de curto prazo – também conhecida como estado oculto – e de longo prazo – estado da célula. O *gate* de entrada filtra o *input* atual e a memória de curto prazo recebida do estado anterior. O *gate* de esquecimento filtra a memória de longo prazo herdada do estado anterior multiplicando-a por um vetor de esquecimento gerado pela memória de curto prazo anterior e pelo *input* atual. As saídas destes dois *gates* são

Figura 10 – Ilustração do funcionamento de um *gate*.



manipuladas, gerando um novo estado de célula. Este, por sua vez, é também utilizado pelo *gate* de saída, que, juntamente com o *input* atual e a memória de curto prazo do estado anterior, produzirão o novo estado oculto e o *output* atual. As memórias de curto e longo prazo recém-calculadas são transferidas para a célula seguinte, dando continuidade ao processo. De forma sintetizada, a atividade da célula LSTM é retratada pela Figura 11.

Figura 11 – Estrutura de uma célula LSTM.



Comparada à uma RNR simples a arquitetura LSTM demonstrou ser superior em termos de aprendizado de dependências de longo alcance (LIPTON; BERKOWITZ; ELKAN, 2015).

Já para corrigir o problema do gradiente de explosão, pode-se usar a retropropagação truncada ao longo do tempo (LIPTON; BERKOWITZ; ELKAN, 2015; PEDRYCZ; CHEN, 2019). Na arquitetura TBPTT – descrita por Williams e Peng (1990) – a sequência de treinamento inicial é dividida arbitrariamente em subsequências de tamanho uniforme (chamadas janelas), e dentro de cada uma delas é implementado o algoritmo do *Backpropagation Through Time*³ (BPTT), fazendo com que a retropropagação aconteça internamente a estas janelas (TALLEC; OLLIVIER, 2017; LILICRAP; SANTORO, 2019). Em outras palavras, o método consiste na escolha de um número máximo de etapas pelo qual o erro poderá se propagar (LIPTON; BERKOWITZ; ELKAN, 2015).

³ Retropropagação ao Longo do Tempo

Com o fluxo do gradiente interrompido entre as janelas, o risco de este explodir ou desaparecer é reduzido. Por outro lado, não se pode realizar atribuição de pesos fora da janela de truncamento, ainda que os gradientes não desapareçam (TALLEC; OLLIVIER, 2017; LILICRAP; SANTORO, 2019).

O TBPTT é aplicado com sucesso quando os intervalos possuem algumas centenas de etapas; no entanto, para longas dependências ele não é bem aplicado. Isto se deve ao fato de que a frequência de atualização dos parâmetros diminui conforme o horizonte de tempo aumenta, tornando-se fundamental que se tenha mais memória para armazenar o conjunto de estados passados (MUJICA; MEIER; STEGER, 2018). Como consequência imediata, esta arquitetura apresenta problemas para aprender dependências de longo alcance (LIPTON; BERKOWITZ; ELKAN, 2015; TALLEC; OLLIVIER, 2017; MUJICA; MEIER; STEGER, 2018).

O custo de memória do BPTT truncado varia proporcionalmente ao número de etapas de truncamento (LIAO et al., 2018). De fácil implementação, é geralmente empregado no treinamento de redes recorrentes para reconhecimento de fala e modelagem de linguagem (LIAO et al., 2018; TANG; GLASS, 2018).

Assim sendo, estas duas arquiteturas vêm com o objetivo de solucionar os problemas de gradiente. Mas além delas, outros tipos de camadas podem ser aplicadas às RNRs, como por exemplo *Gated Recurrent Unit*⁴ (GRU) e *Simple Recurrent Neural Network*⁵ (*SimpleRNN*).

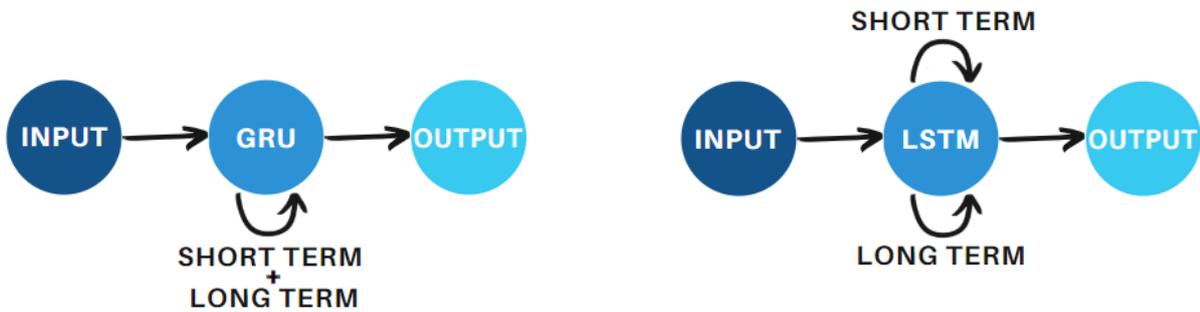
A arquitetura *SimpleRNN* é a arquitetura de rede mais simples e consiste na existência de apenas uma camada oculta na RNR, fazendo a predição com base somente no estado da amostra anterior (YOUNG et al., 2018; OLABARRERA et al., 2020). As camadas LSTM, quando comparadas às camadas de uma RNR, operam de forma mais eficiente quanto ao aprendizado de dependências de longo prazo. As GRU, elaboradas em 2014 por Cho et al. (2014), utilizam apenas um estado oculto para transportar as informações de curto e longo prazo – diferentemente das LSTM, como mostra Figura 12 (NAKAMURA et al., 2019). Esta arquitetura possui apenas dois *gates*, que filtram as informações que devem ou não ser passadas adiante; assim como já foi ilustrado na Figura 10.

Como melhoria, os *gates* da arquitetura GRU podem ser treinados para que retenham informações significativamente antigas sem que elas se percam ou alguma parte seja removida. São eles: os *gates* de redefinição (*reset gate*) e de atualização (*update gate*). Ambos trabalham com o estado oculto herdado da etapa anterior e o *input* atual, cada um à sua maneira, gerando a saída da célula. No entanto, de forma particular, o *update gate* tem a função de assistir o modelo na determinação do quanto das informações ascen-

⁴ Unidade Recorrente Fechada

⁵ Rede Neural Recorrente Simples

Figura 12 – Comparação de estados ocultos entre GRU e LSTM.

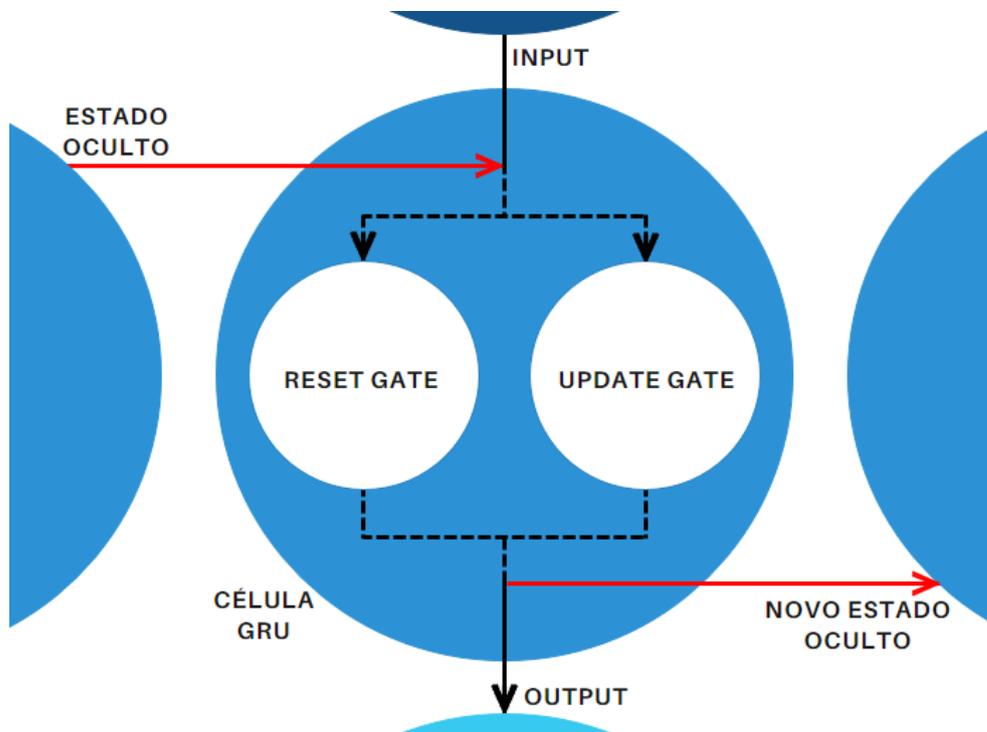


Fonte: Adaptada de *The Deep Learning Book* (20-).

dentes armazenadas no estado oculto anterior precisam ser protegidas e passadas adiante, dando prosseguimento ao processo. O funcionamento da célula GRU está representado genericamente na Figura 13.

Por fim, pode-se dizer que embora as redes neurais recorrentes possuam não-linearidades não sofisticadas, elas podem atingir uma dinâmica elaborada por meio das iterações que realizam.

Figura 13 – Estrutura de funcionamento de uma célula GRU.



3.3 Conclusão

A perfeição com que o cérebro humano comanda seus elementos estruturais é responsável por permitir que o corpo humano seja capaz de realizar múltiplas tarefas

simultânea e otimamente. As grandes responsáveis por este gerenciamento de excelência são as redes neurais, e foi com base nelas que os cientistas desenvolveram as redes neurais artificiais.

Formadas por uma camada de entrada, uma ou mais camadas ocultas, uma camada de saída e possuindo natureza massivamente paralela, as RNAs têm alta capacidade de treinamento, podendo ser utilizadas em diversos setores da engenharia.

Ademais, elas podem adaptar diversas arquiteturas a fim de realizar suas tarefas de acordo com os objetivos de utilização. De maneira especial, a aptidão à lembrança de informações e o processamento das mesmas fazem das redes recorrentes um modelo bastante poderoso.

As redes neurais artificiais possuem diversos atributos, como, por exemplo, as habilidades de aprendizado, previsão e auto-organização. Não obstante, Suykens, Vanderwalle e Moor (2012) dizem que há ainda um hiato entre o que as redes biológicas podem fazer e a capacidade das redes neurais artificiais, se tratando de generalização. Daí conclui-se que muito há para ser melhorado, desenvolvido e talvez descoberto.

Parte II

Proposta

4 Trabalho Proposto e Resultados

4.1 Introdução

O presente estudo tem como proposta a elaboração de um sistema de controle para uma prótese magneto-reológica de joelho com a utilização das técnicas de controle preditivo associadas às redes neurais.

Este capítulo é organizado em subseções, onde primeiro detalha-se todo o sistema de controle de torque fazendo uso dos métodos preditivos. Depois descreve-se o desenvolvimento do sistema de rastreamento de posição, seguido pela implementação de redes neurais – que têm por função modelar a correlação entre os ângulos da coxa e da perna – e, então, chega-se ao controle de posição do joelho MR. Na sequência, caracteriza-se o sistema de controle geral do sistema e, finalmente, fazem-se algumas considerações acerca do desenvolvimento deste estudo.

Todos os modelos utilizados estão representados nesta seção, bem como os resultados obtidos a partir deles.

4.2 Implementação do Controle Preditivo para Controle de Torque

Neste trabalho a elaboração de um controle de torque tem por finalidade garantir que o sistema será capaz de gerar o torque necessário em cada fase do ciclo, propiciando o correto funcionamento do joelho magneto-reológico.

Utilizando-se do modelo matemático do processo o controlador preditivo prevê o comportamento futuro do sistema, sendo possível definir, de forma antecipativa, ações ótimas de controle que minimizem a função de custo.

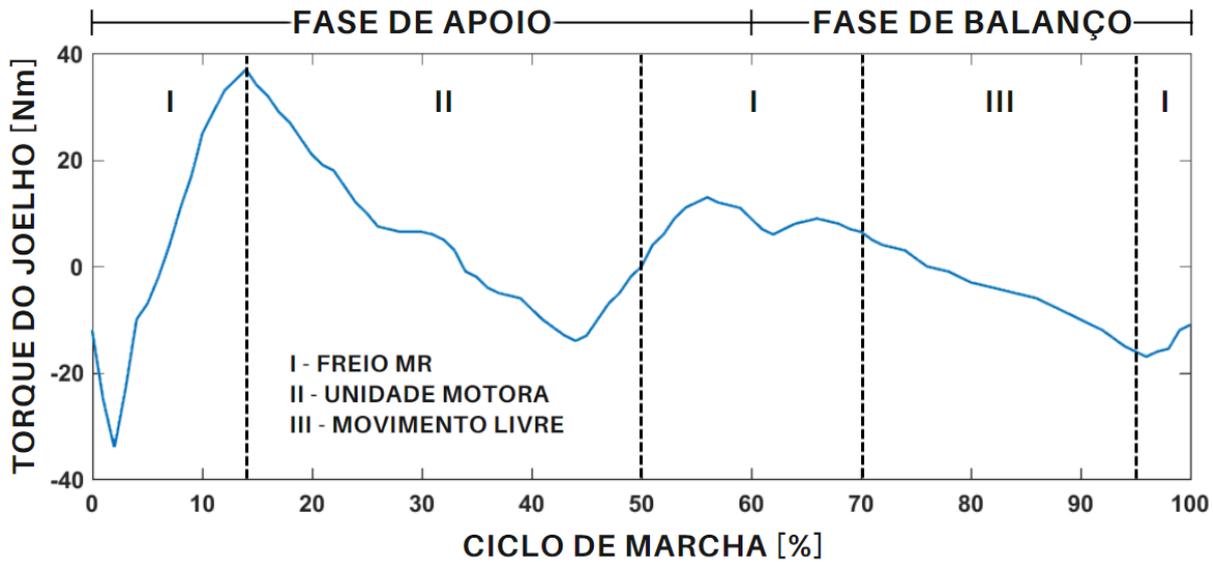
O objetivo desta primeira parte é demonstrar, por meio de simulação, que o uso do controle preditivo para a aplicação em pauta é viável e vantajosa.

4.2.1 Modelo

A partir de um modelo de marcha proposto por Kapti e Yucenur (2006) foi possível definir a curva de referência do torque de um joelho, dada pela Figura 14.

Visando desenvolver um sistema de controle capaz de seguir a trajetória de referência da curva de torque, primeiro determinou-se o modelo do joelho artificial a ser tratado. Considerou-se um joelho com um grau de liberdade ou mobilidade (flexão/extensão), assim

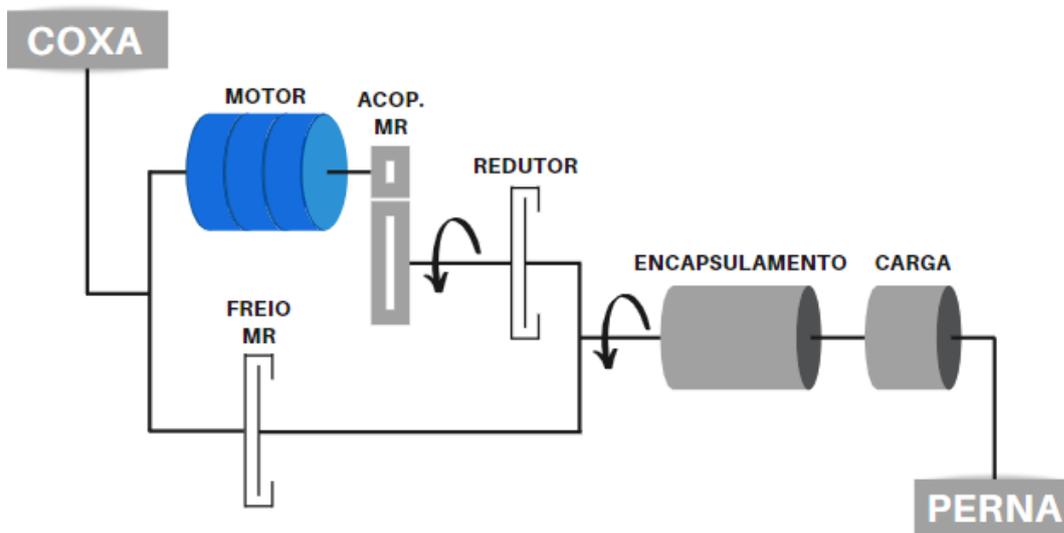
Figura 14 – Torque do joelho no ciclo de marcha.



Fonte: Adaptada de Kapti e Yucenur (2006).

como sugerido por Andrade, R. M. (2018), e seu modelo dinâmico está representado na Figura 15.

Figura 15 – Modelo dinâmico do joelho MR.



Fonte: Adaptada de Andrade, R. M. (2018).

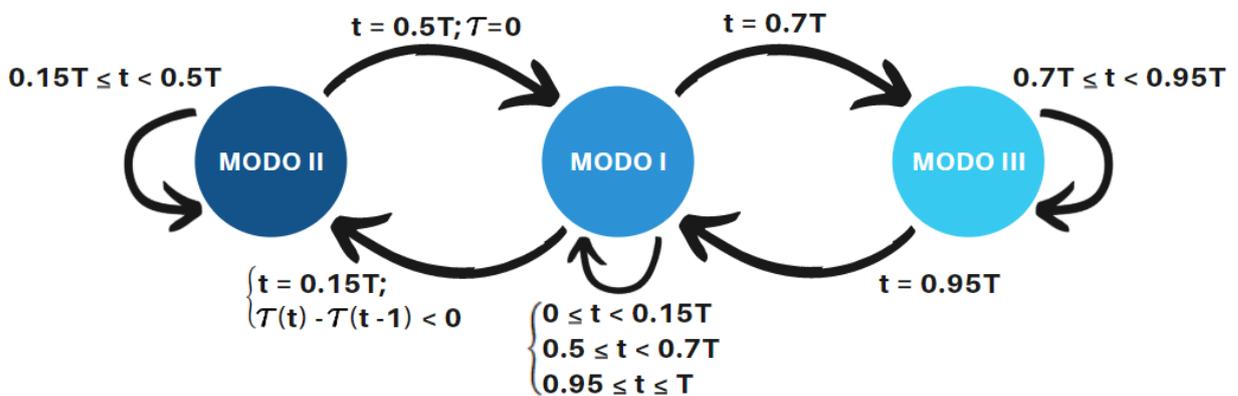
O modelo proposto constitui-se de uma unidade motora (composta por motor, redutor e acoplamento MR) e um freio MR. As duas unidades atuam em paralelo, de forma complementar e em diferentes momentos, como será visto posteriormente. O torque ativo é fornecido pela unidade motora enquanto o torque passivo é gerado pelo freio MR. Os sistemas de acoplamento MR e freio MR são formados por um conjunto de bobina, núcleo de ferro, discos e fluido MR. O campo magnético aplicado aos dispositivos MR é gerado pela corrente elétrica na bobina (quanto maior a corrente, maior a força do campo

magnético) e é direcionado ao fluido, que tem sua tensão limite de cisalhamento alterada – com a maior força do campo, maior a resistência do material ferromagnético em se manter alinhado e, portanto, maior a tensão de cisalhamento necessária. Sendo assim, as variáveis de controle sobre os sistemas de acoplamento e freio, em malha aberta, são as correntes nas bobinas, e a variável de saída o torque resultante.

Não obstante o sistema locomotor seja muito mais complexo no que se refere à atuação e performance do joelho, pretendeu-se demonstrar com este projeto que a utilização das técnicas de controle preditivo pode trazer vantagens ao controle de próteses transfemorais, uma vez que o próprio cérebro humano atua de forma preditiva (CAMACHO; ALBA, 2013; MARENGO, 2018).

Tendo em vista a realização das transições de trabalho entre a unidade motora e o freio MR, foi utilizada a técnica que mescla lógica e dinâmica, já abordada no Capítulo 2 (BEMPORAD; MORARI, 1999). A simulação é contínua para as unidades do motor e do freio, mas cada uma é acionada apenas quando necessário. Assim, as regras para o funcionamento do joelho e as regras para o controle preditivo estão representadas no esquema mostrado na Figura 16 – onde t é o tempo, T é o tempo total do ciclo e τ é o torque no instante t –, que concorda com a descrição subsequente.

Figura 16 – Modos de operação com base no controle preditivo híbrido.



O torque medido em um joelho saudável durante o ciclo de marcha (Figura 2) foi utilizado como referência de entrada. O ciclo é dividido em cinco etapas; entretanto, os modos de operação do sistema de controle são três, como retrata a Figura 16. Embora a fase de apoio corresponda aos primeiros 60% do ciclo – começando quando se dá o primeiro contato entre o pé e o chão e terminando quando não há mais contato entre eles –, a unidade motora é apenas utilizada no tempo correspondente ao intervalo entre 15% e 50% do ciclo, fornecendo torque ativo ao sistema; no restante do período da fase de apoio o freio MR é responsável pelo fornecimento de torque resistivo (VAUGHAN et al., 1999; ANDRADE, R. M., 2018). A fim de detalhar melhor os modos de operação, estes foram

descritos a seguir:

- **Modo de operação I:** No modo de operação I – que vai de 0% a 15%, de 50% a 70% e de 95% a 100% – apenas o torque resistivo é requerido, obtido pelo uso do freio MR. Nesta fase o controle preditivo é baseado no modelo do freio MR.
- **Modo de operação II:** Responsável pelo fornecimento de torque ativo durante o intervalo de 15% a 50% do ciclo. O controle preditivo é baseado no modelo da unidade motora e na atuação do acoplamento MR. Durante a atividade deste modo de operação o freio MR está desligado. Apresenta o maior consumo de energia.
- **Modo de operação III:** Neste modo de operação há o movimento livre do freio MR e do sistema de acoplamento MR, o que significa total desenergização. Há redução do consumo de energia.

Portanto, se o ciclo de marcha está no Modo I a unidade motora é desligada, o sistema de freio é ativado e o sistema de controle preditivo baseado no modelo do freio é responsável por controlar o torque do joelho. Se o ciclo de marcha está no Modo II, a unidade motora é acionada e o controlador preditivo baseado na unidade motora e no modelo de acoplamento MR é responsável pelo controle do torque no joelho. Finalmente, com a marcha na etapa correspondente ao Modo III de operação, o joelho se movimenta livremente e não há ativação do motor e nem do freio; a perna é projetada para frente apenas com o movimento do quadril e a velocidade angular da articulação da prótese é maior.

4.2.2 Resultados

Os dados apresentados por Andrade, R. M. (2018) foram aqui utilizados como modelo de referência de um joelho magneto-reológico. No trabalho citado foi desenvolvido um joelho cuja carcaça é composta por peças feitas de liga de alumínio 70-75, um motor EC 60 *flat* e um redutor harmônico CSG-14-100-2a. A massa do joelho MR completo é de 1998 gramas, com largura de 80,5 mm e 117 mm de diâmetro. A partir de experimentos realizados, Andrade, R. M. (2018) apresenta as funções de transferência (FT) para a unidade motor + acoplamento MR e para o freio MR, dadas por (4.1) e (4.2), respectivamente.

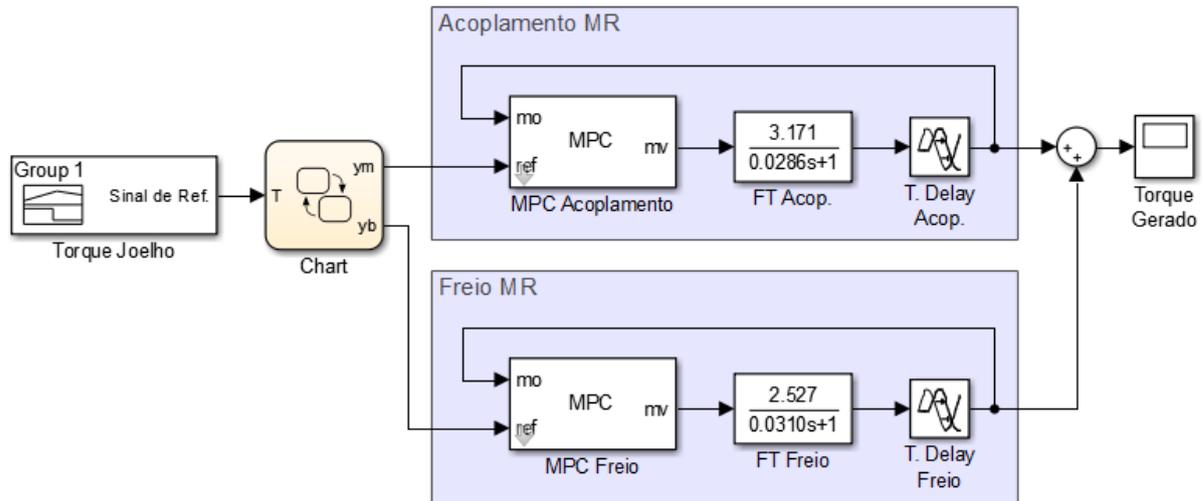
$$G_c(s) = \frac{3,171}{0,0286s + 1} e^{-8,3 \cdot 10^{-3}s} \quad (4.1)$$

$$G_b(s) = \frac{2,527}{0,0310s + 1} e^{-8,5 \cdot 10^{-3}s} \quad (4.2)$$

Utilizando-se os modelos apresentados nas equações (4.1) e (4.2) e considerando-se que o objetivo é realizar o controle de torque do joelho de forma preditiva, implementou-se

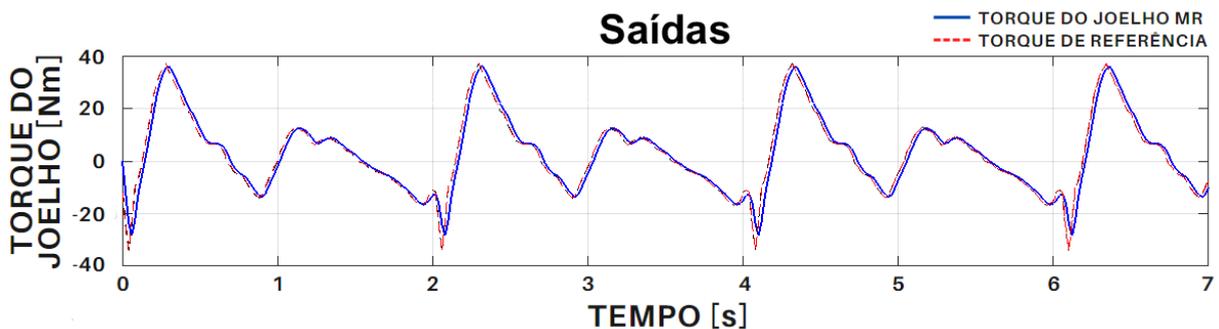
uma estrutura de simulação conforme a exibida na Figura 17. Neste diagrama tem-se o modelo do joelho, como retratado na Figura 15, controlado pela estrutura de controle descrita anteriormente. O bloco MPC, a partir do modelo preditor, dos horizontes de predição e controle e das ponderações, resolve o problema de otimização, minimizando a função de custo J (2.1).

Figura 17 – Diagrama de blocos do controle de torque do joelho MR.



A simulação foi realizada considerando um ciclo de marcha de 2 segundos, condizente com o tempo de um ciclo em uma caminhada. Os parâmetros utilizados no controlador preditivo, obtidos de maneira empírica, foram: $\Delta t = 0,2$ segundos, horizonte de predição $P = 30$, horizonte de controle $M = 15$ e as ponderações de entrada e saída $\lambda = 1$ e $\gamma = 10$, respectivamente, conforme a equação (2.1). O resultado da simulação para 3 ciclos de marcha é apresentado na Figura 18, onde a curva que representa a resposta de saída para o torque do joelho MR (em azul) é comparada à curva do torque de referência (em vermelho).

Figura 18 – Torque de referência do joelho e torque do teste.



O erro quadrático médio (EQM) entre o sinal de referência e o sinal de saída, os quais são dados em $N.m$, é apresentado na Tabela 1.

Tabela 1 – Erro Quadrático Médio.

EQM
$6,0536 \cdot 10^{-4}$

Com base na análise dos dados obtidos, percebe-se que o método proposto funciona corretamente. Chega-se à mesma conclusão tanto a partir da percepção de que na Figura 18 o sinal referencial foi rastreado com boa precisão, quanto por meio da análise do valor do EQM na Tabela 1. Comparando-se este valor ao EQM que se obtém a partir da curva apresentada por Andrade, R. M. (2018), é possível verificar que o sistema de controle preditivo funciona melhor que o sistema de controle proporcional-integral (PI) apresentado no trabalho citado, uma vez que o erro a que se chega com o uso do controlador PI é igual a 1,4746. Além disso, pode-se apontar outra vantagem: o comportamento do ciclo de marcha com uso da metodologia de controle preditivo numa prótese tende a aproximar melhor à marcha de uma pessoa saudável, uma vez que o corpo humano trabalha suas ações de forma antecipatória.

4.3 Sistema de Rastreamento de Posição

Tendo em vista o desenvolvimento de um modelo de prótese transfemural ativa, vê-se que somente garantir o controle de torque é insuficiente. Para o correto funcionamento da prótese faz-se também necessário um controle de posição angular – e, conseqüentemente, da velocidade angular –, de forma a satisfazer os requisitos do problema (ANDRADE, R. M., 2018).

Por controle de posição pode-se entender o controle da posição da perna tomando como base o ângulo do joelho em cada instante do ciclo, uma vez que o movimento é controlado pela própria pessoa, de acordo com a posição da coxa.

Na literatura as fases do ciclo de marcha, descritas na Seção 1, geralmente são apresentadas em termos dos ângulos do joelho (KAPTI; YUCENUR, 2006; FITE et al., 2007; MARTINEZ-VILLALPANDO; HERR, 2009), joelho e quadril (ASTEPHEN et al., 2008; GENG et al., 2010), joelho e tornozelo (SUP; VAROL; GOLDFARB, 2011), e uma combinação dos três (ANDRADE, L. M., 2002; MCMILLAN et al., 2010; SASAKI; NEPTUNE, 2010; NEPTUNE; MCGOWAN, 2011; MILLER; BRANDON; DELUZIO, 2013; PRADA, 2014). Pensando na circunstância concreta deste estudo, o ângulo do tornozelo é fixo com a utilização da prótese; além disso, pela maior complexidade em rastrear o ângulo do quadril, é mais viável que se rastreie o ângulo da coxa para correlacioná-lo ao ângulo do joelho.

Dessa forma, viu-se a necessidade da realização do rastreamento da posição angular não só da coxa, mas também da perna de uma pessoa com marcha normal, sendo possível

chegar à posição angular do joelho através de manipulação matemática destas informações. Para um paciente amputado transfemural com prótese, um referencial do movimento da coxa torna-se importante uma vez que o movimento da perna é resposta ao movimento da coxa, segundo uma curva de referência a qual o joelho precisa seguir. Comparando-se as curvas obtidas às apresentadas na literatura, assegura-se a correta descrição do movimento da coxa e da perna. As curvas da coxa e do joelho servirão, posteriormente, como referência de entrada para o sistema de controle e como saída estimada – que deve ser garantida para que a resposta da perna possibilite a marcha do paciente –, respectivamente.

4.3.1 Modelo

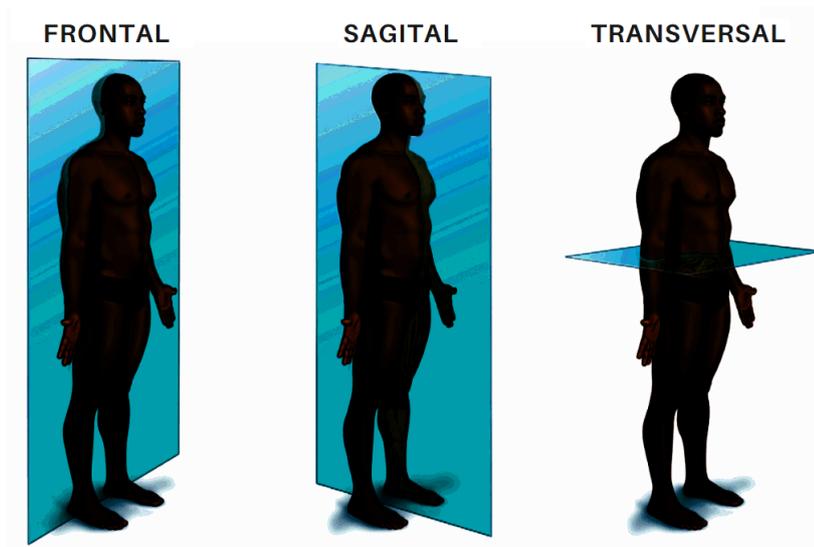
Diversos são os trabalhos que apresentam as curvas do ângulo do joelho durante o ciclo de marcha (ANDRADE, L. M., 2002; KAPTI; YUCENUR, 2006; FITE et al., 2007; ASTEPHEN et al., 2008; MARTINEZ-VILLALPANDO; HERR, 2009; GENG et al., 2010; MCMILLAN et al., 2010; SASAKI; NEPTUNE, 2010; SUP; VAROL; GOLDFARB, 2011; NEPTUNE; MCGOWAN, 2011; INOUE et al., 2013; MILLER; BRANDON; DELUZIO, 2013; FAVRE; ERHART-HLEDIK; ANDRIACCHI, 2014; PRADA, 2014). Entretanto, em apenas dois deles o movimento da coxa foi descrito (INOUE et al., 2013; FAVRE; ERHART-HLEDIK; ANDRIACCHI, 2014) e não se encontrou uma representação da curva referente ao movimento da perna. À vista disso, com o presente trabalho pretende-se colaborar para que a lacuna identificada seja preenchida. Outro fator que foi preponderante para que neste estudo se rastreasse os movimentos da coxa e da perna foi a necessidade de um modelo personalizado.

Os movimentos do corpo são definidos segundo uma posição referencial universal, chamada posição anatômica, e observados em três eixos: frontal (ou coronal), sagital e transversal (ou transverso), demonstrados na Figura 19. Como o modelo aqui proposto tem por finalidade maior a obtenção de curvas que representem o ângulo do joelho durante a marcha, abordou-se apenas os movimentos de flexão e extensão, descritos no plano sagital.

Embora existam recursos mais aprimorados para a realização da aquisição de dados, optou-se por fazer a coleta com auxílio de aparelhos celulares. Uma alternativa seria o uso de sensores eletromiográficos, que, através da aplicação de eletrodos, permitem a análise da atividade elétrica muscular e posterior avaliação da ativação dos músculos. Há diferentes formas de se empregar estes sensores para realizar a aquisição, além de diversos tipos possíveis de tratamento de dados (DUARTE et al., 2011). Outra possibilidade seria a construção de um sistema de câmeras e a utilização de marcadores nas pernas, para que, em seguida, se fizesse a triangulação das imagens e fosse possível analisar o movimento (PRADA, 2014).

Mesmo que outros artifícios forneçam, de forma eficaz, informações acerca do posicionamento da perna durante a marcha, decidiu-se pelos celulares uma vez que

Figura 19 – Planos anatômicos do corpo humano.



Fonte: Adaptada de Kobiraki et al. (2018).

a viabilidade da aplicação é maior. Além disso, avaliou-se que a presença de filtros internos poderia diminuir a necessidade de um extenso tratamento de dados e viu-se a vantajosa possibilidade de se trabalhar com o vetor gravidade – utilizado em vez da manipulação de dados fornecidos pelo acelerômetro e giroscópio. Pensou-se ainda que, devido a acessibilidade dos celulares, futuramente os próprios usuários possam efetuar coletas de dados e atualizá-los em um sistema embarcado, favorecendo o funcionamento do controle e posicionamento da prótese.

Assim, a fim de realizar a coleta de dados deste experimento foram utilizados dois celulares: um Motorola G5 *Plus* e um Asus Zenfone 5, que serão aqui tratados como *celular1* e *celular2*, nesta ordem. Para acessar os sensores presentes nos celulares utilizou-se o aplicativo *Sensorstream IMU+GPS* para Android, disponível gratuitamente na *PlayStore*. Tal aplicativo foi escolhido por ser de simples manuseio e permitir o compartilhamento de dados em tempo real por meio do protocolo UDP (*User Datagram Protocol*¹). Foi criada uma rede interna, cuja conexão permitiu somente o acesso dos dois celulares e do computador utilizado, como pode ser visto na Figura 20.

Foi desenvolvido um programa em linguagem *Python* no ambiente *Spyder* do *software* Anaconda, cuja função é estabelecer conexão com os celulares e receber os dados provenientes de cada um deles, salvando estas informações para posterior processamento. Os dados são arquivados em duas matrizes com r linhas e 17 colunas, cada uma; sendo o número de linhas referente à quantidade de amostras escolhido e o número de colunas relativo à quantidade de células necessárias para salvar os dados do tempo, acelerômetro, giroscópio, magnetômetro, vetor gravidade e seus identificadores (exceto para o tempo). Embora as informações do acelerômetro, giroscópio e magnetômetro não tenham utilidade

¹ Protocolo de Datagrama de Usuário

para o presente estudo, eles são obrigatoriamente enviados pelo aplicativo.

Com o intuito de assegurar que os dados da perna e da coxa sejam referentes ao mesmo instante de tempo, para que assim se possa atestar a veracidade do ângulo do joelho, prezou-se por uma perfeita sincronia entre as coletas de dados dos dois celulares. Para tal, fez-se o uso de *threads*. As *threads* permitem que a aplicação execute tarefas de forma assíncrona, ou seja, rotinas podem ser processadas simultânea e separadamente. Cada *thread* é responsável por capturar as informações de um aparelho e fazer a verificação do tamanho de seus vetores. Esta checagem é de suma importância para garantir que não haja insuficiência de dados para análise, comprometendo-a posteriormente.

O programa de aquisição de dados desenvolvido é responsável por chamar e iniciar as *threads*. Para asseverar a sincronicidade dos dados, um contador de tempo é acionado. Durante o processo de aquisição as *threads* – *thread1* e *thread2* – são responsáveis pela realização da leitura e armazenamento dos dados dos celulares, *celular1* e *celular2*, respectivamente.

É importante que alguns pontos sejam destacados:

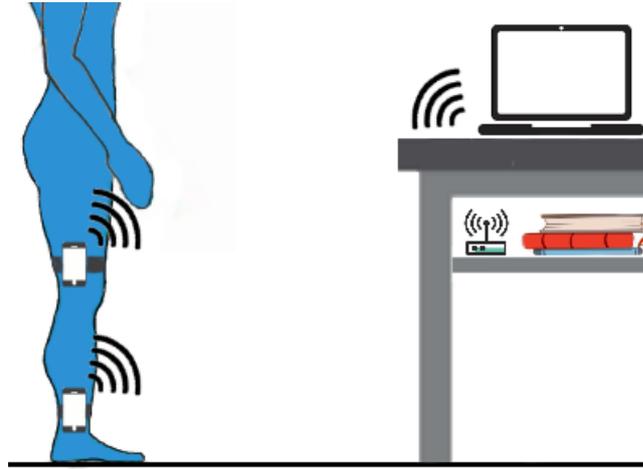
- Os dois celulares e o computador, no qual será executado o programa, devem estar conectados à mesma rede.
- Duas portas devem ser escolhidas para que sejam estabelecidas as conexões entre o computador e os celulares, uma porta para cada celular.
- No *template* do aplicativo deve ser inserido o endereço IP (*Internet Protocol*²) do computador, bem como o número da porta escolhido; além disso, a frequência do sensor é selecionada entre *slow*, *medium*, *fast* e *fastest*.
- As mesmas portas inseridas para os celulares *1* e *2* devem ser inseridas nas *threads 1* e *2*, respectivamente.
- O número da porta deve ser superior a 1024; números inferiores a este são reservados a atividades específicas.

Com a ajuda de braçadeiras porta-celular o *celular1* foi posicionado logo acima do joelho e o *celular2* foi instalado um pouco acima da canela, ambos na lateral externa da perna direita, como pode ser observado através da Figura 20. Tomou-se o devido cuidado para que os dois ficassem alinhados entre si no plano sagital e perpendiculares ao solo.

Estando ativado o fluxo de dados pelo *Sensorstream IMU+GPS* nos dois celulares, o programa destinado a realizar captação de dados pode ser acionado e as informações começam a ser capturadas até que sejam obtidas todas as r amostras. O número de amostras

² Protocolo da Internet

Figura 20 – Representação do modelo de testes.



escolhido deve ser suficiente para que se faça toda a aquisição durante a realização do ensaio.

Com os dados dos vetores da gravidade decompostos nos três eixos, conforme indicado na Figura 21, pode-se calcular o ângulo da coxa e da perna no plano sagital; com essa finalidade foi desenvolvido um programa no software *MATLAB*®. O programa tem por função acessar a matriz de tempo e as duas matrizes contendo os dados referentes às componentes dos vetores da aceleração da gravidade nos respectivos aparelhos celulares localizados na coxa e na perna, fazer a manipulação dos dados para obter o ângulo da coxa e da perna no plano sagital para cada amostra e, por fim, calcular o ângulo do joelho.

O ângulo no plano sagital é dado segundo a equação (4.3), onde g é a gravidade em m/s^2 , Gx é o valor da componente da aceleração da gravidade no eixo x e Gy é o valor da componente da aceleração gravidade no eixo y .

$$\gamma_s = \text{acos} \left(\frac{Gy}{g} \right) \frac{180}{\pi} Gx \quad (4.3)$$

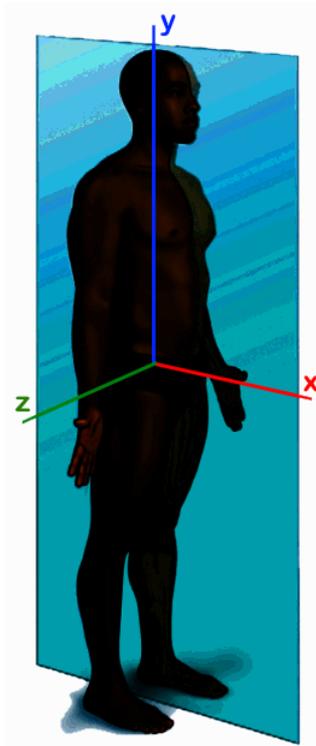
A referência -0° – é a normal, i.e., perpendicular ao solo. Um ângulo positivo da coxa é dado quando esta é projetada para frente, num movimento de flexão; do contrário, um ângulo negativo se dá com o movimento de extensão, como pode ser observado na subfigura (a) da Figura 22. Da mesma maneira ocorre para a perna, conforme a subfigura (b).

Após a obtenção dos ângulos da coxa e da perna no plano sagital para todas as r amostras, os resultados foram filtrados por um filtro FIR para que, por fim, se fizesse o cálculo do ângulo do joelho, conforme a equação:

$$\gamma_{\text{joelho}} = |\gamma_{\text{coxa}} - \gamma_{\text{perna}}| \quad (4.4)$$

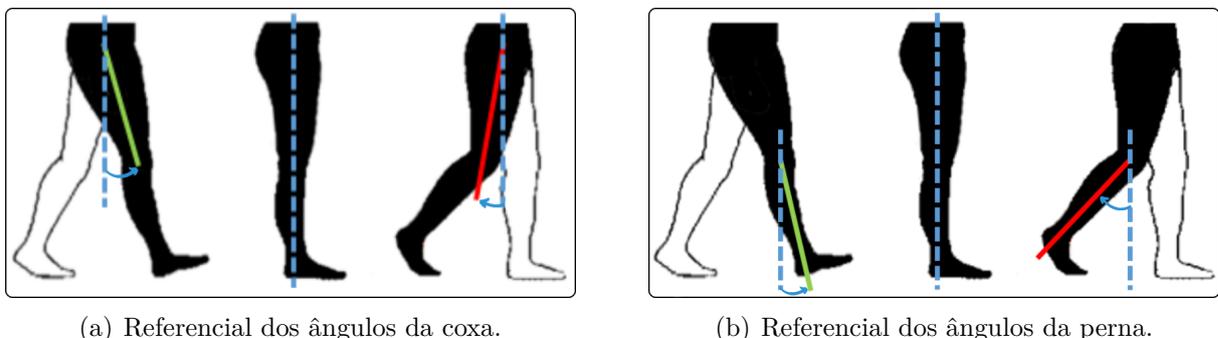
onde γ_{joelho} é o ângulo do joelho, γ_{coxa} é o ângulo da coxa e γ_{perna} é o ângulo da perna.

Figura 21 – Eixos no plano sagital.



Fonte: Adaptada de Kobiraki et al. (2018).

Figura 22 – Referenciais angulares da coxa e da perna.



(a) Referencial dos ângulos da coxa.

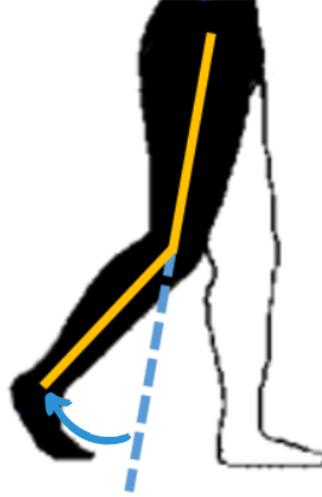
(b) Referencial dos ângulos da perna.

Com filtrações feitas de modo *offline* e tendo em vista o baixo volume de dados, valorizou-se o desempenho do procedimento; ademais, fazendo-se uso somente de dados passados, não considerando *feedback* para executar a filtração, optou-se por utilizar um filtro do tipo FIR causal. Os filtros FIR são não recursivos – ou seja, a saída é obtida apenas em função do sinal de entrada – e priorizam o desempenho em detrimento da rapidez do processo; são de fase linear e sempre estáveis. Eles recebem ainda outros nomes, como filtros *all-zero* (pois não têm polos, apenas zeros), filtros *feedforward*, filtros de média móvel (*moving average*) e filtros transversais (OPPENHEIM; SCHAFER, 2009).

O ângulo do joelho dado pela equação (4.4) representa o quanto a perna está deslocada do referencial da coxa, sendo este deslocamento sempre positivo. A Figura 23

ilustra a referência utilizada para os ângulos do joelho.

Figura 23 – Referencial dos ângulos do joelho.



A partir daí a comparação entre os resultados obtidos e a vasta quantidade de informações disponibilizadas pelas fontes já citadas tornou-se possível.

4.3.2 Resultados

A filtragem dos ângulos da coxa e da perna no plano sagital foi realizada no *MATLAB*® por meio do comando *filter*, dado da forma $y = \text{filter}(B, A, x)$. Os dados do vetor de entrada x foram filtrados com o filtro descrito pelos vetores A e B , gerando o vetor de saída y de dados filtrados. Este filtro é uma implementação transposta da Forma Direta II da equação de diferenças (4.5), fazendo uso de uma função de transferência racional da forma (4.6). Os vetores A e B são formados, respectivamente, pelos coeficientes de denominador a e numerador b ; n_a é a ordem do filtro *feedback* e n_b é a ordem do filtro *feedforward*.

$$a(1)y(n) = b(1)x(n) + b(2)x(n-1) + \dots + b(n_b+1)x(n-n_b) + \\ - a(2)y(n-1) - \dots - a(n_a+1)y(n-n_a) \quad (4.5)$$

$$Y(z) = \frac{b(1) + b(2)z^{-1} + \dots + b(n_b+1)z^{-n_b}}{a(1) + a(2)z^{-1} + \dots + a(n_a+1)z^{-n_a}} X(z) \quad (4.6)$$

A equação (4.5) pode ser ainda representada por (4.7).

$$\sum_{k=0}^N a_k y(n-k) = \sum_{k=0}^M b_k x(n-k) \quad (4.7)$$

Como no presente caso não se faz uso de termos de *feedback*, $N = 0$, e assume-se $a_0 = 1$. Desse modo, a equação (4.7) reduz-se à forma (4.8).

$$y(n) = \sum_{k=0}^M b(k) x(n - k) \quad (4.8)$$

Para implementar o filtro FIR no *MATLAB*® fez-se necessário atribuir valores aos vetores $A = [1]$ e $B = [b_0, b_1, \dots, b_M]$. A ordem do filtro FIR, $M = 5$, foi selecionada de forma empírica levando-se em conta que quanto menor, mais rápida e menos eficiente a filtragem e, por outro lado, quanto mais elevada, maior a exigência computacional e maior o tempo gasto para se efetuar os cálculos; além disso, o excesso de filtragem pode não preservar a característica dos dados.

Os coeficientes foram escolhidos segundo a forma simples do filtro de média móvel: todos assumem o mesmo valor, calculado fazendo-se $\frac{1}{M}$. Este método foi escolhido uma vez que tal filtro apresenta bom desempenho no domínio do tempo e na redução de ruído branco (OPPENHEIM; SCHAFER, 2009). Assim, o vetor B é composto pelos coeficientes $b_0 = b_1 = b_2 = b_3 = b_4 = b_5 = \frac{1}{5}$.

Em virtude de os resultados obtidos terem sido satisfatórios com relação à filtragem – havendo atenuação do ruído, preservação do aspecto das curvas e possibilitando análise considerável – manteve-se a ordem filtro FIR e seus coeficientes conforme mencionados anteriormente. As curvas, já filtradas, que descrevem os ângulos da coxa e da perna estão representadas pelas Figuras 24, 25 e 26, provenientes das aquisições $J01$, $J02$ e $J06$, respectivamente.

Figura 24 – Resultado da aquisição J01.

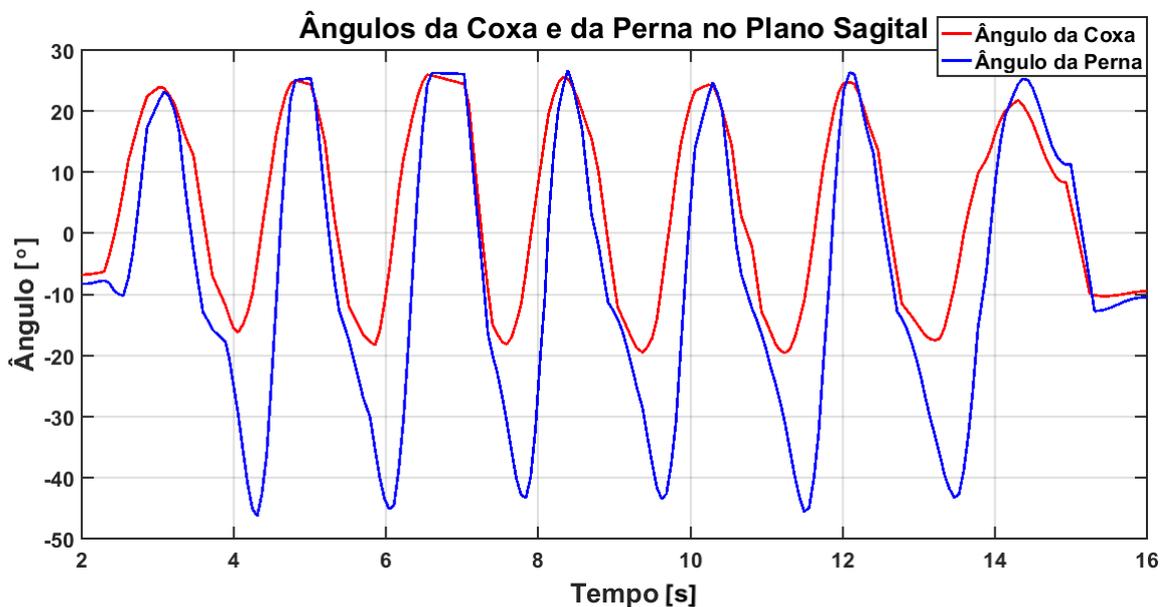


Figura 25 – Resultado da aquisição J02.

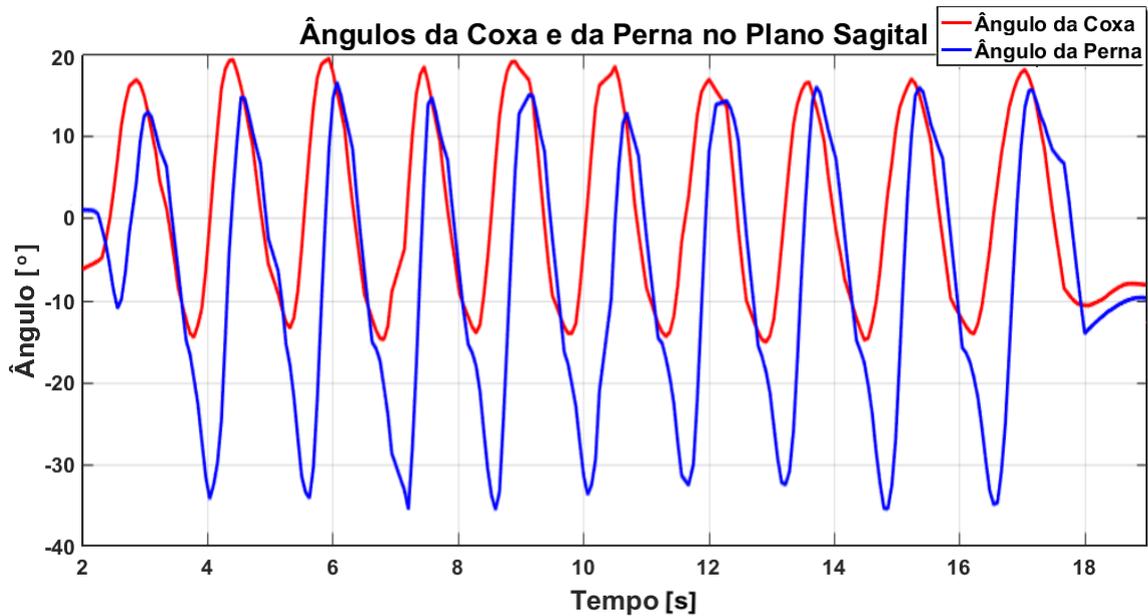
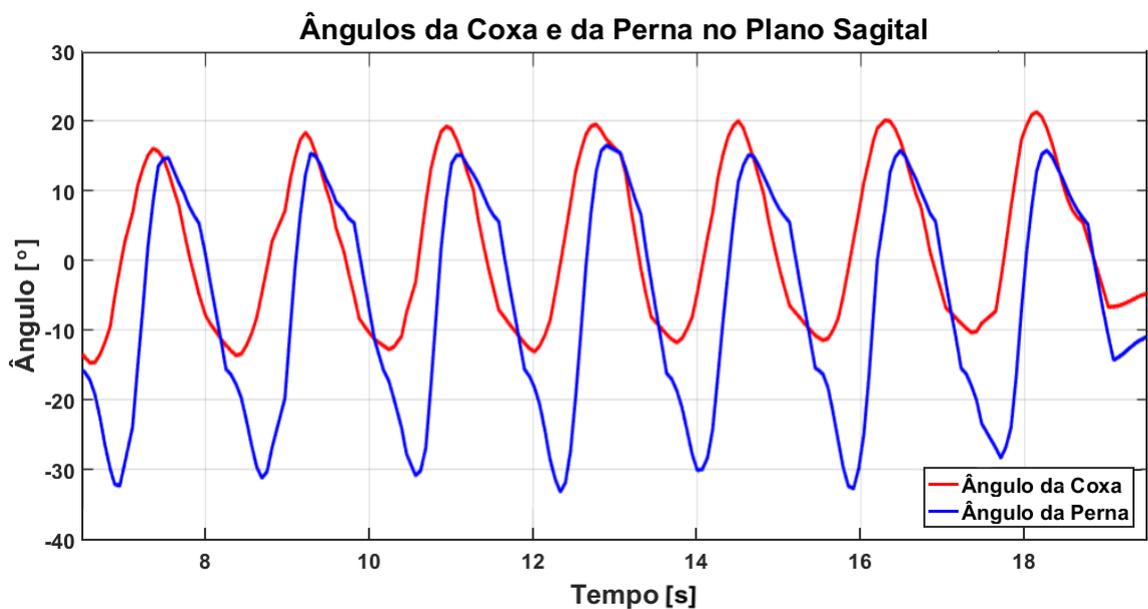


Figura 26 – Resultado da aquisição J06.



A partir dos resultados de filtragem fez-se, então, o cálculo do ângulo do joelho segundo a equação (4.4), cujas curvas são apresentadas nas Figuras 27, 28 e 29.

Enquanto a aquisição J01 refere-se ao movimento segundo uma passada de 75 cm, as aquisições J02 e J06 são resultantes de passadas de 50 cm – diferindo-se pela velocidade maior e menor da marcha, nesta ordem. Compreende-se, a partir de uma leitura dos gráficos, que em ciclos de passadas mais longas exige-se maior extensão e flexão da coxa e das pernas do que em ciclos de passadas curtas, o que é percebido visivelmente na marcha humana. Nas passadas mais longas a extensão da perna sempre acompanha a da coxa e o contato inicial acontece quando os dois ângulos atingem seus máximos. Nas

Figura 27 – Resultado do ângulo do joelho segundo a aquisição J01.

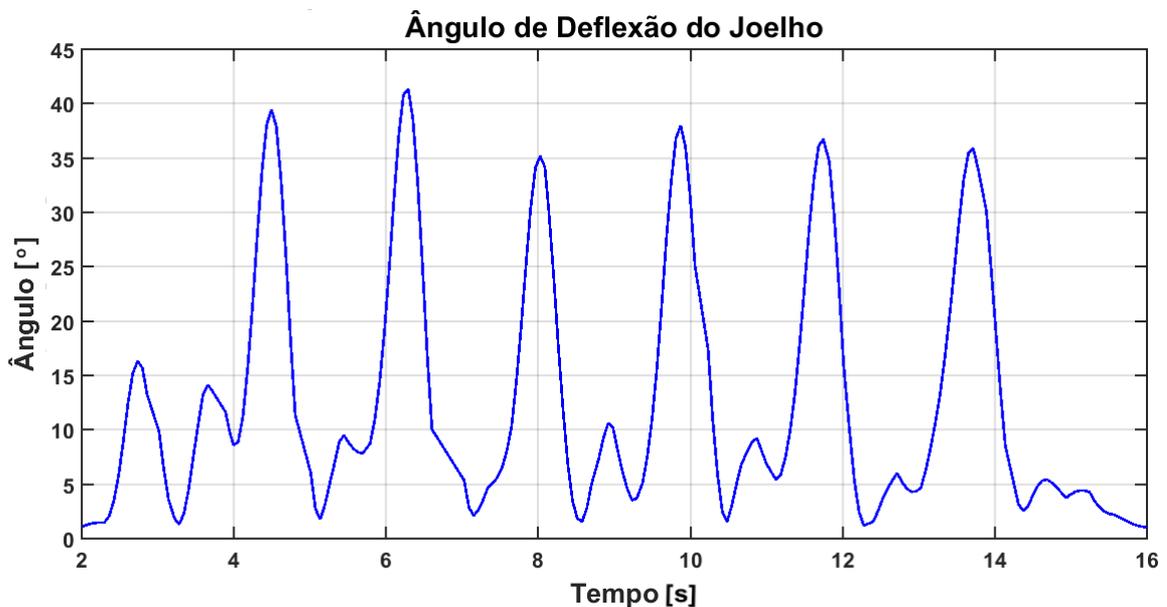
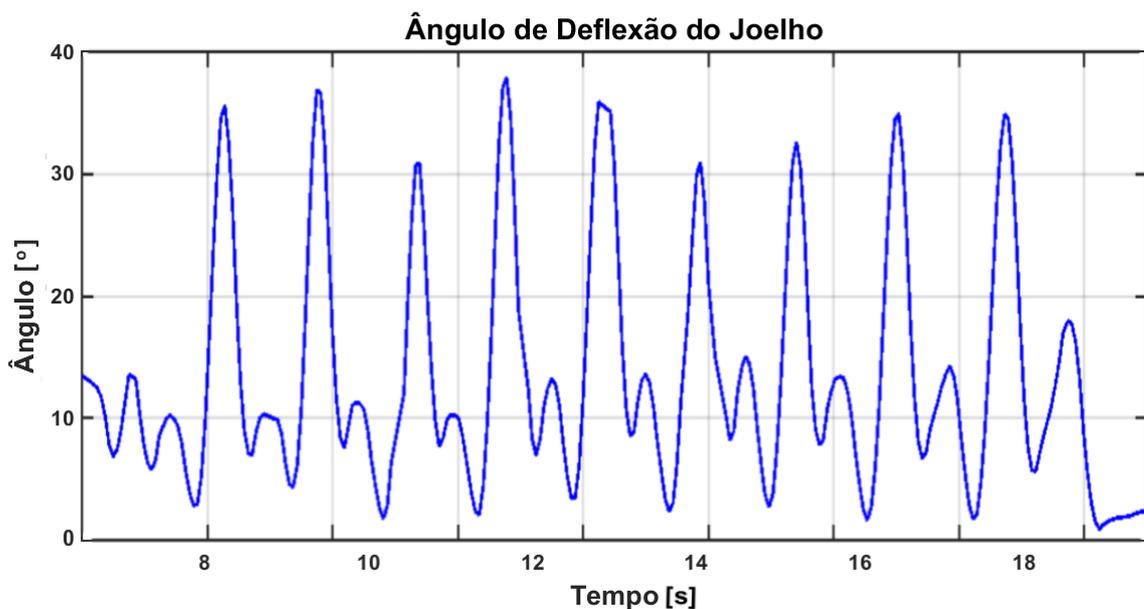


Figura 28 – Resultado do ângulo do joelho segundo a aquisição J02.

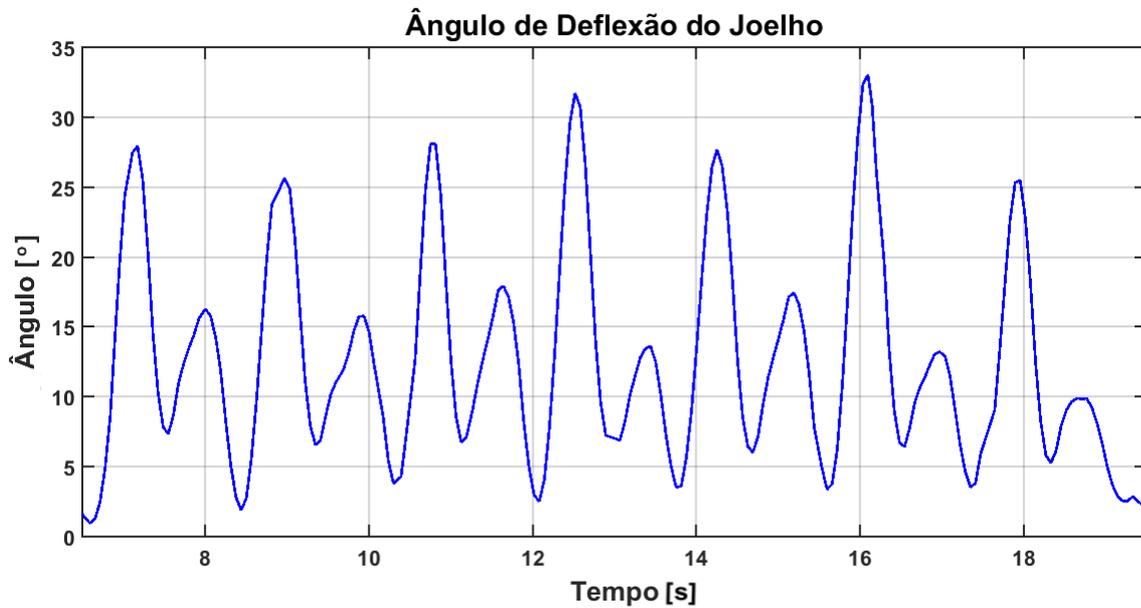


passadas curtas a curva da coxa parece sempre estar adiantada, e o contato inicial acontece quando a perna está em seu maior ângulo; ademais, o movimento de flexão da perna é tão menor que mal inicia-se a fase de balanço e a coxa já chega a 0° .

Por estas razões, se comparadas as curvas que descrevem os ângulos do joelho em passadas de 50 cm e 75 cm, elas parecem estar invertidas horizontalmente; no entanto, o ciclo sempre tem o formato de duas colinas, sendo a primeira menor e a segunda mais elevada.

Obtida a curva que descreve um ciclo normal da marcha segundo o ângulo do joelho no plano sagital, é importante validar os resultados comparando-os com outros modelos

Figura 29 – Resultado do ângulo do joelho segundo a aquisição J06.

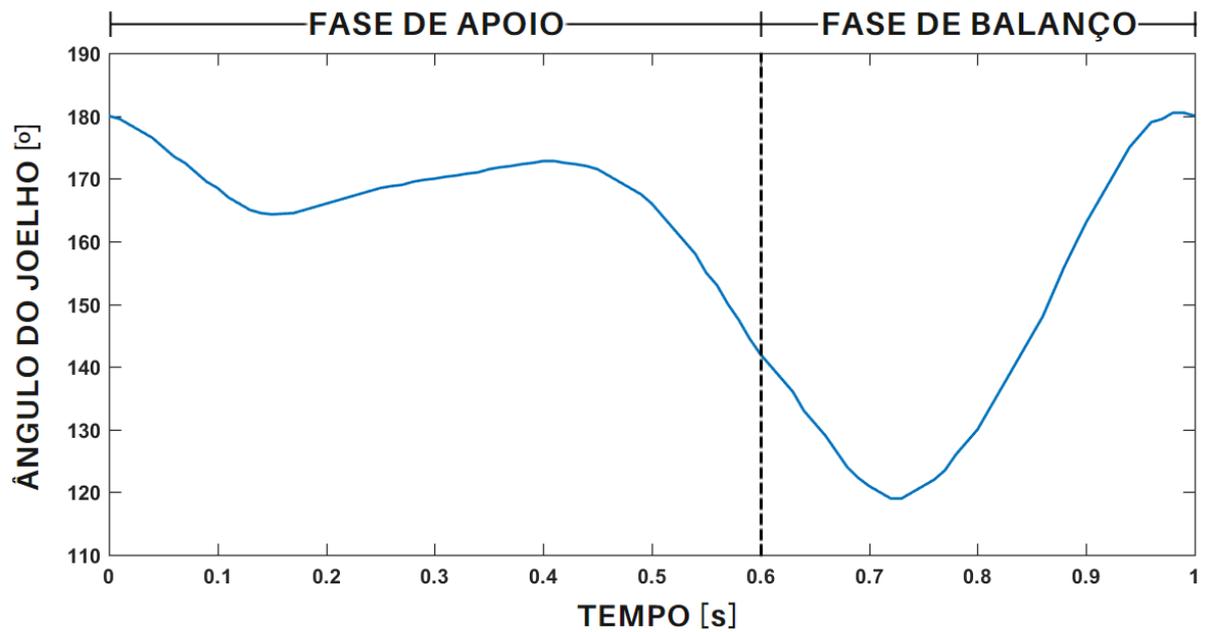


apontados na literatura. Kapti e Yucenur (2006), Neptune e McGowan (2011) e Sasaki e Neptune (2010) descrevem o movimento conforme a Figura 30 apresenta, enquanto Andrade, L. M. (2002), Astephen et al.(2008), Geng et al. (2010), Martinez-Villalpando e Herr (2009) e Miller, Brandon e Deluzio (2013) representam-no como na Figura 31. Muito embora as imagens sejam distintas, facilmente nota-se que elas estão apenas espelhadas verticalmente.

Considerando-se que coxa e perna formam um ângulo de 180° de abertura entre si, a primeira forma de representação (Figura 30) indica os ângulos entre suas partes posteriores durante o ciclo de marcha. A segunda forma (Figura 31) consiste na ilustração do complemento destes ângulos, ou seja, tomando-se o eixo da coxa como referência, mostra-se o quanto a perna está deslocada desse referencial enquanto o corpo é projetado para frente no decorrer do movimento. Assim sendo, pode-se dizer que os ângulos retratados pelas figuras são complementares.

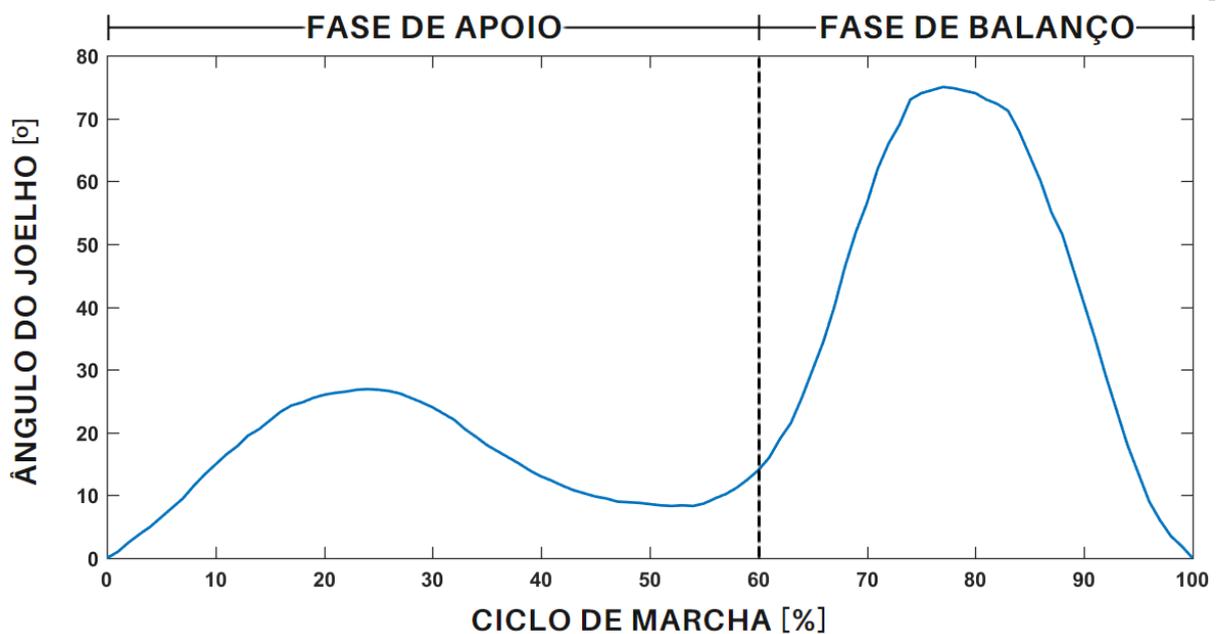
A fim de validar, finalmente, os resultados obtidos pela coleta de dados e elaboração matemática feitas até aqui neste trabalho, estes foram comparados aos modelos de referência literária. As variações angulares encontradas nas curvas provêm de diversos fatores, como a impossibilidade da manutenção de uma velocidade perfeitamente constante, as diferentes velocidades e amplitudes da passada exercidas em cada experimento retratado nas referências citadas acima, as próprias características físicas de cada indivíduo voluntário para coleta de dados, entre outros. Ainda que existam estas distinções quanto aos ângulos máximos e mínimos de cada ciclo e entre uma curva e outra, constata-se claramente a semelhança entre os movimentos representados neste trabalho e os descritos na literatura, uma vez que as curvas seguem uma característica padrão.

Figura 30 – Modelo de curva do ângulo do joelho proposto por Kapti e Yucenur.



Fonte: Adaptada de Kapti e Yucenur (2006).

Figura 31 – Modelo de curva do ângulo do joelho proposto por Geng et al.



Fonte: Adaptada de Geng et al.. (2010).

4.4 Rede Neural para Modelar a Correlação entre os Ângulos da Coxa e do Joelho

Entre os três padrões de marcha apresentados na seção anterior, escolheu-se o segundo – o qual será tratado por Padrão II e cujas curvas estão reproduzidas na Figura 28 – para dar continuidade ao estudo. A maior similaridade entre seus ciclos acarreta em uma marcha mais constante, favorecendo os resultados posteriores.

Os dados angulares extraídos do Padrão II foram, pois, utilizados para treinar diversas redes com diferentes combinações de camadas ocultas LSTM, GRU e *SimpleRNN*.

Em primeiro lugar, justifica-se a seleção destes três tipos de camadas uma vez que pertencem à família das redes recorrentes, ideais para o problema proposto. Além disso, embora sejam redes de simples configuração, com elas bons resultados já foram atingidos – como registrado pela literatura (BENGIO; SIMARD; FRASCONI, 1994; MIKOLOV et al., 2011; HASHIMOTO et al., 2013; CHUNG et al., 2014; FU; ZHANG; LI, 2016; PEDRYCZ; CHEN, 2019).

A implementação da metodologia proposta a partir da utilização das redes neurais recorrentes baseou-se no fornecimento de dados de entrada (ângulo da coxa) e dados pretendidos na saída (ângulo do joelho). O treinamento consistiu na seguinte aprendizagem: a cada vetor de entrada foi relacionado o respectivo vetor de saída, assim, as sinapses ponderadas assumiram valores de forma a permitir que tal correlação fosse atingida e um valor aproximado da saída alcançado. No fim, pode-se obter redes – com tantas camadas e neurônios quanto desejado – capazes de prever um sinal de saída, dado um sinal de entrada.

A escolha dos parâmetros de cada rede (número de neurônios, tipos e número de camadas) foi feita de maneira empírica e a partir dos resultados alcançados novos ajustes foram realizados, tendo sido mantidos aqueles que forneceram os resultados mais significativos. Estes são apresentados na subseção 4.4.2.

4.4.1 Modelo

Para a construção das redes neurais utilizou-se o *Tensorflow* em ambiente *Python*. O programa foi responsável por realizar a leitura dos dados angulares da coxa e do joelho provenientes do Padrão II (Figura 28) e, com eles, construir duas matrizes: uma formada por dados de entrada e outra por dados de saída.

Para cada 10 amostras de entrada a rede fez a previsão das próximas 5 saídas; isto porque pretendeu-se utilizar os dados de saída, posteriormente, em um sistema preditor. Ademais, a escolha por considerar as próximas 5 saídas se deu como forma de avaliar se a rede realmente estava fazendo uma previsão acurada dos resultados quanto à tendência do

movimento, reduzindo as chances de um acerto ocasional. As matrizes de entrada E e saída S foram, então, formadas por vetores de tamanho 10 e 5, nesta ordem, e estão retratadas, respectivamente, por (4.9) e (4.10), onde n é a primeira e p a última das amostras da coxa a serem utilizadas.

$$E = \begin{bmatrix} x_n & x_{n+1} & x_{n+2} & \cdots & x_{n+9} \\ x_{n+1} & x_{n+2} & x_{n+3} & \cdots & x_{n+10} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ x_{p-9} & x_{p-8} & x_{p-7} & \cdots & x_p \end{bmatrix} \quad (4.9)$$

$$S = \begin{bmatrix} y_{n+10} & y_{n+11} & y_{n+12} & y_{n+13} & y_{n+14} \\ y_{n+11} & y_{n+12} & y_{n+13} & y_{n+14} & y_{n+15} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ y_{p+1} & y_{p+2} & y_{p+3} & y_{p+4} & y_{p+5} \end{bmatrix} \quad (4.10)$$

Os dados matriciais foram divididos em 70% para treinamento e os 30% restantes para teste. Fornecido o *design* desejado da rede – suas características, como o número de neurônios, número de camadas e a customização de cada camada –, fez-se um treinamento utilizando os dados referentes à esta atividade. Em seguida, a rede foi testada com os dados destinados a esta função, prevendo-se a matriz de saída \check{S} (4.11), onde k é o primeiro termo relativo à primeira amostra dos dados de teste. Os termos desta matriz \check{S} foram comparados aos seus correspondentes em S , gerando-se o erro quadrático médio entre eles, ou seja, o erro existente entre os valores desejados e os atingidos.

$$\check{S} = \begin{bmatrix} \check{y}_k & \check{y}_{k+1} & \check{y}_{k+2} & \check{y}_{k+3} & \check{y}_{k+4} \\ \check{y}_{k+1} & \check{y}_{k+2} & \check{y}_{k+3} & \check{y}_{k+4} & \check{y}_{k+5} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ \check{y}_{p+1} & \check{y}_{p+2} & \check{y}_{p+3} & \check{y}_{p+4} & \check{y}_{p+5} \end{bmatrix} \quad (4.11)$$

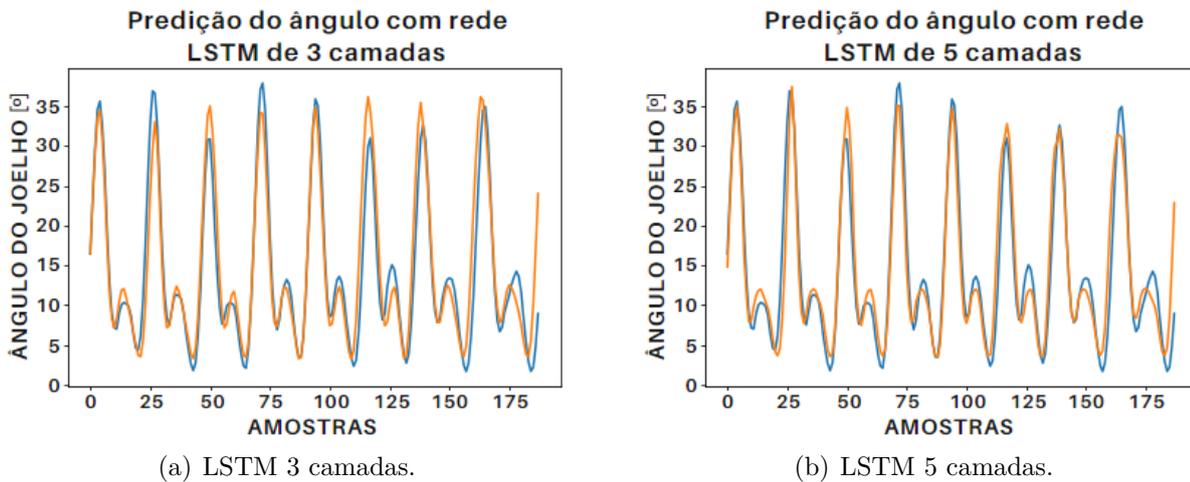
Com sucessivas alterações da quantidade de neurônios e épocas e demais especificações relativas a cada tipo de arquitetura, numerosas redes foram criadas com *designs* distintos tendo em vista a obtenção de modelos de melhor desempenho com erros quadráticos médios cada vez menores. As redes treinadas que apresentaram os menores erros foram, pois, selecionadas e testadas para todo o conjunto de amostras, tendo também o erro quadrático médio associado a elas.

A fim de não fundamentar a análise e a comparação entre as redes apenas pelos EQMs obtidos, foram plotadas curvas de forma a permitir uma análise visual. Tais curvas foram elaboradas a partir dos primeiros termos de cada vetor de saída que compõem S e \check{S} , ou seja, representou-se visualmente a primeira coluna da matriz S juntamente à primeira coluna da matriz \check{S} . Dessarte, avaliou-se o ângulo do joelho segundo a saída imediata a cada entrada, tendo como base a saída esperada para todos os ciclos de marcha descritos no movimento.

4.4.2 Resultados

Partindo do pressuposto de que as camadas LSTM seriam ideais para tratar o problema, uma vez que são capacitadas para modelar informações de sequência e esquecer dados dispensáveis, iniciou-se o treinamento a partir delas.

Figura 32 – Curvas dos ângulos do joelho previstas por uma rede LSTM 3 camadas e uma rede LSTM 5 camadas.



Como o modelo não é tão complexo e exigente, partiu-se de estruturas de treinos com três camadas. Entre todos os ensaios feitos, o melhor resultado foi atingido com 20 neurônios em cada camada e 400 épocas de treinamento, cuja saída para todo o conjunto de amostras é indicada pela subfigura (a) da Figura 32. Nesta subfigura (a) é vista em azul a curva resultante da operação matemática (4.4), feita a partir da coleta de dados, e em laranja a primeira coluna da matriz de saída gerada pela rede; o erro quadrático médio associado à rede é igual a 2,935, sendo os ângulos dados em graus. É importante ressaltar que para as figuras subsequentes relativas às saídas de rede, tem-se que estas curvas são plotadas com base nos dados da primeira coluna de \check{S} para todo o banco de amostras.

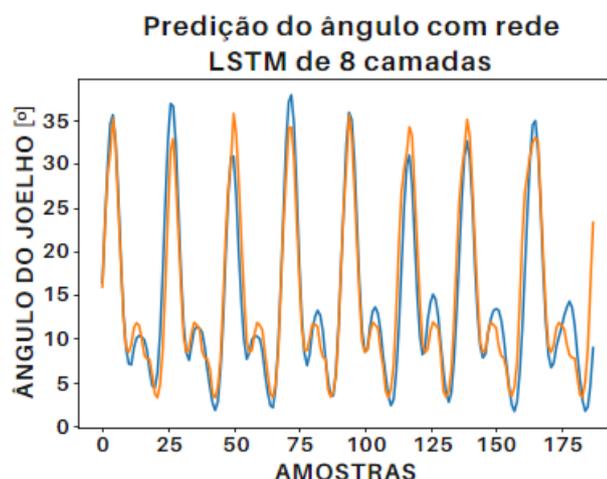
Analisando as duas curvas percebe-se que a rede foi capaz de fornecer dados de saída próximos ao que se esperava, atingindo um resultado que exprime seguramente o movimento o qual a curva azul representa. No entanto, visando uma melhor performance, aumentou-se o número de camadas para cinco, sendo a melhor saída representada pela subfigura (b) da Figura 32, conseguida com uso de 81 neurônios em cada camada e 375 épocas de treinamento.

Nota-se que na subfigura (b) a curva laranja aproximou-se ligeiramente da azul, apontando um melhor desempenho dessa nova rede se comparada à anterior. O erro quadrático médio relativo a esta rede é 2,647, pouco abaixo do primeiro, acordando com o que se pode observar através do gráfico.

Buscando resultados ainda melhores novas redes foram treinadas, agora com oito

camadas. A mais razoável saída, obtida com uma rede de 60 neurônios em cada camada e 400 épocas, é apresentada por meio da Figura 33. O erro quadrático médio relacionado à rede é 2,688.

Figura 33 – Curva do ângulo do joelho prevista por uma rede LSTM 8 camadas.



Com base na curva e no erro gerados, observou-se que com o uso de uma rede com oito camadas LSTM não foram obtidos melhores resultados, havendo, inclusive, leve queda de desempenho, o que indica o início de uma saturação. Além de o erro ter crescido ligeiramente, o indício da saturação é percebido principalmente pelas pequenas não-linearidades da curva laranja em pontos importantes do ciclo, o que na prática poderia comprometer o movimento da perna e a caminhada do paciente.

Desse modo, tomou-se como referência a rede com cinco camadas LSTM treinada com 81 neurônios em cada camada.

É preciso ressaltar que a região mais importante do rastreamento é a inferior, quando ocorre, de fato, o movimento da passada. Como os pontos de inflexão superiores referem-se aos momentos em que a perna está na fase de balanço, subfase de balanço inicial, é indiferente que se atinja 30° ou 40°, desde que o movimento seja feito de forma correta e regular.

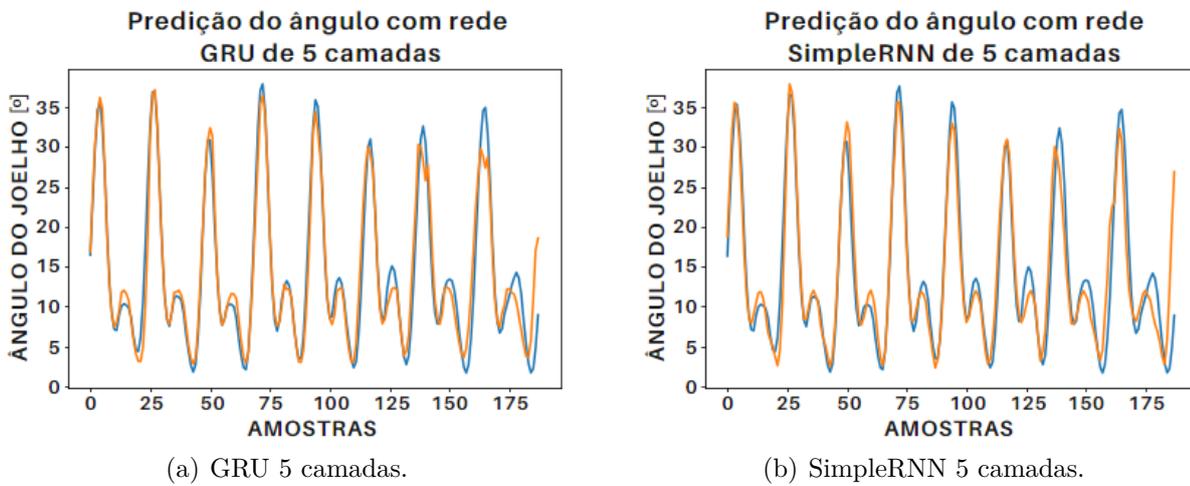
Com o objetivo de traçar uma comparação com os dois outros tipos de camadas mencionados anteriormente, foram treinadas mais redes fazendo uso do mesmo número de camadas – cinco.

A saída de uma rede com design de 5 camadas GRU e 79 neurônios por camada é mostrada na subfigura (a) da Figura 34, enquanto a subfigura (b) aponta a saída produzida por uma rede com a configuração de 5 camadas *SimpleRNN* e 79 neurônios em cada camada; ambas aplicadas a todo o conjunto de amostras. O erro quadrático médio associado a cada rede foi de:

$$EQM_{GRU5cam} = 1,858$$

$$EQM_{SimpleRNN5cam} = 2,549$$

Figura 34 – Curvas dos ângulos do joelho previstas por uma rede GRU 5 camadas e uma rede *SimpleRNN* 5 camadas.



Uma análise visual gráfica, no entanto, mostra que apesar de a rede com camadas GRU ter conseguido menor erro, ela não acompanha a curva com dados reais de forma tão eficiente. O comportamento da curva demonstra que na prática o modelo não conferiria sutileza ao movimento da perna durante a subfase de balanço inicial nos últimos dois ciclos.

Também o erro associado à rede treinada com camadas do tipo *SimpleRNN* é inferior ao relativo à rede com LSTM, mas novamente a curva apresenta algumas sinuosidades – que bastante tímidas, talvez não sejam capazes de comprometer o movimento do paciente.

Tendo em vista a garantia do melhor desempenho possível do sistema selecionou-se a rede LSTM de 5 camadas, cuja performance foi superior entre as redes testadas, e sua saída foi utilizada como entrada para a próxima etapa do processo.

4.5 Controle de Posição via Técnicas de Controle Preditivo

Com o intuito de atender completamente aos requisitos definidos para o resolver o problema abordado neste trabalho, realizou-se, por fim, o controle de posição angular do sistema. Elaborado o modelo personalizado e treinada a rede recorrente, fez-se o controle de posição do sistema utilizando-se novamente técnicas de controle preditivo, conforme apresentado no Capítulo 2.

Os dados referentes à primeira coluna da saída da rede LSTM de 5 camadas foram usados como sinal de referência de entrada para a etapa final do estudo em questão. Ajustando-se os parâmetros do controlador e utilizada a função de transferência adequada, foi finalmente realizado o ensaio.

São aqui apresentados o modelo e o resultado atingido.

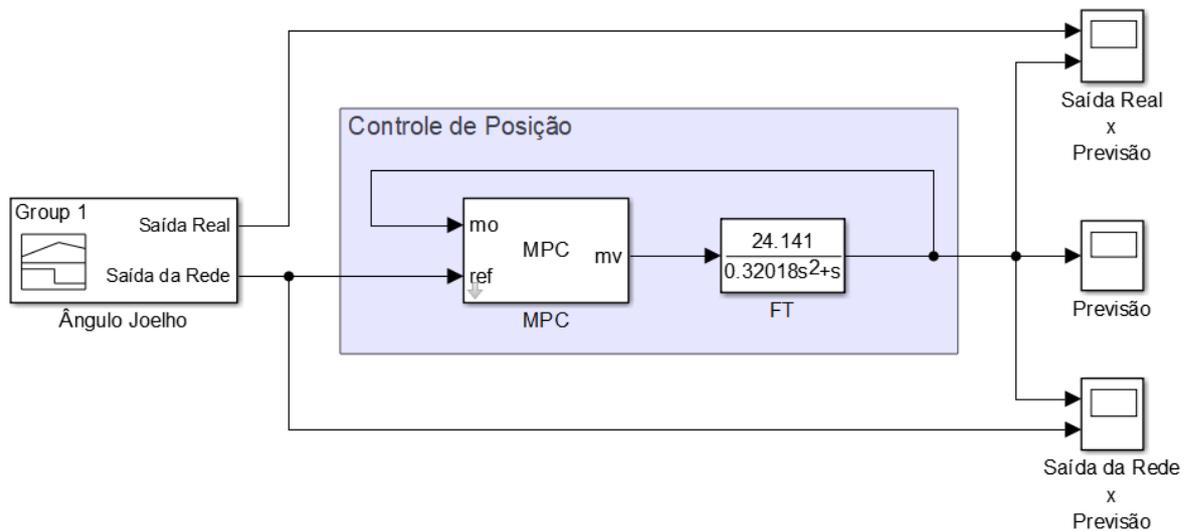
4.5.1 Modelo

A partir de experimentos realizados, Andrade, R. M. (2018) fornece a função de transferência que descreve o comportamento dinâmico da prótese MR com relação ao posicionamento angular do joelho. A FT é dada pela equação (4.12).

$$G(s) = \frac{24,141}{0,32018s^2 + s} \quad (4.12)$$

Utilizando a função de transferência (4.12) e levando em conta que o objetivo é controlar o sistema de forma preditiva, o diagrama de blocos que representa o sistema de controle de posição do joelho MR é apresentado na Figura 35.

Figura 35 – Diagrama de blocos do controle de posição do joelho MR.



4.5.2 Resultados

A simulação foi feita considerando os seguintes parâmetros, obtidos de forma empírica: $\Delta t = 0,05$ segundos, horizonte de predição $P = 6$, horizonte de controle $M = 2$ e ponderações de entrada e saída com os valores $\lambda = 0,1$ e $\gamma = 1$, respectivamente. O resultado da simulação preditiva para 8 ciclos de marcha é dado pela curva \hat{S} , retratada nas Figuras 36 e 37.

Na Figura 36 são apresentados os resultados comparativos entre os dados de referência do sistema preditivo – ou seja, a saída \check{S} da rede recorrente LSTM de 5 camadas – e a saída \hat{S} do sistema de controle de posicionamento. Já na Figura 37 comparou-se esta mesma saída \hat{S} à curva plotada com valores angulares referentes ao Padrão II, representado pela Figura 28, oriundos da primeira coluna da matriz S .

Figura 36 – Curvas do ângulo do joelho segundo a referência do sistema de controle de posicionamento e a saída \hat{S} do sistema de controle de posicionamento.

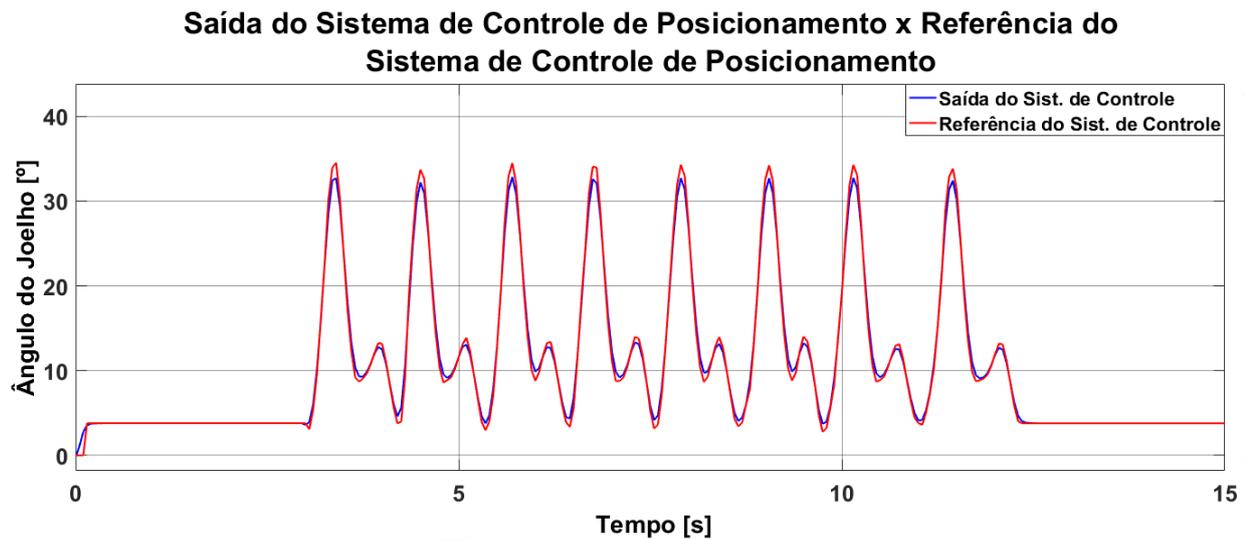
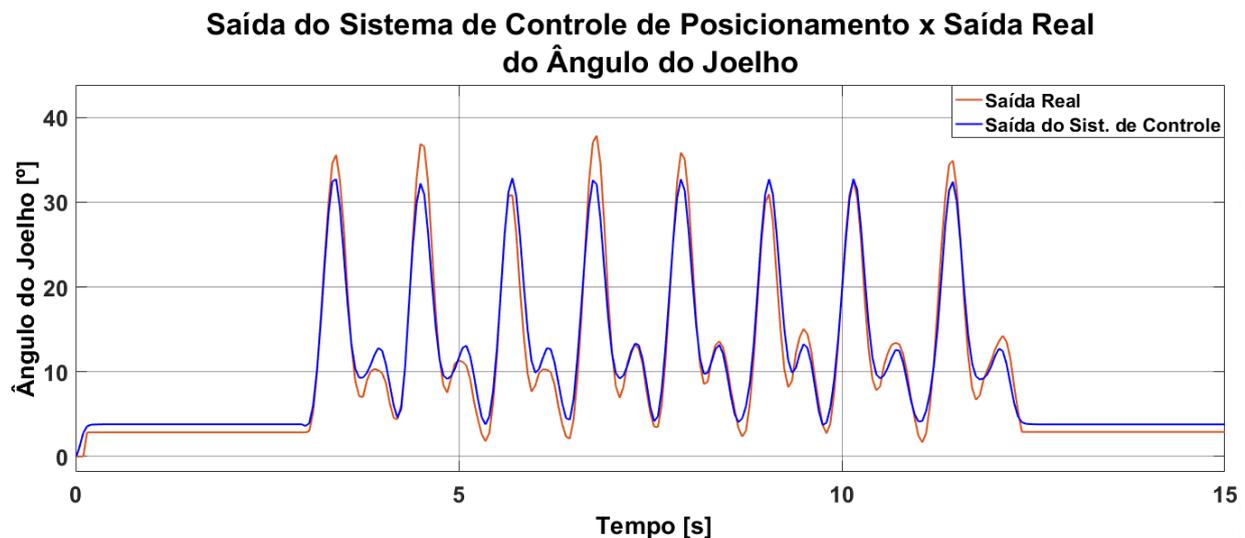


Figura 37 – Curvas do ângulo do joelho referentes ao Padrão de Marcha II e à saída \hat{S} do sistema de controle de posicionamento.



Graficamente é possível perceber que o resultado previsto pelo sistema de controle de posicionamento, traduzido pela curva \hat{S} , muito se aproxima à sua curva de referência, que é a saída imediata da rede LSTM de 5 camadas.

Quando a saída \hat{S} é, porém, comparada aos dados de referência obtidos de uma marcha real, vê-se que ela acompanha a curva do ângulo do movimento praticado pelo joelho; além disso, as inflexões de ambas as curvas acontecem em instantes de tempo muito próximos, comprovando a eficiência do método. No entanto, os pontos de inflexão de \hat{S} assumem valores mais centrais e homogêneos durante a marcha, evidenciando um pequeno erro na previsão do sistema.

4.6 Sistema de Controle Geral

Apoiando-se nas seções precedentes e cumpridas as exigências até aqui impostas pelo problema proposto, garantiu-se o torque necessário durante todo o ciclo de marcha e o posicionamento ideal da perna a partir do controle do joelho magneto-reológico.

Os sistemas de controle de torque e de posição funcionam concomitantemente e compassados, compondo um sistema de controle geral. Este, quando implementado em uma prótese ativa, assegura ao usuário uma marcha um tanto quanto satisfatória.

4.7 Considerações Finais

O controle do torque do joelho MR foi atingido fazendo-se uso das técnicas de controle preditivo, que demonstrou ser vantajosa para tal tipo de aplicação. Ensaios mostraram que a metodologia proposta para a execução deste primeiro sistema de controle é factível.

Para a elaboração de um sistema de controle de posicionamento foi necessária a prévia coleta de dados de posição de um membro inferior de uma pessoa saudável e sem problemas motores e, partir deles, a elaboração de um modelo customizado para tratar pacientes amputados transfemorais no desenvolvimento de uma prótese.

Partindo dos dados auferidos deste modelo personalizado, foram construídas diferentes combinações de redes recorrentes LSTM, GRU e *SimpleRNN* visando correlacionar os dados da coxa (entrada) aos do joelho (saída). Depois de as melhores redes terem sido testadas para todo o conjunto de dados, foi selecionada a que melhor conseguiu executar a correlação. Sua saída foi utilizada como referência no sistema de controle de posicionamento, cujo resultado demonstrou a viabilidade da aplicação de tal sistema.

Dessa maneira, a implementação, em trabalhos futuros, de um sistema geral embarcado se manifesta favorável para que, com testes práticos, se possa validar sua utilização.

Parte III

Parte Final

5 Conclusões e Trabalhos Futuros

Conclusões

Considerando as inúmeras dificuldades enfrentadas por pessoas com deficiências físicas com patologias motoras, pesquisadores nessa área procuram desenvolver novas tecnologias que favoreçam a ampliação da qualidade de vida destes pacientes. Sabendo que a maior parte das amputações de membros inferiores são amputações transfemurais e em vista dos diferentes tipos de próteses e de seus sistemas de controle, foi observado o espaço que pode ser preenchido pelo trabalho na área de próteses transfemurais combinando o uso de dispositivos de fluido magneto-reológico, redes recorrentes e controle preditivo.

A fim de rastrear a curva de torque de um joelho saudável durante o ciclo de marcha para controle de um joelho MR, o presente trabalho apresentou resultados de um ensaio utilizando técnicas de controle preditivo híbrido. Com este ensaio garante-se que o motor selecionado possui a capacidade de fornecimento do torque necessário para a realização o movimento da perna durante todo o processo da marcha. Ademais, devido à possibilidade de acoplamento e desacoplamento e pelo fato de a perna atuar em movimento livre no Modo de Operação III, o sistema ainda previne que torque seja desperdiçado.

Na etapa seguinte fez-se o rastreamento das posições da coxa e da perna de uma pessoa sem patologias motoras durante sucessivos ciclos de marcha. Foram utilizados aparelhos celulares para a realização da coleta de dados dos seus sensores. A partir dos dados coletados e da utilização de redes neurais, criou-se um modelo personalizado de marcha, relacionando os ângulos da coxa aos respectivos ângulos do joelho, ambos no plano sagital. Tendo representado visualmente, por meio de gráficos, todo o conjunto de informações angulares, foi possível analisar e comparar os dados com o que há disponível na literatura. Embora não haja similaridade estética entre eles – pois cada um representa a locomoção à sua maneira, variando com o tamanho da passada – conclui-se que as curvas obtidas descrevem, de fato, os movimentos da perna, do joelho e da coxa durante a marcha.

Para o treinamento da rede neural capaz de fazer a modelagem da correlação entre os ângulos da coxa e do joelho, selecionou-se o Padrão II de marcha como o que melhor descreveu o posicionamento do membro inferior durante os ciclos. Inúmeras redes com diferentes combinações de camadas ocultas foram treinadas utilizando como entrada os ângulos da coxa e como saída pretendida os ângulos do joelho. Avaliadas segundo o erro quadrático médio associado a cada uma delas, às melhores redes aplicou-se todo o conjunto de dados de entrada proveniente do Padrão II, de forma que, dado o ângulo da coxa, a rede gerasse sua saída tão próxima quanto possível da saída pretendida. Os gráficos

resultantes dos ensaios realizados demonstraram o alcance de soluções adequadas com mais de uma rede. A obtenção de resultados bastante próximos aos esperados não só comprova a eficiência do método escolhido para a realização da correlação, mas também o justifica. De forma a proporcionar maior refinamento ao modelo foi preferida a rede LSTM de 5 camadas; ademais, assegurou-se, por ensaio, que a saída obtida por esta rede corresponde ao que seria a resposta de um joelho normal.

Tal saída foi, pois, utilizada como sinal de referência para o sistema de controle de posicionamento do joelho MR mediante o uso de ferramentas do controle preditivo. Dos resultados experimentais concluiu-se que muito embora exista uma disparidade entre as curvas das saídas real e prevista, este erro é aceitável em virtude de poder conferir, na prática, maior estabilidade e sutileza ao movimento, uma vez que pequenas variações angulares durante a marcha são naturais. Por conseguinte, diz-se que o controle feito com os parâmetros selecionados se mostrou eficaz e aplicável ao uso do joelho objeto deste estudo.

Os sistemas de controle de torque e posicionamento, funcionando de forma simultânea e harmoniosa, constituem o sistema de controle geral do joelho magneto-reológico.

Conclui-se, finalmente, que com a metodologia empregada neste estudo foi possível chegar a uma solução prática que pode ser embarcada a uma prótese e vir a propiciar ao seu futuro usuário caminhar com uma marcha adequada e suficiente para as utilizações do dia-a-dia, favorecendo a conquista da qualidade de vida.

Trabalhos Futuros

Formado o sistema de controle geral, que une os sistemas de controle de torque e posição, e atestado seu funcionamento no ambiente de ensaio, pretende-se futuramente dar continuidade ao projeto embarcando este sistema em uma prótese real.

Neste sentido, pretende-se desenvolver um sistema mecânico que atenda aos pré-requisitos de funcionamento do projeto proposto e garanta mobilidade a um futuro usuário do sistema. Também vale destacar que este projeto pode ser utilizado no desenvolvimento de um sistema robótico bípede.

6 Trabalhos Publicados e em Andamento

Trabalho Publicado

Em 2019 foi publicado um artigo, intitulado *Control of a Mechanical Knee Based on Predictive Control Techniques*, apresentando os resultados alcançados com a utilização das técnicas de controle preditivo para efetuar o controle de torque do joelho magneto-reológico objeto de estudo desta dissertação. Este artigo, no mesmo ano da publicação, foi apresentado na *Canadian Conference of Electrical and Computer Engineering*.

Trabalho em Andamento

Um novo artigo está sendo elaborado a fim de expor, agora, a aplicação do sistema de controle de posicionamento do joelho MR, elaborado com base nas técnicas de controle preditivo e uso de redes neurais recorrentes. Será também explanado todo o processo de aquisição de dados aqui realizado e a construção, treinamento e comparação das redes LSTM, GRU e *SimpleRNN* testadas.

Referências

- ABBR, A. B. B. de R. *Relatório Anual*. 2018. Citado na página 3.
- AGNE, J. E. et al. Limbs amputation causes identification in the university hospital of santa maria. *Saúde*, v. 30, n. 1-2, p. 84–89, 2004. Citado 2 vezes nas páginas 2 e 3.
- AL-SHAYEA, Q. K. Artificial neural networks in medical diagnosis. *International Journal of Computer Science Issues*, Citeseer, v. 8, n. 2, p. 150–154, 2011. Citado na página 28.
- AMATO, F. et al. *Artificial neural networks in medical diagnosis*. [S.l.]: Elsevier, 2013. Citado 5 vezes nas páginas 23, 24, 26, 27 e 28.
- ANDRADE, L. M. *Análise de marcha: protocolo experimental a partir de variáveis cinemáticas e antropométricas*. Dissertação (Mestrado) — Universidade Estadual de Campinas, julho 2002. Citado 6 vezes nas páginas 11, 12, 14, 46, 47 e 56.
- ANDRADE, R. M. *Joelho Magneto-Reológico para Próteses Transfemorais: Prototipagem Digital, Fabricação e Identificação Experimental*. Dissertação (Mestrado) — Escola de Engenharia da Universidade Federal de Minas Gerais/UFMG, maio 2018. Citado 10 vezes nas páginas 3, 4, 5, 11, 14, 42, 43, 44, 46 e 63.
- ANDRADE, R. M. et al. Evaluating energy consumption of an active magnetorheological knee prosthesis. In: IEEE. *2019 19th International Conference on Advanced Robotics (ICAR)*. [S.l.], 2019. p. 75–80. Citado na página 5.
- ARQUITETURA de Redes Neurais Gated Recurrent Unit (GRU). 20–. Acesso em: 15 de maio de 2020. Disponível em: <<http://deeplearningbook.com.br/arquitetura-de-redes-neurais-gated-recurrent-unit-gru/>>. Citado na página 36.
- ASHTIANI, M.; HASHEMABADI, S.; GHAFFARI, A. A review on the magnetorheological fluid preparation and stabilization. *Journal of Magnetism and Magnetic Materials*, v. 374, p. 716–730, 2015. Citado na página 4.
- ASTEPHEN, J. L. et al. Biomechanical changes at the hip, knee, and ankle joints during gait are associated with knee osteoarthritis severity. *Journal of orthopaedic research*, Wiley Online Library, v. 26, n. 3, p. 332–341, 2008. Citado 3 vezes nas páginas 46, 47 e 56.
- BABS, T. *The Mathematics of Neural Networks*. 2018. Acesso em: 14 de maio de 2020. Disponível em: <<https://medium.com/coinmonks/the-mathematics-of-neural-network-60a112dd3e05>>. Citado na página 27.
- BARWAD, A.; DEY, P.; SUSHEILIA, S. Artificial neural network in diagnosis of metastatic carcinoma in effusion cytology. *Cytometry Part B: Clinical Cytometry*, Wiley Online Library, v. 82, n. 2, p. 107–111, 2012. Citado na página 28.
- BEMPORAD, A.; MORARI, M. Control of systems integrating logic, dynamics, and constraints. *Automatica*, Elsevier, v. 35, n. 3, p. 407–427, 1999. Citado 4 vezes nas páginas 18, 21, 22 e 43.

- BENGIO, Y.; SIMARD, P.; FRASCONI, P. Learning long-term dependencies with gradient descent is difficult. *IEEE transactions on neural networks*, IEEE, v. 5, n. 2, p. 157–166, 1994. Citado 3 vezes nas páginas 32, 33 e 58.
- BRAVO, C. O. A.; NORMEY-RICO, J. E. Controle de plantas não lineares utilizando control preditivo linear baseado em modelos locais. *Sba: Controle & Automação Sociedade Brasileira de Automatica*, SciELO Brasil, v. 20, n. 4, p. 465–481, 2009. Citado 2 vezes nas páginas 18 e 21.
- BRITZ, D. *Recurrent Neural Networks Tutorial, Part 1 – Introduction to RNNs*. 2015. Acesso em: 14 de maio de 2020. Disponível em: <<http://www.wildml.com/2015/09/recurrent-neural-networks-tutorial-part-1-introduction-to-rnns/>>. Citado na página 29.
- CAMACHO, E. F.; ALBA, C. B. *Model predictive control*. [S.l.]: Springer Science & Business Media, 2013. Citado 4 vezes nas páginas 4, 5, 20 e 43.
- CANETE, J. F. de; GONZALEZ-PEREZ, S.; RAMOS-DIAZ, J. Artificial neural networks for closed loop control of in silico and ad hoc type 1 diabetes. *Computer methods and programs in biomedicine*, Elsevier, v. 106, n. 1, p. 55–66, 2012. Citado na página 28.
- CANTORANI, J. R. H. et al. A dimensão da deficiência e o olhar a respeito das pessoas com deficiência a partir dos recenseamentos no brasil. *Revista Brasileira de Educação Especial*, SciELO Brasil, v. 21, n. 1, p. 159–176, 2015. Citado 2 vezes nas páginas 1 e 2.
- CHAGAS, A. M. d. R.; VIOTTI, R. B. Retrato da pessoa com deficiência no brasil segundo o censo de 1991. Instituto de Pesquisa Econômica Aplicada (Ipea), 2003. Citado 2 vezes nas páginas 1 e 2.
- CHAMBERS, H. G.; SUTHERLAND, D. H. A practical guide to gait analysis. *JAAOS-Journal of the American Academy of Orthopaedic Surgeons*, LWW, v. 10, n. 3, p. 222–231, 2002. Citado na página 12.
- CHAMLIAN, T. et al. Epidemiological profile of lower limb amputees patients assisted at the lar escola são francisco between 2006 and 2012. *Acta Fisiatr*, v. 20, n. 4, p. 219–23, 2013. Citado 2 vezes nas páginas 2 e 3.
- CHEN, J.; LIAO, W. Design, testing and control of a magnetorheological actuator for assistive knee braces. *Smart Materials and Structures*, IOP Publishing, v. 19, n. 3, p. 035029, 2010. Citado na página 5.
- CHO, K. et al. Learning phrase representations using rnn encoder-decoder for statistical machine translation. *arXiv preprint arXiv:1406.1078*, 2014. Citado na página 35.
- CHUNG, J. et al. Empirical evaluation of gated recurrent neural networks on sequence modeling. *arXiv preprint arXiv:1412.3555*, 2014. Citado na página 58.
- COLMENARES, W. et al. Mld systems: modeling and control. experience with a pilot process. In: IEEE. *Proceedings of the 2001 IEEE International Conference on Control Applications (CCA '01)(Cat. No. 01CH37204)*. [S.l.], 2001. p. 618–625. Citado 2 vezes nas páginas 21 e 22.
- CONCEITOS, E. *Neurônio - Conceito, o que é, Significado*. c2019. Acesso em: 17 de out. de 2019. Disponível em: <<https://conceitos.com/neuronio/>>. Citado na página 24.

- CUTLER, C. R.; RAMAKER, B. L. Dynamic matrix control - a computer control algorithm. In: . [S.l.: s.n.], 1979. Citado na página 17.
- DUARTE, M. M. et al. Revisão sobre materiais e métodos: eletromiografia. 2011. Citado na página 47.
- EKICI, B. B.; AKSOY, U. T. Prediction of building energy consumption by using artificial neural networks. *Advances in Engineering Software*, Elsevier, v. 40, n. 5, p. 356–362, 2009. Citado 4 vezes nas páginas 23, 24, 25 e 28.
- ELVEREN, E.; YUMUŞAK, N. Tuberculosis disease diagnosis using artificial neural network trained with genetic algorithm. *Journal of medical systems*, Springer, v. 35, n. 3, p. 329–332, 2011. Citado na página 28.
- ER, O.; TEMURTAS, F.; TANRIKULU, A. Ç. Tuberculosis disease diagnosis using artificial neural networks. *Journal of medical systems*, Springer, v. 34, n. 3, p. 299–302, 2010. Citado na página 28.
- FARJOD, A. et al. Magneto-rheological fluid behavior in squeeze mode. *Smart Materials and Structures*, v. 18, n. 9, 2009. Citado 3 vezes nas páginas 3, 4 e 5.
- FAVARO, J. *Controle preditivo aplicado à planta piloto de neutralização de pH*. Tese (Doutorado) — Universidade de São Paulo, 2012. Citado na página 19.
- FAVRE, J.; ERHART-HLEDIK, J. C.; ANDRIACCHI, T. P. Age-related differences in sagittal-plane knee function at heel-strike of walking are increased in osteoarthritic patients. *Osteoarthritis and cartilage*, Elsevier, v. 22, n. 3, p. 464–471, 2014. Citado na página 47.
- FINDEISEN, R. Nonlinear model predictive control: a sampled data feedback perspective. 2005. Citado 2 vezes nas páginas 18 e 21.
- FITE, K. et al. Design and control of an electrically powered knee prosthesis. In: IEEE. *Rehabilitation robotics, 2007. ICORR 2007. IEEE 10th international conference on*. [S.l.], 2007. p. 902–905. Citado 3 vezes nas páginas 4, 46 e 47.
- FU, R.; ZHANG, Z.; LI, L. Using lstm and gru neural network methods for traffic flow prediction. In: *2016 31st Youth Academic Annual Conference of Chinese Association of Automation (YAC)*. [S.l.: s.n.], 2016. p. 324–328. Citado na página 58.
- GARCIA, C. E.; PRETT, D. M.; MORARI, M. Model predictive control: theory and practice—a survey. *Automatica*, Pergamon, v. 25, n. 3, p. 335–348, 1989. Citado 2 vezes nas páginas 18 e 19.
- GARLIPPE, L. A. *Estudo Epidemiológico dos Pacientes com Amputação de Membros Inferiores Atendidos no Centro Regional de Reabilitação de Araraquara, Estado de São Paulo, Brasil*. Dissertação (Mestrado) — Faculdade de Medicina de Ribeirão Preto da Universidade de São Paulo/USP, 2014. Citado 2 vezes nas páginas 2 e 3.
- GENG, Y. et al. Design and analysis of active transfemoral prosthesis. In: IEEE. *IECON 2010-36th Annual Conference on IEEE Industrial Electronics Society*. [S.l.], 2010. p. 1495–1499. Citado 5 vezes nas páginas 4, 46, 47, 56 e 57.

- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep learning*. [S.l.]: MIT press, 2016. Citado 4 vezes nas páginas 29, 30, 31 e 32.
- GRAVES, A.; MOHAMED, A.-r.; HINTON, G. Speech recognition with deep recurrent neural networks. In: IEEE. *2013 IEEE international conference on acoustics, speech and signal processing*. [S.l.], 2013. p. 6645–6649. Citado 2 vezes nas páginas 30 e 31.
- GUDMUNDSSON, K.; JONSDOTTIR, F.; THORSTEINSSON, F. A geometrical optimization of a magneto-rheological rotary brake in a prosthetic knee. *Smart Materials and Structures*, IOP Publishing, v. 19, n. 3, p. 035023, 2010. Citado 2 vezes nas páginas 4 e 5.
- HASHIMOTO, K. et al. Simple customization of recursive neural networks for semantic relation classification. In: *Proceedings of the 2013 Conference on Empirical Methods in Natural Language Processing*. [S.l.: s.n.], 2013. p. 1372–1376. Citado na página 58.
- HAYKIN, S. *Neural networks: a comprehensive foundation*. [S.l.]: Prentice Hall PTR, 1994. Citado na página 23.
- HEEMELS, W. P.; SCHUTTER, B. D.; BEMPORAD, A. Equivalence of hybrid dynamical models. *Automatica*, Elsevier, v. 37, n. 7, p. 1085–1091, 2001. Citado na página 21.
- IBGE. *Pesquisa Nacional de Saúde 2013 - Indicadores de Saúde e Mercado de Trabalho: Brasil e Grandes Regiões*. 2010. Citado na página 2.
- IBGE. *Características gerais da população, religião e pessoas com deficiência*. 2012. Citado na página 2.
- IBGE, C. D. *Características gerais da população e instrução*. 1991. Citado na página 1.
- IBGE, C. D. *Características gerais da população*. 2000. Citado na página 2.
- IBGE, C. D. *Releitura dos dados de pessoas com deficiência no Censo Demográfico 2010 à luz das recomendações do Grupo de Washington. Nota Técnica. 2012*. 2010. Citado na página 2.
- INOUE, K. et al. Novel knee joint mechanism of transfemoral prosthesis for stair ascent. In: IEEE. *Rehabilitation Robotics (ICORR), 2013 IEEE International Conference on*. [S.l.], 2013. p. 1–6. Citado 2 vezes nas páginas 4 e 47.
- JAIN, A.; MAO, J.; MOHIUDDIN, K. Artificial neural networks: A tutorial. *Computer, IEEE*, v. 29, n. 3, p. 31–44, 1996. Citado 3 vezes nas páginas 23, 24 e 25.
- JANNUZZI, G.S.M.; JANNUZZI, N. Incidência de deficientes no brasil segundo censo demográfico de 1991: resultados empíricos e implicações para políticas. *Anais*, p. 2889–2908, 2016. Citado na página 1.
- JANNUZZI, G.S.M.; JANNUZZI, N. Portadores de necessidades especiais no brasil; reflexões a partir do censo demográfico 1991. *Integração, MEC/Secretaria de Educação Especial*, v. 18, p. 40–6, 1994. Citado na página 1.
- KAPTI, A. O.; YUCENUR, M. S. Design and control of an active artificial knee joint. *Mechanism and machine theory*, Elsevier, v. 41, n. 12, p. 1477–1485, 2006. Citado 7 vezes nas páginas 4, 41, 42, 46, 47, 56 e 57.

- KARAMAN, S.; SANFELICE, R. G.; FRAZZOLI, E. Optimal control of mixed logical dynamical systems with linear temporal logic specifications. In: IEEE. *2008 47th IEEE Conference on Decision and Control*. [S.l.], 2008. p. 2117–2122. Citado na página 21.
- KARAYIANNIS, N.; VENETSANOPOULOS, A. N. *Artificial neural networks: learning algorithms, performance evaluation, and applications*. [S.l.]: Springer Science & Business Media, 2013. v. 209. Citado 5 vezes nas páginas 23, 24, 25, 27 e 28.
- KHAN, I. Y.; ZOPE, P.; SURALKAR, S. Importance of artificial neural network in medical diagnosis disease like acute nephritis disease and heart disease. *International Journal of Engineering Science and Innovative Technology (IJESIT)*, v. 2, n. 2, p. 210–217, 2013. Citado na página 28.
- KOBIRAKI, L. C. G. et al. Análise da influência do carregamento sobre o processo de remodelação do osso femoral. 2018. Citado 2 vezes nas páginas 48 e 51.
- KUMAR, K.; ABHISHEK, B. *Artificial neural networks for diagnosis of kidney stones disease*. [S.l.]: GRIN Verlag, 2012. Citado na página 28.
- LAWSON, B. E.; VAROL, H. A.; GOLDFARB, M. Standing stability enhancement with an intelligent powered transfemoral prosthesis. *IEEE transactions on biomedical engineering*, Institute of Electrical and Electronics Engineers, Inc., 345 E. 47 th St. NY . . . , v. 58, n. 9, p. 2617–2624, 2011. Citado na página 4.
- LEE, J. H. Model predictive control: Review of the three decades of development. *International Journal of Control, Automation and Systems*, Springer, v. 9, n. 3, p. 415, 2011. Citado na página 17.
- LEITE, C. F. et al. Análise retrospectiva sobre a prevalência de amputações bilaterais de membros inferiores. *J Vasc Br*, v. 3, n. 3, p. 206–13, 2004. Citado na página 3.
- LENZI, M. B. Os dados sobre deficiência nos censos demográficos brasileiro. *Anais*, p. 1–20, 2016. Citado na página 1.
- LIAO, R. et al. Reviving and improving recurrent back-propagation. *arXiv preprint arXiv:1803.06396*, 2018. Citado na página 35.
- LILLICRAP, T. P.; SANTORO, A. Backpropagation through time and the brain. *Current opinion in neurobiology*, Elsevier, v. 55, p. 82–89, 2019. Citado 2 vezes nas páginas 34 e 35.
- LIPTON, Z. C.; BERKOWITZ, J.; ELKAN, C. A critical review of recurrent neural networks for sequence learning. *arXiv preprint arXiv:1506.00019*, 2015. Citado 6 vezes nas páginas 30, 31, 32, 33, 34 e 35.
- LOTERIO, F. A. *Análise do padrão de ativação muscular de indivíduos hemiparéticos pós-AVC em marcha assistida por andador robótico*. Dissertação (Mestrado), 2015. Citado 2 vezes nas páginas 11 e 14.
- MA, Y. et al. Model predictive control for the operation of building cooling systems. *IEEE Transactions on control systems technology*, IEEE, v. 20, n. 3, p. 796–803, 2011. Citado na página 18.

- MARÃES, V. R. F. d. S. et al. Hip evaluation of transfemoral amputees during isometric contraction in isokinetic dynamometer. *Rev Bras Med Esporte*, v. 20, n. 5, 2014. Citado na página 11.
- MARENCO, S. E. Tipos de imaginación motora y procesamiento predictivo. *Poiésis*, v. 1, n. 34, p. 58–71, 2018. Citado na página 43.
- MARTINEZ-VILLALPANDO, E. C.; HERR, H. Agonist-antagonist active knee prosthesis: a preliminary study in level-ground walking. *Journal of Rehabilitation Research & Development*, v. 46, n. 3, 2009. Citado 4 vezes nas páginas 4, 46, 47 e 56.
- MAYNE, D. Q. et al. Constrained model predictive control: Stability and optimality. *Automatica*, Elsevier, v. 36, n. 6, p. 789–814, 2000. Citado na página 18.
- MCMILLAN, A. et al. Sagittal and frontal plane joint mechanics throughout the stance phase of walking in adolescents who are obese. *Gait & posture*, Elsevier, v. 32, n. 2, p. 263–268, 2010. Citado 2 vezes nas páginas 46 e 47.
- MEHDY, M. et al. Artificial neural networks in image processing for early detection of breast cancer. *Computational and mathematical methods in medicine*, Hindawi, v. 2017, 2017. Citado na página 28.
- MIKOLOV, T. et al. Strategies for training large scale neural network language models. In: *2011 IEEE Workshop on Automatic Speech Recognition Understanding*. [S.l.: s.n.], 2011. p. 196–201. Citado na página 58.
- MIKOLOV, T. et al. Recurrent neural network based language model. In: *Eleventh annual conference of the international speech communication association*. [S.l.: s.n.], 2010. Citado 2 vezes nas páginas 29 e 32.
- MILECH, A. et al. Diretrizes da sociedade brasileira de diabetes (2015-2016). *São Paulo: AC Farmacêutica*, 2016. Citado na página 2.
- MILLER, R. H.; BRANDON, S. C.; DELUZIO, K. J. Predicting sagittal plane biomechanics that minimize the axial knee joint contact force during walking. *Journal of biomechanical engineering*, American Society of Mechanical Engineers Digital Collection, v. 135, n. 1, 2013. Citado 3 vezes nas páginas 46, 47 e 56.
- MS, M. da S. *Diretrizes de atenção à pessoa amputada*. Brasília: Ministério da Saúde, 2013. v. 1. 36 p. [S.l.], 2013. Citado 2 vezes nas páginas 2 e 3.
- MUJIK, A.; MEIER, F.; STEGER, A. Approximating real-time recurrent learning with random kronecker factors. In: *Advances in Neural Information Processing Systems*. [S.l.: s.n.], 2018. p. 6594–6603. Citado na página 35.
- NAKAMURA, T. A. et al. An anatomy for neural search engines. *Information Sciences*, Elsevier, v. 480, p. 339–353, 2019. Citado na página 35.
- NASSER, I. M.; ABU-NASER, S. S. Predicting tumor category using artificial neural networks. *IJARW*, 2019. Citado na página 28.
- NEPTUNE, R. R.; MCGOWAN, C. P. Muscle contributions to whole-body sagittal plane angular momentum during walking. *Journal of biomechanics*, Elsevier, v. 44, n. 1, p. 6–12, 2011. Citado 3 vezes nas páginas 46, 47 e 56.

NESI, C. *Principais Causas e Níveis das Amputações de Membros Inferiores nos Pacientes do Instituto de Reabilitação do Hospital Erasto Gaertner*. 2005. Citado na página 3.

OLABARRERA, W. H. M. et al. Desenvolvimento de um sistema de previsão de demanda de exames de teledermatologia. Florianópolis, SC, 2020. Citado na página 35.

OPPENHEIM, A. V.; SCHAFFER, R. W. *Discrete-Time Signal Processing*. [S.l.]: Pearson, 2009. v. 1. Citado 2 vezes nas páginas 51 e 53.

OTTOBOCK. *History: Over 90 years of progress and tradition*. s.d. Disponível em: <<https://www.ottobock.com/en/company/history/>>. Acesso em: 2019-01-25. Citado na página 4.

PASCANU, R.; MIKOLOV, T.; BENGIO, Y. Understanding the exploding gradient problem. *CoRR*, *abs/1211.5063*, v. 2, p. 417, 2012. Citado na página 32.

PASCANU, R.; MIKOLOV, T.; BENGIO, Y. On the difficulty of training recurrent neural networks. In: *International conference on machine learning*. [S.l.: s.n.], 2013. p. 1310–1318. Citado 3 vezes nas páginas 29, 30 e 32.

PEDRYCZ, W.; CHEN, S.-M. *Deep Learning: Concepts and Architectures*. [S.l.]: Springer, 2019. v. 1. Citado 5 vezes nas páginas 31, 32, 33, 34 e 58.

PEIXOTO, A. M. et al. Prevalência de amputações de membros superiores e inferiores no estado de alagoas atendidos pelo sus entre 2008 e 2015. *Fisioterapia e Pesquisa*, v. 24, n. 4, p. 378–384, 2017. Citado na página 2.

PERRY, J.; BURNFIELD, J. M. Gait analysis: Normal and pathological function. *Journal of Sports Science Medicine*, v. 9, n. 2, p. 353, 2010. Citado na página 14.

PRADA, L. M. *Análise cinemática da marcha de amputados transfemorais pré e pós a aplicação de um protocolo de reabilitação*. 2014. Citado 3 vezes nas páginas 3, 46 e 47.

QIN, S. J.; BADGWELL, T. A. A survey of industrial model predictive control technology. *Control engineering practice*, Elsevier, v. 11, n. 7, p. 733–764, 2003. Citado 2 vezes nas páginas 18 e 19.

REIS, G. dos; JÚNIOR, A. J. C.; CAMPOS, R. da S. Perfil epidemiológico de amputados de membros superiores e inferiores atendidos em um centro de referência. 2012. Citado 2 vezes nas páginas 2 e 3.

RHEO-KNEE. *It's Official. Ossur's Rheo Knee(r) is Available*. 2005. "<<https://www.ossur.com/corporate/newslist/1069-it-s-official-ossur-s-rheo-knee-r-is-available>>", note = "[Online; accessed 25-January-2019]". Citado na página 4.

RICHALET, J. et al. Model predictive heuristic control: Applications to industrial processes. *International Journal of Control, Automation and Systems*, Automatica, v. 14, n. 5, p. 413–428, 1978. Citado na página 17.

SAAD, M.; BATTISTELLA, L. R.; MASIERO, D. Técnicas de análise de marcha. *Acta fisiátrica*, v. 3, n. 2, p. 23–26, 1996. Citado na página 11.

SANTANA, R. E. S. *Projeto de um Robô Bípede para a Reprodução da Marcha Humana*. Dissertação (Mestrado) — Escola Politécnica da Universidade de São Paulo/USP, 2005. Citado na página 11.

- SANTOS, K. P. B. d. et al. Carga da doença para as amputações de membros inferiores atribuíveis ao diabetes mellitus no estado de santa catarina, brasil, 2008-2013. *Cadernos de Saúde Pública*, SciELO Public Health, v. 34, p. e00013116, 2018. Citado na página 2.
- SASAKI, K.; NEPTUNE, R. R. Individual muscle contributions to the axial knee joint contact force during normal walking. *Journal of biomechanics*, Elsevier, v. 43, n. 14, p. 2780–2784, 2010. Citado 3 vezes nas páginas 46, 47 e 56.
- SCAFETTA, N.; MARCHI, D.; WEST, B. J. Understanding the complexity of human gait dynamics. *Chaos: An Interdisciplinary Journal of Nonlinear Science*, AIP, v. 19, n. 2, p. 026108, 2009. Citado na página 11.
- SUP, F.; VAROL, H. A.; GOLDFARB, M. Upslope walking with a powered knee and ankle prosthesis: initial results with an amputee subject. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, IEEE, v. 19, n. 1, p. 71–78, 2011. Citado 3 vezes nas páginas 4, 46 e 47.
- SUTSKEVER, I.; MARTENS, J.; HINTON, G. E. Generating text with recurrent neural networks. In: *Proceedings of the 28th international conference on machine learning (ICML-11)*. [S.l.: s.n.], 2011. p. 1017–1024. Citado 4 vezes nas páginas 29, 30, 31 e 32.
- SUYKENS, J. A.; VANDEWALLE, J. P.; MOOR, B. L. de. *Artificial neural networks for modelling and control of non-linear systems*. [S.l.]: Springer Science & Business Media, 2012. Citado 4 vezes nas páginas 23, 25, 28 e 37.
- TALLEC, C.; OLLIVIER, Y. Unbiasing truncated backpropagation through time. *arXiv preprint arXiv:1705.08209*, 2017. Citado 2 vezes nas páginas 34 e 35.
- TANG, H.; GLASS, J. On training recurrent networks with truncated backpropagation through time in speech recognition. In: IEEE. *2018 IEEE Spoken Language Technology Workshop (SLT)*. [S.l.], 2018. p. 48–55. Citado na página 35.
- TEIXEIRA, A.; OLIVEIRA, F. Relatório sobre a prevalência de deficiências, incapacidades e desvantagens.[relatório na internet]. *Niterói: Ministério da Justiça*, 2004. Citado 2 vezes nas páginas 1 e 2.
- THATTE, N.; GEYER, H. Toward balance recovery with leg prostheses using neuromuscular model control. *IEEE Transactions on Biomedical Engineering*, IEEE, v. 63, n. 5, p. 904–913, 2016. Citado na página 4.
- TORREALBA, R. et al. Characterisation of gait cycle from accelerometer data. *Electronics Letters*, IET, v. 43, n. 20, p. 1066–1068, 2007. Citado 2 vezes nas páginas 12 e 14.
- UNWIN, N. Epidemiology of lower extremity amputation in centres in europe, north america and east asia. *British Journal of Surgery*, v. 87, p. 328–337, 2000. Citado na página 2.
- VALE, J. M. de C. *Controle Preditivo Aplicado na Otimização de um Processo de Concentração Típico de Flotação em Coluna para Aproveitamento de Minérios*. Tese (Doutorado) — Centro Federal de Educação Tecnológica de Minas Gerais, 2017. Citado 3 vezes nas páginas 18, 19 e 20.

- VAUGHAN, C. L. et al. Dynamics of human gait. Kiboho Publishers, 1999. Citado 2 vezes nas páginas 14 e 43.
- VICENTE, J. D.; KLINGENBERG, D. J.; HIDALGO-ALVAREZ, R. Magnetorheological fluids: a review. *Soft matter*, Royal Society of Chemistry, v. 7, n. 8, p. 3701–3710, 2011. Citado 2 vezes nas páginas 4 e 5.
- WEST, M. *Explaining Recurrent Neural Networks*. 2020. Acesso em: 11 de jun de 2020. Disponível em: <<https://www.bouvet.no/bouvet-deler/explaining-recurrent-neural-networks>>. Citado na página 31.
- WILLIAMS, R. J.; PENG, J. An efficient gradient-based algorithm for on-line training of recurrent network trajectories. *Neural computation*, MIT Press, v. 2, n. 4, p. 490–501, 1990. Citado na página 34.
- YASNITSKY, L. et al. Artificial neural networks for obtaining new medical knowledge: diagnostics and prediction of cardiovascular disease progression. *Biology and Medicine (Aligarh)*, v. 7, n. 2, p. BM, 2015. Citado na página 28.
- YOUNG, T. et al. Recent trends in deep learning based natural language processing. *IEEE Computational Intelligence Magazine*, IEEE, v. 13, n. 3, p. 55–75, 2018. Citado na página 35.
- YOUSUF, M.; AL-DUWAISH, H.; HAMOUZ, Z. Pso based predictive nonlinear automatic generation control. *12th WSEAS International Conference on Automatic Control, Modelling and Simulation, ACMOS '10*, p. 87–92, 05 2010. Citado na página 19.
- ZAREMBA, W.; SUTSKEVER, I.; VINYALS, O. Recurrent neural network regularization. *arXiv preprint arXiv:1409.2329*, 2014. Citado na página 30.
- ZUBIETA, M. et al. Magnetorheological fluids: characterization and modeling of magnetization. *Smart Materials and Structures*, IOP Publishing, v. 18, n. 9, p. 095019, 2009. Citado 2 vezes nas páginas 4 e 5.