

UNIVERSIDADE FEDERAL DA PARAÍBA
CENTRO DE ENERGIAS ALTERNATIVAS E RENOVÁVEIS
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

Modelo para Estimação do Estado de Carga
de Baterias de Lítio-Íon Baseado em Redes
Neurais Auto Regressivas Não-Lineares Com
Entradas Externas



Jonathan Jefferson Pereira Moura

João Pessoa
Julho - 2019

JONATHAN JEFFERSON PEREIRA MOURA

**Modelo para Estimação do Estado de Carga de Baterias
de Lítio-Íon Baseado em Redes Neurais Auto Regressivas
Não-Lineares Com Entradas Externas**

Exame de defesa final apresentado ao Programa de Pós-Graduação em Engenharia Elétrica - PPGEE, da Universidade Federal da Paraíba - UFPB, como requisito final para a obtenção do título de Mestre em Engenharia Elétrica.

Orientador: Prof. Dr. Juan Moisés Maurício Villanueva

João Pessoa - PB

2019

Catálogo na publicação
Seção de Catalogação e Classificação

M929m Moura, Jonathan Jefferson Pereira.

Modelo para Estimação do Estado de Carga de Baterias de
Lítio-Íon Baseado em Redes Neurais Auto Regressivas
Não-Lineares Com Entradas Externas / Jonathan Jefferson
Pereira Moura. - João Pessoa, 2019.
83 f.

Dissertação (Mestrado) - UFPB/CT.

1. Redes Neurais Artificiais. 2. Estado de Carga. 3.
Baterias de Lítio-íon. 4. Redes Neurais Não-Lineares
Auto Regressivas com En. 5. Matlab/Simulink. 6.
Estruturas de Rede. I. Título

UFPB/BC

UNIVERSIDADE FEDERAL DA PARAÍBA - UFPB
CENTRO DE ENERGIAS ALTERNATIVAS E RENOVÁVEIS - CEAR
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA -
PPGEE

A Comissão Examinadora, abaixo assinada, aprova a Dissertação de Mestrado

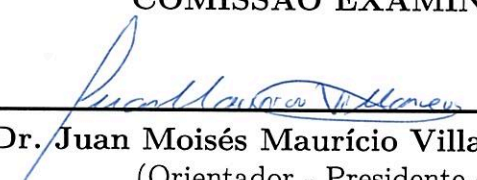
**Modelo para Estimação do Estado de Carga de Baterias
de Lítio-Íon Baseado em Redes Neurais Auto Regressivas
Não-Lineares Com Entradas Externas**

Elaborada por

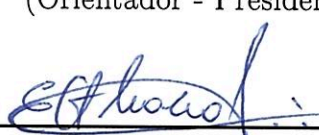
JONATHAN JEFFERSON PEREIRA MOURA

como requisito final para obtenção do grau de
Mestre em Engenharia Elétrica.

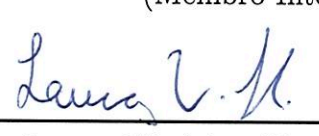
COMISSÃO EXAMINADORA



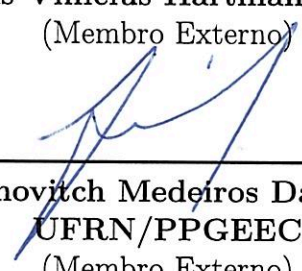
Prof. Dr. Juan Moisés Maurício Villanueva - UFPB/PPGEE
(Orientador - Presidente da Banca)



Prof. Dr. Euler Cássio Tavares de Macedo - UFPB/PPGEE
(Membro Interno)



Prof. Dr. Lucas Vinícius Hartmann - UFPB/DEE
(Membro Externo)



Prof. Dr. Ivanovitch Medeiros Dantas da Silva -
UFRN/PPGEEC
(Membro Externo)

João Pessoa-PB, 29 de julho de 2019.

Dedicatória

*Este trabalho é dedicado a todas as crianças adultas, que quando pequenas sonharam em
se tornar cientistas.*

Agradecimentos

Agradeço aos meus pais, José Moura da Silva e Marluce Pereira da Silva, por sempre me guiarem pelo melhor caminho, nunca duvidarem da minha capacidade de ir sempre mais longe e me apoiarem incondicionalmente.

A minha namorada Amanda por estar ao meu lado durante todos os momentos difíceis ou de conquistas, e sempre acreditar em mim.

Agradeço ao meu orientador, Juan Villanueva, por todos os conselhos, pela paciência e ajuda durante o mestrado.

Aos meus amigos Caio, Kaique, Ricardo, Diego, Raoni, Jean, Joel, Frank, Rafael dentre outros que de alguma forma me ajudaram durante este dois anos.

A Professora Maria de Fátima e ao CPqD por estarem disponíveis a estabelecerem uma ponte para troca de informações e auxílio no decorrer da pesquisa.

*“Se fosse fácil achar o caminho das pedras,
tantas pedras no caminho não seria ruim.” (Humberto Gessinger)*

Resumo

Atualmente, a busca pela utilização e o aprimoramento do armazenamento de energia elétrica seja para utilização em sistemas isolados de energia (*off grid*), dispositivos móveis ou implantação em veículos elétricos tem se tornado foco de pesquisas que visam uma maior eficiência no controle de carga e descarga de baterias. Neste cenário, é proposto um método para estimação do Estado de Carga (SoC) para baterias de lítio-íon, utilizando como estrutura base as redes neurais artificiais do tipo não-linear auto regressivas com entradas externas (NARX). A estrutura usada para determinação do SoC consiste em uma rede NARX tendo como entradas tensão dos terminais da bateria e temperatura ambiente além do SoC no instante anterior realimentado, fornecendo na saída da rede o valor do SoC no instante atual. Os procedimentos de criação do banco de dados com ensaios de descarga para várias correntes e temperatura diferentes foram efetuados utilizando a ferramenta Simulink. O treinamento da rede neural se deu por meio do *toolbox Neural Net Time Series* do *software* Matlab®. Foram desenvolvidas um total de 12 redes neurais utilizando funções de ativação tangente hiperbólica, sigmóide, linear saturada e puramente linear de tal forma que suas validações foram realizadas também através do Matlab®. Os resultados dos testes de validação foram comparados com outras estruturas de redes neurais baseadas em técnicas reportadas na literatura, de modo que a estrutura proposta obteve um Erro Quadrático Médio máximo de 1,864% e um Erro Percentual Absoluto Médio máximo de 2,807%.

Palavras-chave: Redes Neurais Artificiais, Estado de Carga, Baterias de Lítio-Íon, Redes Neurais Não-Lineares Auto Regressivas com Entradas Externas, Matlab/Simulink®, Estruturas de Rede.

Abstract

Nowadays, the research for use and enhancement in the electrical energy storage for use in isolated power systems (off-grid), mobile devices or electric vehicles applications was became a focus of research that aim a greater efficiency in the charge and discharge control of batteries. In this scenario, a method is proposed to State of Charge (SoC) estimation for lithium-ion batteries using as base structure a neural network of type nonlinear autoregressive with external inputs (NARX). The structure used to determine the SoC consists of a NARX network containing the battery terminal voltage and ambient temperature as external inputs in addition to the feedback SoC in the previous instant, providing in the network output the SoC value at the current instant. The procedures for creating the database with discharge tests for different currents and temperatures were performed in the Simulink tool. The training of the neural network was done using the Neural Net Time Series toolbox of Matlab[®] software. A total of 12 neural networks were developed using hyperbolic tangent, sigmoid, linear saturated and purely linear activation functions so that their validations were also performed through Matlab[®]. The results of the validation tests were compared with other structures of neural networks based on techniques reported in the literature, so that the proposed structure obtained a maximum Mean Squared Error of 1.864% and a maximum Maximum Absolute Percent Error of 2.807%.

Keywords: Artificial Neural Networks, State of Charge, Lithium-ion batteries, Nonlinear Autoregressive with External Input Neural Networks, Matlab/Simulink[®], Network structures.

Lista de ilustrações

Figura 1 – Evolução do estoque global de carros elétricos.	20
Figura 2 – Representação dos modos de carga (direita) e descarga (esquerda) de uma célula.	24
Figura 3 – Diagrama de blocos para um BMS.	27
Figura 4 – Classificação dos métodos para estimação do Estado de Carga.	29
Figura 5 – Dados de análise por espectroscopia de impedância.	30
Figura 6 – Modelos de circuito equivalente.	31
Figura 7 – Diagrama do algoritmo de estimação de SoC baseado em FK.	32
Figura 8 – Estrutura de um <i>perceptron</i>	37
Figura 9 – Funções de ativação, eixo horizontal = y' e eixo vertical = $f(y') = y$	38
Figura 10 – Arquiteturas de redes.	39
Figura 11 – Fluxograma de aprendizagem supervisionada.	41
Figura 12 – Curvas de descarga de células AMP20.	43
Figura 13 – Estrutura para desenvolvimento do método proposto.	44
Figura 14 – Modelo de bateria disponibilizado pelo Matlab/Simulink®.	45
Figura 15 – Estrutura base da rede proposta.	48
Figura 16 – Fluxograma para as simulações de corrente pulsada.	51
Figura 17 – Curvas para simulações de corrente pulsada.	52
Figura 18 – Diagrama de blocos para simulações de descarga implementados via Simulink.	54
Figura 19 – Diagramas de implementação da RNA via Matlab®.	55
Figura 20 – Implementação da rede NARX para determinação do SoC.	56
Figura 21 – SoCs obtidos para as RNA-P-S, RNA-ISA-S e RNA-ICA-S.	58
Figura 22 – MAPE em função do ruído para a RNA-P-S.	60
Figura 23 – MSE em função do ruído para a RNA-P-S.	61
Figura 24 – SoCs obtidos para as RNA-P-TH, RNA-ISA-TH e RNA-ICA-TH.	62
Figura 25 – MAPE em função do ruído para a RNA-P-TH.	63
Figura 26 – MSE em função do ruído para a RNA-P-TH.	64
Figura 27 – SoCs obtidos para as RNA-P-LS, RNA-ISA-LS e RNA-ICA-LS.	65
Figura 28 – MAPE em função do ruído para a RNA-P-LS.	66
Figura 29 – MSE em função do ruído para a RNA-P-LS.	67
Figura 30 – SoCs obtidos para as RNA-P-PL, RNA-ISA-PL e RNA-ICA-PL.	68
Figura 31 – MAPE em função do ruído para a RNA-P-PL.	69
Figura 32 – MSE em função do ruído para a RNA-P-PL.	70
Figura 33 – Estrutura implementada para simulações MIL.	71
Figura 34 – Curvas obtidas para simulação MIL com perfil de corrente 1.	72

Figura 35 – Curvas obtidas através da simulação MIL com erro inicial do SoC para o perfil de corrente 1.	74
Figura 36 – Curvas obtidas para simulação MIL para o perfil de corrente 2.	75

Lista de tabelas

Tabela 1	–	Valores de SoF para diferentes SoCs e SoHs.	26
Tabela 2	–	Principais funções do BMS.	27
Tabela 3	–	Tabela de méritos para as topologias de estimação do SoC.	35
Tabela 4	–	Principais estruturas de um neurônio biológico.	37
Tabela 5	–	Parâmetros da bateria.	48
Tabela 6	–	Especificações RNAs propostas neste trabalho.	49
Tabela 7	–	Especificações RNAs propostas por Ismail (sem atrasos).	49
Tabela 8	–	Especificações RNAs propostas por Ismail (com atrasos).	50
Tabela 9	–	Dados de treinamento da RNA proposta.	53
Tabela 10	–	Parâmetros de treinamento das RNAs.	56
Tabela 11	–	MAPE e MSE para as RNA-P-S, RNA-ISA-S e RNA-ICA-S.	59
Tabela 12	–	Influência do ruído na RNA-P-S.	61
Tabela 13	–	MAPE e MSE para as RNA-P-TH, RNA-ISA-TH e RNA-ICA-TH. . .	63
Tabela 14	–	Influência do ruído na RNA-P-TH.	64
Tabela 15	–	MAPE e MSE para as RNA-P-LS, RNA-ISA-LS e RNA-ICA-LS. . . .	66
Tabela 16	–	Influência do ruído na RNA-P-LS.	67
Tabela 17	–	MAPE e MSE para as RNA-P-PL, RNA-ISA-PL e RNA-ICA-PL. . . .	69
Tabela 18	–	Influência do ruído na RNA-P-PL.	70
Tabela 19	–	MAPE e MSE para simulação MIL com perfil de corrente 1.	72
Tabela 20	–	MAPE e MSE para simulação MIL para o perfil de corrente 1 com erro inicial do SoC.	73
Tabela 21	–	MAPE e MSE para simulação MIL para o perfil de corrente 2.	75

Lista de abreviaturas e siglas

ANFIS	<i>Adaptive Neuro-Fuzzy Inference System</i>
AWGN	<i>Additive White Gaussian Noise</i>
ABEV	Associação Brasileira de Veículos Elétricos
ARX	<i>Autoregressive with External Input</i>
BEV	<i>Battery Electric Vehicle</i>
BMS	<i>Battery Management System</i>
CE	Camada de Entrada
CI	Camada Intermediária
CS	Camada de Saída
CC	<i>Counting Coulomb</i>
CAN	<i>Controller Area Network</i>
DNN	<i>Dynamic Neural Network</i>
EV	<i>Electric Vehicle</i>
FFNN	<i>Feedforward Neural Network</i>
FK	Filtro de Kalman
HEV	<i>Hybrid Electric Vehicle</i>
IBS	<i>Intelligent Battery Sensor</i>
IEA	<i>International Energy Agency</i>
LVQ	<i>Learning Vector Quantization</i>
LM	Levenberg Marquardt
LF	Lógica <i>Fuzzy</i>
MAPE	<i>Mean Absolute Percentage Error</i>
MSE	<i>Mean Squared Error</i>

MQR	Mínimos Quadrados Recursivos
MIL	<i>Model in the Loop</i>
MCE	Modelo de Circuito Equivalente
EchM	Modelo Eletroquímico
MLP	<i>Multilayer Perceptron</i>
NAR	<i>Nolinear Autoregressive</i>
NARX	<i>Nonlinear Autoregressive with External Input</i>
OCV	<i>Open Circuit Voltage</i>
PHEV	<i>Plug-in Hybrid Electric Vehicle</i>
RBF	<i>Radio Basis Function</i>
RNA	Rede Neural Artificial
SNR	<i>Signal-Noise Ratio</i>
SoC	<i>State of Charge</i>
SoF	<i>State of Function</i>
SoH	<i>State of Health</i>

Lista de símbolos

E_{bat}/T_{bat}	Coeficiente de temperatura de tensão reversível
b	<i>bias</i> da rede neural
P_{loss}	Calor global gerado durante a carga/descarga
Q_{atual}	Capacidade atual
Q	Capacidade da bateria
Q_{nova}	Capacidade de uma bateria nova
B_{exp}	Capacidade exponencial
$Q_{nominal}$	Capacidade nominal
C_{cap}	Capacitância de capacidade de armazenamento
C_p	Capacitância de polarização
C	Capacitor
$\Delta Q/\Delta T_{bat}$	Coeficiente de temperatura na capacidade máxima
K	Constante de polarização
t_c	Constante de tempo térmico
I_{bat}	Corrente de carga/descarga da bateria
Exp	Dinâmica da zona exponencial
i^*	Dinâmica de corrente em baixas frequências
CO_2	Dióxido de carbono
x	Entrada da rede neural
e_{bat}	Erro entre a tensão estimada da bateria e a tensão real
SoC	Estado de Carga
\hat{SoC}	Estado de Carga estimado
SoC_t	Estado de Carga teórico

SoF	Estado de Função
SoH	Estado de Saúde
μ	Gradiente do método de Levenberg Marquardt
D	Inclinação da curva de descarga nominal
Li-íon	Lítio íon
I	Matriz identidade
J	Matriz Jacobiana
Sel	Modo da bateria
Ni-Cd	Níquel cádmio
Ni-MH	Níquel metal hidreto
n_i	Número de amostras passadas da entrada da rede neural
n_o	Número de amostras passadas da saída da rede neural
L	Número total de pontos
Ω	Ohms
P_{desc}	Período de descarga
ω	peso da rede neural
R_p	Resistência de polarização
R_{int}	Resistência interna
R_{th}	Resistência térmica da bateria para com o ambiente
R	Resistor
y	Saída da rede neural
y'	Saída parcial da rede neural
α	Taxa de Arrhenius para a resistência de polarização
β	Taxa de Arrhenius para a resistência interna
T_{amb}	Temperatura ambiente
T_{bat}	Temperatura interna da bateria

T_{ref}	Temperatura nominal
t_{desc}	Tempo de descarga
E_0	Tensão constante
OCV	Tensão de circuito aberto
E_d	Tensão de efeito dinâmico
E_{bat}^*	Tensão estimada nos terminais da bateria
A_{exp}	Tensão exponencial
E_{nl}	Tensão não-linear
E_{bat}	Tensão nos terminais da bateria
e	Vetor de erros

Sumário

1	INTRODUÇÃO	19
1.1	Objetivos	22
1.1.1	Objetivo Geral	22
1.1.2	Objetivos específicos	22
1.2	Contribuições do Trabalho	22
1.3	Organização do Trabalho	23
2	ESTADO DA ARTE	24
2.1	Baterias de Lítio-Íon	24
2.1.1	Fundamentação Teórica	24
2.1.2	Ciclo de Vida	25
2.1.3	Estado de Carga (SoC)	25
2.1.4	Estado de Saúde (SoH)	25
2.1.5	Estado de Função (SoF)	25
2.2	Sistemas de Gerenciamento de Baterias (BMS)	26
2.3	Modelos para Estimação do SoC	28
2.3.1	Métodos Diretos	28
2.3.2	Métodos Indiretos	31
2.3.2.1	Metodologias de Estimação Baseadas em Modelos	31
2.3.2.2	Metodologias de Estimação Baseadas em Filtros Adaptativos	32
2.3.2.3	Metodologias de Estimação Baseadas em Inteligência Artificial Adaptativa	33
3	REDES NEURAIS ARTIFICIAIS (RNAs)	36
3.1	Breve Histórico	36
3.2	Base Biológica	37
3.3	O Neurônio Genérico	37
3.4	Arquiteturas de Rede	39
3.5	Topologias de Treinamento	40
4	MÉTODO PROPOSTO PARA ESTIMAÇÃO DO SOC	42
4.1	Problemática	42
4.2	Método proposto	43
4.2.1	Modelo da Bateria	44
4.2.2	NARX: Parâmetros e Construção do Banco de Dados	47
4.2.3	Treinamento da Rede	54
4.2.4	Métricas para Determinação da Melhor Rede	55

5	RESULTADOS	58
5.1	Redes Neurais com Função Sigmóide	58
5.2	Redes Neurais com Função Tangente Hiperbólica	61
5.3	Redes Neurais com Função Linear Saturada	64
5.4	Redes Neurais com Função Puramente Linear	67
5.5	Análise de Simulações com <i>Model in the Loop</i>	70
6	CONCLUSÃO	77
	REFERÊNCIAS	79

1 Introdução

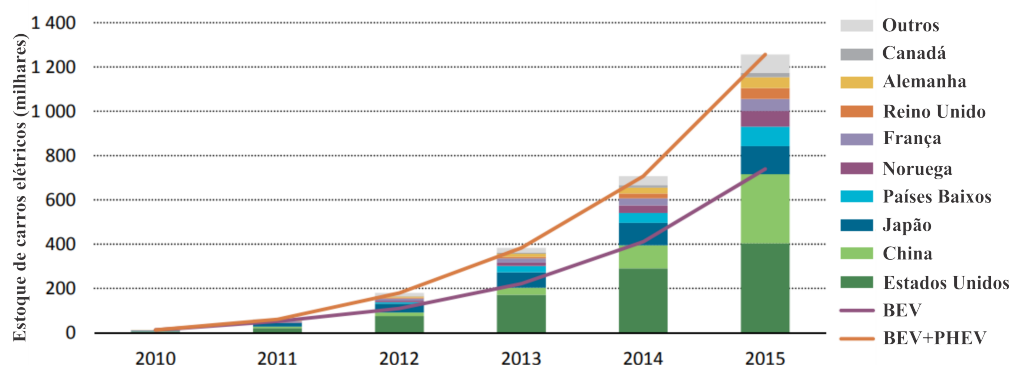
Nas duas últimas décadas, a busca pela utilização e o aprimoramento dos sistemas de armazenamento de energia elétrica tem se tornado o foco de interesse para pesquisadores em todo o mundo. Principalmente devido ao crescente número de cenários os quais estão sendo demandadas a utilização destes tipos de sistemas, como exemplo o grande número de aparelhos móveis (*smathphones*, *tables*, notebooks, etc.) no mercado atual, cada vez mais a implantação de sistemas de geração de energia elétrica que demanda armazenamento energético (parques eólicos, sistemas fotovoltaicos, etc.), os sistemas *off-grid*, além das políticas para redução da utilização de combustíveis fósseis, que afeta de forma considerável o mercado automotivo.

Ao se analisar a busca por geração de energia elétrica limpa, a utilização de sistemas fotovoltaicos e eólicos são opções que estão ganhando cada vez mais espaço no mercado de geração de energia. Ambos os sistemas citados são dependentes da utilização de baterias, uma vez que em sistemas eólicos não se pode garantir a ocorrência de ventos a todo momento, assim como em sistemas fotovoltaicos não é contínua a incidência de raios solares em todos os horários do dia. De modo que, são necessárias técnicas para armazenamento e balanceamento de energia elétrica como as utilizadas em Photovoltaics e Storage (2014), Sassi *et al.* (2017), Rout *et al.* (2018).

Levando-se em consideração a restrição ambiental de emissão de CO₂, é observado um limiar de mudanças no setor de veículos automotivos. Com as políticas de redução do efeito estufa, em breve será cada vez mais restrito o uso de gasolina ou óleo diesel, de modo que este setor está iniciando uma migração de veículos a combustão para Veículos Elétricos (*Electric Vehicles* - EVs), Veículos Elétricos Híbridos (*Hybrid Electric Vehicles* - HEVs), Veículos Elétricos Híbridos *Plug-in* (*Plug-in Hybrid Electric Vehicles* - PHEVs) e Veículos Elétricos a Bateria (*Battery Electric Vehicles* - BEVs).

Segundo a Associação Brasileira de Veículos Elétricos (ABVE), no último relatório da *International Energy Agency* (IEA), o estoque mundial de carros elétricos chegou a 1,26 milhão no final de 2015, um aumento de 70% em relação ao ano anterior. Este crescimento exponencial do mercado de veículos elétricos nos países mais desenvolvidos do mundo é uma das tendências do século 21, com poder de mudar radicalmente o ambiente urbano das grandes cidades e o perfil da economia global nas próximas décadas (IEA, 2016). É apresentado na Figura 1 a tendência de produção de EVs nos últimos anos em algumas das maiores potências econômicas mundiais.

Figura 1 – Evolução do estoque global de carros elétricos.



Fonte: (IEA, 2016) modificado.

Independente do tipo de veículo elétrico utilizado (EVs, HEVs, PHEVs ou BEVs), suas principais fontes energéticas são os bancos de baterias. Estes bancos são por sua vez compostos de conjuntos de baterias conectadas em arranjos série/paralelo, onde em cada bateria está contida uma grande quantidade de células, a unidade básica de uma bateria, também chamada de “elemento” (ROSOLEM *et al.*, 2012).

Vários tipos de baterias são utilizadas em aplicações de veículos elétricos: chumbo ácido, níquel metal hidreto (Ni-MH), níquel cádmio (Ni-Cd) e lítio-íon (Li-íon). Dentre as baterias supracitadas, as baterias de Li-íon têm ganhado bastante atenção científica e de mercado durante as últimas duas décadas devido as suas características, sendo elas: segurança de implementação, ampla faixa de operação de temperatura, alta densidade energética, baixa taxa de auto descarga e uma vida útil relativamente longa.

Como o banco de baterias é um dos elementos mais importantes para aplicações em veículos elétricos e por possuir varias baterias acopladas, existem equipamentos especialmente dedicados em fazer o monitoramento destes componentes no veículo. São eles: o Sistema de Gerenciamento de Baterias (*Battery Management System* - BMS) e o Sensor Inteligente de Bateria (*Intelligent Battery Sensor* - IBS). Ambos são responsáveis por coletar dados como tensão, corrente (carga/descarga) e temperatura e, a partir disto, estimar parâmetros críticos como Estado de Carga, Estado de Saúde e Estado de Função, utilizados para proporcionar o funcionamento adequado e seguro das baterias. Neste trabalho estes parâmetros serão referenciados em termos de suas abreviações em inglês: *State of Charge* (SoC), *State of Health* (SoH) e *State of Function* (SoF).

Pelo fato dos IBSs e BMSs determinarem vários parâmetros das baterias simultaneamente, existe o desafio de implementar cada um destes blocos de modo que se obtenha na estimação em primeiro lugar uma aproximação correta, uma vez que a determinação destes dados de forma incorreta pode produzir danos aos bancos de baterias reduzindo sua vida útil ou até mesmo causar sua explosão; em segundo lugar, buscar sempre um

baixo esforço computacional, visto que estes sensores devem ser embutidos nos veículos de forma a ocupar o menor espaço possível, além de utilizar um *hardware* de baixo consumo de forma a deixar o equipamento adequado a competitividade do mercado.

Existem várias formas de se projetar IBSs e BMSs, dependendo de sua funcionalidade desejada ou aplicação específica, porém muitos deles focam na determinação do SoC. Este dado é considerado uma das principais informações para o correto funcionamento das baterias. Isto se deve ao fato do SoC determinar a capacidade remanescente na bateria em relação a capacidade inicial quando a mesma está totalmente carregada, de modo que o seu valor é geralmente dado em porcentagem. Este parâmetro, muitas vezes, é utilizado em técnicas de controle para gerenciar o balanceamento das baterias inseridas em um banco.

As formas para determinação do SoC geralmente remetem a combinação de dois ou mais métodos de estimação além da inclusão de diferentes ferramentas matemáticas heurísticas ou determinísticas (RIVERA-BARRERA; GALEANO; SARMIENTO-MALDONADO, 2017). Estes métodos estão divididos em diretos e indiretos, de tal forma que ambos utilizam de ferramentas já bem difundidas na literatura, que vão desde estimações por *Coulomb Counting* (também conhecida como Ah) (PURWADI *et al.*, 2014), Tensão de Circuito Aberto (*Open Circuit Voltage* - OCV) (XING *et al.*, 2014) ou Impedância Eletroquímica (PARK; ZHANG; MOURA, 2017), até métodos baseados em Filtros Adaptativos e Inteligência Artificial Adaptativa (CIORTEA *et al.*, 2017).

Levando-se em consideração os dados promissores de crescimento da frota mundial de EVs, associado a busca por melhorias na forma de implementação tanto via *software* quanto via *hardware* de mecanismos para determinação do SoC, a realização deste trabalho tem como objetivo o desenvolvimento de um estimador para o SoC de bateria de lítio-íon baseado em técnicas de *machine learning*. O estimador foi desenvolvido baseado em Redes Neurais Artificiais (RNA) do tipo Auto Regressiva Não-Lineares com Entradas Externas (*Nonlinear Autoregressive with External Input* - NARX). Optou-se pela utilização de RNAs por serem ferramentas capazes de modelarem não-linearidades acentuadas como a existente entre a relação de tensão dos terminais da bateria e o SoC. Adicionalmente, ao se empregar topologias NARX é possível utilizar uma combinação de entradas como a proposta neste trabalho.

O método proposto apresenta modificações nas escolhas para os dados de treinamento relacionadas às camadas de entrada da rede neural em relação aos métodos encontrados na literatura. Tomando como entradas: tensão dos terminais da bateria e temperatura ambiente no instante atual e o SoC estimado no instante anterior. Por outro lado, a camada de saída da rede fornece o SoC no instante atual. Além de uma nova proposta de dados para a camada de entrada da RNA, neste trabalho foram feitas análises para diferentes tipos de função de ativação e estrutura da rede.

Para validação de resultados, o método proposto foi comparado com estimadores

de SoC baseados em estruturas de rede propostas por Ismail *et al.* (2017) implementados computacionalmente em diferentes cenários de validação contendo variações na estrutura de rede, mais especificamente na função de ativação empregada na camada escondida das RNAs.

Todo o processo de obtenção do banco de dados para treinamento e validação, estruturas de rede, treinamento e análise de resultados foi desenvolvido e implementado através da ferramenta de simulação Matlab/Simulink®.

1.1 Objetivos

1.1.1 Objetivo Geral

Este trabalho tem como objetivo desenvolver um estimador de Estado de Carga para baterias de lítio-íon utilizando Redes Neurais Artificiais do tipo Auto Regressivas Não-Lineares com Entradas Externas.

1.1.2 Objetivos específicos

Como objetivos específicos podem ser citados:

- Propor modelos para a estimação do SoC de baterias de Li-íon considerando entradas de tensão da bateria, temperatura ambiente e valores anteriores do SoC;
- Propor modificações na estrutura de rede da RNA utilizada para determinação do SoC;
- Utilizar o modelo proposto para uma análise comparativa entre estruturas de RNAs de modelos já existentes (ISMAIL *et al.*, 2017) e (SOUSA *et al.*, 2016).

1.2 Contribuições do Trabalho

As principais contribuições desse trabalho são:

- Proposta de uma nova metodologia de modelos de RNA para determinação do SoC;
- A consideração de variações de temperatura no treinamento da rede, uma vez que as baterias de Li-íon apresentam modificações em suas curvas de descarga em função da temperatura ambiente;
- O desenvolvimento de um modelo com a finalidade de realizar uma solução embarcada utilizando *hardware* de baixo custo através da construção de um modelo que demande um processamento computacional reduzido.

No que diz respeito à divulgação dos resultados obtidos durante a pesquisa deste trabalho, listam-se as seguintes produções:

Identificação Paramétrica para Baterias de lítio-Íon Utilizando Modelos Auto Regressivos, apresentado no XXII Congresso Brasileiro de Automática, João Pessoa - PB em setembro de 2018 (MOURA *et al.*, 2018);

State of Charge Estimation for Li-Ion Batteries Based on Recurrent NARX Neural Network with Temperature Effect, apresentado no *2019 IEEE International Instrumentation & Measurement Technology Conference - I2MTC*, Auckland Nova Zelândia, em maio de 2019 (MOURA *et al.*, 2019);

Noise Propagation Analyses in the State of Charge Estimation Models of Lithium ion Batteries, aceito para publicação no *4th International Symposium on Instrumentation System, Circuits and Transducers - INSCIT*, São Paulo - SP, que será realizado de 26 à 30 de agosto de 2019.

1.3 Organização do Trabalho

Este trabalho contém em sua estrutura um total de seis capítulos, sendo o Capítulo 1 dedicado à introdução do tema desenvolvido durante o decorrer do texto. O Capítulo 2 consiste em uma revisão bibliográfica do estado da arte em relação as metodologias empregadas na determinação do SoC de baterias, além de descrever alguns conceitos relacionados a baterias.

No Capítulo 3 é dada uma visão geral em relação as RNAs, seus elementos básicos como o *perceptron*, funções de ativação, estruturas de rede e metodologias de treinamento.

O Capítulo 4 apresenta a formulação do problema em relação a estimação de SoC para baterias de Li-íon, descrição do método proposto neste trabalho detalhando cada etapa para obtenção da RNA proposta.

Os resultados obtidos são apresentados no Capítulo 5, onde o método proposto é comparado com estruturas de rede baseadas em metodologias empregadas na literatura.

Por fim, o Capítulo 6 contém as conclusões obtidas a partir da realização de todas as atividades desenvolvidas durante a construção deste trabalho, além das descrições dos próximos passos relacionados a defesa final de mestrado.

2 Estado da Arte

Neste capítulo serão apresentados alguns fundamentos sobre baterias (SoH, SoC e SoF), assim como o BMS e IBS. Por fim, será descrita uma revisão bibliográfica do estado da arte dos modelos para estimação do SoC.

2.1 Baterias de Lítio-Íon

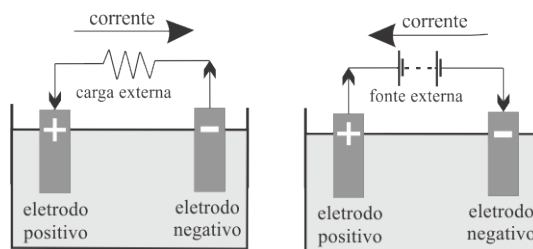
2.1.1 Fundamentação Teórica

Baterias baseadas em lítio e Li-íon apresentam vantagens promissoras na criação de um armazenamento de energia menor, mais leve e mais barato para aplicações de ponta (GROSS; SWOYER, 2002). Lítio é o elemento mais eletropositivo e o metal mais leve, é um elemento único para projeto de sistemas de armazenamento de energia com alta densidade (MEKONNEN; SUNDARARAJAN; SARWAT, 2016).

Alguns dos componentes mais comuns do cátodo são lítio níquel, óxido de cobalto manganês, óxido de níquel, óxido de cobalto, fosfato de ferro, dentre outros. A solução eletrolítica é o sal de lítio em solvente de carbonato orgânico (WINTER; BRODD, 2004). O princípio operacional por trás das baterias de Li-íon é uma transmissão recorrente de íons de lítio entre ânodo e cátodo (VETTER *et al.*, 2005), (WOHLFAHRT-MEHRENS; VOGLER; GARCHE, 2004).

Durante a descarga, a bateria converte energia química em energia elétrica. Os eletrólitos são capazes de se mover como íons internos, devido ao eletrodo negativo conter substâncias oxidadas, enquanto o eletrodo positivo contém as substâncias oxidantes que serão reduzidas (LUO *et al.*, 2015). Durante a carga, esta reação é reversa e uma quantidade correspondente de energia proveniente de uma fonte externa deve ser fornecida para a bateria (LI; KE, 2011). Na Figura 2 são ilustradas estas reações.

Figura 2 – Representação dos modos de carga (direita) e descarga (esquerda) de uma célula.



Fonte: (MARS *et al.*, 2017) modificado.

2.1.2 Ciclo de Vida

Para baterias recarregáveis, os procedimentos de carga e descarga podem ser realizados por algumas centenas de vezes antes que a bateria chegue ao seu fim de vida útil. Este parâmetro é definido como o ciclo de vida da bateria, que prevê a quantidade aproximada de ciclos de carga e descarga que uma bateria pode realizar. Este valor pode variar em função tanto da bateria quanto da temperatura a qual ela está submetida, tendo um valor médio de 3000 ciclos para uma célula do tipo AMP20mlHD-A submetida a temperatura ambiente de 45 °C. Porém, este valor pode variar de 1500 (55 °C) à mais de 6000 ciclos (25 °C) (A123 SYSTEMS, 2014).

2.1.3 Estado de Carga (SoC)

Células da bateria são usualmente modeladas usando resistores, capacitores e alguns indutores. Durante cada ciclo de carga e descarga todos os parâmetros internos da bateria mudam com o SoC, de tal modo que este parâmetro varia de acordo com a química empregada na bateria.

Em geral, o SoC é definido como a razão entre a capacidade atual da bateria Q_{atual} e a capacidade nominal $Q_{nominal}$, dada pela Equação 2.1. A capacidade nominal difere de bateria para bateria e é dada pelos fabricantes. Ela representa a carga máxima da bateria (KHAYAT; KARAMI, 2016).

$$SoC = \frac{Q_{atual}}{Q_{nominal}} \times 100\% \quad (2.1)$$

2.1.4 Estado de Saúde (SoH)

O SoH descreve o grau de envelhecimento da bateria, podendo ser refletido pela perda de capacidade e/ou aumento de resistência interna da bateria que vai se degradando a medida que ela é utilizada. Este parâmetro é dado como 100% quando a bateria é nova e 0% quando a capacidade chega abaixo de um nível em específico, por exemplo, 80% da capacidade de uma bateria nova (SHEN *et al.*, 2018).

2.1.5 Estado de Função (SoF)

O SoF descreve como a bateria atende a demanda de energia, sendo frequentemente representado pela energia máxima disponível. Considerando a segurança da bateria, a tensão dos terminais e a corrente sempre são limitadas dentro de um determinado intervalo, e consequentemente, a energia máxima disponível é restringida por estes limiares (SHEN *et al.*, 2016).

Alguns dos fatores que afetam o SoF são o SoC, o SoH, a temperatura e a tensão dos terminais da bateria. Os possíveis resultados do SoF baseado no SoC e SoH são apresentados na Tabela 1. Estes resultados são obtidos considerando a temperatura constante. Entretanto, quando a temperatura muda, a taxa de variação do SoC e do SoH são diferentes. Ou seja, isto significa que o SoF também é diretamente relacionada a temperatura de operação da bateria (BALAGOPAL; CHOW, 2015).

Tabela 1 – Valores de SoF para diferentes SoCs e SoHs.

<i>SoC/SoH</i>	<i>SoH baixo</i>	<i>SoH alto</i>
<i>SoC baixo</i>	SoF=0	SoF=0/1
<i>SoC alto</i>	SoF=0/1	SoF=1

Fonte: (BALAGOPAL; CHOW, 2015) modificado.

2.2 Sistemas de Gerenciamento de Baterias (BMS)

Vários parâmetros como os citados na Seção 2.1 influenciam no funcionamento das baterias. Entretanto, além deste fatores, outros efeitos provenientes de um supervisionamento incorreto das baterias podem acarretar em redução de vida útil, superaquecimento ou até mesmo explosão.

Em sistemas de *smart grid* ou EVs que demandam uma grande quantidade de baterias para compor um banco, é de fundamental importância a utilização de sistemas que englobem atividades como: controle de carga e descarga, balanceamento de carga, controle de temperatura, etc.

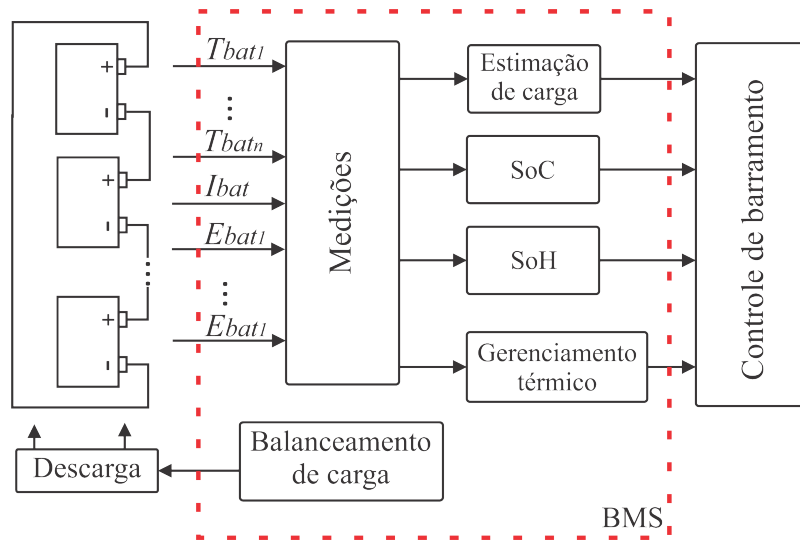
Um dos elementos chave utilizados para os sistemas supracitados são os BMSs. O BMS não controla apenas as condições de operação (limiares de tensão, corrente e temperatura) da bateria para prolongar sua vida útil e garantir sua segurança, ele também fornece estimativa precisa do SoC e SoH para o módulo de gerenciamento de energia nas *smart grid* e EVs (RAHIMI-EICHI *et al.*, 2013). Algumas das funções do BMS são citadas na Tabela 2 e um diagrama genérico deste sistema é ilustrado na Figura 3.

Tabela 2 – Principais funções do BMS.

Controle de carga e descarga	O objetivo principal do BMS é manter a bateria em sua zona de segurança. Caso ocorra alguma anomalia durante a carga ou descarga, danos podem ocorrer fazendo com que a bateria saia de sua zona de segurança.
Determinação do SoC	Através do SoC, podem ser enviados sinais para um usuário e em paralelo realizar o controle dos processos de carga e descarga da bateria.
Determinação do SoH	Os parâmetros de impedância ou condutância que mudam significativamente com o envelhecimento da bateria podem ser detectados a tempo de começarem a ter efeitos negativos no banco como um todo.
Balanceamento de células	O balanceamento é um método de compensar as baterias com menor energia armazenada, equalizando a carga em todas as baterias da cadeia para estender a vida útil total do banco.
Comunicação	A função de comunicação de um BMS pode ser fornecida através de um link de dados usado para monitorar o desempenho, registrar dados, fornecer diagnósticos ou definir parâmetros do sistema.

Fonte: (HU, 2011).

Figura 3 – Diagrama de blocos para um BMS.



Fonte: (BUCCOLINI *et al.*, 2016) modificado.

Como pode ser observado, o BMS é constituído de blocos para balanceamento de carga que equalizam as descargas das baterias inseridas no banco, assim como contém um bloco responsável pelo gerenciamento térmico que monitora a temperatura de operação do banco e das baterias individualmente. O bloco de medições é responsável por mensurar os valores de temperatura (T_{bat}), corrente (I_{bat}) e tensão (E_{bat}) do banco e de cada bateria para que, a partir disto, seja possível a estimativa dos parâmetros como SoC e SoH. O bloco de medições é de fundamental relevância para a correta operação do BMS, uma vez que todos os parâmetros estimados por este dispositivo são dependentes da exatidão com que os sensores do BMS aferem os dados (T_{bat} , I_{bat} e E_{bat}).

2.3 Modelos para Estimação do SoC

Na literatura científica, existe uma variedade de alternativas para se determinar o SoC das baterias, de tal modo que obter uma classificação para cada método não é um procedimento simples, uma vez que a maioria dos estimadores apresentam uma combinação de dois ou mais métodos e a inclusão de diferentes ferramentas matemáticas heurísticas e determinísticas em sua construção (RIVERA-BARRERA; GALEANO; SARMIENTO-MALDONADO, 2017).

Esta seção apresentará uma revisão de métodos para estimação de SoC observados na literatura. Baseado na classificação realizada em Waag, Fleischer e Sauer (2014), esta revisão está dividida em duas categorias (métodos diretos e indiretos) e várias subcategorias que resumem as tendências na estimação do SoC. Na Figura 4, são listados os métodos de estimação com suas respectivas desvantagens de acordo com suas categorias.

2.3.1 Métodos Diretos

A estimação do SoC através de métodos diretos é efetuada por meio da medição e uso de parâmetros físicos da bateria como corrente, tensão dos terminais e temperatura. A partir destes dados é então determinado o SoC da bateria por intermédio de equações ou relações (*Look-up Tables*).

O princípio do método de Coulomb Counting (CC), também conhecido como método ampere-hora, funciona através do cálculo da corrente de carga e descarga, integrando-a para obter o SoC estimado (PURWADI *et al.*, 2014). Ele é o método mais usado, uma vez que é a técnica com mais exatidão para cálculos de curto prazo. O SoC para este método é definido por (FLEISCHER *et al.*, 2013):

$$SoC(t) = SoC(t_0) + \frac{1}{Q_{nominal}} \int_{t_0}^{t_0+t} I_{bat}(d\tau) 100\%, \quad (2.2)$$

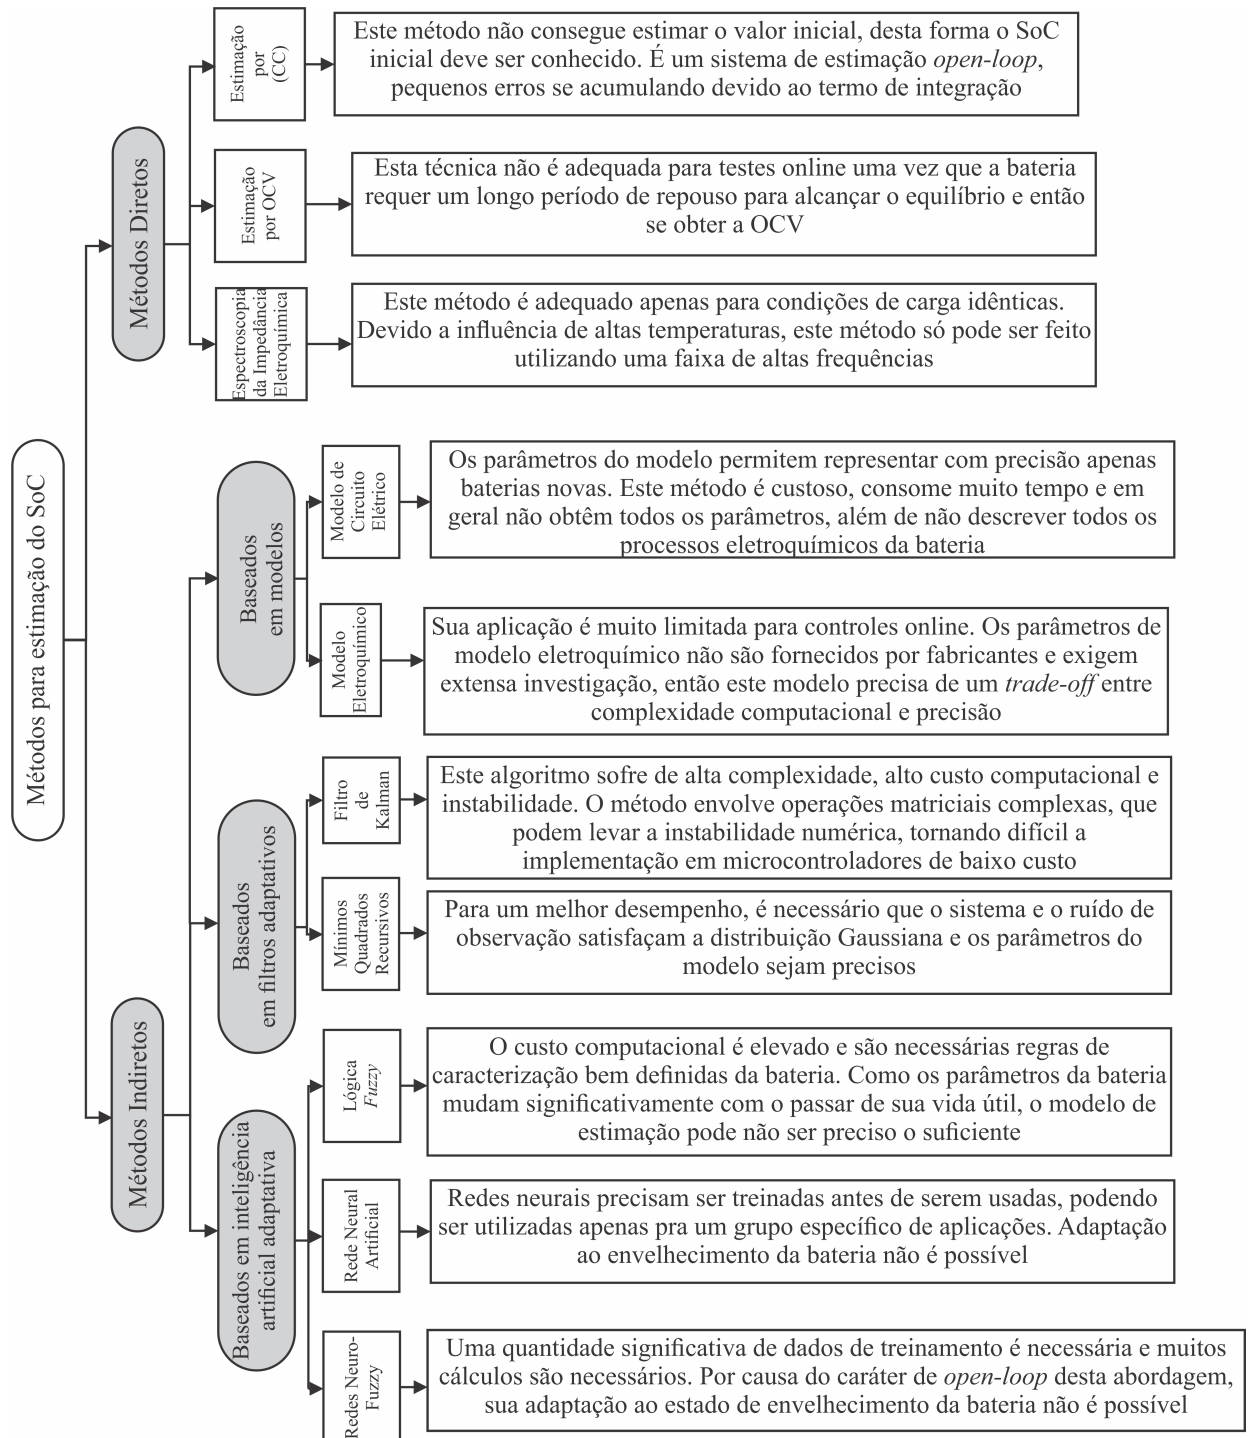
onde $SoC(t_0)$ é o SoC inicial, $Q_{nominal}$ é a capacidade nominal e I_{bat} é a corrente de carga e descarga. O método CC é simples, mas possui como problema o erro de valor inicial e erros acumulados. Por esta razão, ele é comumente utilizado em conjuntos com outras técnicas que corrigem o problema de valor inicial.

O envelhecimento é uma condição crucial para a aplicação deste método, uma vez que a estimação por CC não tem a capacidade de acompanhar as mudanças provenientes da deterioração das baterias devido ao envelhecimento.

Métodos de estimação de SoC geralmente utilizam uma caracterização da curva de OCV, principalmente por meio do uso de um polinômio ou *look-up tables*, uma vez que eles usam um método de inversão direta da curva OCV (se a aplicação permitir a medição de tensão de estado estacionário da bateria), ou um método baseado em modelo de bateria

(LAVIGNE *et al.*, 2016). A partir da tensão mensurada dos terminais da bateria, pode ser definida a relação $SoC = f^{-1}(OCV)$, que associa o SoC diretamente ao valor de OCV.

Figura 4 – Classificação dos métodos para estimação do Estado de Carga.



Fonte: (RIVERA-BARRERA; GALEANO; SARMIENTO-MALDONADO, 2017) modificado.

Algumas restrições são impostas à utilização da estimação de SoC via OCV. Os sensores devem ter uma exatidão elevada, uma vez que qualquer alteração na medição da

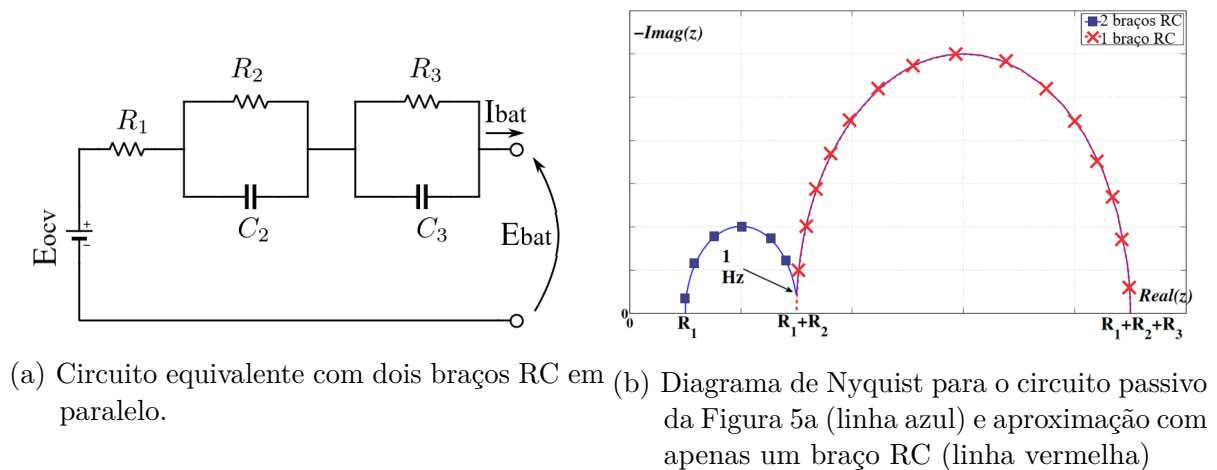
tensão dos terminais da bateria irá influenciar diretamente na estimação do SoC. Outro fator importante é a necessidade de um tempo de repouso para que a bateria alcance sua tensão de equilíbrio, que torna a aplicação deste método inviável em aplicações em tempo real.

Deste modo, a estimação de SoC através da OCV geralmente é utilizada em conjunto com outros métodos, servindo normalmente como um fator de calibração. Por exemplo, em Mejdoubi *et al.* (2016) um método de descarga descontínua para estabelecer a caracterização OCV-SoC é usado para calcular a resistência interna da bateria e, em combinação com o modelo de circuito elétrico e um observador de Kalman estendido, estimam o SoC.

O espectro de impedância eletroquímica ou a característica de resposta de frequência atua como uma impressão digital de uma bateria. A partir do espectro de impedância, os parâmetros de um certo modelo de bateria podem ser obtidos. Então, ao conhecer a impedância eletroquímica, o modelo de bateria pode ser estabelecido (RAHMOUN; LOSKE; ROSIN, 2014).

Um sistema de medição de impedância é obtido a partir de excitações senoidais em diferentes valores de frequência, no qual os valores de tensão e corrente são armazenados e seu quociente complexo é computado como a impedância da bateria. A espectroscopia de impedância de uma bateria pode ser aproximada como dois círculos no plano de Nyquist (BARCELLONA; GRILLO; PIEGARI, 2016). Um exemplo de curva de espectroscopia de impedância e o modelo o qual os dados foram extraídos os dados são ilustrados na Figura 5. Uma das desvantagens deste tipo de modelo é o fato de serem necessários estímulos com sinais com corrente alternada, dificultando a realização de ensaios experimentais. Além disto, extrair as características eletroquímicas de baterias não é uma atividade simples.

Figura 5 – Dados de análise por espectroscopia de impedância.



Fonte: (BARCELLONA; GRILLO; PIEGARI, 2016) modificado.

2.3.2 Métodos Indiretos

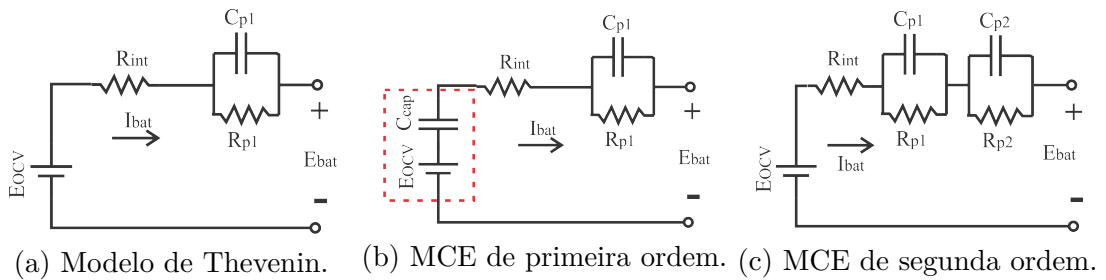
São propostos nestes métodos, a conexão entre os sinais medidos na bateria (tensão, corrente e temperatura) e o SoC da bateria, empregados em um modelo. É fundamental uma alta exatidão do modelo, de modo a capturar as características de uma bateria real e prever seu comportamento sobre uma grande variedade de condições (RIVERA-BARRERA; GALEANO; SARMIENTO-MALDONADO, 2017).

2.3.2.1 Metodologias de Estimação Baseadas em Modelos

Nesta subseção serão descritas algumas metodologias para estimação do SoC baseadas em modelos, sendo elas: Modelo de Circuito Equivalente (MCE) e o Modelo Eletroquímico (EchM).

Existem três MCEs para baterias de Lí-íon amplamente usados devido a seu desempenho dinâmico para estimar o SoC, eles são descritos mais detalhadamente em Wang *et al.* (2017b). As três estruturas de modelo são apresentados na Figura 6.

Figura 6 – Modelos de circuito equivalente.



Fonte: Autor (2018).

O primeiro modelo, apresentado na Figura 6a, é conhecido como modelo de Thevenin RC de primeira ordem, que consiste em uma fonte de tensão não-linear E_{OCV} dada em função do SoC, um capacitor C_{p1} para modelar a capacitância de polarização e efeitos de difusão interno da bateria, uma resistência de difusão R_{p1} , uma resistência interna R_{int} , uma corrente de carga/descarga I_{bat} e uma tensão de terminal E_{bat} (RIVERA-BARRERA; GALEANO; SARMIENTO-MALDONADO, 2017).

O MCE de primeira ordem, ilustrado na Figura 6b, contém os mesmo elementos descritos para o modelo de Thevenin, com a adição de um capacitor C_{cap} que caracteriza a capacidade de armazenamento de carga da bateria e descreve as mudanças na tensão de circuito aberto em função do tempo. Por último, o MCE de segunda ordem consiste na utilização de mais um ramo RC em série com a resistência interna R_{int} e a fonte de tensão não-linear E_{OCV} apresentado no modelo de Thevenin. A quantidade de ramos RC pode ser incrementada para se obter uma melhor aproximação, porém o custo computacional para determinar os parâmetros também é incrementado.

Os EchM são estimadores que determinam o valor do SoC da bateria a partir de um conjunto de equacionamentos relacionados a fenômenos físico-químicos como difusão, intercalação e cinética eletroquímica que ocorrem em uma bateria. Para se desenvolver estes tipos de modelos, é necessário conhecimento específico de eletroquímica, o que em campos da engenharia elétrica e eletrônica não é comum. Exemplos da utilização de EchM podem ser encontrados em Madani, Swierczynski e Kær (2017), Moura *et al.* (2017) e Tran *et al.* (2016).

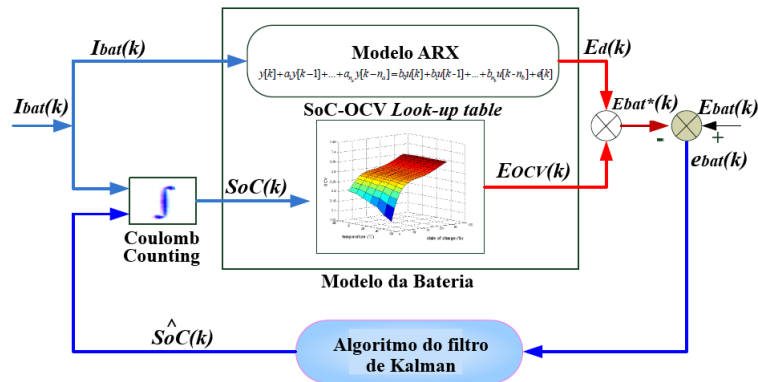
2.3.2.2 Metodologias de Estimação Baseadas em Filtros Adaptativos

Nesta seção, serão apresentadas estratégias de estimação de SoC que têm como princípio a utilização de técnicas adaptativas. Estas técnicas geralmente contêm em sua metodologia uma realimentação para ajuste dos parâmetros de saída de acordo com a variação na entrada (KHAYAT; KARAMI, 2016). De modo que, em geral são combinações de métodos diretos de estimação com métodos baseados em modelos.

O Filtro de Kalman (FK) compreende um conjunto de equações que são avaliadas recursivamente conforme o sistema opera (GJENGEDAL; VIE; MOLINAS, 2017). A implementação do FK compreende dois passos. Primeiramente, o modelo da bateria é desenvolvido para reproduzir com maior exatidão o comportamento real do dispositivo. Este passo é concluído ao se gerar as equações de espaço de estados do modelo (CIORTEA *et al.*, 2017).

Baseado no erro entre a saída da tensão do modelo desenvolvido e a tensão mensurada, o FK ajusta os parâmetros do SoC para mudar a saída de tensão do modelo, tendo como objetivo, minimizar o erro de tensão. Um exemplo da utilização do FK na estimação do SoC é ilustrado na Figura 7, na qual são combinadas as técnicas de Coulomb Counting, modelos Auto Regressivos com Entradas Externas (*Autoregressive with External Input* - ARX) e o próprio FK.

Figura 7 – Diagrama do algoritmo de estimação de SoC baseado em FK.



Fonte: (YUAN; WU; YIN, 2013).

Outro método que possui como base a utilização de filtros adaptativos são os Mínimos Quadrados Recursivos (MQR). Este método calcula parâmetros do sistema que minimizam o erro quadrático mínimo entre o sinal de saída mensurado e o sinal de saída estimado, assumindo que o sistema é perturbado por um ruído branco.

O MQR é usado em filtros adaptativos para encontrar os coeficientes do filtro que permitem a obtenção do mínimo quadrado para o sinal de erro (definido pela diferença entre o sinal desejado e o sinal produzido na saída do filtro). O algoritmo do MQR realiza este procedimento recursivamente e atualiza os valores dos parâmetros estimados incorporando novas informações proveniente de cada amostra de tempo (RIVERA-BARRERA; GALEANO; SARMIENTO-MALDONADO, 2017).

2.3.2.3 Metodologias de Estimação Baseadas em Inteligência Artificial Adaptativa

Por fim, são referenciadas as técnicas utilizadas para estimação de SoC baseadas em inteligência artificial adaptativa. Sendo elas: Lógica *Fuzzy* (LF), RNAs e Sistemas de Inferência Neuro-Difuso Adaptativo (do inglês, *Adaptive Neuro-Fuzzy Inference System - ANFIS*).

Dentre as técnicas de inteligência artificial, uma das primeiras abordagens que podem ser citadas estão os modelos baseados em LF. Nestes modelos, são utilizadas regras objetivas para encontrar o valor real da entrada, sendo uma metodologia de resolução de problemas que simplifica todos os dados de entrada ruidosos, vagos, ambíguos ou imprecisos (KHAYAT; KARAMI, 2016).

Modelos de LF têm sido usados na estimação de SoC principalmente para a identificação de baterias a partir de dados obtidos da espectroscopia de impedância eletroquímica como em Salkind *et al.* (1999), Singh, Jr e Reisner (2004), e em menor grau, diretamente de medições de tensão ou corrente de descarga. Salkind *et al.* (1999) propõe um estimador de SoC baseado em modelos Fuzzy para dois sistemas de armazenamento de baterias: dióxido de lítio/enxofre e hidreto de níquel/metálico. Neste estimador, a relação entre o componente imaginário da impedância em 10,3 Hz, 41,01 Hz e 4101 Hz e o SoC da célula são modelados usando um sistema Fuzzy de Sugeno ¹ (BURGOS *et al.*, 2015).

Outra alternativa na implementação de modelos de bateria remete a utilização de RNAs. RNAs são ferramentas de aprendizagem de máquina inteligente que vem sendo usadas em várias aplicações como modelagem de sistemas, classificação e controle. Compreendem sistemas computacionais formados por unidades de processamento massivamente conectadas, essas unidades são chamadas de neurônios artificiais, os quais podem ser modelados com uma função não-linear aplicada a uma soma de produtos onde cada neurônio

¹ O modelo fuzzy Takagi-Sugeno (TS) consiste em um sistema de inferência capaz de descrever, de forma exata ou aproximada, sistemas dinâmicos não-lineares por meio de um conjunto de sistemas dinâmicos lineares, localmente válidos, interpolados de forma suave, não-linear e convexa (MOZELLI, 2008).

é multiplicado pelo seu respectivo peso (SOUSA *et al.*, 2016).

RNAs são adaptativas, possuem auto aprendizagem e podem aproximar vários sistemas não-lineares. Este estimador não requer nenhum conhecimento físico do sistema modelado, o que o torna uma boa alternativa para sistemas complexos. Entretanto, como uma ferramenta de auto aprendizagem, RNAs necessitam de dados dos quais ele possa aprender. A quantidade de dados de treinamento requeridos é frequentemente dependente da complexidade do sistema modelo (ISMAIL *et al.*, 2017). Em Park, Zhang e Moura (2017) por exemplo, rede neurais são utilizadas em conjunto com princípio de modelos eletroquímicos para modelagem de sistemas de baterias.

Um sistema híbrido desenvolvido em Jang (1993), propõe a utilização de RNA para treinamento e LF para realizar relações entre a entrada e saída do sistema. Este método é conhecido como ANFIS.

Esta metodologia pode identificar sistemas não-lineares, e como resultado, a rede pode aproximar os dados de entrada e saída do sistema. ANFIS reúne ambas vantagens de identificação por LF e RNA. Ele utiliza menos épocas computacionais que redes neurais para sistemas não-lineares com alta confiabilidade, também podendo ser usado para controlar a saída de sistemas de previsão online (MARTINS; ARAÚJO, 2015).

Neste capítulo foram apresentados conceitos básicos sobre baterias, assim como revisões sobre sistemas com a capacidade de gerencia-las. Por fim, foram expostas as mais diversas técnicas e metodologias para estimação do SoC de baterias. A começar por estratégias que determinam o SoC de forma direta como Coulomb Counting, até técnicas indiretas como Filtros de Kalman e Redes Neurais Artificiais, onde foram descritas algumas vantagens e desvantagens na utilização de cada metodologia. É apresentado na Tabela 3 um resumo das técnicas descritas neste capítulo com suas respectivas vantagens e desvantagens de implementação.

Analisando-se as restrições de implementações dos modelos estudados na revisão bibliográfica, neste trabalho é proposto a utilização de RNAs do tipo NARX empregada na estimação do SoC para baterias de Lí-íon visando a construção de modelos para serem embarcados em hardware de baixo custo, além das vantagens atreladas à redução do custo computacional.

No próximo capítulo, são apresentadas as principais características das RNAs e NARXs, assim como suas estruturas de rede básicas, funções de ativação e metodologias de treinamento.

Tabela 3 – Tabela de méritos para as topologias de estimação do SoC.

Estimação por CC	Vantagens	Fácil implementação.
	Desvantagens	Este método não estima o valor inicial, então o SoC necessita ser conhecido.
Estimação por OCV	Vantagens	O modelo pode ser bastante preciso.
	Desvantagens	Esta técnica não é factível para aplicações online, uma vez que é requerido um longo período de repouso para estimação do SoC.
Espectroscopia de Impedância Eletroquímica	Vantagens	Permite uma simplificação dos parâmetros do Modelo de Circuito Elétrico da bateria.
	Desvantagens	Viável apenas para condições de carga/descarga idênticas as utilizadas para estimação.
Modelo de Circuito Equivalente	Vantagens	Esse modelo é bastante preciso e pode aumentar significativamente a identificação do comportamento dinâmico não-linear da bateria.
	Desvantagens	O modelo é capaz de parametrizar com precisão apenas baterias novas, tendo uma implementação dispendiosa e que requer uma análise custo benefício.
Modelo Eletroquímico	Vantagens	Previsão de comportamentos da bateria como temperatura.
	Desvantagens	Parâmetros eletroquímicos geralmente não são fornecidos por fabricantes e são difíceis de serem obtidos.
Filtro de Kalman	Vantagens	Em sua implementação é capaz de prever variações em função da temperatura.
	Desvantagens	Alta complexidade, elevado custo computacional e instabilidade.
Mínimos Quadrados Recursivos	Vantagens	Pode ser implementado para estimação dinâmica em tempo real de parâmetros do Modelo de Circuito Equivalente.
	Desvantagens	É necessário que o sistema e o ruído de observação satisfaçam a distribuição Gaussiana.
Lógica Fuzzy	Vantagens	Simplifica todos os parâmetros e efeitos eletroquímicos da bateria em regras.
	Desvantagens	Incapaz de prever modificações decorrentes de degradação e redução de vida útil.
Rede Neural Artificial	Vantagens	Não necessita de conhecimento específico do sistema, capacidade de modelar sistema com não-linearidade elevada.
	Desvantagens	Necessita de uma elevada quantidade de dados de treinamento para uma aproximação aceitável.
Redes Neuro-Fuzzy	Vantagens	Simplifica todos os parâmetros e efeitos eletroquímicos da bateria em regras.
	Desvantagens	Necessita de uma elevada quantidade de dados de treinamento para uma aproximação aceitável.

3 Redes Neurais Artificiais (RNAs)

Neste capítulo, serão apresentados os conceitos fundamentais sobre Redes Neurais Artificiais. Inicialmente, é feita uma descrição histórica a respeito da origem das redes neurais, seguida por sua base biológica, seus elementos básicos, arquiteturas de rede e metodologias de treinamento.

3.1 Breve Histórico

Em 1943, o psiquiatra e neuroanatomista Warren Mc Culloch e o matemático Walter Pitts desenvolveram uma máquina inspirada no cérebro humano e um modelo matemático de neurônio biológico artificial denominado *Psychon*. Entretanto, este modelo não era capaz de desempenhar uma de suas principais tarefas: o aprendizado (VELLASCO, 2007).

Em 1958, Frank Rosenblatt e Charles Wightman desenvolveram o primeiro neuro-computador bem sucedido. Estes estudos sustentaram os modelos do tipo *perceptron* (rede de uma camada) e o *Multilayer Perceptron* (MLP).

Em 1986, foi desenvolvida a teoria de redes MLP treinadas com o algoritmo de aprendizado por retro propagação (*Backpropagation*) desenvolvida por Rumelhart, Hinton e Willians. Além disso, com avanços no desenvolvimento de computadores com processamento e desempenho cada vez mais rápidos, observam-se melhorias nas simulações das redes neurais.

Dentre os principais marcos na pesquisa e evolução da RNA dos anos 2000 até o momento podem ser citadas (ACADEMY., 2018):

- Em meados de 2000 o termo “aprendizagem profunda” (*deep learning*) ganha popularidade após um artigo de Geoffrey Hinton e Ruslan Salakhutdinov mostrar como uma rede neural de várias camadas poderia ser pré-treinada uma camada por vez;
- Em 2009 acontece o Workshop sobre Aprendizagem Profunda para Reconhecimento de Voz. É descoberto que, com um conjunto de dados suficientemente grande, as redes neurais não precisam de pré-treinamento e as taxas de erro caem significativamente;
- Em 2012, algoritmos de reconhecimento de padrões artificiais alcançam desempenho de nível humano em determinadas tarefas;
- Em 2017 ocorre a adoção em massa do *Deep Learning* em diversas aplicações corporativas e *mobile*.

3.2 Base Biológica

O cérebro é especialista em desempenhar funções como reconhecimento de padrões, controle motor, percepção, inferência, etc. As unidades básicas de processamento do cérebro são os neurônios, de forma que estão conectados uns aos outros através de conexões sinápticas. Acredita-se que a capacidade das sinapses serem moduladas é a principal base para todos os processos cognitivos, como percepção, raciocínio e memória (SILVA, 1998).

Neurônios biológicos possuem três tipos de componentes que são particularmente fundamentais para o entendimento de RNAs, são eles: Dendritos, Soma e Axônio. Suas funcionalidades são descritas na Tabela 4.

Tabela 4 – Principais estruturas de um neurônio biológico.

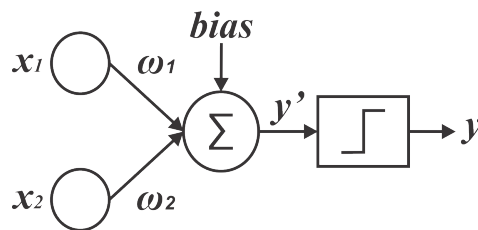
Dendritos	Estes elementos recebem sinais provenientes de outros neurônios. Os sinais são impulsos elétricos que são transmitidos através de uma lacuna sináptica por meio de processos químicos.
Soma	O soma, ou corpo celular, realiza um somatório dos sinais recebidos. Quando uma quantidade suficiente de entradas é recebida, a célula “dispara”, isto é, ela transmite um sinal por meio de seu axônio para outros neurônios.
Axônio	É através do axônio que os impulsos elétricos são retransmitidos para os próximos neurônios da rede neural.

Fonte: (FAUSETT *et al.*, 1994).

3.3 O Neurônio Genérico

Na Figura 8, é ilustrado o modelo de um neurônio simples, conhecido como *perceptron*, contendo 2 entradas e uma única saída.

Figura 8 – Estrutura de um *perceptron*.



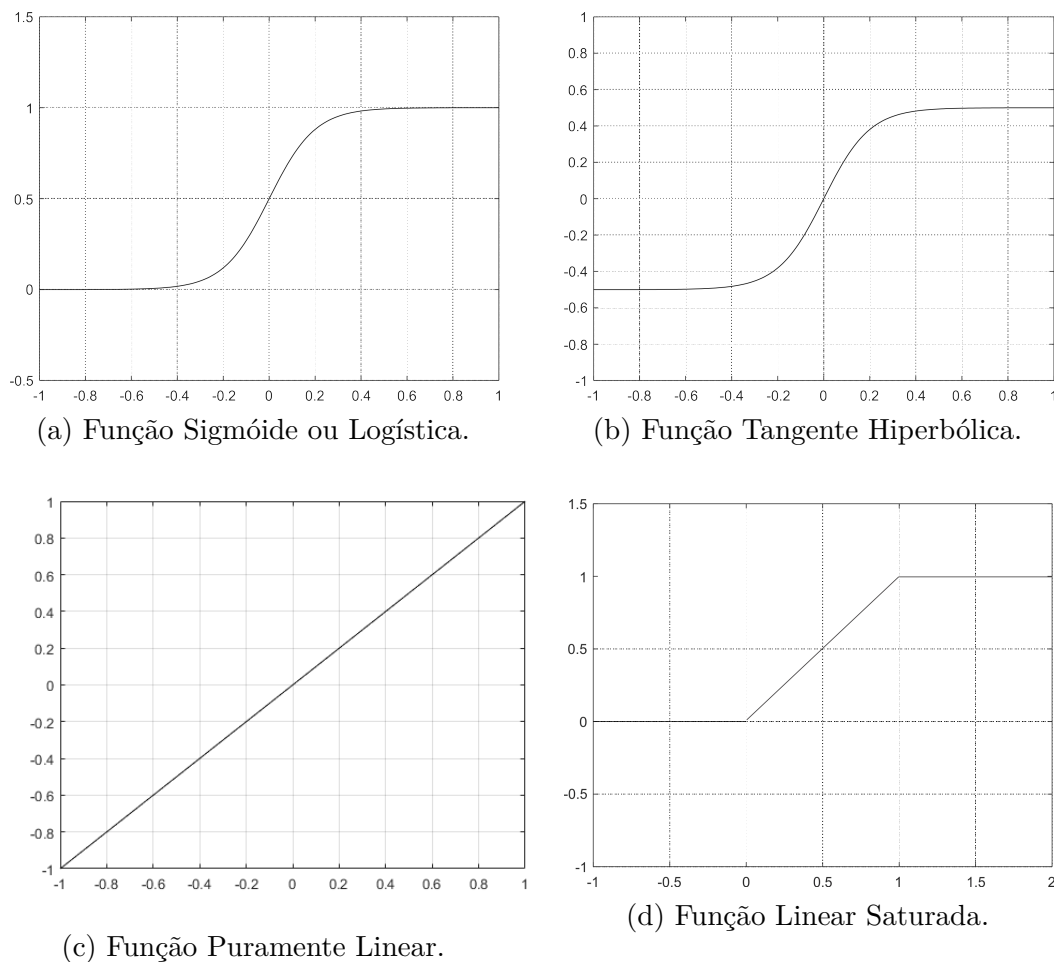
Fonte: Autor (2018).

As entradas x_1 e x_2 são estruturas equivalentes aos dendritos do neurônio biológico, sendo os elementos por onde os sinais provenientes de outros neurônios ou de entradas externas são inicialmente recebidos. Cada entrada é multiplicada por um ponderador, chamado de peso, descrito na Figura 8 por ω_1 e ω_2 . Além das entradas já descritas, o *perceptron* contém uma entrada adicional chamada *bias*, o qual atua como um peso ou

conexão com uma entrada de valor constante que permite uma maior flexibilidade durante o treinamento da rede, elevando o campo de possibilidades para treinamento e busca de uma melhor aproximação.

Todas as entradas juntamente com o *bias* multiplicados por seus respectivos pesos são então somados para gerar uma saída parcial definida por y' . Este termo é então aplicado a uma função chamada de função de ativação. A função de ativação é responsável por passar os sinais das camadas anteriores para a próxima camada. Esta função pode ser implementada de várias formas, sendo as mais difundidas na literatura: Função Sigmóide, Função Tangente Hiperbólica, Função Puramente Linear e Função Linear Saturada. As curvas para cada função de ativação descrita são ilustradas na Figura 9. Os blocos descritos neste parágrafo tem funcionamento análogo ao soma (corpo celular) do neurônio biológico.

Figura 9 – Funções de ativação, eixo horizontal = y' e eixo vertical = $f(y') = y$.



Fonte: Autor (2018).

Após o sinal y' ser aplicado à função de ativação, o sinal de saída y é então transmitido para os neurônios da próxima camada ou para a saída da rede. De modo que, sua função é simular a desempenhada pelo axônio do neurônio biológico. Assim, a saída y

do *perceptron* é dada por:

$$y = f(y') = f(x_1 \times \omega_1 + x_2 \times \omega_2 + bias). \quad (3.1)$$

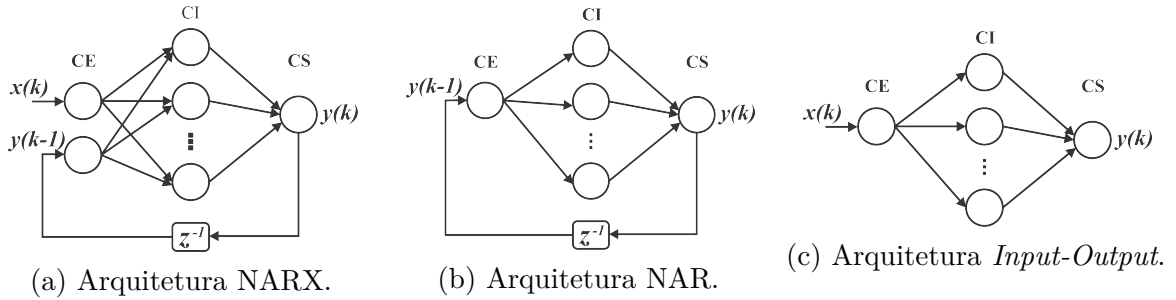
Para um neurônio com i entradas e uma saída, a Equação 3.1 é dada por:

$$y = f(y') = f\left(\sum_{j=1}^i (x_j \times \omega_j) + bias\right). \quad (3.2)$$

3.4 Arquiteturas de Rede

A maioria das RNAs utilizam arquiteturas padronizadas projetadas para resolver classes de problemas específicos. Normalmente, existem três camadas em uma rede neural: camada de entrada (CE), camada intermediária (CI) ou camada escondida e camada de saída (CS). Estas camadas podem ser arranjadas de tal forma a construírem redes do tipo NARX, Auto Regressiva Não-Linear (*Nonlinear Autoregressive* - NAR) ou *Input-Output* Não-Linear. Cada uma destas possíveis arquiteturas são ilustradas na Figura 10.

Figura 10 – Arquiteturas de redes.



Fonte: Autor (2018).

A configuração NARX tem como principal característica a realimentação com valores obtidos na saída da rede, que são somados com entradas externas à rede. Desta forma, a saída é uma função das amostras k das entradas atuais e/ou passadas em conjuntos com as saídas passadas como é descrito na Equação 3.3.

$$y(k) = f(x(k-1), \dots, x(k-n_i), y(k-1), \dots, y(k-n_o)), \quad (3.3)$$

onde n_i e n_o são o número de amostras passadas da entrada e da saída, respectivamente.

A disposição NAR se assemelha a NARX, com ressalva no fato de não haverem entradas externas a rede. Isto é, a rede é realimentada apenas com valores passados da

saída. Sua função de saída é:

$$y(k) = f(y(k-1), \dots, y(k-n_o)). \quad (3.4)$$

Por último, tem-se a configuração *Input-Output* Não-Linear. Nesta estrutura, não existe realimentação da rede e sua saída é dada apenas em função de entradas externas. Sua função de saída é dada pela Equação 3.5.

$$y(k) = f(x(k-1), \dots, x(k-n_o)) \quad (3.5)$$

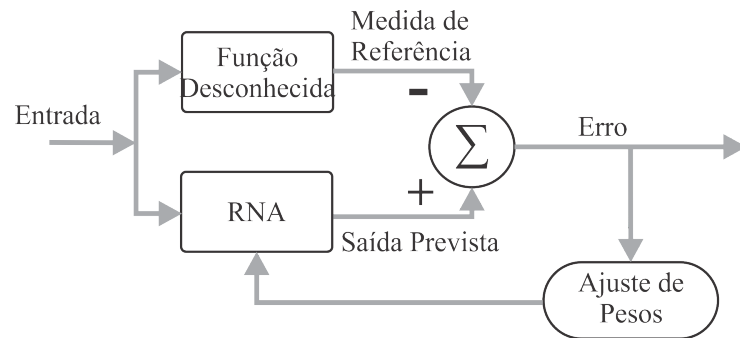
3.5 Topologias de Treinamento

Uma das formas mais comuns de se categorizar uma rede neural é pela metodologia de aprendizagem, que é uma das principais características que decide à aplicabilidade e usabilidade da rede para uma tarefa específica (ISMAIL *et al.*, 2017). Os métodos de aprendizagem mais utilizados para realizar o treinamento das redes neurais são: Supervisionado e Não-Supervisionado. Neste trabalho serão explicados apenas os conceitos a respeito do primeiro método de treinamento, uma vez que os procedimentos empregados no desenvolvimento das redes propostas se restringiram ao Método Supervisionado.

O modo de treinamento supervisionado utiliza um algoritmo de aprendizagem em que a rede é alimentada com valores de entrada e saída oriundos de um banco de dados desenvolvido previamente. De modo que, com estes dados a rede desenvolve um modelo que tenha a capacidade de gerar saídas condizentes com os valores desejados quando alimentada com entradas que compreendam a faixa de valores utilizada no treinamento.

Caso os dados de entrada não façam parte do grupo utilizado durante a aprendizagem, mas estejam dentro da faixa de valores para a qual a rede foi treinada, ela realiza generalização do conceito apreendido para determinar qual valor deve ser gerado na saída da RNA, sendo capaz de fornecer resultados a partir de uma nova entrada inédita. Alguns exemplos de aprendizagem supervisionada são: *Feedforward Neural Network* (FFNN), *Radial Basis Function* (RBF), *Learning Vector Quantization* (LVQ) e *Dynamic Neural Network* (DNN). No fluxograma da Figura 11 é ilustrado o procedimento de treinamento supervisionado.

Figura 11 – Fluxograma de aprendizagem supervisionada.



Fonte: (HUSSEIN, 2017) modificado.

As entradas são aplicadas a RNA e, a partir da saída da rede, é determinado o erro entre os valores previstos pela rede e os valores reais dados pelo banco de dados de treinamento. A partir do erro, são efetuados ajustes por meio da minimização do erro quadrático nos pesos ω dos neurônios de cada camada da rede, e sua saída é novamente gerada. Este procedimento é realizado até que seja alcançado um valor de tolerância de erro pré-estabelecido pelo projetista da rede.

4 Método Proposto para Estimação do SoC

Nesse capítulo é discutido o problema da estimação do SoC para baterias de Li-íon. Primeiramente, é apresentada a problemática a respeito da implementação de estimadores do SoC. Em seguida, para a solução do problema, é proposto o desenvolvimento de uma metodologia de implementação de redes NARX.

4.1 Problemática

A utilização de bancos de baterias em aplicações de sistemas isolados de energia (*off-grid*), sistemas de geração de energia elétrica que demandam armazenamento de energia (parques eólicos ou sistemas fotovoltaicos) e aplicações do setor automotivo (EVs, HEVs, BEVs, PEVs) necessitam de BMSs de baterias capazes de efetuar estimações do SoC que possuam em suas características, robustez aliada à implementação com mínimo esforço computacional.

Uma determinação errônea em sistemas de armazenamento de energia pode resultar em uma acumulação de energia insuficiente, acarretando em uma possível falta de carga em momentos nos quais o sistema de geração venha a reduzir sua produção. Por outro lado, ao ser gerada uma quantidade de energia acima dos limites de segurança das baterias, é possível que a mesma produza reações químicas que resultem em super aquecimento ou explosão.

Em aplicações de veículos elétricos em geral, a exatidão dos resultados gerados pelo estimador de SoC é o diferencial na segurança, assim como na confiabilidade da autonomia do veículo.

Com resultados exatos do estado atual de carga das baterias que alimentam o inversor de frequência, o BMS do automóvel pode estimar com mais exatidão dados como a quantidade de quilômetros os quais ele ainda está apto a percorrer (autonomia).

Levando-se estes dados em consideração, na literatura é sempre dado enfoque em desenvolver modelos de estimação que apresentem em sua metodologia uma exatidão o mais elevada possível como em Yuan, Wu e Yin (2013), Ciortea *et al.* (2017) ou Wang *et al.* (2017a), onde são obtidos erros de aproximação do SoC nos valores de 0,47%, 2%, e 2%, respectivamente. Porém estes métodos utilizam metodologias baseadas em filtros adaptativos que estimam o SoC utilizando FK, que possui como principais desvantagens a alta complexidade e alto custo computacional.

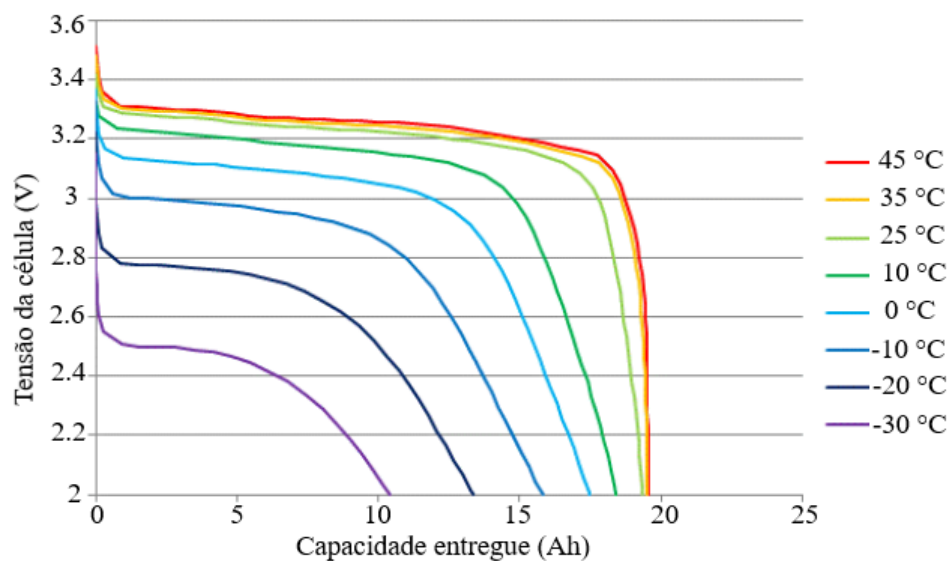
Com o alto custo de implementação computacional, a implantação destes métodos não pode ser embarcada em placas de desenvolvimento com um processamento mais

limitado. Assim, suas utilizações se restringem a placas mais robustas, elevando assim o custo total do desenvolvimento.

Outro fator observado frequentemente é a não utilização do parâmetro de temperatura da bateria ao se estimar o SoC. Isto limita à aplicação dos modelos obtidos pra um único valor de temperatura. Isso se dá pelo fato das baterias apresentarem uma variação considerável em sua curva de descarga em função da temperatura como pode ser visto na Figura 12, na qual é possível observar o comportamento das curvas de descarga a corrente constante de 19,5 A para uma bateria de Li-íon modelo AMP20 para várias temperaturas distintas.

É possível constatar que, para um mesmo valor de corrente de descarga, baterias expostas a temperaturas mais baixas apresentam uma redução na capacidade entregue. Isto faz com que o tempo de descarga da bateria seja reduzido, fazendo com que o SoC chegue mais rapidamente a 0%, diminuindo assim o seu tempo de utilização.

Figura 12 – Curvas de descarga de células AMP20.



Fonte: (A123 SYSTEMS, 2014) modificado.

4.2 Método proposto

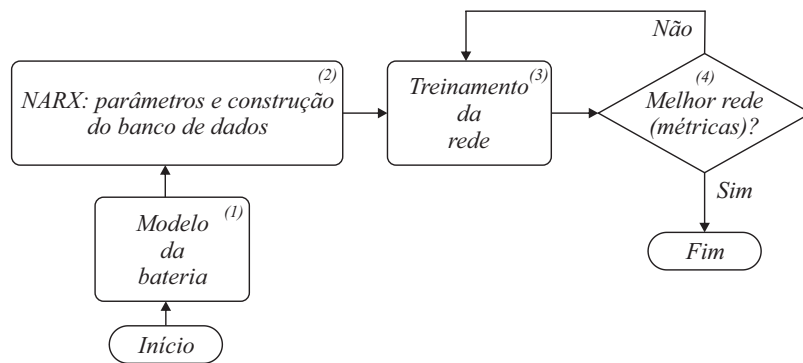
A utilização de redes neurais para a determinação do SoC de baterias é uma prática amplamente empregada na literatura. Em Ismail *et al.* (2017), é aplicada uma metodologia na qual são utilizadas como entradas da rede a tensão e corrente no instante atual, assim como tensão e corrente no instante anterior para se obter como saída o SoC de uma bateria de Li-íon genérica. De modo que, este modelo não é capaz de prever com exatidão o SoC para valores de temperatura ambiente diferentes do valor utilizado durante o processo de

treinamento da RNA.

Em Sousa *et al.* (2016), três redes neurais foram desenvolvidas para determinar o valor de SoC utilizando como informação os valores de tensão, corrente e valores atuais e anteriores do SoC. Novamente os dados de entrada da rede não consideram dados de temperatura ambiente, apesar de neste trabalho ser adotada uma nova variável de entrada para a rede, o SoC da bateria.

Como proposta para este trabalho, foram desenvolvidas redes NARX, uma vez que esta estrutura de rede neural é capaz de receber entradas externas além de realimentações dos sinais de saída, desta forma criando um sistema em malha fechada (*closed-loop*). É descrito no diagrama de blocos da Figura 13, a estrutura para desenvolvimento do método proposto neste trabalho. Cada um dos blocos apresentados neste diagrama são descritos mais detalhadamente nas próximas seções.

Figura 13 – Estrutura para desenvolvimento do método proposto.

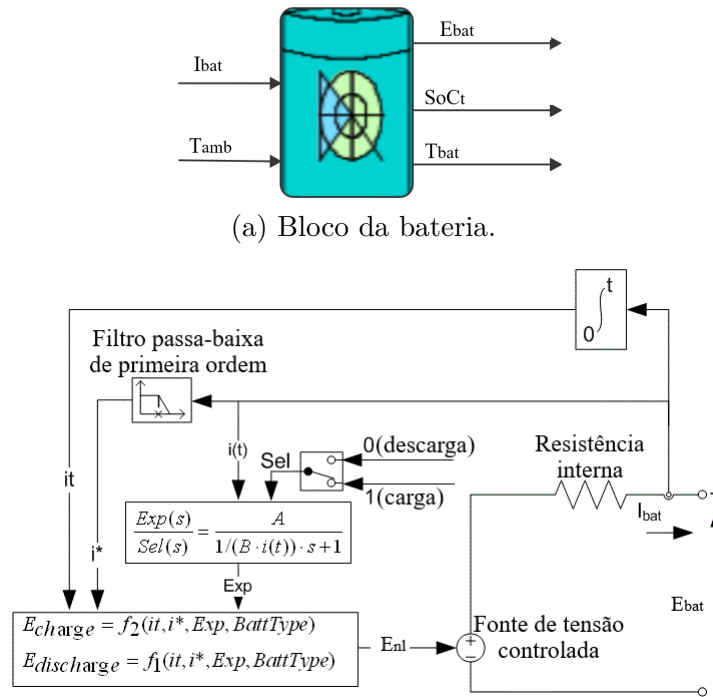


Fonte: Autor (2018).

4.2.1 Modelo da Bateria

Levando-se em consideração o fato da necessidade de uma grande quantidade de dados para se ter um treinamento correto da rede, e considerando a quantidade de tempo demandada para um único ensaio ser de no mínimo duas horas, os ensaios para treinamento foram substituídos por simulações na ferramenta computacional Matlab/Simulink®. Para tal, a bateria escolhida para desenvolvimento do modelo de estimação de SoC foi a bateria de lítio óxido de cobalto (LiCoO₂) disponível no Simulink. Este tipo de bateria é utilizada para aplicações em *smartphones*, *tablets*, notebooks e câmeras. Sua estrutura é descrita na Figura 14.

Figura 14 – Modelo de bateria disponibilizado pelo Matlab/Simulink[®].



(b) Diagrama de implementação do modelo.

Fonte: (MATHWORKS, 2008) modificado.

Este modelo de bateria possui como entradas corrente e temperatura ambiente, e em sua saída são fornecidos os valores de tensão dos terminais (E_{bat}), SoC teórico e temperatura interna da bateria (T_{bat}).

Para baterias do tipo Li-íon, o modelo usa a Equação 4.1 para o modelo de descarga ($i^* > 0$) e a Equação 4.2 para o modelo de carga ($i^* < 0$).

$$f_1(it, i^*, I_{bat}) = E_0 - K \cdot \frac{Q_{max}}{Q_{max} - it} \cdot i^* - K \cdot \frac{Q_{max}}{Q_{max} - it} \cdot it + A_{exp} \cdot \exp(-B_{exp} \cdot it) \quad (4.1)$$

$$f_2(it, i^*, I_{bat}) = E_0 - K. \frac{Q_{max}}{it + 0, 1.Q_{max}}.i^* - K. \frac{Q_{max}}{Q_{max} - it}.it + A_{exp}.exp(-B_{exp}.it) \quad (4.2)$$

Nestas equações:

- E_{nl} é a tensão não-linear, em volts;
- E_0 é a tensão constante, em volts;
- $Exp(s)$ é a dinâmica da zona exponencial, em volts;

- $Sel(s)$ representa o modo da bateria. $Sel(s) = 0$ durante a descarga da bateria, $Sel(s) = 1$ durante a carga da bateria;
- K é a constante de polarização em volt por ampères-hora, ou resistência de polarização, em ohms;
- i^* é a dinâmica de corrente em baixas frequências, em ampères;
- I_{bat} é a corrente da bateria, em ampères;
- it é a capacidade extraída, em ampères;
- Q_{max} é a capacidade máxima da bateria, em ampères hora;
- A_{exp} é a tensão exponencial, em volts;
- B_{exp} é a capacidade exponencial, em ampères-hora elevado a -1.

Os efeitos da temperatura nos parâmetros do modelo são representados pelas Equações 4.3, 4.4, para o modelo de descarga ($i^* > 0$) e Equações 4.5, 4.6, para o modelo de carga ($i^* < 0$).

$$f_1(it, i^*, I_{bat}, T_{bat}, T_{amb}) = E_0(T_{bat}) - K(T_{bat}) \cdot \frac{Q(T_{amb})}{Q(T_{amb}) - it} \cdot (i^* + it) + A_{exp} \cdot \exp(-B_{exp} \cdot it) - D \cdot it \quad (4.3)$$

$$E_{bat}(T_{bat}) = f_1(it, i^*, I_{bat}, T_{bat}, T_{amb}) - R(T_{bat}) \cdot I_{bat} \quad (4.4)$$

$$f_1(it, i^*, I_{bat}, T_{bat}, T_{amb}) = E_0(T_{bat}) - K(T_{bat}) \cdot \frac{Q(T_{amb})}{it + 0,1 \cdot Q(T_{amb})} \cdot i^* - K(T_{bat}) \cdot \frac{Q(T_{amb})}{Q(T_{amb}) - it} \cdot it + A_{exp} \cdot \exp(-B_{exp} \cdot it) - D \cdot it \quad (4.5)$$

$$E_{bat}(T_{bat}) = f_1(it, i^*, I_{bat}, T_{bat}, T_{amb}) - R(T_{bat}) \cdot I_{bat}, \quad (4.6)$$

com

$$E_0(T_{bat}) = E_0|_{T_{ref}} + \frac{\partial E_{bat}}{\partial T_{bat}}(T_{bat} - T_{ref}) \quad (4.7)$$

$$K(T_{bat}) = K|_{T_{ref}} \cdot \exp\left(\alpha \left(\frac{1}{T_{bat}} - \frac{1}{T_{ref}}\right)\right) \quad (4.8)$$

$$Q(T_{amb}) = Q|_{T_{amb}} + \frac{\Delta Q}{\Delta T_{bat}} \cdot (T_{amb} - T_{ref}) \quad (4.9)$$

$$R(T_{bat}) = R|_{T_{ref}} \cdot \exp \left(\beta \left(\frac{1}{T_{bat}} - \frac{1}{T_{ref}} \right) \right), \quad (4.10)$$

onde:

- T_{ref} é a temperatura nominal, em Kelvins;
- T_{bat} é a temperatura interna da bateria, em Kelvins;
- E_{bat}/T_{bat} é o coeficiente de temperatura de tensão reversível;
- α é a taxa de Arrhenius para a resistência de polarização;
- β é a taxa de Arrhenius para a resistência interna;
- $\Delta Q/\Delta T_{bat}$ é o coeficiente de temperatura na capacidade máxima, em ampères-hora por Kelvin;
- D é a inclinação da curva de descarga nominal, em volts por ampère-hora.

A temperatura interna da bateria, T_{bat} , em qualquer tempo t é expressa por:

$$T_{bat}(t) = L^{-1} \left(\frac{P_{loss} R_{th} + T_{amb}}{1 + s \cdot t_c} \right). \quad (4.11)$$

Para esta equação se têm as variáveis:

- R_{th} igual a resistência térmica da bateria para com o ambiente em °C por watts;
- t_c igual a constante de tempo térmico em segundos;
- P_{loss} igual ao calor global gerado, em watts, durante o processo de carga/descarga, dado por:

$$P_{loss} = (E_0(T_{bat}) - E_{bat}(T_{bat})) \cdot I_{bat} + \frac{\partial E_{bat}}{\partial T_{bat}} \cdot I_{bat} \cdot T_{bat}. \quad (4.12)$$

Os parâmetros da bateria utilizada são descritos na Tabela 5.

4.2.2 NARX: Parâmetros e Construção do Banco de Dados

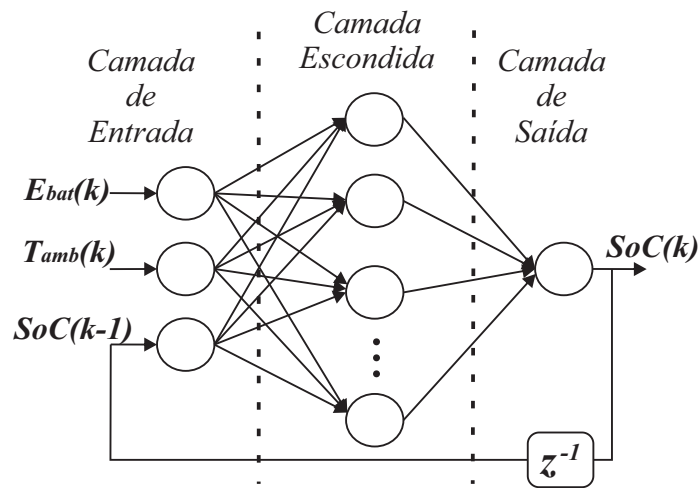
Para implementação da NARX, foram utilizados como parâmetros de entrada da rede os valores de tensão dos terminais da bateria no instante atual, a temperatura ambiente a qual a bateria está submetida também no instante atual e uma entrada realimentada contendo o valor do SoC do instante anterior. Estes dados de entrada foram utilizados para gerar como saída o SoC no instante atual. Na Figura 15, é ilustrada a estrutura base para o desenvolvimento das redes utilizadas neste trabalho.

Tabela 5 – Parâmetros da bateria.

Tipo	Lítio Óxido de Cobalto (LiCoO ₂)
Tensão nominal	3,350 V
Capacidade nominal	2,050 Ah
Tensão de corte	2,513 V
Tensão de carga completa	4,200 V
Resistência interna	16,500 mΩ
Capacidade na tensão nominal	1,810 Ah
Tensão de zona exponencial	3,710 V
Capacidade de zona exponencial	0,600 Ah
Resistência térmica	0,060 °C/W
Constante de tempo térmico	1000 s

Fonte: Autor (2018).

Figura 15 – Estrutura base da rede proposta.



Fonte: Autor (2018).

Foram desenvolvidas seis topologias de redes utilizando algumas das estruturas e funções de ativações descritas nas Seções 3.3 e 3.4, a fim de serem realizadas comparações entre as mesmas. Resumem-se nas Tabelas 6 a 8 as estruturas das doze redes desenvolvidas. Cada rede foi nomeada de acordo com suas características inerentes, de modo que são descritas por três campos distintos na forma RNA-“Autor que propôs”-“Função de ativação utilizada”. No segundo campo, o termo “P” significa proposto, ou seja, sugerido neste trabalho. Por outro lado, os termos “ISA” e “ICA” significam Ismail sem atraso e Ismail com atraso, respectivamente.

Tabela 6 – Especificações RNAs propostas neste trabalho.

RNA-P-S	
Entradas	$V(k)$, $T_{amb}(k)$ e $SoC(k-1)$
Saídas	$SoC(k)$.
Função de ativação camada escondida	Sigmóide
Função de ativação camada de saída	Puramente Linear
RNA-P-TH	
Entradas	$V(k)$, $T_{amb}(k)$ e $SoC(k-1)$
Saídas	$SoC(k)$
Função de ativação camada escondida	Tangente Hiperbólica
Função de ativação camada de saída	Puramente Linear
RNA-P-LS	
Entradas	$V(k)$, $T_{amb}(k)$ e $SoC(k-1)$
Saídas	$SoC(k)$
Função de ativação camada escondida	Linear Saturada
Função de ativação camada de saída	Puramente Linear
RNA-P-PL	
Entradas	$V(k)$, $T_{amb}(k)$ e $SoC(k-1)$
Saídas	$SoC(k)$
Função de ativação camada escondida	Puramente Linear
Função de ativação camada de saída	Puramente Linear

Fonte: Autor (2018).

Tabela 7 – Especificações RNAs propostas por Ismail (sem atrasos).

RNA-ISA-S	
Entradas	$V(k)$ e $I(k)$
Saídas	$SoC(k)$.
Função de ativação camada escondida	Sigmóide
Função de ativação camada de saída	Puramente Linear
RNA-ISA-TH	
Entradas	$V(k)$ e $I(k)$
Saídas	$SoC(k)$
Função de ativação camada escondida	Tangente Hiperbólica
Função de ativação camada de saída	Puramente Linear
RNA-ISA-LS	
Entradas	$V(k)$ e $I(k)$
Saídas	$SoC(k)$
Função de ativação camada escondida	Linear Saturada
Função de ativação camada de saída	Puramente Linear
RNA-ISA-PL	
Entradas	$V(k)$ e $I(k)$
Saídas	$SoC(k)$
Função de ativação camada escondida	Puramente Linear
Função de ativação camada de saída	Puramente Linear

Fonte: Autor (2018).

Tabela 8 – Especificações RNAs propostas por Ismail (com atrasos).

RNA-ICA-S	
Entradas	$V(k), V(k-1), I(k)$ e $I(k-1)$
Saídas	$SoC(k)$
Função de ativação camada escondida	Sigmóide
Função de ativação camada de saída	Puramente Linear
RNA-ICA-TH	
Entradas	$V(k), V(k-1), I(k)$ e $I(k-1)$
Saídas	$SoC(k)$
Função de ativação camada escondida	Tangente Hiperbólica
Função de ativação camada de saída	Puramente Linear
RNA-ICA-LS	
Entradas	$V(k), V(k-1), I(k)$ e $I(k-1)$
Saídas	$SoC(k)$
Função de ativação camada escondida	Linear Saturada
Função de ativação camada de saída	Puramente Linear
RNA-ICA-PL	
Entradas	$V(k), V(k-1), I(k)$ e $I(k-1)$
Saídas	$SoC(k)$
Função de ativação camada escondida	Puramente Linear
Função de ativação camada de saída	Puramente Linear

Fonte: Autor (2018).

Para se obter os dados utilizados na rede, foi necessária a realização de simulações de descarga com corrente pulsada da bateria.

As simulações de corrente pulsada se basearam inicialmente em uma carga da bateria até os 100% de SoC, em seguida é aplicada uma corrente de descarga pulsada de modo que, a cada pulso de descarga, seja reduzido um equivalente de 10% do SoC da bateria. Este procedimento é realizado até que a bateria atinja um SoC de 0% em simulação, porém os dados utilizados para treinamento e validação da topologias apresentadas neste trabalho se resumem a uma faixa de 20% a 80% do SoC.

O Fluxograma para as simulações de corrente pulsada é ilustrado na Figura 16. Na Figura 17, são apresentados exemplos de curvas de corrente, SoC e tensão para as simulações de descarga pulsada, respectivamente.

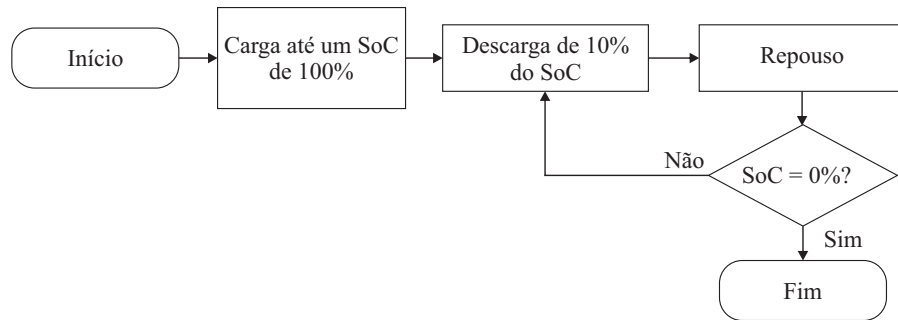
Durante as simulações, os intervalos de repouso foram determinados com base no tempo total demandado para fazer o SoC chegar ao valor de 0%. É representado na Equação 4.13 o tempo total para realizar uma descarga contínua com base na corrente utilizada.

$$t_{desc} = 3600 \times \frac{2,05}{I_{bat}} \times 2, \quad (4.13)$$

onde: t_{desc} representa o tempo de descarga (em segundos) e I_{bat} é a corrente de descarga

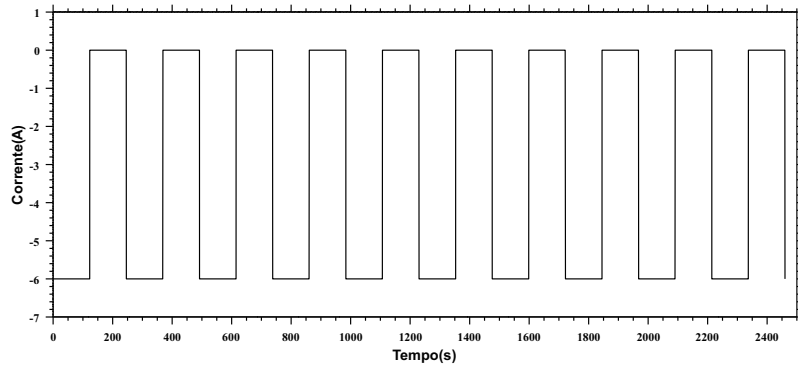
(em ampères) utilizada para a simulação. O valor 2,05 corresponde a capacidade nominal da bateria utilizada. A Equação 4.13 contém uma multiplicação por 2, uma vez que a mesma quantidade de tempo demandada para descarga é também utilizada para o repouso. Para gerar a curva de corrente foi aplicado um bloco gerador de pulso com período $P_{desc} = t_{desc} \times 0,1$ com *duty cycle* de 50%.

Figura 16 – Fluxograma para as simulações de corrente pulsada.

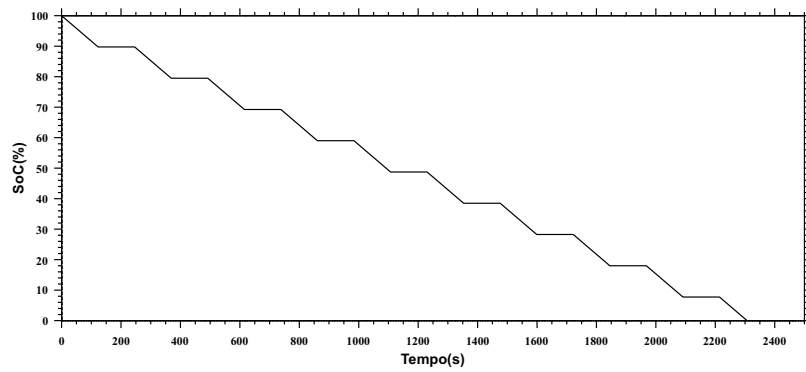


Fonte: Autor (2018).

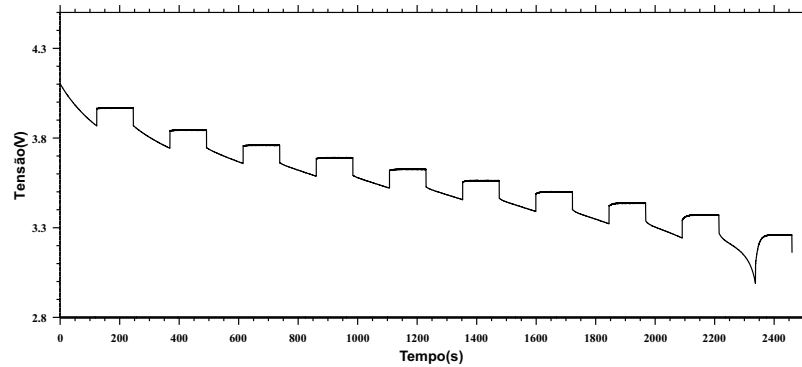
Figura 17 – Curvas para simulações de corrente pulsada.



(a) Corrente de descarga.



(b) SoC.



(c) Tensão dos terminais da bateria.

Fonte: Autor (2018).

Nas simulações de descarga de corrente pulsada, os intervalos de repouso são necessários para que a bateria alcance o equilíbrio termodinâmico e os efeitos de histerese química sejam reduzidos. Este intervalo é de suma importância em metodologias de estimação de SoC que utilizam modelos de circuito equivalente. Pois, longos períodos de repouso acarretam uma aproximação fiel da tensão de circuito aberto, mas apresenta um impacto considerável no tempo de teste em geral.

Os valores de corrente e temperatura utilizados para treinamento da rede são

resumidos na Tabela 9. Utilizaram-se estas faixas de valores na construção do banco de dados por conter uma parcela de valores onde a maioria das baterias de LiCoO_2 com 3,35 V e 2,05 Ah podem atuar.

Tabela 9 – Dados de treinamento da RNA proposta.

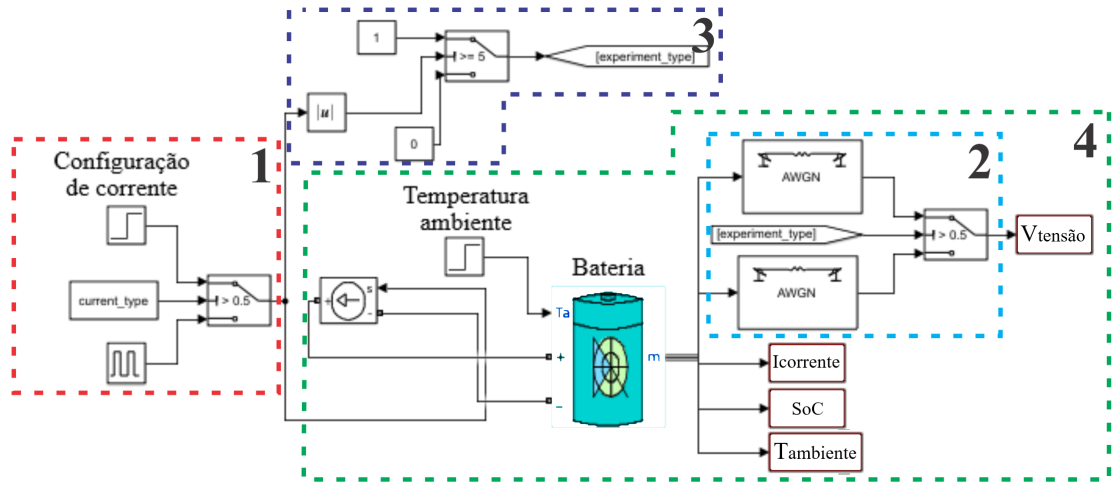
Corrente pulsada	2 A à 10 A com um passo de 2
Temperatura	10 °C à 35 °C com um passo de 5
Simulações para treinamento	30
Simulações para validação	6
Total de simulações	36

Fonte: Autor (2018).

A estrutura montada para obtenção dos dados é ilustrada na Figura 18 e seus principais blocos são descritos a seguir:

1. Neste bloco são geradas as correntes que irão realizar a descarga da bateria, além de selecionar o tipo de simulação, corrente contínua ou corrente pulsada. Para este trabalho, o bloco 1 foi configurado apenas para simulações de corrente pulsada;
2. Bloco responsável por adicionar ruído a tensão dos terminais da bateria. O ruído pode ser de dois tipos: ruído de descarga ou ruído de relaxamento. De modo que, quando a bateria está sob descarga, a tensão recebe um Ruído Gaussiano Branco Aditivo (*Additive White Gaussian Noise* - AWGN) com variância $0,874 \mu\text{V}$. Por outro lado, quando a bateria está em seu tempo de relaxamento, é adicionado um ruído AWGN com variância $23,820 \text{ nV}$. Os valores de variância destes ruídos foram obtidos com base em ensaios experimentais de descarga de baterias de Li-íon realizados em laboratório;
3. Neste bloco o valor de corrente gerado no bloco 1 é utilizado para determinar qual ruído deve ser introduzido na tensão dos terminais da bateria;
4. Aqui se encontra o modelo de bateria disponibilizado pela ferramenta Simulink. Este modelo é baseado nos artigos de Tremblay, Dessaint e Dekkiche (2007), Zhu *et al.* (2013) e Saw *et al.* (2014). Em sua saída, são disponibilizados os valores de tensão dos terminais, temperatura ambiente e interna da bateria além do SoC. Neste bloco também é configurado o valor de temperatura ambiente a qual a bateria estará submetida.

Figura 18 – Diagrama de blocos para simulações de descarga implementados via Simulink.



Fonte: Autor (2018)

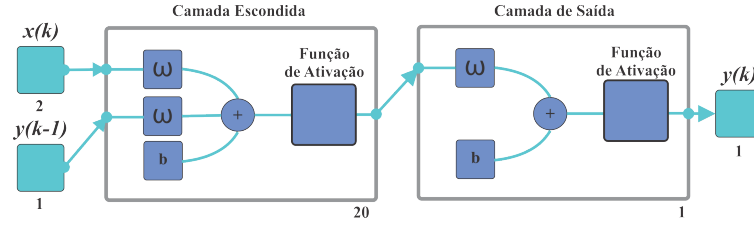
4.2.3 Treinamento da Rede

Foram criadas RNAs por meio da utilização do *toolbox Neural Net Time Series* da ferramenta Matlab®, variando o número de neurônios na camada escondida de 15 a 25. Para tal, foram aplicadas as funções de ativação sigmóide, tangente hiperbólica, linear saturada e puramente linear. Estas funções de ativação foram escolhidas para avaliar o desempenho da estrutura quando implementada com funções mais complexas (sigmóide e tangente hiperbólica) em comparação com o uso de funções lineares (linear saturada e puramente linear). As topologias implementadas via Matlab® para realizar o treinamento da rede proposta neste trabalho são ilustradas na Figura 19, na qual os blocos ω e b correspondem aos pesos adicionados às entradas dos neurônios e limiares (*bias*), respectivamente.

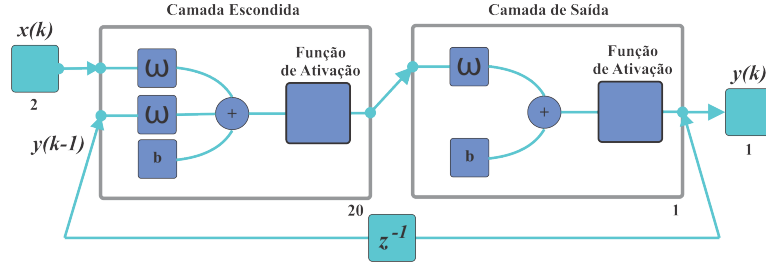
Na Figura 19a, a entrada $x(k)$ representa um vetor contendo duas colunas, uma para tensão dos terminais e outra para temperatura ambiente. O vetor $y(k)$ representa a saída da rede. Por fim, $y(k-1)$ é o vetor de saída da rede atrasado de uma amostra. Como pode ser observado, o processo de treinamento é desenvolvido em *open-loop*.

Por outro lado, no processo de validação descrito na Figura 19b, o vetor $y(k-1)$ dá lugar ao valor de saída da rede $y(k)$ atraso de uma amostra, formando uma estrutura *closed-loop*.

Figura 19 – Diagramas de implementação da RNA via Matlab®.



(a) Diagrama de Treinamento.



(b) Diagrama de validação.

Fonte: Autor (2018).

Em relação ao banco de dados utilizado, das 36 simulações realizadas, 30 foram utilizadas para treinamento enquanto 6 foram usadas para testes. A regra de aprendizagem adotada foi do tipo supervisionada, utilizando o algoritmo de Levenberg Marquardt (LM). Este algoritmo usa a aproximação abaixo.

$$x_{k+1} = x_k - [J^T J + \mu I]^{-1} J^T e, \quad (4.14)$$

onde J é a matriz Jacobiana que contém a primeira derivada dos erros da rede com relação aos pesos e limiares e e é o vetor de erros da rede. Quando o escalar μ é zero, esta função se torna o método de Newton, mais detalhado em Cunha (2003). O método de Newton é mais rápido e mais exato levando a um erro mínimo, porém é mais suscetível a produzir mínimos locais. Assim, μ é reduzido a cada iteração até alcançar um valor de tolerância de erro definido previamente pelo projetista da rede. Os parâmetros utilizados para criação das RNAs são resumidos na Tabela 10.

Como as aplicações de uma RNA estão limitadas ao banco de dados utilizado para o treinamento, a rede neural desenvolvida neste trabalho apresenta como restrições entradas em corrente que estejam compreendidas na faixa de valores de 2 a 10 A em conjunto com uma temperatura dentro da faixa de 10 a 35 °C.

4.2.4 Métricas para Determinação da Melhor Rede

Para quantificar a exatidão das redes treinadas, foram usados o Erro Quadrático Médio (*Mean Squared Error* -MSE) e o Erro Percentual Absoluto Médio (*Mean Absolute*

Tabela 10 – Parâmetros de treinamento das RNAs.

Função de treinamento	Levenberg Marquardt
Número máximo de épocas para o treinamento	1000
Tempo máximo de treinamento	Infinito
μ inicial	1×10^{-3}
Fator de diminuição do μ	0,1
Fator de aumento do μ	10
μ máximo	1×10^{10}
μ mínimo	1×10^{-4}
Número de validações máxima por época	20
Desempenho desejado (erro)	0

Fonte: Autor (2018).

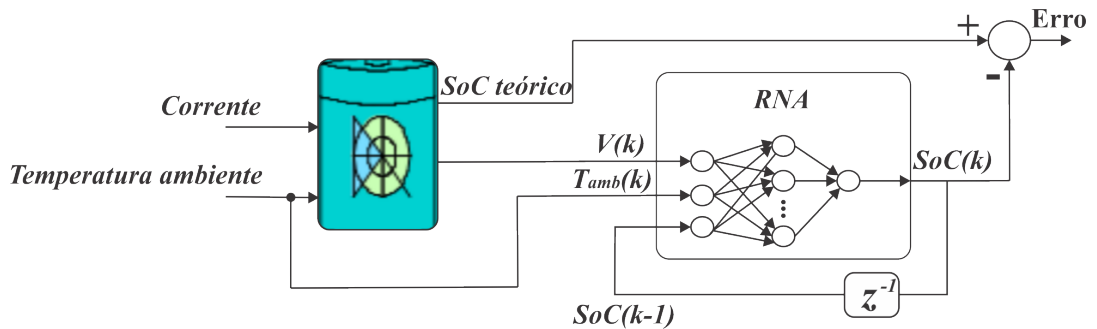
Percentage Error - MAPE) entre os dados estimados pelas RNAs e os dados teóricos fornecidos pelo modelo da bateria do Simulink. As Equações 4.15 e 4.16 definem estas métricas.

$$MSE = \frac{1}{N} \sum_{k=1}^N (SoC_t(k) - \hat{SoC}(k))^2 \quad (4.15)$$

$$MAPE = \frac{1}{N} \sum_{k=1}^N \left| \frac{SoC_t(k) - \hat{SoC}(k)}{SoC_t(k)} \right| \times 100\%, \quad (4.16)$$

onde, L é o número total de pontos, $SoC_t(k)$ é o valor teórico do SoC da bateria obtido através do modelo Matlab/Simulink® no instante k e $\hat{SoC}(k)$ é o SoC estimado da bateria obtido a partir da RNA no instante k . A estrutura montada para determinar os valores de SoC teórico e estimado é apresentada na Figura 20.

Figura 20 – Implementação da rede NARX para determinação do SoC.



Fonte: Autor (2018).

Para determinar a escolha das melhores RNAs desenvolvidas, foram realizados um total de 30 treinamentos para cada estrutura de rede.

Isto se fez necessário devido ao fato dos pesos iniciais durante o treinamento serem determinados aleatoriamente pelo *toolbox* do Matlab®, fazendo com que a realização de

um único treinamento leve a uma rede condicionada incorretamente apenas por apresentar pesos iniciais fora dos padrões para esta aplicação em específico.

Assim, com o treinamento de 30 RNAs para cada uma das estruturas definidas na Seção 4.2.2, totalizando 360 treinamentos, foram escolhidas as melhores topologias de rede para cada estrutura proposta com base nas métricas das Equações 4.15 e 4.16.

5 Resultados

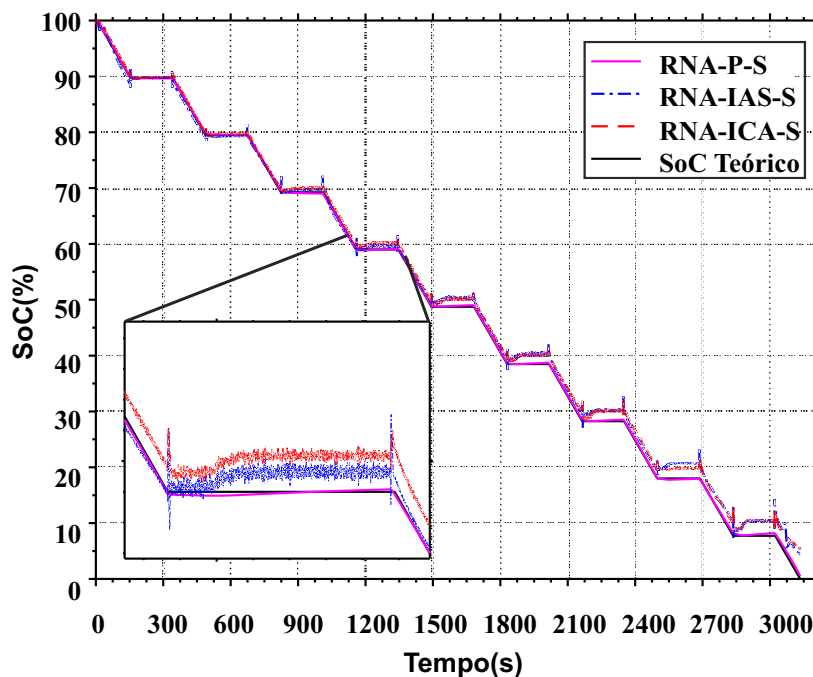
Neste capítulo, serão apresentados os resultados obtidos a partir das simulações de descarga a corrente pulsada, aplicando correntes e temperaturas de validação nas redes propostas neste trabalho. Vale ressaltar que os valores aplicados para os testes de validação neste capítulo levaram em consideração as restrições de valores que podem ser aplicados as redes, sendo eles especificados na Tabela 9 do Capítulo 4. Além disto, são apresentados dados comparativos entre as redes propostas e metodologias encontradas na literatura.

5.1 Redes Neurais com Função Sigmóide

Nesta seção, são apresentados os resultados referentes as redes as quais foram implementadas em sua estrutura a função de ativação tangente hiperbólica, sendo elas: RNA-P-S, RNA-ISA-S e RNA-ICA-S.

Com base no que foi dito na Capítulo 4, após a realização dos 30 treinamentos para cada estrutura de rede, foram selecionadas as melhores RNAs a partir do MAPE e MSE. Na Figura 21, são ilustrados os resultados da melhor rede para cada estrutura em comparação com o resultado teórico.

Figura 21 – SoCs obtidos para as RNA-P-S, RNA-ISA-S e RNA-ICA-S.



Fonte: Autor (2019).

Analisando os resultados, observa-se que apesar das não-linearidades encontradas entre os períodos de repouso (linhas horizontais) e os períodos de descarga (declives), a RNA-P-S que utiliza a estrutura proposta neste trabalho acompanha a curva teórica de forma quase sobreposta. Por outro lado, as curvas correspondentes as RNA-ISA-S e RNA-ICA-S obtiveram desempenhos inferiores em relação ao modelo proposto, principalmente nos períodos de repouso. As RNA-ISA-S e RNA-ICA-S também apresentaram um ruído considerável sobreposto a curva de SoC, fato que não ocorreu na curva referente a rede proposta.

Após a obtenção das melhores RNAs para cada estrutura de rede, foram efetuadas simulações de validação com o intuito de extrair valores de MSE e MAPE para cada uma desta simulações. Os resultados obtidos para as RNA-P-S, RNA-ISA-S e RNA-ICA-S estão resumidos na Tabela 11.

Tabela 11 – MAPE e MSE para as RNA-P-S, RNA-ISA-S e RNA-ICA-S.

RNA-P-S			
I_{bat}	T_{amb}	MAPE	MSE
3	25	0,369	0,040
5	20	0,398	0,058
5	28	0,279	0,020
6	17	0,810	0,241
7	12	2,574	1,373
9	35	2,807	1,543
RNA-ISA-S			
I_{bat}	T_{amb}	MAPE	MSE
3	25	1,241	0,362
5	20	4,809	4,9322
5	28	2,193	1,123
6	17	5,857	1,293
7	12	10,566	15,6188
9	35	6,831	12,433
RNA-ICA-S			
I_{bat}	T_{amb}	MAPE	MSE
3	25	0,493	0,095
5	20	4,458	3,770
5	28	2,520	1,335
6	17	5,773	5,607
7	12	11,731	19,091
9	35	7,470	14,662

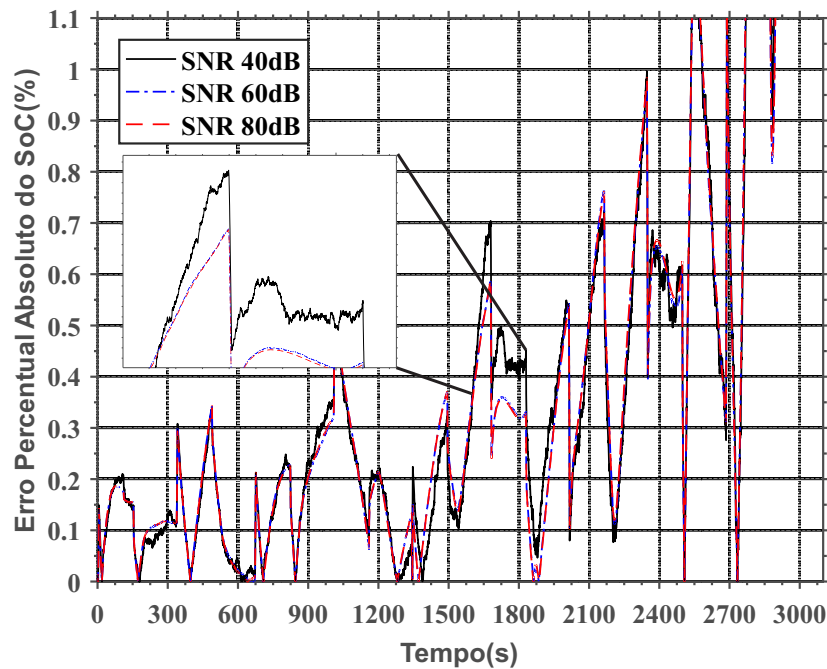
Analisando-se os valores encontrados para as métricas de validação, constatou-se que, os maiores MSE e MAPE para a RNA-P-S foram obtidos quando a rede neural foi testada com uma temperatura de 35 °C, um valor quase em seu limite de operação. Por outro lado, as redes RNA-ISA-S e RNA-ICA-S obtiveram seus melhores resultados quando aplicadas temperaturas próximas a utilizada para a validação inicial das 30 redes desenvolvidas, que foi de 28 °C. Ao passo que a temperatura ambiente imposta a bateria durante os testes se distanciou do valor de 28 °C, os erros quadrático e percentual absoluto também cresceram. Este fenômeno foi igualmente observado nos resultados da RNA-P-S

(rede proposta), porém os efeitos decorrentes da variação de temperatura provocaram um aumento bem mais significativo nos erros das RNA-ISA-S e RNA-ICA-S (literatura).

Com base nos dados da Tabela 11, a RNA que obteve melhor desempenho foi a proposta neste trabalho, seguida pela RNA-ISA-S e a RNA-ICA-S, respectivamente.

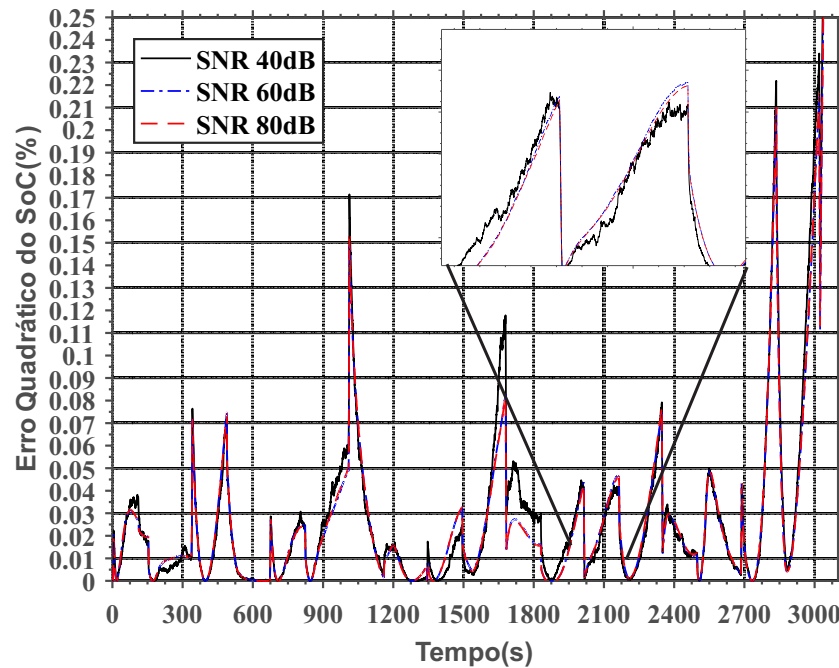
Para analisar o comportamento da RNA proposta neste trabalho em relação a influência de ruído, foram realizadas simulações de descarga a corrente pulsada adicionando ruídos AWGN na entrada da RNA-P-S. Foram escolhidas as relações sinal ruído (*Signal-Noise Ratio* - SNR) de 40 dB, 60 dB e 80 dB. Não foram utilizados SNRs abaixo de 40 dB devido ao ruído sobrepor o sinal. Em contra partida, SNRs acima de 80 dB não apresentaram variações significativas. Na Figura 22, são ilustrados os resultados de erro percentual absoluto para a RNA-P-S, já na Figura 23, são ilustrados os resultados de erro quadrático.

Figura 22 – MAPE em função do ruído para a RNA-P-S.



Fonte: Autor (2019).

Figura 23 – MSE em função do ruído para a RNA-P-S.



Fonte: Autor (2019).

Como é possível observar, um SNR de 40 dB apresenta uma pequena variação nas curvas de erro percentual absoluto e erro quadrático, ainda que possua pouca influência na eficiência da rede neural. Já as curvas para SNRs de 60 dB e 80 dB indicam que a adição de ruídos com SNR mais elevadas produzem curvas quase superpostas, ou seja, não provocam muito impacto na RNA. Na Tabela 12 são resumidos os resultados de MAPE e MSE para a análise de ruído.

Tabela 12 – Influência do ruído na RNA-P-S.

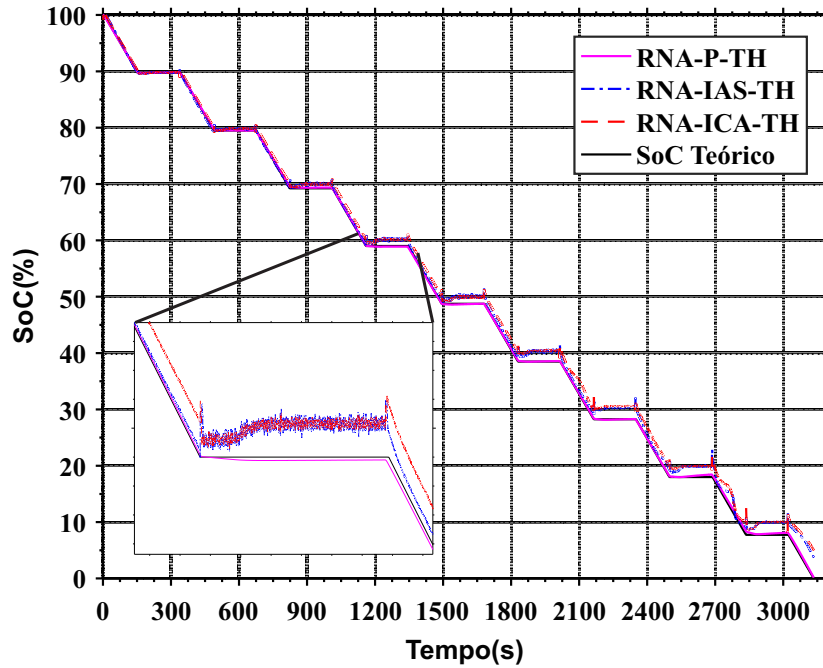
	Sem ruído	40 dB	60 dB	80 dB
MAPE	0,279	0,286	0,279	0,279
MSE	0,020	0,022	0,020	0,020

Fonte: Autor (2019).

5.2 Redes Neurais com Função Tangente Hiperbólica

Os mesmos procedimentos efetuados na Seção 5.1, foram também executados para as redes neurais contendo em sua estrutura funções de ativação do tipo tangente hiperbólica. As RNAs que utilizam a função tangente hiperbólica são: RNA-P-TH, RNA-ISA-TH e RNA-ICA-TH. As redes neurais que apresentaram o melhor desempenho para cada estrutura produziram as curvas de SoC ilustradas na Figura 24.

Figura 24 – SoCs obtidos para as RNA-P-TH, RNA-ISA-TH e RNA-ICA-TH.



Fonte: Autor (2019).

Os valores de MAPE e MSE utilizando as mesmas simulações de validação na Seção 5.1 são descritos na Tabela 13.

Através da análise dos dados apresentados na tabela, constatou-se que a melhor estrutura de rede para as simulações de validação utilizadas continua sendo a rede proposta neste trabalho. Vale mencionar que a RNA-ICA-TH apresentou um melhor desempenho em relação a RNA-ISA-TH para esta função de ativação, ou seja, a mudança de função de ativação de sigmóide para tangente hiperbólica fez com que a estrutura contendo tensão, corrente, tensões e correntes atrasadas com entradas da RNA melhorasse seu desempenho, em contra partida o desempenho da rede contendo entradas apenas em corrente e tensão atuais teve uma redução em seu desempenho.

Também foram realizadas análises de influência do ruído para a RNA-P-TH utilizando as mesmas SNRs descritas na Subseção 5.1. As curvas de erro percentual absoluto e erro quadrático são ilustradas nas Figuras 25 e 26, respectivamente.

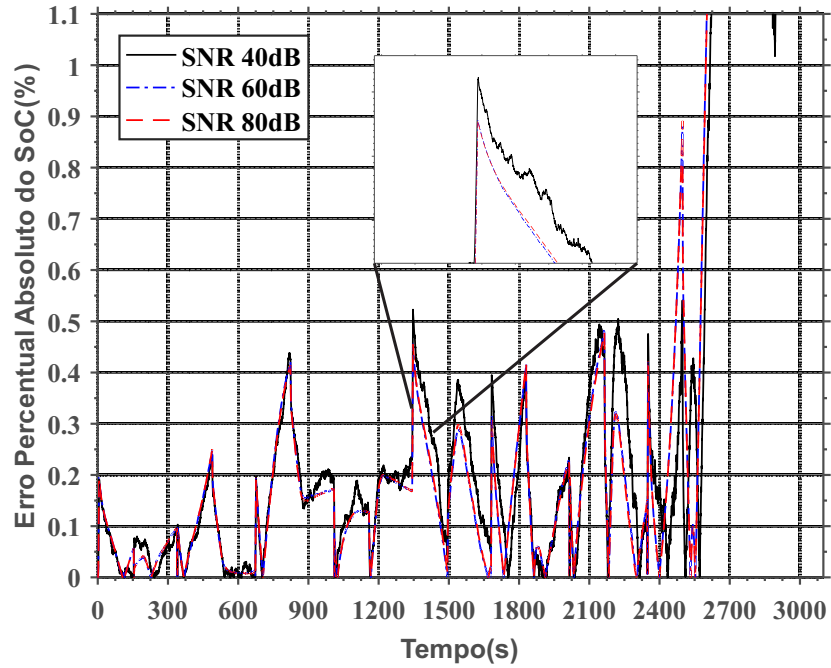
Tabela 13 – MAPE e MSE para as RNA-P-TH, RNA-ISA-TH e RNA-ICA-TH.

RNA-P-TH			
I_{bat}	T_{amb}	MAPE	MSE
3	25	0,299	0,021
5	20	0,621	0,103
5	28	0,159	0,258
6	17	0,565	0,096
7	12	2,774	1,592
9	35	2,387	1,172

RNA-ISA-TH			
I_{bat}	T_{amb}	MAPE	MSE
3	25	1,032	0,300
5	20	5,049	5,180
5	28	2,123	1,123
6	17	5,932	5,837
7	12	12,745	21,008
9	35	6,732	11,337

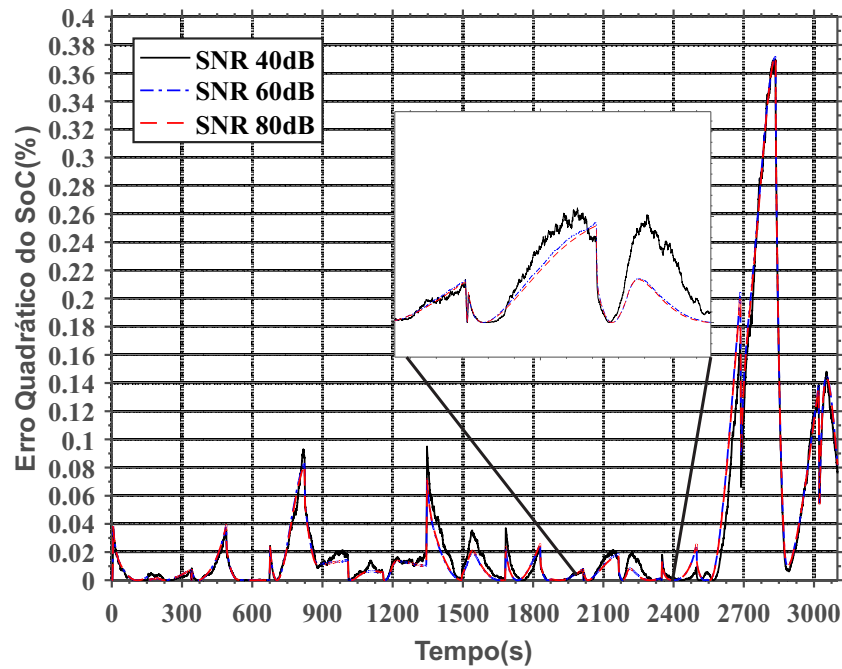
RNA-ICA-TH			
I_{bat}	T_{amb}	MAPE	MSE
3	25	1,187	0,402
5	20	3,651	2,886
5	28	3,129	2,089
6	17	5,796	5,808
7	12	10,834	15,209
9	35	7,531	16,183

Figura 25 – MAPE em função do ruído para a RNA-P-TH.



Fonte: Autor (2019).

Figura 26 – MSE em função do ruído para a RNA-P-TH.



Fonte: Autor (2019).

O comportamento observado quando foi utilizada a função tangente hiperbólica foi similar ao perfil observado quando aplicada a função sigmóide. Uma vez que, a adição de ruídos AWGN apresentam uma leve variação apenas para curva com SNR de 40 dB. Na Tabela 14, são resumidos os resultados de MAPE e MSE para a análise de ruído utilizando a função tangente hiperbólica.

Tabela 14 – Influência do ruído na RNA-P-TH.

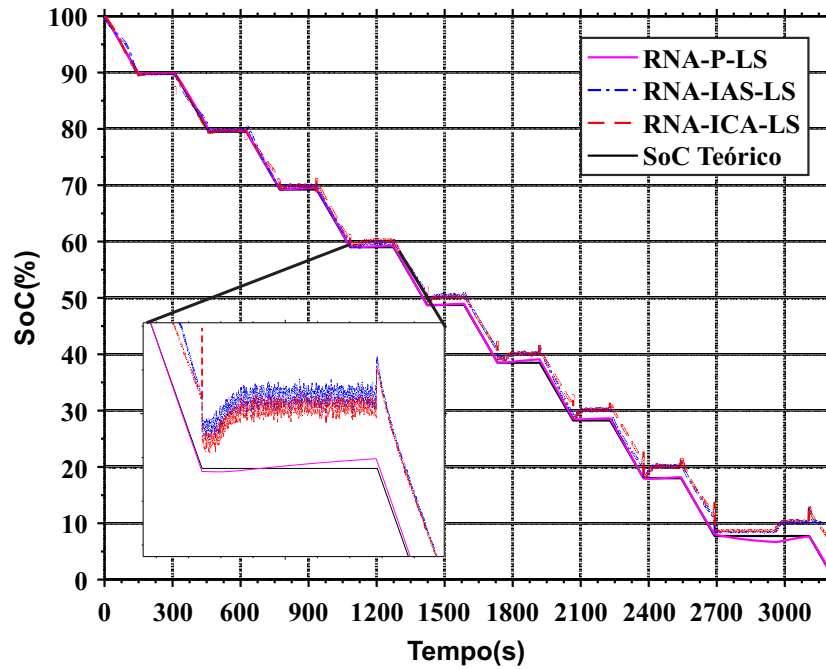
	0 dB	40 dB	60 dB	80 dB
MAPE	0,159	0,182	0,160	0,160
MSE	0,010	0,012	0,010	0,010

Fonte: Autor (2019).

5.3 Redes Neurais com Função Linear Saturada

Assim como nas Seções 5.1 e 5.2, agora são apresentados os resultados para topologias utilizando FA linear saturada. As RNAs analisadas são: RNA-P-LS, RNA-ISA-LS e RNA-ICA-LS. As redes que apresentaram o melhor desempenho para cada estrutura produziram as curvas de SoC ilustradas na Figura 27.

Figura 27 – SoCs obtidos para as RNA-P-LS, RNA-ISA-LS e RNA-ICA-LS.



Fonte: Autor (2019).

Os valores de MAPE e MSE utilizando as mesmas simulações de validação na Seção 5.1 são descritos na Tabela 15.

Através da análise dos dados apresentados na Tabela 15, constatou-se que a melhor estrutura de rede para as simulações de validação utilizadas continua sendo a rede proposta neste trabalho. Um ponto importante é que, os resultados obtidos para todas as redes são muito próximos aos obtidos utilizando FAs não lineares como a tangente hiperbólica e sigmóide, o que torna esta topologia uma alternativa viável ao levar em consideração o custo de implementação da rede neural. Complementarmente, o tempo requerido para treinamento das redes que utilizam a FA linear saturada é aproximadamente 60% inferior em relação ao tempo de treinamento para redes que utilizam FA tangente hiperbólica ou sigmóide. Por fim, o último teste efetuado para as RNAs com função de ativação foi referente à robustez ao ruído assim como nas subseções anteriores. As curvas de erro percentual absoluto e erro quadrático são ilustradas nas Figuras 28 e 29, respectivamente.

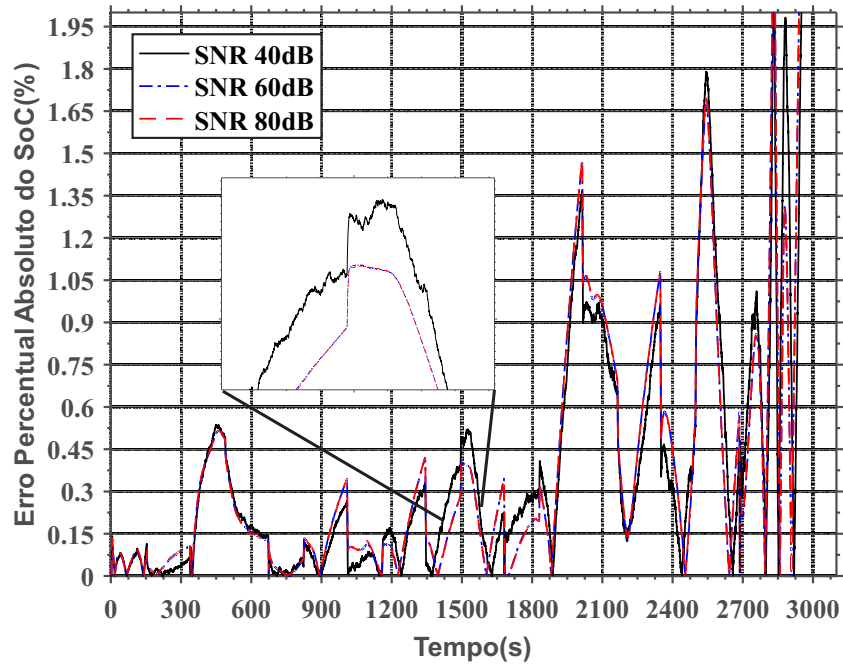
Tabela 15 – MAPE e MSE para as RNA-P-LS, RNA-ISA-LS e RNA-ICA-LS.

RNA-P-LS			
I_{bat}	T_{amb}	MAPE	MSE
3	25	0,400	0,053
5	20	0,598	0,097
5	28	0,439	0,052
6	17	1,563	0,505
7	12	2,464	1,864
9	35	2,195	0,925

RNA-ISA-LS			
I_{bat}	T_{amb}	MAPE	MSE
3	25	1,493	0,658
5	20	4,322	3,615
5	28	2,572	1,588
6	17	7,154	7,180
7	12	10,116	16,924
9	35	8,213	20,963

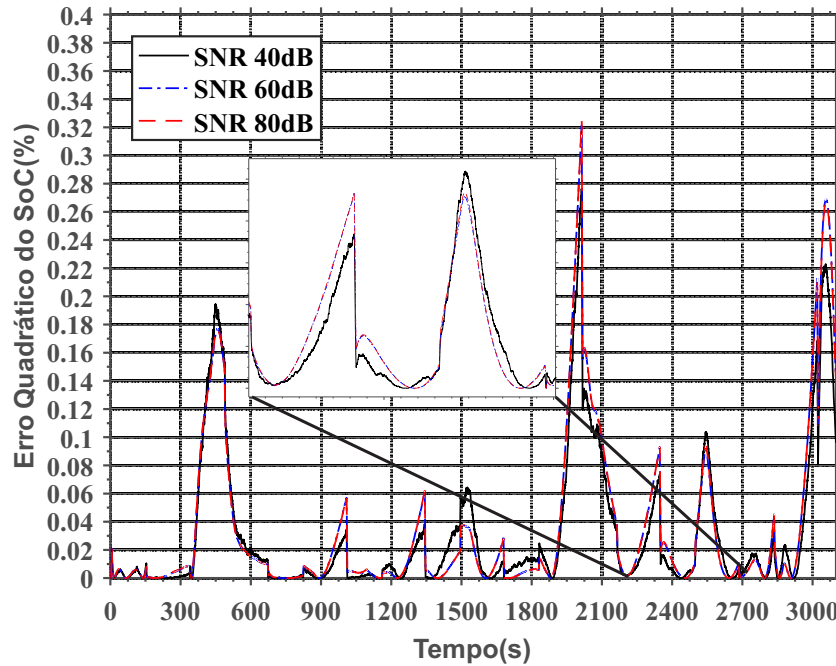
RNA-ICA-LS			
I_{bat}	T_{amb}	MAPE	MSE
3	25	0,894	0,213
5	20	3,546	2,385
5	28	3,265	2,366
6	17	7,305	7,327
7	12	9,477	14,014
9	35	7,157	13,536

Figura 28 – MAPE em função do ruído para a RNA-P-LS.



Fonte: Autor (2019).

Figura 29 – MSE em função do ruído para a RNA-P-LS.



Fonte: Autor (2019).

Novamente é possível constatar que o modelo permanece com uma tolerância ao ruído mesmo com valores de de 40 dB aplicados a relação sinal ruído do sinal. Verificou-se também que, os maiores valores de MAPE e MSE foram obtidos para uma simulação sem adição de ruído ao sinal.

Tabela 16 – Influência do ruído na RNA-P-LS.

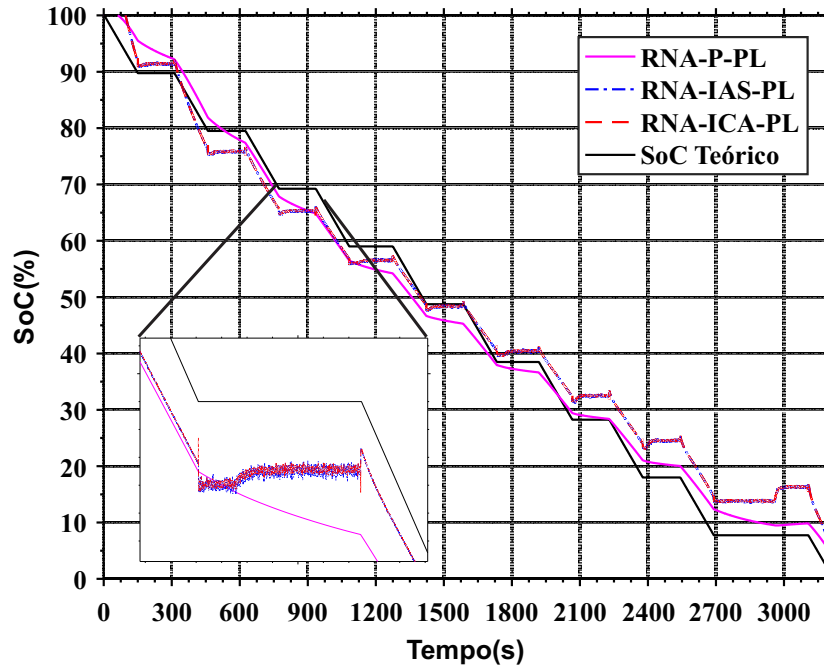
	Sem ruído	40 dB	60 dB	80 dB
MAPE	0,439	0,288	0,300	0,301
MSE	0,052	0,026	0,029	0,029

Fonte: Autor (2019).

5.4 Redes Neurais com Função Puramente Linear

Nesta seção são apresentados os resultados obtidos a partir das simulações de validação para topologias com função de ativação do tipo puramente linear. As RNAs analisadas são: RNA-P-PL, RNA-ISA-PL e RNA-ICA-PL. Os resultados para as melhores redes em suas respectivas topologias são ilustradas na Figura 30.

Figura 30 – SoCs obtidos para as RNA-P-PL, RNA-ISA-PL e RNA-ICA-PL.



Fonte: Autor (2019).

Utilizando as mesmas simulações de validação da Seção 5.1, para estas topologias foram obtidos os resultados ilustrados na Tabela 17.

De modo geral, todas as redes desenvolvidas utilizando a FA puramente linear não obtiveram resultados satisfatórios levando em consideração uma comparação com as demais topologias, apresentando erros máximos em média de 8,482%.

As curvas de erro percentual absoluto e erro quadrático para aplicações de ruído AWGN com SNRs de 40 dB, 60 dB, 80 dB e sem ruído são ilustradas nas Figuras 31 e 32, respectivamente.

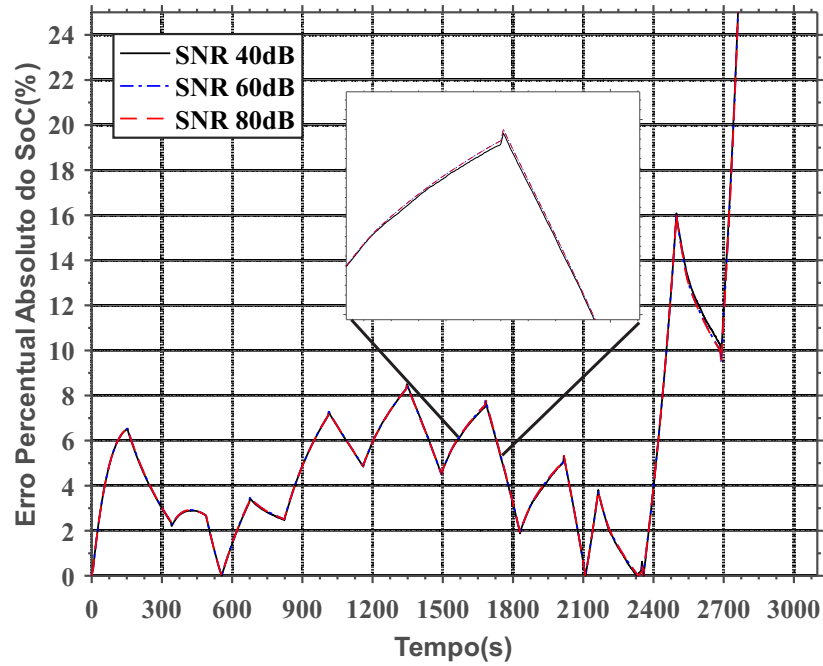
Tabela 17 – MAPE e MSE para as RNA-P-PL, RNA-ISA-PL e RNA-ICA-PL.

RNA-P-PL			
I_{bat}	T_{amb}	MAPE	MSE
3	25	6,554	14,427
5	20	3,313	4,202
5	28	4,332	6,183
6	17	2,559	2,678
7	12	4,730	7,662
9	35	3,955	5,997

RNA-ISA-PL			
I_{bat}	T_{amb}	MAPE	MSE
3	25	5,860	10,875
5	20	5,941	13,346
5	28	6,231	9,473
6	17	9,465	13,711
7	12	7,577	21,618
9	35	6,732	15,892

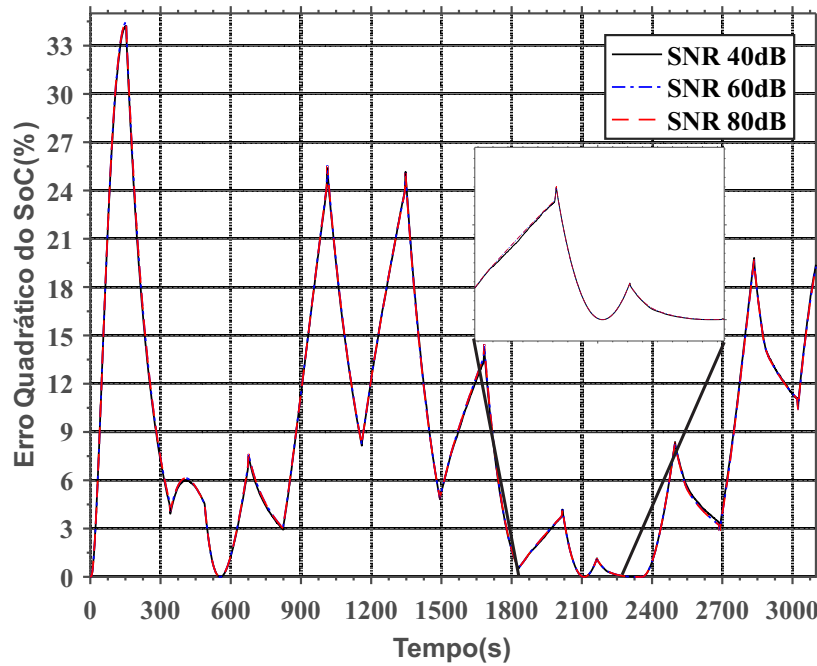
RNA-ICA-PL			
I_{bat}	T_{amb}	MAPE	MSE
3	25	5,847	10,741
5	20	5,924	13,180
5	28	5,924	9,428
6	17	6,175	13,551
7	12	9,427	21,419
9	35	7,577	15,890

Figura 31 – MAPE em função do ruído para a RNA-P-PL.



Fonte: Autor (2019).

Figura 32 – MSE em função do ruído para a RNA-P-PL.



Fonte: Autor (2019).

Mesmo com erros elevados provenientes do tipo de função de ativação utilizado, novamente o modelo não apresentou uma influência elevada em relação à adição de ruído.

Tabela 18 – Influência do ruído na RNA-P-PL.

	Sem ruído	40 dB	60 dB	80 dB
MAPE	4,332	4,570	4,595	4,593
MSE	6,183	7,293	7,347	7,339

Fonte: Autor (2019).

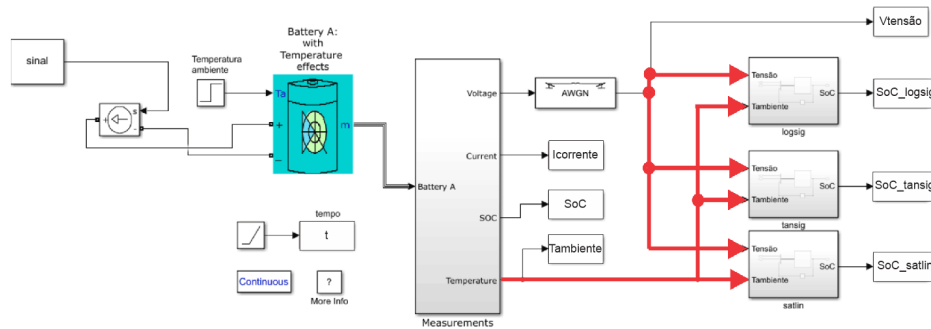
5.5 Análise de Simulações com *Model in the Loop*

Realizados os teste de validação para extração de métricas como MAPE e MSE, foram gerados blocos contendo as topologias das RNA-P-S, RNA-P-TH E RNA-P-LS a fim de desenvolver simulações com *Model in the Loop* (MIL) como teste visando implementações em placas de desenvolvimento. Para construção dos blocos foi utilizada a função *gensim* do Matlab®.

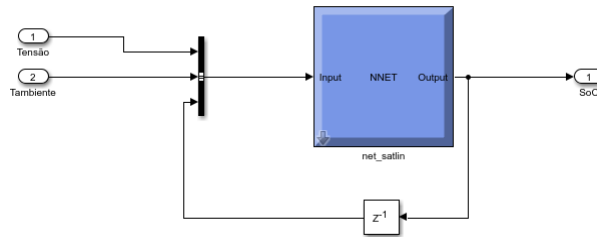
O sistema utilizado para produzir as curvas obtidas a partir de simulações MIL é ilustrado na Figura 33a, onde são destacadas as linhas que alimentam as redes provenientes do modelo da bateria de LiCoO₂. Já na Figura 33b é apresentado o diagrama de blocos

gerado a partir da conversão da RNA em forma de linhas de código para um bloco do Simulink® que contém a rede com suas entradas externas (tensão e temperatura ambiente) e interna (SoC). Optou-se por migrar os dados das RNAs e efetuar as simulações em MIL no Simulink® por existirem pacotes e ferramentas que auxiliam a migração dos código para placas de desenvolvimento como Arduino e Raspberry Pi em uma possível implementação em *hardware*.

Figura 33 – Estrutura implementada para simulações MIL.



(a) Esquemático simulink.



(b) Estrutura de rede implementada.

Fonte: Autor (2019).

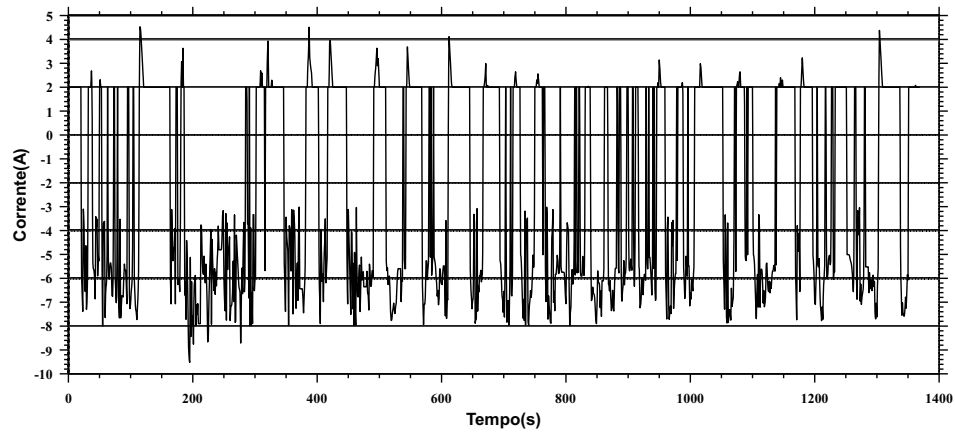
Foi implementado um perfil de corrente assim como o ilustrado na Figura 34a definido como perfil 1, nesta curva existem momentos de carga e descarga para verificar como a rede se comporta. Este perfil foi adaptado da curva UDDS (*Urban Dynamometer Driving Schedule*) (EPA, 2016). De modo que, a partir da curva de velocidade, foi gerada uma curva de corrente que após parametrizações de valores devido à limitações de entrada em corrente das RNAs, foi aplicada às redes. A temperatura ambiente utilizada para realização desta simulação foi de 27 °C com um SoC inicial da bateria de 80%. Ao calcular os valores de MAPE e MSE para os SoC das RNAs foram obtidos os resultados apresentados na Tabela 20.

Tabela 19 – MAPE e MSE para simulação MIL com perfil de corrente 1.

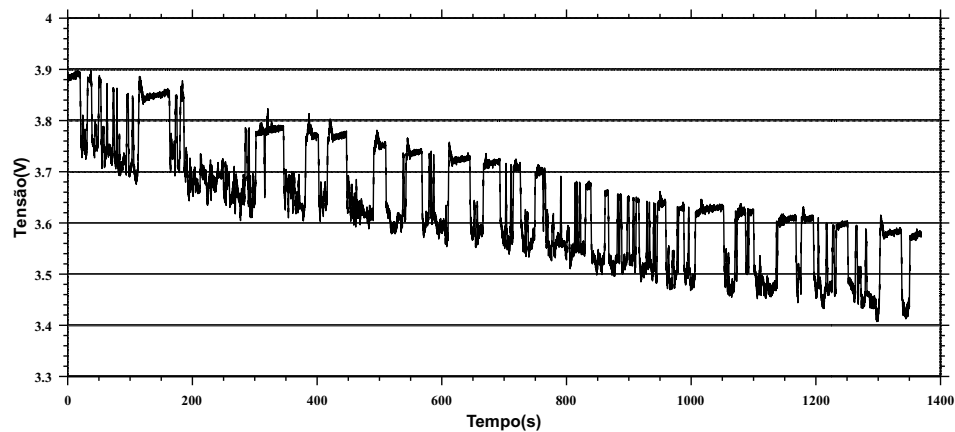
	RNA-P-S	RNA-P-TH	RNA-P-LS
MAPE	0,279	0,784	0,437
MSE	0,070	0,375	0,114

Fonte: Autor (2019).

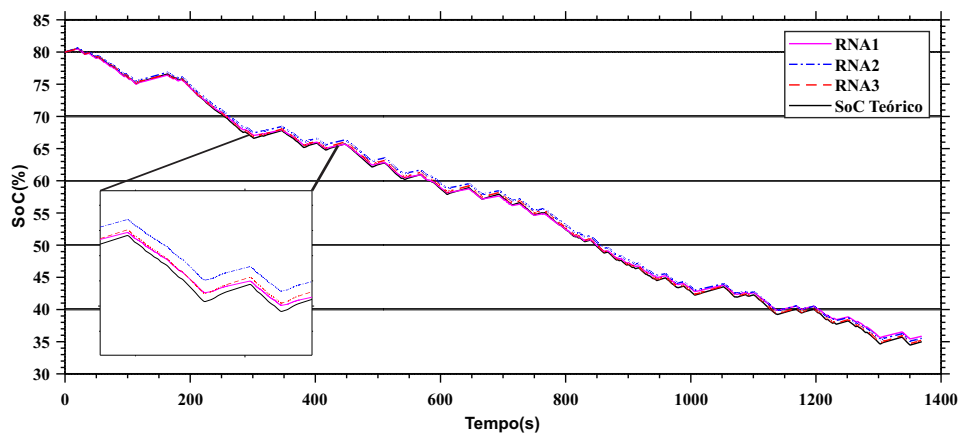
Figura 34 – Curvas obtidas para simulação MIL com perfil de corrente 1.



(a) Perfil de corrente 1 aplicado.



(b) Curva de tensão obtida pelo modelo de bateria para perfil de corrente 1.



(c) Comparação das curvas de SoC geradas pelas RNAs e o modelo Matlab® para o perfil de corrente 1.

Fonte: (EPA, 2016) adaptado.

Analisando os resultados apresentados nas curvas acima em conjunto com as métricas obtidas, o modelo apresentou um desempenho superior (erro abaixo de 1%) independente das topologias de função de ativação implementada. Vale destacar que a RNA-P-LS, que utiliza função de ativação linear saturada, produziu um Erro Percentual Absoluto Médio 0,347% inferior em relação a RNA-P-TH que utiliza uma função de ativação relativamente mais complexa (tangente hiperbólica).

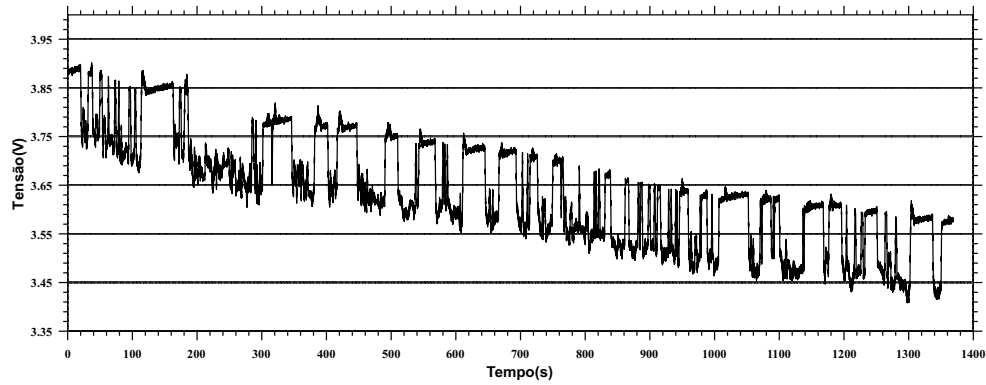
Foram implementadas simulações utilizando o mesmo perfil de corrente, porém inserindo um erro ao SoC inicial das redes para verificar o comportamento das mesma em relação à erros de aproximação inicial. O SoC inicial teórico foi de 80%, enquanto o SoC das redes foi de 70%. Os dados extraídos das métricas e as curvas são apresentados na Tabela e Figuras , respectivamente.

Tabela 20 – MAPE e MSE para simulação MIL para o perfil de corrente 1 com erro inicial do SoC.

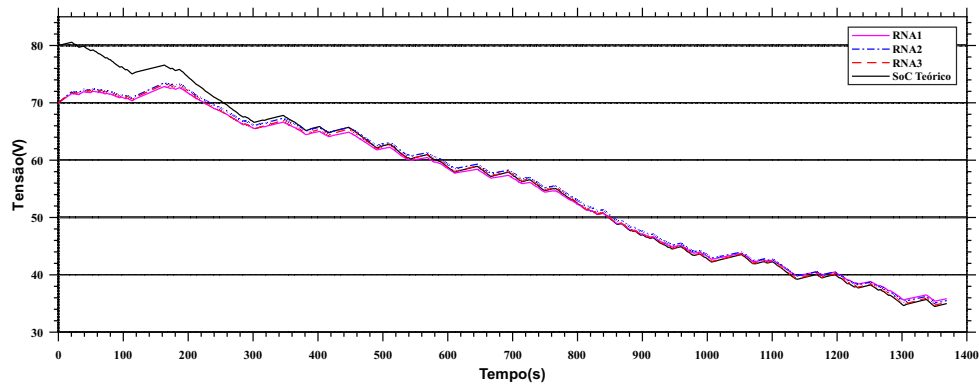
	RNA-P-S	RNA-P-TH	RNA-P-LS
MAPE	1,523	1,930	2,030
MSE	5,060	4,780	5,666

Fonte: Autor (2019).

Figura 35 – Curvas obtidas através da simulação MIL com erro inicial do SoC para o perfil de corrente 1.



(a) Curva de tensão obtida para o perfil de corrente 1.



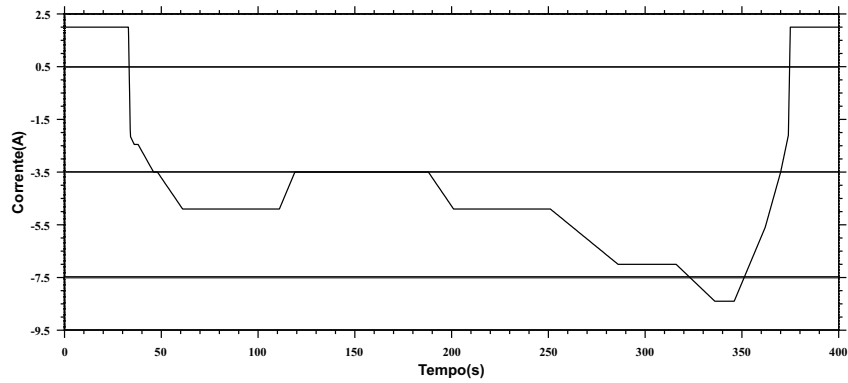
(b) Comparação das curvas de SoC geradas pelas RNAs contendo erro inicial e o modelo Matlab® para o perfil de corrente 1.

Fonte: Autor (2019).

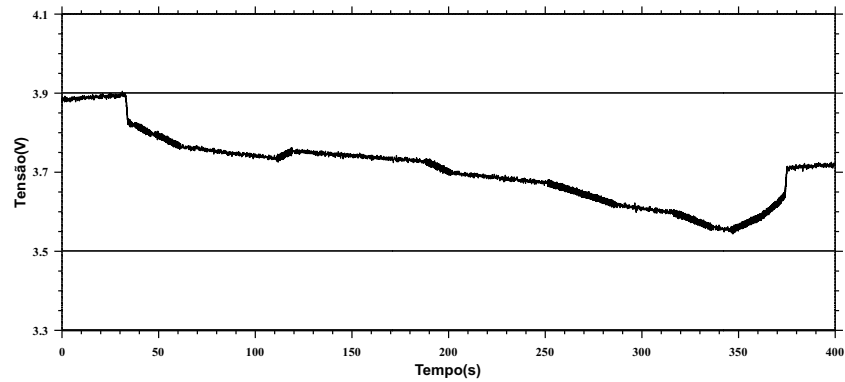
Como esperado, devido ao erro inicial aplicado, os erros de MAPE e MSE apresentaram valores mais elevados. Porém, após 300 segundos (aproximadamente 5 minutos) de simulação, todas as RNAs foram capazes de seguir a curva teórica.

Por fim, foi implementado um segundo perfil de corrente como o ilustrado na Figura 36a, que possui curvas mais suaves. Assim como o perfil de corrente 1, o perfil 2 também é uma adaptação da curva UN/ECE *Extra-Urban Driving Cycle (Part 2)* (EPA, 2016).

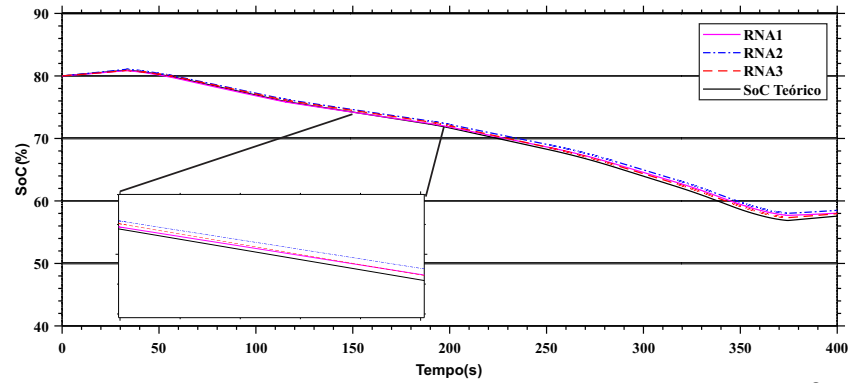
Figura 36 – Curvas obtidas para simulação MIL para o perfil de corrente 2.



(a) Perfil de corrente 2 aplicado.



(b) Curva de tensão obtida pelo modelo de bateria para o perfil de corrente 2.

(c) Comparação das curvas de SoC geradas pelas RNAs e o modelo Matlab[®] para o perfil de corrente 2.

Fonte: (EPA, 2016) adaptado.

Tabela 21 – MAPE e MSE para simulação MIL para o perfil de corrente 2.

	RNA-P-S	RNA-P-TH	RNA-P-LS
MAPE	0,538	1,266	0,810
MSE	0,134	0,773	0,342

Fonte: Autor (2019).

Novamente a RNA-P-LS que contém uma função de ativação linear saturada apresentou erros inferiores aos obtidos pela RNA-P-TH que possui uma função de ativação tangente hiperbólica

Como conclusões, a utilização da estrutura de rede proposta neste trabalho apresentou resultados satisfatórios de aproximação do SoC, além de se mostrar um sistema com tolerância a ruídos de entrada, fornecendo resultados aceitáveis mesmo sob influência de ruídos com SNR de até 40 dB. Ao adicionar perfis de corrente mais complexos e com erros de aproximação inicial, as RNAs foram capazes de seguir o valor teórico produzido pelo modelo de bateria independente das FAs utilizadas.

6 Conclusão

Neste trabalho, foi desenvolvido um modelo para estimação do estado de carga de baterias de lítio-íon por meio da utilização de redes neurais artificiais. Todo o processo de construção de banco de dados, treinamento e validação do modelo foi desenvolvido por meio da ferramenta Matlab/Simulink®. A aplicação do modelo proposto possibilitou a redução no erro de aproximação da curva de estado de carga da bateria utilizada.

O estimador de estado de carga desenvolvido consiste de uma estrutura de rede neural do tipo NARX, a qual possui como diferencial a consideração do impacto da variação da temperatura ambiente na curva de estado de carga e a substituição da corrente pela tensão como sinal de entrada externo, o que facilita a medição da grandeza e reduz o custo do sensor utilizado uma vez que mensurar tensão é mais simples em comparação a mensurar corrente. De modo que, as entradas da rede são: tensão nos terminais da bateria no instante k , temperatura ambiente no instante k e estado de carga no instante $k - 1$. Além de apresentar um algoritmo simples, a rede ainda pode ser facilmente adaptada para outros tipos de bateria.

Optou-se pela construção do modelo via Matlab/Simulink® por ser uma ferramenta completa e com um vasto acervo de apoio existentes a respeito do *software* em implementação de redes neurais além de acelerar o processo de treinamento e análise das RNAs, possibilitando vários testes com estruturas distintas para solucionar o problema de estimação do estado de carga. Além disto, é possível exportar toda a estrutura da rede neural desenvolvida para o Simulink onde podem ser feitos testes de validação e posteriormente exportar a estrutura de rede para um *hardware* a fim de desenvolver teste com *Hardware in the Loop* ou *Software in the Loop*.

O modelo foi validado a partir de simulações de descarga com corrente pulsada em cenários não utilizados no treinamento da rede neural e perfis de descarga com variações leves e bruscas na corrente aplicada às redes.

Ao se aplicar funções de ativação sigmóides na camada escondida, os piores cenários obtidos para os indicadores de MAPE e MSE para a RNA-P-S foram 2,807% e 1,543%, respectivamente. Em contrapartida, os resultados para os piores cenários das RNA-ISA-S e RNA-ICA-S foram: 10,566% (MAPE para RNA-ISA-S); 15,619% (MSE para RNA-ISA-S); 11,731% (MAPE para RNA-ICA-S) e 19,091% (MSE para RNA-ICA-S).

Para as funções de ativação tangente hiperbólica, novamente a rede desenvolvida com base no método proposto neste trabalho obtendo 2,774% de MAPE e 1,592% de MSE se sobressaiu em relação as demais redes.

Utilizando funções de ativação linear saturadas, as redes apresentaram um desempenho equiparado com os observados com funções mais complexas como tangente hiperbólica ou sigmóide. Desta forma, é possível manter a mesma quantidade de neurônios das redes com funções tangente hiperbólica ou sigmóide com um custo computacional reduzido ou igualar o custo computacional aumentando a quantidade de neurônio, assim elevando o desempenho das redes com função linear saturada. A topologia proposta neste trabalho apresentou erros 2,464% de MAPE e 1,864% de MSE, enquanto as demais redes obtiveram valores inferiores (10,116% de MAPE para RNA-ISA-LS, 20,963% de MSE para RNA-ISA-LS, 9,477% de MAPE para RNA-ICA-LS e 14,014% de MSE para RNA-ICA-LS).

Aplicando testes de validação com as redes contendo em sua estrutura funções de ativação puramente linear todas as redes apresentaram um desempenho bastante abaixo se comparado às demais estruturas, devido a função de ativação não ser capaz de aproximar as não-linearidades características da relação SoC - Tensão nos terminais.

Para analisar o comportamento e robustez das RNAs, foram aplicados perfis de corrente com cargas e descargas além aplicação de ruído AWGN na entrada de tensão nos terminais do sistema e erros de valor inicial do SoC. A melhor performance constatada ocorreu para a RNA com função de ativação sigmóide (0,279% de MAPE e 0,070% de MSE), seguido pelas funções linear saturada (0,437% de MAPE e 0,114% de MSE) e tangente hiperbólica (0,784% de MAPE e 0,375% de MSE).

Por fim, foram aplicados dois perfis de corrente, de modo a observar como as estruturas propostas se comportariam quando submetidas correntes de carga ou descarga da bateria com variações bruscas ou leves. Adicionalmente, foi inserido um erro inicial do SoC a fim de verificar se as topologias eram capazes de seguir a curva teórica. A partir dos resultados constatou-se que, após um certo período de tempo, os modelos são capazes de seguir a curva teórica mesmo contendo erros iniciais em conjunto com variações bruscas da corrente aplicada à bateria.

A partir dos resultados e ponderações, pode-se notar o desempenho mais eficiente do modelo proposto em relação a estruturas citadas na bibliografia.

Referências

- A123 SYSTEMS. *Battery Pack, Design, Validation, and Assembly Guide using A123 Systems Nanophosphate @Cells*. [S.l.], 2014. Citado 2 vezes nas páginas 25 e 43.
- ACADEMY., D. S. *Deep Learning Book*. 2018. <<http://deeplearningbook.com.br/>>. Acessado em 08 de Outubro de 2018. Citado na página 36.
- BALAGOPAL, B.; CHOW, M.-Y. The state of the art approaches to estimate the state of health (soh) and state of function (sof) of lithium ion batteries. In: IEEE. *Industrial Informatics (INDIN), 2015 IEEE 13th International Conference on*. [S.l.], 2015. p. 1302–1307. Citado na página 26.
- BARCELONA, S.; GRILLO, S.; PIEGARI, L. A simple battery model for ev range prediction: Theory and experimental validation. In: IEEE. *Electrical Systems for Aircraft, Railway, Ship Propulsion and Road Vehicles & International Transportation Electrification Conference (ESARS-ITEC), International Conference on*. [S.l.], 2016. p. 1–7. Citado na página 30.
- BUCCOLINI, L. *et al.* Battery management system (bms) simulation environment for electric vehicles. In: IEEE. *Environment and Electrical Engineering (EEEIC), 2016 IEEE 16th International Conference on*. [S.l.], 2016. p. 1–6. Citado na página 27.
- BURGOS, C. *et al.* Fuzzy modelling for the state-of-charge estimation of lead-acid batteries. *Journal of Power Sources*, Elsevier, v. 274, p. 355–366, 2015. Citado na página 33.
- CIORTEA, F. *et al.* Extended kalman filter for state-of-charge estimation in electric vehicles battery packs. In: IEEE. *Optimization of Electrical and Electronic Equipment (OPTIM) & 2017 Intl Aegean Conference on Electrical Machines and Power Electronics (ACEMP), 2017 International Conference on*. [S.l.], 2017. p. 611–616. Citado 3 vezes nas páginas 21, 32 e 42.
- CUNHA, M. C. C. *Métodos numéricos*. [S.l.]: Editora da UNICAMP, 2003. Citado na página 55.
- EPA, U. S. E. P. A. *Vehicle and Fuel Emissions Testing*. 2016. <<https://www.epa.gov/vehicle-and-fuel-emissions-testing/dynamometer-drive-schedules>>. Acessado em 10 de Agosto de 2019. Citado 4 vezes nas páginas 71, 72, 74 e 75.
- FAUSETT, L. V. *et al.* *Fundamentals of neural networks: architectures, algorithms, and applications*. [S.l.]: Prentice-Hall Englewood Cliffs, 1994. v. 3. Citado na página 37.
- FLEISCHER, C. *et al.* Adaptive on-line state-of-available-power prediction of lithium-ion batteries. *Journal of Power Electronics*, The Korean Institute of Power Electronics, v. 13, n. 4, p. 516–527, 2013. Citado na página 28.
- GJENGEDAL, Ø.; VIE, P. J. S.; MOLINAS, M. Battery modeling and kalman filter-based state-of-charge estimation for a race car application. In: IEEE. *Networking, Sensing and Control (ICNSC), 2017 IEEE 14th International Conference on*. [S.l.], 2017. p. 561–567. Citado na página 32.

- GROSS, O. J.; SWOYER, J. The next step in low cost lithium ion polymer systems. In: IEEE. *Battery Conference on Applications and Advances, 2002. The Seventeenth Annual*. [S.l.], 2002. p. 135–139. Citado na página 24.
- HU, R. Battery management system for electric vehicle applications. University of Windsor, 2011. Citado na página 27.
- HUSSEIN, A. A. A neural network based method for instantaneous power estimation in electric vehicles' li-ion batteries. In: IEEE. *Applied Power Electronics Conference and Exposition (APEC), 2017 IEEE*. [S.l.], 2017. p. 3122–3126. Citado na página 41.
- IEA. Global ev outlook 2016: Beyond on million electric cars. 2016. Citado 2 vezes nas páginas 19 e 20.
- ISMAIL, M. *et al.* Battery state of charge estimation using an artificial neural network. In: IEEE. *Transportation Electrification Conference and Expo (ITEC), 2017 IEEE*. [S.l.], 2017. p. 342–349. Citado 4 vezes nas páginas 22, 34, 40 e 43.
- JANG, J.-S. Anfis: adaptive-network-based fuzzy inference system. *IEEE transactions on systems, man, and cybernetics*, IEEE, v. 23, n. 3, p. 665–685, 1993. Citado na página 34.
- KHAYAT, N.; KARAMI, N. Adaptive techniques used for lifetime estimation of lithium-ion batteries. In: IEEE. *Electrical, Electronics, Computer Engineering and their Applications (EECEA), 2016 Third International Conference on*. [S.l.], 2016. p. 98–103. Citado 3 vezes nas páginas 25, 32 e 33.
- LAVIGNE, L. *et al.* Lithium-ion open circuit voltage (ocv) curve modelling and its ageing adjustment. *Journal of Power Sources*, Elsevier, v. 324, p. 694–703, 2016. Citado na página 29.
- LI, S.; KE, B. Study of battery modeling using mathematical and circuit oriented approaches. In: IEEE. *Power and Energy Society General Meeting, 2011 IEEE*. [S.l.], 2011. p. 1–8. Citado na página 24.
- LUO, X. *et al.* Overview of current development in electrical energy storage technologies and the application potential in power system operation. *Applied energy*, Elsevier, v. 137, p. 511–536, 2015. Citado na página 24.
- MADANI, S. S.; SWIERCZYNSKI, M. J.; KÆR, S. K. The discharge behavior of lithium-ion batteries using the dual-potential multi-scale multi-dimensional (msmd) battery model. In: IEEE. *Ecological Vehicles and Renewable Energies (EVER), 2017 Twelfth International Conference on*. [S.l.], 2017. p. 1–14. Citado na página 32.
- MARS, N. *et al.* Comparison study of different dynamic battery model. In: IEEE. *Green Energy Conversion Systems (GECS), 2017 International Conference on*. [S.l.], 2017. p. 1–6. Citado na página 24.
- MARTINS, J. K. E. da C.; ARAÚJO, F. M. U. Nonlinear system identification based on modified anfis. In: *ICINCO (1)*. [S.l.: s.n.], 2015. p. 588–595. Citado na página 34.
- MATHWORKS. *Implement generic battery model*. 2008. <<https://www.mathworks.com/help/physmod/sps/powersys/ref/battery.html>>. Acessado em 19 de Outubro de 2018. Citado na página 45.

- MEJDOUBI, A. E. *et al.* State-of-charge and state-of-health lithium-ion batteries' diagnosis according to surface temperature variation. *IEEE Transactions on Industrial Electronics*, IEEE, v. 63, n. 4, p. 2391–2402, 2016. Citado na página 30.
- MEKONNEN, Y.; SUNDARARAJAN, A.; SARWAT, A. I. A review of cathode and anode materials for lithium-ion batteries. In: IEEE. *SoutheastCon, 2016*. [S.l.], 2016. p. 1–6. Citado na página 24.
- MOURA, J. J. P. *et al.* State of charge estimation for li-ion batteries based on recurrent narx neural network with temperature effect. In: IEEE. *2019 IEEE International Instrumentation & Measurement Technology Conference - I2MTC*. [S.l.], 2019. Citado na página 23.
- MOURA, J. J. P. *et al.* Identificação paramétrica para baterias de lítio-Íon utilizando modelos auto regressivos. In: SBA. *XXII Congresso Brasileiro de Automática*. [S.l.], 2018. Citado na página 23.
- MOURA, S. J. *et al.* Battery state estimation for a single particle model with electrolyte dynamics. *IEEE Transactions on Control Systems Technology*, IEEE, v. 25, n. 2, p. 453–468, 2017. Citado na página 32.
- MOZELLI, L. A. Controle fuzzy para sistemas takagi-sugeno: Condições aprimoradas e aplicações. *Diss. de mestrado. Universidade Federal de Minas Gerais*, 2008. Citado na página 33.
- PARK, S.; ZHANG, D.; MOURA, S. Hybrid electrochemical modeling with recurrent neural networks for li-ion batteries. In: IEEE. *American Control Conference (ACC), 2017*. [S.l.], 2017. p. 3777–3782. Citado 2 vezes nas páginas 21 e 34.
- PHOTOVOLTAICS, D. G.; STORAGE, E. Ieee guide for selecting, charging, testing, and evaluating lead-acid batteries used in stand-alone photovoltaic (pv) systems. 2014. Citado na página 19.
- PURWADI, A. *et al.* State of charge estimation method for lithium battery using combination of coulomb counting and adaptive system with considering the effect of temperature. In: IEEE. *Power Engineering and Renewable Energy (ICPERE), 2014 International Conference on*. [S.l.], 2014. p. 91–95. Citado 2 vezes nas páginas 21 e 28.
- RAHIMI-EICHI, H. *et al.* Battery management system: An overview of its application in the smart grid and electric vehicles. *IEEE Industrial Electronics Magazine*, IEEE, v. 7, n. 2, p. 4–16, 2013. Citado na página 26.
- RAHMOUN, A.; LOSKE, M.; ROSIN, A. Determination of the impedance of lithium-ion batteries using methods of digital signal processing. *Energy Procedia*, Elsevier, v. 46, p. 204–213, 2014. Citado na página 30.
- RIVERA-BARRERA, J. P.; GALEANO, N.; SARMIENTO-MALDONADO, H. O. Soc estimation for lithium-ion batteries: review and future challenges. *Electronics*, Multidisciplinary Digital Publishing Institute, v. 6, n. 4, p. 102, 2017. Citado 5 vezes nas páginas 21, 28, 29, 31 e 33.
- ROSOLEM, M. de F. N. C. *et al.* Bateria de lítio-íon: conceitos básicos e potencialidades. *Caderno CPqD Tecnologia*, v. 8, n. 2, p. 59–72, jul/dez 2012. Citado na página 20.

- ROUT, T. *et al.* Analysis of energy management system for photovoltaic system with battery and supercapacitor using fuzzy logic controller. In: IEEE. *Technologies for Smart-City Energy Security and Power (ICSESP)*, 2018. [S.l.], 2018. p. 1–4. Citado na página 19.
- SALKIND, A. J. *et al.* Determination of state-of-charge and state-of-health of batteries by fuzzy logic methodology. *Journal of Power sources*, Elsevier, v. 80, n. 1-2, p. 293–300, 1999. Citado na página 33.
- SASSI, A. *et al.* Energy management of pv/wind/battery hybrid energy system based on batteries utilization optimization. In: IEEE. *Green Energy Conversion Systems (GECS)*, 2017 International Conference on. [S.l.], 2017. p. 1–7. Citado na página 19.
- SAW, L. *et al.* Electro-thermal analysis of lithium iron phosphate battery for electric vehicles. *Journal of Power Sources*, Elsevier, v. 249, p. 231–238, 2014. Citado na página 53.
- SHEN, P. *et al.* State of charge, state of health and state of function co-estimation of lithium-ion batteries for electric vehicles. In: IEEE. *Vehicle Power and Propulsion Conference (VPPC)*, 2016 IEEE. [S.l.], 2016. p. 1–5. Citado na página 25.
- SHEN, P. *et al.* The co-estimation of state of charge, state of health, and state of function for lithium-ion batteries in electric vehicles. *IEEE Transactions on Vehicular Technology*, IEEE, v. 67, n. 1, p. 92–103, 2018. Citado na página 25.
- SILVA, L. N. de C. *Análise e síntese de estratégias de aprendizado para redes neurais artificiais*. Dissertação (Mestrado) — Departamento de Engenharia de Computação e Automação Industrial, Universidade Estadual de Campinas,, 1998. Citado na página 37.
- SINGH, P.; JR, C. F.; REISNER, D. Fuzzy logic modelling of state-of-charge and available capacity of nickel/metal hydride batteries. *Journal of Power Sources*, Elsevier, v. 136, n. 2, p. 322–333, 2004. Citado na página 33.
- SOUSA, T. T. de *et al.* Comparison of different approaches for lead acid battery state of health estimation based on artificial neural networks algorithms. In: IEEE. *Evolving and Adaptive Intelligent Systems (EAIS)*, 2016 IEEE Conference on. [S.l.], 2016. p. 79–84. Citado 3 vezes nas páginas 22, 34 e 44.
- TRAN, N. T. *et al.* Matlab simulation of lithium ion cell using electrochemical single particle model. In: IEEE. *Power Electronics Conference (SPEC)*, IEEE Annual Southern. [S.l.], 2016. p. 1–6. Citado na página 32.
- TREMBLAY, O.; DESSAINT, L.-A.; DEKKICHE, A.-I. A generic battery model for the dynamic simulation of hybrid electric vehicles. In: IEEE. *Vehicle Power and Propulsion Conference*, 2007. *VPPC 2007. IEEE*. [S.l.], 2007. p. 284–289. Citado na página 53.
- VELLASCO, M. M. B. R. *Redes Neurais Artificiais*. [S.l.]: Laboratório de Inteligência Computacional Aplicada, PUC Rio, 2007. Citado na página 36.
- VETTER, J. *et al.* Ageing mechanisms in lithium-ion batteries. *Journal of power sources*, Elsevier, v. 147, n. 1-2, p. 269–281, 2005. Citado na página 24.

- WAAG, W.; FLEISCHER, C.; SAUER, D. U. Critical review of the methods for monitoring of lithium-ion batteries in electric and hybrid vehicles. *Journal of Power Sources*, Elsevier, v. 258, p. 321–339, 2014. Citado na página 28.
- WANG, A. *et al.* Lifepo4 battery modeling and soc estimation algorithm. In: IEEE. *Control And Decision Conference (CCDC), 2017 29th Chinese*. [S.l.], 2017. p. 7574–7578. Citado na página 42.
- WANG, Q. *et al.* Correlation between the model accuracy and model-based soc estimation. *Electrochimica Acta*, Elsevier, v. 228, p. 146–159, 2017. Citado na página 31.
- WINTER, M.; BRODD, R. J. *What are batteries, fuel cells, and supercapacitors?* [S.l.]: ACS Publications, 2004. Citado na página 24.
- WOHLFAHRT-MEHRENS, M.; VOGLER, C.; GARCHE, J. Aging mechanisms of lithium cathode materials. *Journal of power sources*, Elsevier, v. 127, n. 1-2, p. 58–64, 2004. Citado na página 24.
- XING, Y. *et al.* State of charge estimation of lithium-ion batteries using the open-circuit voltage at various ambient temperatures. *Applied Energy*, Elsevier, v. 113, p. 106–115, 2014. Citado na página 21.
- YUAN, S.; WU, H.; YIN, C. State of charge estimation using the extended kalman filter for battery management systems based on the arx battery model. *Energies*, Multidisciplinary Digital Publishing Institute, v. 6, n. 1, p. 444–470, 2013. Citado 2 vezes nas páginas 32 e 42.
- ZHU, C. *et al.* Development of a theoretically based thermal model for lithium ion battery pack. *Journal of Power Sources*, Elsevier, v. 223, p. 155–164, 2013. Citado na página 53.