

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ**

**JOELTON DEONEI GOTZ**

**APLICAÇÃO DE MACHINE LEARNING PARA A IDENTIFICAÇÃO,  
TRATAMENTO E ANTECIPAÇÃO DE FALHAS EM BATERIAS DE  
ÍONS DE LÍTIO**

**TESE**

**CURITIBA**

**2023**

**JOELTON DEONEI GOTZ**

**APLICAÇÃO DE MACHINE LEARNING PARA A  
IDENTIFICAÇÃO, TRATAMENTO E ANTECIPAÇÃO DE  
FALHAS EM BATERIAS DE ÍONS DE LÍTIO**

**Application of Machine Learning for Identification, Treatment, and  
Anticipation of Failures in Lithium-Ion Batteries**

Tese apresentada como requisito para obtenção do título de Doutor em Engenharia da Universidade Tecnológica Federal do Paraná (UTFPR). Área de Concentração: Engenharia De Manufatura.

Orientador: Prof. Dr. Milton Borsato

**CURITIBA**

**2023**



[4.0 Internacional](#)

Esta licença permite *download* e compartilhamento do trabalho desde que sejam atribuídos créditos ao(s) autor(es), sem a possibilidade de alterá-lo ou utilizá-lo para fins comerciais.

Conteúdos elaborados por terceiros, citados e referenciados nesta obra não são cobertos pela licença.



---

JOELTON DEONEI GOTZ

**APLICAÇÃO DE MACHINE LEARNING PARA A IDENTIFICAÇÃO, TRATAMENTO E ANTECIPAÇÃO DE FALHAS EM BATERIAS DE ÍONS DE LÍTIO**

Trabalho de pesquisa de doutorado apresentado como requisito para obtenção do título de Doutor Em Engenharia da Universidade Tecnológica Federal do Paraná (UTFPR). Área de concentração: Engenharia De Manufatura.

Data de aprovação: 07 de Junho de 2023

Dr. Milton Borsato, Doutorado - Universidade Tecnológica Federal do Paraná

Dr. Alexandre Rasi Aoki, Doutorado - Universidade Federal do Paraná (Ufpr)

Dr. Eduardo Felix Ribeiro Romaneli, Doutorado - Universidade Tecnológica Federal do Paraná

Dr. Julio Cesar Nievola, Doutorado - Pontifícia Universidade Católica do Paraná (Pucpr)

Dra. Myriam Regattieri De Biase Da Silva Delgado, Doutorado - Universidade Tecnológica Federal do Paraná

Documento gerado pelo Sistema Acadêmico da UTFPR a partir dos dados da Ata de Defesa em 07/06/2023.

## **AGRADECIMENTOS**

Em primeiro lugar, gostaria de agradecer a Deus Pai Todo Poderoso, criador do Céu e da Terra, e à Virgem Maria por sua interação sempre poderosa junto ao seu Filho Jesus Cristo.

Além disso, gostaria de agradecer à minha esposa, Querulin Malena Perret Gotz, por seu amor, cuidado e paciência comigo durante este período de doutorado. Sabemos que neste período, tivemos que nos privar de diversas coisas, eventos e viagens e adiar sonhos que a partir de agora poderemos realizar. Apesar disso, conseguimos sobreviver a todo esse período juntos em muitos momentos em plena pandemia.

Adicionalmente, gostaria de agradecer aos meus pais: Artemio Gotz e Dirlei Maria Preczewski Gotz. Apesar de terem uma vida simples no campo e não terem tido oportunidade de estudar, eles sempre me apoiaram, incentivaram e me ajudaram desde o ensino médio. Foram anos de apoio financeiro e emocional desde minha chegada em Curitiba, minha estada de dois anos na Alemanha, meu mestrado e, por fim, meu doutorado. Espero um dia poder retribuir tudo que fizeram por mim.

Também gostaria de agradecer ao meu orientador, Professor Doutor Milton Borsato, por me escolher para este projeto. Além disso, pelo apoio, suporte, motivação e auxílio em todas as etapas do doutorado, sempre buscando meios e subsídios para desenvolver todo o estudo.

Não posso deixar de agradecer aos Professores Emilson Ribeiro Viana e Fernanda Cristina Corrêa, ao Doutor José Rodolfo Galvão, ao meu colega Mestre Samuel Henrique Werlich, ao senhor Alexandre de Moura Silveira e aos estagiários que participaram diretamente do meu projeto. Eles me ajudaram e apoiaram no desenvolvimento do doutorado, principalmente nesta coletânea de artigos, por meio de incentivo, elaboração, correção e sugestões de melhoria.

Por fim, agradeço à Fundep e ao programa Rota 2030 pelo apoio financeiro durante o doutorado e pela possibilidade de participar de um projeto super motivador de desenvolvimento e montagem de um carro elétrico com tecnologia nacional. Além disso, agradeço a todos os desenvolvedores participantes do projeto e aos órgãos envolvidos: UTFPR Curitiba Centro, UTFPR Curitiba Ecoville, UTFPR Ponta Grossa, Senai Curitiba e Senai Londrina.

## RESUMO

**Aplicação de Machine Learning para a Identificação, Tratamento e Antecipação de Falhas em Baterias de Íons de Lítio.** 2023. 71 f. Tese (Doutorado em Engenharia). Programa de Pós-Graduação em Engenharia Mecânica e de Materiais – Universidade Tecnológica Federal do Paraná. Curitiba, 2023.

A busca por veículos elétricos vem crescendo fortemente, desde a última década, devido a pressões governamentais e climáticas, além da substituição de combustíveis fósseis por energias renováveis. Como consequência, ocorre a aceleração da adoção de baterias de íons de lítio (BIL) para sistemas de armazenamento. BIL é uma tecnologia dominante com várias vantagens em comparação com outras formas de armazenamento, a saber: maior densidade de energia, maior capacidade, vida útil mais longa, entre outras características. Apesar disso, BIL é sensível a falhas e deve ser operada com segurança e em condições controladas. Caso contrário, diversos abusos e falhas podem aparecer, como: falhas de curto-círcuito externo e interno, *overcharging*, *overdischarging*, *overheating* e avalanche térmica. Visando gerenciar o estado da bateria e prevenir falhas tem-se o *Battery Management System* (BMS), o qual é utilizado para equalizar e controlar a operação da bateria e evitar falhas. No entanto, o BMS carece de soluções adaptáveis em seus algoritmos de gerenciamento do estado da bateria e, portanto, é eficiente somente para células novas e equalizadas. Sendo assim, devido à degradação natural e o desbalanceamento devido à própria construção da bateria, o BMS pode apresentar falhas e não operar corretamente, o que pode causar falhas e abusos. Assim, a aplicação de técnicas de *Machine Learning* (ML) pode ser uma excelente abordagem para auxiliar no diagnóstico e prognóstico de falhas em baterias de íons de lítio. Portanto, este trabalho apresenta uma coleção de quatro aplicações de ML em baterias. A primeira aplicação empregou seis modelos de ML para diagnosticar abusos e falhas em células de íons de lítio. Este trabalho utilizou a Sensibilidade como métrica de comparação entre os modelos. Os resultados indicaram que os modelos propostos podem ser aplicados para identificar falhas em baterias com alta precisão. Em seguida, o segundo desenvolvimento utilizou o conceito de detecção de anomalias para identificar anormalidades nas células através do monitoramento térmico de um *pack* com três células. O trabalho demonstrou que uma anomalia é um primeiro estágio de uma falha, e os modelos conseguiram antecipar as falhas de *overheating* em até 52 segundos. A terceira abordagem aplicou o contexto de *Random Forest* and *Isolation Forest* para interromper e tratar falhas em células individuais. O trabalho desenvolvido pode interromper o curto-círcuito externo, *overcharging*, *overdischarging* e a combinação das três falhas. Como resultado do trabalho, o sistema aplicado conseguiu reduzir a perda de capacidade em até 91%. Por fim, o quarto trabalho foi desenvolvido para estimar falhas de *overheating* em um pacote de baterias aplicando uma estratégia composta por duas etapas. Na primeira etapa, o sistema estima os valores futuros dos principais parâmetros coletadas das baterias. Em seguida, na segunda etapa, o sistema classifica falhas ou não falhas a partir dos valores estimados da primeira etapa. O trabalho foi aplicado a dois conjuntos de dados. Inicialmente, o sistema pode prever uma falha em cerca de 35 a 40 segundos de forma antecipada. Por outro lado, ele conseguiu antecipar uma falha em até 70 segundos para o segundo conjunto de dados que possuía casos de curto-círcuito externo. Desta forma, esta tese pode demonstrar o potencial da aplicação de ML podendo diagnosticar, tratar, interromper e prever falhas e abusos em células de íons de lítio e, desta forma, auxiliar o BMS a prolongar a vida útil da bateria.

**Palavras-chave:** baterias de íons de lítio; falhas; aprendizado de máquinas; diagnósticos de falhas; estimações de falhas.

## ABSTRACT

**Application of Machine Learning for Identification, Treatment, and Anticipation of Failures in Lithium Ion Batteries.** 2023. 71 p. Thesis (Doctorate in Engineering).

Post-Graduation Program in Mechanical Engineering and Materials – Universidade Tecnológica Federal do Paraná. Curitiba, 2023.

The search for electric vehicles has been growing strongly since the last decade due to governmental and climate pressures and the replacement of fossil fuels by renewable energies. Consequently, the adoption of lithium-ion batteries (LIB) for storage systems is accelerating. LIB is a dominant technology with several advantages compared to other forms of storage, such as higher energy density, higher capacity, and longer lifetime, among other characteristics. Despite this, LIB is sensitive to failure and must be operated safely and under controlled conditions. Otherwise, various abuses and faults may appear, such as external and internal short-circuit faults, overcharging, over-discharging, overheating, and thermal avalanche. This way, the Battery Management System (BMS) is used to equalize and control battery operation and prevent failures. However, the BMS is designed with inflexible programming and is only effective for new and balanced cells. Therefore, due to natural degradation and imbalance resulting from the battery construction, the BMS may fail and not operate correctly, which can cause failures and abuse. Thus, the application of Machine Learning (ML) techniques can be an excellent approach to assist in diagnosing and prognosis of failures in lithium-ion batteries. Therefore, this work presents a collection of four ML applications in batteries, which were published in high-impact international journals. The first work applied six ML models to diagnose abuse and failures in lithium-ion cells. This work used Sensitivity as a comparison metric between the models. The results indicated that the proposed models could be applied to identify faults in batteries with high accuracy. Then, the second article used the concept of anomaly detection to identify abnormalities in cells through thermal monitoring of a 3-cell pack. The work demonstrated that an anomaly is the first failure stage, and the models could anticipate overheating failures by up to 52 seconds. The third article applied the context of Random Forest and Isolation Forest to stop and handle failures in individual cells. The developed work can interrupt external short circuits, overcharging, over-discharging, and combining the three failures. As a result of the work, the applied system reduced capacity loss by up to 91%. Finally, the fourth work was developed to estimate overheating failures in a battery pack using a context composed of two steps. In the first step, the system calculates the future values of the main parameters collected from the batteries. Then, in the second stage, the system classifies failures or non-failures based on the estimated values of the first stage. The work was applied to two sets of data. Initially, the system can predict a failure about 35 to 40 seconds in advance. On the other hand, it could anticipate a failure by up to 70 seconds for the second dataset with external short circuit cases. In this way, this collection of articles can demonstrate the potential of applying ML to diagnose, treat, interrupt, and predict failures and abuses in lithium-ion cells and, in this way, help the BMS extend the battery life.

**Keywords:** lithium-ion batteries; failures; machine learning; diagnosis; forecast.

## LISTA DE SIGLAS

ANN	Redes Neurais Artificiais – <i>Artificial Neural Network</i>
ARIMA	<i>Autoregressive Integrated Moving Average</i>
AWS	<i>Amazon Web Services</i>
BIL	Baterias de Íons de Lítio
BMS	Sistema de Gerenciamento de Baterias – <i>Battery Management System</i>
CC	Corrente Contínua
CM	Matriz de Confusão – <i>Confusion Matrix</i>
DD	<i>Data-driven</i>
EDA	Engenharia e Análise de Dados – <i>Engineering Data Analysis</i>
ESC	Curto-Círculo Externo – <i>External Short-Circuit</i>
EV	Veículo Elétrico – <i>Electric Vehicle</i>
FUNDEP	Fundação de Desenvolvimento da Pesquisa
KNN	<i>K-Nearst Neighbor</i>
I2C	<i>Inter-Integrated Circuit</i>
IF	<i>Isolation Forest</i>
ISC	Curto-Círculo Interno – <i>Internal Short-Circuit</i>
LR	Regressão Logística – <i>Logistic Regression</i>
LSTM	<i>Long Short-Term Memory</i>
ML	Aprendizado de Máquina – <i>Machine Learning</i>
NB	<i>Naives Bayes</i>
OC	Sobrecarga – <i>Overcharging</i>
OC-SVM	<i>One-Class Support Vector Machine</i>
OD	Sobre-Descarga – <i>Over-discharging</i>
OH	Sobreaquecimento – <i>Overheating</i>
RF	<i>Random Forest</i>
SENAI	Serviço Nacional de Aprendizagem Industrial
SOH	Estado de Saúde – <i>State of Health</i>
SVM	<i>Support Vector Machine</i>
TR	Avalanche Térmica – <i>Thermal Runaway</i>
UB-IOT	<i>Ubivis Industrial Internet of Things</i>
UTFPR-CT	Universidade Tecnológica Federal do Paraná - Campus Curitiba
UTFPR-PG	Universidade Tecnológica Federal do Paraná - Campus Ponta Grossa

## RESUMO

A busca por veículos elétricos vem crescendo fortemente, desde a última década, devido a pressões governamentais e climáticas, além da substituição de combustíveis fósseis por energias renováveis. Como consequência, ocorre a aceleração da adoção de baterias de íons de lítio (BIL) para sistemas de armazenamento. BIL é uma tecnologia dominante com várias vantagens em comparação com outras formas de armazenamento, a saber: maior densidade de energia, maior capacidade, vida útil mais longa, entre outras características. Apesar disso, BIL é sensível a falhas e deve ser operada com segurança e em condições controladas. Caso contrário, diversos abusos e falhas podem aparecer, como: falhas de curto-círcito externo e interno, overcharging, over-discharging, overheating e avalanche térmica. Visando gerenciar o estado da bateria e prevenir falhas tem-se o Battery Management System (BMS), o qual é utilizado para equalizar e controlar a operação da bateria e evitar falhas. No entanto, o BMS carece de soluções adaptáveis em seus algoritmos de gerenciamento do estado da bateria e, portanto, é eficiente somente para células novas e equalizadas. Sendo assim, devido à degradação natural e o desbalanceamento devido à própria construção da bateria, o BMS pode apresentar falhas e não operar corretamente, o que pode causar falhas e abusos. Assim, a aplicação de técnicas de Machine Learning (ML) pode ser uma excelente abordagem para auxiliar no diagnóstico e prognóstico de falhas em baterias de íons de lítio. Portanto, este trabalho apresenta uma coleção de quatro aplicações de ML em baterias. A primeira aplicação empregou seis modelos de ML para diagnosticar abusos e falhas em células de íons de lítio. Este trabalho utilizou a Sensibilidade como métrica de comparação entre os modelos. Os resultados indicaram que os modelos propostos podem ser aplicados para identificar falhas em baterias com alta precisão. Em seguida, o segundo desenvolvimento utilizou o conceito de detecção de anomalias para identificar anormalidades nas células através do monitoramento térmico de um pack com três células. O trabalho demonstrou que uma anomalia é um primeiro estágio de uma falha, e os modelos conseguiram antecipar as falhas de overheating em até 52 segundos. A terceira abordagem aplicou o contexto de Random Forest and Isolation Forest para interromper e tratar falhas em células individuais. O trabalho desenvolvido pode interromper o curto-círcito externo, overcharging, overdischarging e a combinação das três falhas. Como resultado do trabalho, o sistema aplicado conseguiu reduzir a perda de capacidade em até 91%. Por fim, o quarto trabalho foi desenvolvido para estimar falhas de overheating em um pacote de baterias aplicando uma estratégia composta por duas etapas. Na primeira etapa, o sistema estima os valores futuros dos principais parâmetros coletadas das baterias. Em seguida, na segunda etapa, o sistema classifica falhas ou não falhas a partir dos valores estimados da primeira etapa. O trabalho foi aplicado a dois conjuntos de dados. Inicialmente, o sistema pode prever uma falha em cerca de 35 a 40 segundos de forma antecipada. Por outro lado, ele conseguiu antecipar uma falha em até 70 segundos para o segundo conjunto de dados que possuía casos de curto-círcito externo. Desta forma, esta tese pode demonstrar o potencial da aplicação de ML podendo diagnosticar, tratar, interromper e prever falhas e abusos em células de íons de lítio e, desta forma, auxiliar o BMS a prolongar a vida útil da bateria.

Palavras-chave: baterias de íons de lítio; falhas; aprendizado de máquinas; diagnósticos de falhas; estimações de falhas.

## ABSTRACT

The search for electric vehicles has been growing strongly since the last decade due to governmental and climate pressures and the replacement of fossil fuels by renewable energies. Consequently, the adoption of lithium-ion batteries (LIB) for storage systems is accelerating. LIB is a dominant technology with several advantages compared to other forms of storage, such as higher energy density, higher capacity, and longer lifetime, among other characteristics. Despite this, LIB is sensitive to failure and must be operated safely and under controlled conditions. Otherwise, various abuses and faults may appear, such as external and internal short-circuit faults, overcharging, over-discharging, overheating, and thermal avalanche. This way, the Battery Management System (BMS) is used to equalize and control battery operation and prevent failures. However, the BMS is designed with inflexible programming and is only effective for new and balanced cells. Therefore, due to natural degradation and imbalance resulting from the battery construction, the BMS may fail and not operate correctly, which can cause failures and abuse. Thus, the application of Machine Learning (ML) techniques can be an excellent approach to assist in diagnosing and prognosis of failures in lithium-ion batteries. Therefore, this work presents a collection of four ML applications in batteries, which were published in high-impact international journals. The first work applied six ML models to diagnose abuse and failures in lithium-ion cells. This work used Sensitivity as a comparison metric between the models. The results indicated that the proposed models could be applied to identify faults in batteries with high accuracy. Then, the second article used the concept of anomaly detection to identify abnormalities in cells through thermal monitoring of a 3-cell pack. The work demonstrated that an anomaly is the first failure stage, and the models could anticipate overheating failures by up to 52 seconds. The third article applied the context of Random Forest and Isolation Forest to stop and handle failures in individual cells. The developed work can interrupt external short circuits, overcharging, over-discharging, and combining the three failures. As a result of the work, the applied system reduced capacity loss by up to 91%. Finally, the fourth work was developed to estimate overheating failures in a battery pack using a context composed of two steps. In the first step, the system calculates the future values of the main parameters collected from the batteries. Then, in the second stage, the system classifies failures or non-failures based on the estimated values of the first stage. The work was applied to two sets of data. Initially, the system can predict a failure about 35 to 40 seconds in advance. On the other hand, it could anticipate a failure by up to 70 seconds for the second dataset with external short circuit cases. In this way, this collection of articles can demonstrate the potential of applying ML to diagnose, treat, interrupt, and predict failures and abuses in lithium-ion cells and, in this way, help the BMS extend the battery life.

Keywords: lithium-ion batteries; failures; machine learning; diagnosis; forecast.

## LISTA DE ABREVIATURAS E SIGLAS

ANN	Redes Neurais Artificiais – Artificial Neural Network
ARIMA	Autoregressive Integrated Moving Average
AWS	Amazon Web Services
BIL	Baterias de Íons de Lítio
BMS	Sistema de Gerenciamento de Baterias – Battery Management System
CC	Corrente Contínua
CM	Matriz de Confusão – Confusion Matrix
DD	Data-driven
EDA	Engenharia e Análise de Dados – Engineering Data Analysis
ESC	Curto-Círculo Externo – External Short-Circuit
EV	Veículo Elétrico – Electric Vehicle
FUNDEP	Fundação de Desenvolvimento da Pesquisa
KNN	K-Nearst Neighbor
I2C	Inter-Integrated Circuit
IF	Isolation Forest
ISC	Curto-Círculo Interno – Internal Short-Circuit
LR	Rregressão Logística – Logistic Regression
LSTM	Long Short-Term Memory
ML	Aprendizado de Máquina – Machine Learning
NB	Naives Bayes
OC	Sobrecarga – Overcharging
OC-SVM	One-Class Support Vector Machine
OD	Sobre-Descarga – Over-discharging
OH	Sobreaquecimento – Overheating
RF	Random Forest
SENAI	Serviço Nacional de Aprendizagem Industrial
SOH	Estado de Saúde – State of Health
SVM	Support Vector Machine
TR	Avalanche Térmica – Thermal Runaway
UB-IOT	Ubivis Industrial Internet of Things
UTFPR-CT	Universidade Tecnológica Federal do Paraná - Campus Curitiba
UTFPR-PG	Universidade Tecnológica Federal do Paraná - Campus Ponta Grossa

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO .....</b>	<b>9</b>
<b>1.1</b>	<b>Objetivos .....</b>	<b>14</b>
1.1.1	Objetivo Geral.....	14
1.1.2	Objetivos Específicos .....	14
<b>1.2</b>	<b>Estrutura do Trabalho .....</b>	<b>14</b>
<b>2</b>	<b>DESCRIÇÃO DA COLETÂNEA.....</b>	<b>16</b>
<b>2.1</b>	<b>Artigo A: <i>Diagnosing failures in lithium-ion batteries with Machine Learning techniques</i> (Gotz et al., 2023A).....</b>	<b>16</b>
<b>2.2</b>	<b>Artigo B: <i>Application of Anomaly Detection Algorithms in Lithium-Ion Battery Packs - A Case</i> (Gotz et al., 2023B) .....</b>	<b>18</b>
<b>2.3</b>	<b>Artigo C: <i>Reducing the Capacity Loss of Lithium-Ion Batteries with Machine Learning in Real-Time—A Study Case</i> (Gotz et al., 2022) .....</b>	<b>19</b>
<b>2.4</b>	<b>Artigo D: <i>Machine Learning for Forecasting and Predicting Failures in Lithium-Ion Batteries</i> (Gotz et al., 2023C).....</b>	<b>23</b>
<b>3</b>	<b>TRABALHOS EM ANDAMENTO .....</b>	<b>24</b>
<b>4</b>	<b>CONCLUSÃO .....</b>	<b>26</b>
	<b>REFERÊNCIAS.....</b>	<b>28</b>
	<b>APÊNDICE A - Artigo A: <i>Diagnosing failures in lithium-ion batteries with Machine Learning techniques</i> .....</b>	<b>31</b>
	<b>APÊNDICE B - Artigo B: <i>Application of Anomaly Detection Algorithms in Lithium-Ion Battery Packs - A Case Study</i> .....</b>	<b>34</b>
	<b>APÊNDICE C - Artigo C: <i>Reducing the Capacity Loss of Lithium-Ion Batteries with Machine Learning in Real-Time—A Study Case</i> .....</b>	<b>42</b>
	<b>APÊNDICE D - Artigo D: <i>Machine Learning for Forecasting and Predicting Failures in Lithium-Ion Batteries</i> .....</b>	<b>60</b>

## 1 INTRODUÇÃO

A procura por fontes de energia renováveis tem crescido consideravelmente nos últimos anos com o principal objetivo de reduzir o consumo de combustíveis fósseis. Essa mudança se deve, em parte, às pressões de órgãos governamentais e ligados a questões ambientais. Por isso, várias fontes de energia limpa e de armazenamento são testadas visando substituir a propulsão de veículos movidos a derivados de petróleo. O advento dos carros elétricos tende a aumentar a busca por tecnologias eficientes de armazenamento e, ao mesmo tempo, reduzir de forma significativa as emissões de dióxido de carbono no ar (LIU *et al.*, 2022).

Sendo assim, a bateria de íons de lítio (BIL) ou célula de íons de lítio é uma tecnologia amplamente empregada para armazenar energia para carros e sistemas estacionários. BIL possui várias vantagens comparadas com outras tecnologias de armazenamento. Entre essas vantagens, encontram-se: maior desempenho, capacidade e densidade de energia, vida útil mais longa, além de possuir baixos índices de auto descarga (CHEN *et al.*, 2021a; HU *et al.*, 2020).

Uma BIL possui quatro componentes principais: ânodo, cátodo, separador e as camadas eletrolíticas. O ânodo é o eletrodo negativo, o qual possui a função de perder elétrons. É formado de matrizes de grafite onde os íons de lítio ficam armazenados. Por outro lado, o cátodo é o polo positivo, o qual sofre redução, portanto, ganha elétrons. Tanto o cátodo como o ânodo são imersos nas camadas de solventes compostas de sal chamadas de camadas eletrolíticas. Por fim, o separador tem a função de isolar os polos e evitar curto-círcuito entre o cátodo e o ânodo. Enquanto o ânodo é formado de matrizes de grafite, o cátodo pode ser formado de materiais pesados como lítio, manganês, cobalto, alumínio, níquel, entre outros (ZUBI *et al.*, 2018).

Apesar das inúmeras vantagens já citadas das baterias de íons de lítio, elas são sensíveis a falhas e abusos e precisam ser operadas sobre parâmetros controlados. Caso contrário, pode haver não apenas aceleração de degradação e envelhecimento, mas também, causar situações de perigo como incêndios e explosões. Por isto, um dispositivo chamado de Sistema de gerenciamento de baterias (do inglês, Battery Management System - BMS) é utilizado para manter a bateria controlada. A função principal do BMS é equalizar as células em um pacote. Desta forma, através do monitoramento dos principais parâmetros como tensão, corrente e

temperatura, o dispositivo consegue balancear os níveis de tensão das células com o objetivo manter todas sob o mesmo nível de energia (HU *et al.*, 2020; LI *et al.*, 2021).

Desta forma, o BMS possui a função de controlar os processos de recarga e descarga garantindo o pleno e correto funcionamento das células. Alguns BMS possuem também a função de fazer controles térmicos e o diagnóstico de falhas. Apesar disso, o BMS é programado com funções originais e inflexíveis que perdem desempenho com a redução do estado de vida (do inglês, *State of Health* - SOH) das células, ou seja, sua eficiência diminui com a degradação natural das células (LI *et al.*, 2021; CHEN *et al.*, 2018).

No caso de ineficiência ou falha na operação do BMS, várias falhas e abusos podem ser observados em um pacote de baterias. Abusos podem ser considerados as causas, enquanto as falhas são as consequências. Os abusos podem ser segmentados em três principais grupos: (I) falhas mecânicas, (II) falhas elétricas e (III) falhas térmicas. Os abusos mecânicos são causados por situações físicas no veículo, como vibração ou má montagem do pacote de baterias que permite o contato direto entre os eletrodos positivo e negativo das células, o que se denomina curto-círcito externo (do inglês, *External Short-Circuit* - ESC). Quando um ESC acontece, devido a uma baixa resistência entre o cátodo e o ânodo, uma corrente com elevada magnitude flui entre os polos da bateria em forma de uma severa descarga. Esse abuso eleva de forma significativa a temperatura e pressão interna da célula o que pode causar outras falhas como o curto-círcito interno (do inglês, *Internal Short-Circuit* - ISC), superaquecimento (do inglês, *Overheating* - OH) e avalanche térmica (do inglês, *Thermal Runaway* - TR) (HU *et al.*, 2021; JI *et al.*, 2020; DONG *et al.*, 2019).

No grupo elétrico, é encontrada a falha de ISC, além dos abusos de sobrecarga (do inglês, *Overcharging* - OC) e sobre-descarga (do inglês, *Over-discharging* - OD). OC acontece quando a célula é carregada acima do seu nível seguro de tensão máxima. Este abuso acontece devido a falhas de equalização do BMS e acelera o processo de oxidação da bateria, o qual dificulta o posicionamento dos íons de lítio nas matrizes de grafite. Como consequência, são observados: o aumento na resistência interna da célula e queda na capacidade de armazenamento (OYANG *et al.*, 2018).

Contrário ao OC, OD acontece no processo de descarga da bateria. Este abuso também é observado em casos de falha de equalização do BMS. OD é registrado quando a célula é submetida à descarga ultrapassando seu nível inferior

mínimo seguro de tensão. Isto causa dissolução do cobre do eletrodo e acumula lítio metálico no eletrodo. Como consequência, a resistência interna aumenta e ocorre a perda de material ativo na célula (MALEKI; HOWARD, 2006).

OC e OD causam ISC. ISC por sua vez, também pode ser causado por ESC. ISC é considerada uma falha, na qual ocorre contato interno direto entre os polos da bateria. A consequência é gerar a falha térmica de TR (HU *et al.*, 2020).

O grupo de falhas térmicas é composto da falha de OH e TR. OH pode ser considerado um abuso, portanto, pode ser reduzido com ações do BMS. OH acontece quando a temperatura se eleva de forma considerável durante a operação da bateria na recarga ou descarga. A temperatura ambiente e a elevada demanda de energia solicitada pelo motor tendem a aumentar a corrente de descarga e causar stress na bateria, a fim de elevarem sua temperatura interna (HU *et al.*, 2020). Caso um OH não seja resolvido, pode causar o TR. TR é a falha mais crítica observada em BIL. Neste caso, a temperatura eleva-se a altos valores em pequenos intervalos, o qual pode provocar incêndio e explosão. Além disso, a dimensão desta falha pode ser grande em caso de contaminação para outras células do pack mediante contato físico ou pelos terminais (KANG *et al.*, 2020).

Devido à possibilidade de várias falhas críticas e à ineficiência de operação do BMS com a degradação natural das células, é necessário encontrar outras soluções viáveis que podem auxiliar o BMS na redução de falhas e abusos. Desta forma, sistemas *Data-Driven* (DD) são uma solução que vem sendo altamente empregada para sistemas de diagnóstico de falhas, como pode ser observado em um trabalho realizado por este grupo de pesquisa em Gotz *et al.* (2021). O uso de DD permite realizar decisões baseadas nos dados e, desta forma, habilita o uso de técnicas de aprendizado de máquina (do inglês, *Machine Learning* - ML) para auxiliar na construção de sistemas de diagnóstico e prognóstico de falhas em baterias de íons de lítio (GOTZ *et al.*, 2021).

ML pode ser aplicada de diversas formas para o diagnóstico de falhas. Este trabalho contém quatro aplicações baseadas em identificação, tratamento e previsão de falhas. Portanto, para identificar falhas, vários modelos de classificação podem ser encontrados na literatura. Regressão Logística (do inglês, *Logistic Regression* - LR) é um dos mais simples e eficientes modelos que se baseiam no cálculo da probabilidade para declarar amostras de dados como sendo evento ou não evento. LR baseia-se na distribuição de Bernoulli. Além disso, *Support Vector Machine* (SVM) calcula a

probabilidade da densidade dos dados. Este modelo cria hiperplanos para segmentar os dados de falhas e não falhas. SVM é um modelo eficiente, porém necessita alto poder computacional. Por outro lado, *Random Forest* (RF) é um modelo Ensemble Learning muito eficiente, o qual realiza a classificação através da distribuição dos dados em várias árvores de decisão. Devido a sua construção de não apenas Ensemble, mas também pela distribuição dos dados, RF possui alta atuação e baixa demanda de processamento (SABERIOON *et al.*, 2018).

*K-Nearest Neighbor* (KNN) é outro modelo de classificação. Ele calcula a distância entre as amostras para separá-las em conjuntos de clusters. Para realizar a separação, o modelo utiliza várias métricas para o cálculo da distância para seus vizinhos, sendo distância Euclidiana como a mais empregada (CHEN *et al.*, 2021b). Por outro lado, *Naives Bayes* (NB) tem operação similar à LR, porém necessita pequenos conjuntos de dados para treinamento e consegue trabalhar de forma eficiente com dados que apresentam ruídos (WIBAWA *et al.*, 2019).

Gotz *et al.* (2021) demonstram o crescente uso de redes neurais para serem aplicadas no diagnóstico de falhas em máquinas. Esse uso crescente se deve à habilidade de redes neurais no entendimento de processos complexos e na absorção de *features* abstratas. Sendo assim, esta caixa preta contém neurônios e três principais camadas: entrada (*input*), ocultas (*hidden*) e saída (*output*). Cada camada contém neurônios conectados entre si e com as camadas via pesos obtidos durante o treinamento (MOHANRAJ *et al.*, 2012).

O segundo artigo de coletânea aplicou o conceito de detecção de anomalias em baterias de íons de lítio. Sendo assim, modelos de detecção de anomalias são similares a modelos de classificação, pois uma anomalia pode ser considerada uma fase prévia de uma falha. Desta forma, alguns modelos podem ser observados. *Isolation Forest* (IF) é baseado em RF, o qual isola as amostras anômalas das normais baseando os cálculos em árvores de decisão (LIU *et al.*, 2008).

Por outro lado, *One-Class Support Vector Machine* (OC-SVM) é baseado no conceito de SVM. Este modelo identifica as anomalias baseado no cálculo de densidade e na separação dos dados em hiperplanos. OC-SVM identifica as amostras anômalas como sendo com baixo nível de densidade e, consequentemente, os dados normais com alto nível de densidade (LEE; LEE, 2021).

O quarto artigo desta coletânea aplicou modelos de séries temporais para realizar previsões de parâmetros futuros para antecipar a ocorrência de falhas. Desta

maneira, dois modelos conhecidos são *Autoregressive Integrated Moving Average* (ARIMA) e *Long Short-Term Memory* (LSTM). ARIMA é um modelo estatístico utilizado para problemas não estacionários onde a média e a variância não são constantes (HUOTARI *et al.*, 2020). Por outro lado, LSTM é uma rede neural aplicada para problemas de séries temporais. Diferente de outros modelos, LSTM consegue reduzir os efeitos de gradiente de *vanish* e explosão vistos em modelos recorrentes. Este desempenho ocorre devido à existência de três portões (*gates*): entrada (*input*), *forget* e saída (*output*). O *forget* é responsável por remover dados desnecessários do modelo e, desta forma, melhorar o desempenho do mesmo (ZHANG *et al.*, 2017).

Sendo assim, devido à existência de várias falhas críticas e abusos que podem ocorrer em baterias de íons de lítio, este trabalho apresenta uma coletânea de quatro artigos publicados durante os últimos anos em periódicos relevantes. Os quatro artigos aplicaram técnicas de ML para diagnosticar, identificar anomalias, realizar o tratamento e previsões de falhas nas baterias.

O primeiro artigo se preocupou em aplicar seis modelos de classificação para detectar falhas em células individuais. Então, o segundo artigo realizou a aplicação de três modelos de detecção de anomalias para antecipar falhas térmicas em um *pack* com três células. Na sequência, o terceiro artigo combinou técnicas de RF e IF para identificar e tratar falhas em células individuais com abusos de OC, OD, ESC e a combinação dos três. Por fim, no quarto artigo, foi desenvolvido um sistema composto de duas camadas (série temporal e classificação) para realizar a previsão de falhas futuras em um *pack* com três células.

Este trabalho de doutorado faz parte de um projeto do programa Rota 2030 executado e coordenado pela FUNDEP. Iniciou em fevereiro de 2021 e será finalizado em agosto de 2023. Diversas equipes compõem esse projeto, entre elas a Renault do Brasil S.A., a Universidade Tecnológica Federal do Paraná representada pelos campus Ponta Grossa (UTFPR-PG) e Curitiba (UTFPR-CT), além do SENAI representado pelo Instituto SENAI de Inovação em Eletroquímica (SENAI-ISI), Instituto SENAI de Londrina e a empresa Clarios Energy Solutions Brasil Ltda.

## 1.1 Objetivos

### 1.1.1 Objetivo Geral

O principal objetivo deste trabalho é aplicar modelos ML para identificar falhas e abusos em BIL na fase inicial (primeiros sinais de incidência de anormalidade), para assim, tratar estas falhas e abusos e prolongar a vida útil das baterias

### 1.1.2 Objetivos Específicos

Esta tese apresenta os seguintes objetivos específicos:

- Entendimento das falhas e abusos encontrados na BIL;
- Diagnóstico de falhas e abusos de ESC, OC, OD e OH através da utilização de técnicas de ML;
- Detecção de anomalias no pacote de baterias;
- Tratamento de abusos em células de íons de lítio com auxílio de técnicas de ML;
- Previsão e estimação de abusos futuros de OH em um pacote de células; e
- Avaliação e comparação dos resultados dos modelos

## 1.2 Estrutura do Trabalho

Este trabalho apresenta uma coletânea de artigos como forma de tese de doutorado. Assim, o trabalho possui três capítulos que melhor descrevem o estudo realizado durante o doutorado. O primeiro capítulo apresenta a Introdução e explica alguns assuntos específicos envolvidos no trabalho completo, como a descrição de BIL, BMS, falhas comuns e modelos DD. No segundo capítulo, há uma descrição detalhada dos quatro artigos publicados. Em seguida, no terceiro capítulo, este trabalho apresenta as conclusões e trabalhos futuros.

No Apêndice A, é possível encontrar o primeiro artigo publicado na revista *Engineering Failure Analysis*. Em seguida, o Apêndice B mostra o segundo artigo

publicado na revista *Lecture Notes in Mechanical Engineering* (LNME). O terceiro artigo se encontra no Apêndice C, o qual foi publicado na revista *Machines* MDPI e o Apêndice D apresenta o quarto artigo também publicado na revista *Lecture Notes in Mechanical Engineering* (LNME).

## 2 DESCRIÇÃO DA COLETÂNEA

Esta coletânea de artigos é composta por quatro trabalhos publicados em periódicos relevantes com SNIP maior que 0,3 entre 2022 e 2023. Os artigos não serão apresentados de forma cronológica de publicação, mas em ordem de conexão lógica entre eles.

Além disso, um trabalho anterior a esta coletânea, o qual foi publicado em 2021, identificou a motivação para a abordagem de ML para a área de baterias. Este trabalho pode ser encontrado em Gotz et al. (2021). O trabalho elaborou uma análise bibliométrica e sistêmica sobre os trabalhos mais frequentes e relevantes no diagnóstico para máquinas. Segundo o manuscrito, as técnicas de ML são eficientes para entender e identificar falhas e abusos em máquinas.

Os resultados do artigo publicado por Gotz et al. (2021) motivaram a elaboração dos quatro seguintes artigos na área de baterias de íons de lítio.

### **2.1 Artigo A: *Diagnosing failures in lithium-ion batteries with Machine Learning techniques* (Gotz et al., 2023A)**

Este artigo foi desenvolvido em 2022 e publicado em 2023. O manuscrito inicialmente demonstra as principais falhas comuns que podem aparecer em BIL (OC, OD, ESC e OH). Em seguida, alguns experimentos foram preparados para submeter as células de íons de lítio aos quatro tipos de abusos para a aplicação do ML.

Assim, quatro circuitos simples foram construídos com o intuito de gerar os dados necessários para a aplicação ML. Um circuito para cada abuso: ESC, OC, OD e OH. Para os quatro experimentos foi utilizado um *Raspberry Pi4* como *Edge computing*. Além disso, um *Arduino Mega* funcionou como BMS e alguns sensores mediram os principais sinais das células (temperatura, corrente e tensão). Cada experimento foi realizado para células individuais.

A comunicação entre o *Arduino* e o *Raspberry* foi realizada através do protocolo I2C. Na mesma direção, dois sensores MAX6675 mediram a temperatura da célula e do ambiente. O sensor de corrente baseado no Resistor *Shunt* foi utilizado para coletar a assinatura da corrente. Por outro lado, a tensão da célula foi coletada diretamente por uma das entradas analógicas do *Arduino*. Células 18650 BIL com 2200 mAh de capacidade nominal e 3,7V foram utilizadas para gerar os experimentos. Um cooler foi utilizado para descarregar as células. Para carregar a célula, uma fonte

externa de corrente contínua (CC) foi usada. Para entender o impacto do abuso na saúde das células, a capacidade de cada célula foi medida antes e depois da aplicação do abuso.

Foram realizados dois experimentos para cada tipo de abuso. Para o experimento com ESC, foi forçado o contato direto entre cátodo e ânodo com uma baixa resistência de  $100\text{ m}\Omega$ . Os testes ocorreram até que a membrana interna de segurança se rompesse, a qual é utilizada para evitar o TR. A corrente no circuito e a temperatura interna da célula aumentaram significativamente até o rompimento, resultando em uma falha de OH. Em ambos os casos, as células perderam toda a capacidade.

Em seguida, dois experimentos com OC foram realizados. Para cada um deles, a célula foi carregada com tensão acima de 4,25V. Durante o experimento, a célula foi carregada na taxa de 1C e a tensão elétrica chegou a 7,5V. O aumento da temperatura foi mais lento do que para abuso de ESC, mas após 350 segundos uma falha de OH pôde ser vista. Em ambos os casos, as células perderam toda a capacidade.

Dois experimentos de OD foram aplicados também para gerar dados. As células foram totalmente descarregadas até que sua tensão estivesse próxima de 0V. Após os experimentos, as capacidades foram medidas e a perda foi de cerca de 25%.

Finalmente, o abuso de OH foi realizado. Os experimentos utilizaram uma fonte de calor externo para aquecer a célula. A capacidade perdida foi média (20%) para ambas as células. Os dados foram coletados e armazenados na Nuvem AWS. Em seguida, foram carregados e trabalhados no Ambiente Anaconda.

No ambiente Anaconda, a engenharia de análise de dados (do inglês, *Engineering Data Analysis - EDA*) foi realizada com objetivo de limpar e preparar os dados para a aplicação dos algoritmos de ML. Durante a EDA, duas análises de Correlação foram realizadas para entender a relação entre os principais parâmetros. Desta forma, uma Correlação de *Pearson* foi usada para identificar a força linear e a direção entre as falhas e os parâmetros de entrada.

Complementarmente à análise de Pearson, a Correlação de *Spearman* foi utilizada para demonstrar não só a Correlação linear, mas também, a Correlação não linear entre as variáveis. Ambas as correlações demonstraram que os três principais parâmetros (temperatura, corrente e tensão) devem ser utilizados como variáveis de entrada nos modelos ML. Por outro lado, os abusos serão considerados saídas. Após,

foram aplicadas cinco técnicas de classificação estatística de ML: LR, SVM, NB, KNN e RF. Adicionalmente, uma rede neural artificial (do inglês, *Artificial Neural Network* (ANN) também foi construída.

RF identificou OD em 100%, seguido por SVM (99%), ANN (98%), KNN (97%) e LR e NB com 94%. Finalmente, SVM, NB e RF identificaram abusos de OH em 100%. ANN conseguiu identificar um OH em 99%, enquanto LR teve baixo desempenho de apenas 84% e os piores resultados foram observados para ANN com 65%.

## **2.2 Artigo B: Application of Anomaly Detection Algorithms in Lithium-Ion Battery Packs - A Case (Gotz et al., 2023B)**

O segundo artigo foi publicado em 2023. O trabalho detalha a aplicação de três algoritmos de detecção de anomalias para encontrar uma anormalidade em células de um pacote de três BILs.

Um pacote de três células 18650 em série, com capacidade de 2200 mAh, foi construído para realizar os experimentos. Um dispositivo chamado UB-IOT foi utilizado como BMS. No UB-IOT, algumas ferramentas da AWS são instaladas para coletar os dados das baterias. Além disso, um cooler com 1,89 Watts de potência foi empregado para descarregar as células. No UB-IOT, uma rotina interna escrita em Python, controlava o processo de recarga e descarga em condições seguras. Dessa forma, as células foram carregadas até que a primeira ficasse acima de 4,2V e descarregadas até que a primeira ficasse abaixo do limite seguro de 2,65V.

A cada dois segundos, os principais parâmetros de cada célula eram coletados dos sensores. Um sensor termopar MAX6675 monitorou a temperatura de cada célula. O sensor se comunicava com o UB-IOT pelo protocolo *Serial Peripheral Interface* (SPI). Por outro lado, um sensor de efeito Hall ACS712 30A mediou a corrente do total do *pack*. Finalmente, a tensão de cada célula foi monitorada pelas entradas analógicas do UB-IOT.

Para gerar o conjunto de dados com objetivo de treinar os modelos, quatorze casos de abusos de OH foram experimentados para elevar a temperatura superficial da célula acima de 50 °C. O aquecimento foi realizado por injeção de calor externo diretamente nas células. O UB-IOT enviou os dados para a Nuvem AWS e os salvou em um *bucket* S3. Em seguida, no ambiente Anaconda, um *notebook Jupyter* foi

elaborado em linguagem Python para limpar os dados, construir, treinar e testar os modelos.

Em seguida, foram utilizados três modelos de detecção de anomalias: IF, KNN e OC-SVM. Para o treinamento, 30% do conjunto de dados foi utilizado. Assim, o restante dos dados foi empregado para testar e avaliar os modelos.

Duas métricas foram utilizadas para comparar e avaliar os modelos: disparo de temperatura e tempo de antecipação para a falha real. Sendo assim, OC-SVM conseguiu identificar uma anomalia quando a temperatura estava em média acima de 30 °C, enquanto KNN acima de 39 °C e IF acima de 45 °C. Por outro lado, OC-SVM pode antecipar uma possível falha em forma de anomalia em até 52 segundos, enquanto IF e KNN levaram 16 segundos. O estudo demonstrou que os três modelos podem ser aplicados em casos reais para antecipar falhas nas baterias.

### **2.3 Artigo C: *Reducing the Capacity Loss of Lithium-Ion Batteries with Machine Learning in Real-Time—A Study Case (Gotz et al., 2022)***

Após usar métodos de classificação e detecção de anomalias para identificar os abusos e falhas nas células, este trabalho apresenta um estudo de caso que combina IF e RF para identificar e interromper as falhas em tempo real, através da paralisação do processo atual da bateria (seja recarga ou descarga). Os resultados serviram de base para a elaboração do artigo publicado em 2022.

Assim como para os demais casos, um circuito foi desenvolvido para gerar as informações. Neste sentido, um *Raspberry Pi4* foi usado como *Edge Computing* (doravante denominado Edge ou computador de borda), enquanto um *Arduino Mega* funcionou como BMS. A comunicação entre ambos foi realizada pelo protocolo I2C. O Edge recebia os dados do BMS e enviava para a Nuvem AWS por conexão Wi-Fi.

Um sensor de efeito *Hall* ACS712 5A mensurava a corrente da célula durante os experimentos. Por outro lado, dois sensores LM35 monitoravam a temperatura ambiente e da célula. Por fim, a tensão da célula era coletada diretamente por uma entrada analógica do Arduino.

Antes dos experimentos, a capacidade de cada célula foi medida para entender o impacto dos experimentos de falhas aplicados nas baterias. Para os experimentos foram utilizadas células 18650 com capacidade nominal de 2200 mAh e tensão nominal igual a 3,7V.

A configuração experimental foi segmentada nas seguintes etapas:

- Identificar as falhas e abusos encontrados nas baterias;
- Criar experimentos para gerar o conjunto de dados com os principais abusos;
- Realizar experimentos de OC;
- Realizar experimentos de OD;
- Realizar experimentos de ESC;
- Realizar experimentos da combinação de OC, OD e ESC.
- Treinar os modelos;
- Testar os modelos; e
- Aplicar os modelos em tempo real.

Os experimentos com abusos OC foram realizados em três células. O processo começou com uma tensão igual de 4,2V. Em seguida, cada célula foi carregada até que sua tensão fosse maior que 5,5V ou a temperatura da célula fosse 12°C maior que a temperatura ambiente. Após, a célula foi descarregada até que sua tensão ficasse abaixo de 3,5V. O processo foi repetido três vezes.

Para experimentos de OD, as células com 4V ou mais descarregaram até que sua tensão estivesse abaixo de 0,8V. A célula foi, então, carregada até que seu nível de tensão fosse superior a 4V. O processo se repetiu por três vezes. Por outro lado, para experimentos com ESC, cada célula iniciava o processo com descarga por 5 minutos. Em seguida, um ESC era aplicado por quatro minutos. Depois disso, a célula era novamente descarregada até que sua tensão ficasse abaixo de 3,1V. A célula, então, era submetida à recarga, até que sua tensão ficasse acima ou igual a 4,2V. O processo foi repetido três vezes.

Finalmente, para os experimentos com a combinação de abusos, cada célula começava com uma tensão de 4,2V. A seguir, a célula era carregada até que sua tensão fosse maior que 5,5V ou o delta de temperatura entre a célula e o ambiente fosse maior que 12 °C. A célula descarregava por 5 minutos e, então, ESC era aplicado por quatro minutos. Depois disso, a célula era submetida à descarga até que sua tensão fosse inferior a 0,8V. Finalmente, a célula era novamente recarregada e o processo se repetiu por três vezes.

Três testes para cada tipo de abuso foram realizados. Os dados foram coletados pelo Arduino Mega e enviados por I2C para o Edge. O Edge enviou os dados diretamente para a nuvem, que foram salvos e armazenados em um *bucket* do S3. Posteriormente, um *notebook Jupyter* em execução no ambiente Anaconda carregou os dados.

A capacidade foi medida novamente após os experimentos. Os abusos de OC resultaram em perda de capacidade média de 1327 mAh. Por outro lado, os abusos submetidos para OD reduziram a capacidade das células em média 345 mAh. Para os abusos de ESC, foi observado uma perda de 926 mAh e para a combinação das falhas, a perda foi de aproximadamente 1620 mAh.

Durante a EDA, várias atividades foram realizadas, como: a limpeza, as transformações, a compreensão de dados e compreensão das falhas. A Correlação entre as variáveis demonstrou que cada abuso (OC, ESC e OD) tem uma alta relação com os parâmetros de corrente, temperatura, tensão e o delta da temperatura entre a célula e as condições ambientais. Esses parâmetros foram utilizados como entradas para os modelos.

Os modelos foram construídos e treinados nos três conjuntos de dados de abusos individuais e testados no conjunto com múltiplas falhas. IF identificou as falhas em 63% conforme observado no parâmetro de Sensibilidade. Por outro lado, o modelo teve péssimos resultados na detecção dos parâmetros de não falha. Por causa dessa péssima eficiência em produção, foi feita uma checagem dupla para verificar a autenticidade da anomalia. Neste caso, a anomalia era confirmada se o delta de temperatura (entre ambiente e da célula) era superior a 5 °C.

Por outro lado, o modelo de RF conseguiu identificar 100% dos abusos de ESC e OC e 89% de OD. A Especificidade foi de 85% para ESC, 100% para OC e 97% para OD. Os resultados indicaram que todos tiveram bom desempenho para serem aplicados em tempo real e, assim, diagnosticar os abusos diretamente no Edge.

Em seguida, os modelos foram transferidos para o *Edge computing* para operar em tempo real. Enquanto o BMS monitora os dados coletados e os envia por I2C para o computador de borda, cada amostra recebida alimenta os modelos treinados de IF e RF com objetivo de identificar uma anomalia ou falha na célula. Caso seja detectada alguma falha ou irregularidade, o Edge envia uma mensagem ao Arduino Mega via I2C para interromper a operação com o relê.

Na combinação de IF e RF, os quatro modelos são aplicados em tempo real para realizar inferência. Caso um dos modelos identifica um abuso ou anomalia, o sistema direciona a interrupção do processo atual. Em seguida, 24 experimentos foram realizados em tempo real e segmentados em:

- Três experimentos com a aplicação de IF para abusos de OC;
- Três experimentos com a aplicação de IF para abusos de OD;
- Três experimentos com a aplicação de IF para abusos de ESC;
- Três experimentos com a aplicação de IF para uma mistura de abusos;
- Três experimentos com a aplicação de IF + RF para abusos de OC;
- Três experimentos com a aplicação de IF + RF para abusos de OD;
- Três experimentos com a aplicação de IF + RF para abusos de ESC;
- e
- Três experimentos aplicaram IF + RF para uma mistura de abusos.

Primeiramente, foram realizados 12 experimentos para aplicar a técnica de IF. O modelo de IF conseguiu reduzir, em média, a capacidade perdida para OC de 1327 para 333 mAh. Neste caso, o modelo de IF pode observar um OC através do monitoramento da temperatura da célula. Como a temperatura demora muito para aumentar durante o abuso de OC, o IF também demorou certo tempo para identificar a anomalia, portanto, a redução de perda de capacidade não foi tão relevante.

Por outro lado, o IF não conseguiu identificar uma anomalia durante o OD porque a temperatura não aumentou significativamente para esse abuso. Já para casos de ESC, como a temperatura aumenta rapidamente, o modelo de IF pôde localizar a falha como anomalia no primeiro estágio e reduzir, desta forma, a perda de capacidade de 926 para 160 mAh. Por fim, para a mistura de abusos, o modelo de IF conseguiu reduzir a perda de capacidade de 1621 para 891 mAh.

Em seguida, foram realizados 12 experimentos para a combinação de RF e IF. A combinação conseguiu reduzir a perda de capacidade par OC de 1327 para 31 mAh. Além disso, a redução para OD foi de 345 para 55 mAh. Por outro lado, para ESC foi de 925 a 115 mAh e, para a mistura de abusos, foi de 1621 a 133 mAh. Por fim, é possível concluir que a combinação de IF e RF pode evitar falhas e abusos e prolongar a vida útil das baterias.

## **2.4 Artigo D: Machine Learning for Forecasting and Predicting Failures in Lithium-Ion Batteries (Gotz et al., 2023C)**

A parte final deste trabalho apresenta o desenvolvimento de um sistema composto de duas etapas baseadas na previsão de futuras falhas em células de íons de lítio. O foco deste trabalho foi nas falhas de OH, sendo que o manuscrito foi publicado em 2023.

O trabalho apresenta um sistema de previsão de falhas em duas camadas da operação de ML. É composto por um modelo de série temporal na primeira etapa para prever valores futuros dos principais parâmetros das células. Na mesma direção, a segunda camada é composta por modelos de classificação utilizados para diagnosticar as previsões futuras e, assim, identificar a presença de falhas no futuro.

Dois conjuntos de dados foram usados neste artigo. O primeiro conjunto de dados é o mesmo aplicado no artigo 2 desta coletânea (GOTZ et al., 2023B), o qual contém dados de 14 casos de OH. O pipeline foi segmentado em algumas etapas. Em primeiro lugar, os modelos de séries temporais ARIMA e LSTM foram configurados e aplicados para prever valores futuros. Assim, ARIMA e LSTM foram treinados e testados para prever valores futuros: 2, 10, 20, 30, 40, 50, 60 e 70 segundos. Em geral, o modelo LSTM teve melhor desempenho que o modelo ARIMA para a maioria das previsões, considerando *Root Square Mean Error* (RSME) como métrica.

Em seguida, os modelos de LR, SVM e RF foram aplicados nas previsões realizadas na primeira etapa. Apesar da interferência da primeira etapa sobre a Sensibilidade e a Especificidade, os resultados dos modelos com SVM tiveram superficial vantagem para os demais.

A aplicação do sistema completo para o primeiro conjunto demonstrou que a técnica proposta pode prever uma falha de OH em até 30-40 segundos. Em seguida, a ideia proposta foi re-treinada e testada no segundo conjunto de dados (7.832 amostras), que contém amostras com ESC e OH forçados. Os resultados indicaram que o sistema proposto pode prever em até 70 segundos de forma antecipada a presença de uma falha de OH nas células. Com a identificação precoce, a BMS pôde tomar medidas para resolver o problema e reduzir a degradação das células devido aos abusos. Apesar da ideia proposta ser aplicada a falhas OH, trabalhos futuros podem usar o mesmo conceito para outras violações e falhas.

### 3 TRABALHOS EM ANDAMENTO

O desenvolvimento dos quatro artigos abriu diversas outras oportunidades de publicação, as quais serão descritas neste Capítulo. A primeira publicação foi elaborada através da realização de uma pesquisa bibliométrica e sistêmica com objetivo de buscar na literatura as publicações mais recentes e tendências da aplicação ML no diagnóstico de falhas em máquinas. O artigo denominado Gotz et al. ((GOTZ et al., 2021)) foi apresentado 13º Congresso Brasileiro de Inovação e Gestão de Desenvolvimento de Produto e publicado na revista Blucher.

Em seguida, o segundo trabalho em andamento conta com a aplicação do conceito de EL para melhorar a precisão dos modelos de classificação e predição. Apesar do excelente desempenho dos modelos de classificação aplicados, Gotz et al. (2021) demonstraram a tendência do EL em melhorar a qualidade dos modelos. Estes estudos já foram realizados e dois artigos foram desenvolvidos. A aplicação de EL para classificações foi submetida em uma conferência da IEEE que será realizado na Itália. Por outro lado, a aplicação de EL para predições gerou um artigo submetido e aceito para ser publicado na revista LNME.

Além disso, o desenvolvimento de circuitos para a geração de dados, proporcionou o desenvolvimento de uma placa padrão geradora de dados de falhas em baterias 18650. Um artigo foi elaborado e submetido à revista *Design Automation for Embedded Systems* e está em fase de revisão.

A placa serviu para a realização de vários testes de ESC e OC. Desta forma, cinco causas específicas de ESC foram testadas através do protótipo. Os resultados geraram um artigo, o qual foi submetido à revista *Journal of Energy Storage* e está em fase de revisão. Também foram gerados 75 Experimentos de OC, a partir da placa. Os resultados foram coletados e estão sendo analisados para futuras publicações.

Durante o desenvolvimento do doutorado, surgiu a possibilidade de trabalhar com ferramentas em nuvem. Isto permitiu a elaboração de um artigo abordando o conceito de *Cloud* e *Edge Computing* para aplicações em veículos elétricos. O artigo foi submetido para uma conferência da IEEE que será realizada na Itália em setembro próximo.

Em seguida, foi realizado um estudo para a identificação de falhas isoladas em pack de baterias. O estudo foi dividido em duas partes. A primeira parte descreve a aplicação de vários testes de ESC, OD e OC nas baterias por diversas configurações

de arranjo. Em seguida, ocorreu a aplicação de técnicas de ML para operar os arranjos a ponto de tratar as falhas do *pack*. Este trabalho resultou em dois artigos que estão sendo preparados para submissão.

Na sequência, foram realizados dois estudos com BMS inteligentes para células de segunda vida útil. O primeiro estudo trabalhou com técnicas para otimizar o tempo de descarga das baterias não equalizadas. O estudo aplicou a adição de uma célula reserva para aumentar o tempo de descarga do *pack*. O artigo foi submetido e aceito para ser publicado na revista LNME.

Em seguida, foi realizado um estudo com várias aplicações de BMS inteligente para carregar de forma eficiente e rápida um *pack* de baterias. Os resultados estão sendo analisados e um artigo será submetido no futuro.

## 4 CONCLUSÃO

O crescimento pela opção por carros elétricos, vistos desde a última década, aumentou a demanda por sistemas de armazenamento de energia como a BIL. BIL é uma das tecnologias mais bem-sucedidas para armazenamento de energia não apenas para carros, mas também, para sistemas estacionários. No entanto, BIL é sensível a falhas e abusos, portanto, precisa operar de maneira segura. O BMS é o dispositivo utilizado para manter a bateria em condições seguras de operação, equalizar as células e evitar falhas que possam encurtar a vida útil das baterias.

Apesar disto, BMS é um dispositivo com programação engessada e pode se tornar ineficiente com o avanço da degradação natural das células. Sendo assim, sistemas baseados em DD podem ser uma opção interessante para diagnosticar falhas e estender a vida útil da bateria. Portanto, este trabalho apresentou uma coletânea de quatro artigos publicados entre 2022 e 2023 para diagnosticar, tratar, antecipar e prever falhas e abusos em baterias. O primeiro artigo aplicou seis modelos ML para classificar falhas e abusos de células individuais. Na totalidade, o trabalho demonstrou que as técnicas de RF, ANN e KNN puderam diagnosticar os abusos com elevado desempenho.

O segundo trabalho aplicou o conceito de detecção de anomalias como forma de antecipação de falhas nas baterias. Três modelos foram aplicados, sendo que a técnica de OC-SVM teve o melhor desempenho e conseguiu identificar de forma antecipada uma falha promissora em até 52 segundos.

No terceiro artigo, uma combinação de IF e RF foi aplicada para interromper falhas em células individuais em tempo real. A aplicação individual de IF conseguiu reduzir a perda de capacidade em até 45% em geral. Porém, a combinação de IF e RF conseguiu melhorar a redução da perda de capacidade para 91%.

Por fim, o quarto artigo demonstrou a aplicação de um sistema de duas camadas para prever falhas futuras. A primeira camada realiza estimativas que então são classificadas na segunda camada. Os resultados indicaram que o sistema proposto pode antecipar falhas de OH em até 40 segundos. Porém, ao adicionar mais *features*, como a presença de ESC, o sistema conseguiu antecipar uma falha em até 70 segundos.

Em síntese, as quatro abordagens podem ser aplicadas no contexto de mitigar as causas e efeitos de falhas em baterias de íons de lítio. Apesar disso, a escolha de

qual abordagem depende do objetivo buscado, ou seja, se o usuário buscar somente a identificação de falhas, o melhor a ser utilizado é o diagnóstico de falhas apresentado no artigo 1. Porém, se o usuário quer entender a origem dos abusos e antecipar as falhas, tanto a detecção de anomalias (artigo 2) como a previsão de falhas (artigo 4) poderão ser utilizados. Por fim, se o objetivo é tratar as falhas, o artigo 3 é a melhor opção.

Portanto, a coletânea demonstrou quatro eficientes aplicações de ML para identificar, diagnosticar, interromper (tratar) e prever falhas em baterias de íons de lítio. Os experimentos foram realizados em laboratório, mas o desempenho indica que podem ser aplicados em uma situação real com veículo elétrico.

Para expectativas futuras, espera-se trabalhar com o conceito de *Smart Cell*. Este conceito, tende a construir circuitos inteligentes acoplados a cada uma das células de um *pack*. Desta forma, cada célula poderá tomar suas próprias decisões de operação para otimizar o processo de recarga, descarga e evitar falhas.

## REFERÊNCIAS

- CHEN, Y.; KANG, Y.; ZHAO, Y.; WANG, L.; LIU, J.; LI, Y.; LIANG, Z.; HE, X.; LI, X.; TAVAJOHI, N.; LI, B. A review of lithium-ion battery safety concerns: The issues, strategies, and testing standards. *Journal of Energy Chemistry*, v. 59, p. 83–99, 2021.
- CHEN, Y.; ZHAO, Qi.; LU, L. Combining the outputs of various k-nearest neighbor anomaly detectors to form a robust ensemble model for high-dimensional geochemical anomaly detection. ***Journal of Geochemical Exploration***, v. 231, p. 106875, 08 2021.
- CHEN, Z.; XIONG, R.; LU, Ji.; LI, X. Temperature rise prediction of lithium-ion battery suffering external short circuit for all-climate electric vehicles application. ***Applied Energy***, v. 213, p. 375–383, 2018.
- DONG, T.; WANG, Y.; PENG, P.; JIANG, F. Electrical-thermal behaviors of a cylindrical graphite-nca li-ion battery responding to external short circuit operation. ***International Journal of Energy Research***, v. 43, n. 4, p. 1444–1459, 2019.
- GOTZ, J. D.; ESPOLADOR, J.; GUERRERO, G. C.; WERLICH, S. H.; BORSATO, M.; CORREA, F. C. Machine learning for forecasting and predicting failures in lithium-ion batteries. In: **Flexible Automation and Intelligent Manufacturing: The Human-Data-Technology Nexus**. Cham: Springer International Publishing, 2023C. v. 2, p. 537–545.
- GOTZ, J. D.; ESPOLADOR, J. F. R.; WERLICH, S. H.; SANTOS, L. I.; BORSATO, M. Análise bibliométrica e sistêmica sobre aplicação de machine learning para diagnóstico de falhas de máquinas em tempo real. ***Blucher Engineering Proceedings***, v. 8, n. 3, p. 1–16, 2021.
- GOTZ, J. D.; GALVÃO, J. R.; WERLICH, S. H.; SILVEIRA, A. M.; CORRÊA, F. C.; BORSATO, M. Reducing the capacity loss of lithium-ion batteries with machine learning in real-time: A study case. ***Machines***, v. 10, n. 12, 2022.
- GOTZ, J. D.; GUERRERO, G. C.; QUEIROZ, J. R. H.; VIANA, RIBEIRO, E. R.; BORSATO, M. Diagnosing failures in lithium-ion batteries with machine learning techniques. ***Engineering Failure Analysis***, v. 150, p. 107309, 2023A.
- GOTZ, J. D.; GUERRERO, G. C.; ESPOLADOR, J. F. R.; WERLICH, S. H.; BORSATO, M.; CORRÊA, F. C. Application of anomaly detection algorithms in lithium-ion battery packs - a case study. In: **Flexible Automation and Intelligent Manufacturing: The Human-Data-Technology Nexus**. Cham: Springer International Publishing, 2023B. p. 753–760.
- HU, J.; LIAO, Y.; CAI, J.; WANG, Z.; ZHANG, W.; ZHOU, X. Insight into health deterioration induced by multi-cycle external short circuits in comercial 18650 lithium-ion battery. ***Journal of The Electrochemical Society***, IOP Publishing, v. 168, n. 9, p. 090565, sep 2021.

- HU, X.; ZHANG, K.; LIU, K.; LIN, X.; DEY, S.; ONORI, S. Advanced fault diagnosis for lithium-ion battery systems: A review of fault mechanisms, fault features, and diagnosis procedures. **IEEE Industrial Electronics Magazine**, v. 14, p. 65–91, 09 2020.
- HUOTARI, M.; ARORA, S.; MALHI, A.; FRÄMLING, K. A dynamic battery state-of-health forecasting model for electric trucks: Li-ion batteries case-study. In: **Volume 8: Energy**. Portland, USA: American Society of Mechanical Engineers, 2020.
- JI, H.; CHUNG, Y.; PAN, X.; HUA, M.; SHU, C.M.; ZHANG, L. Study of lithium-ion battery module's external short circuit under different temperatures. **Journal of Thermal Analysis and Calorimetry**, v. 144, 03 2020.
- KANG, Y.; DENG, C.; CHEN, Y.; LIU, X.; LIANG, Z.; LI, T.; HU, Q.; ZHAO, Y. Binder-free electrodes and their application for li-ion batteries. **Nanoscale Research Letters**, v. 15, 12 2020.
- LEE, G.; LEE, K. Online dependence clustering of multivariate streaming data using one-class svms. **International Journal of Intelligent Systems**, v. 37, n. 6, p. 3682–3708, 2021.
- LI, X.; LI, J.; ABDOLLAHI, A.; JONES, T. Data-driven thermal anomaly detection for batteries using unsupervised shape clustering. In: **2021 IEEE 30th International Symposium on Industrial Electronics (ISIE)**. Kyoto, Japan: IEEE, 2021.
- LIU, F. T.; TING, K. M.; ZHOU, Z. Isolation forest. In: **2008 Eighth IEEE International Conference on Data Mining**. Pisa, Italy: IEEE, 2008. p. 413–422.
- LIU, W.; PLACKE, T.; CHAU, K.T. Overview of batteries and battery management for electric vehicles. **Energy Reports**, v. 8, p. 4058–4084, 2022.
- MALEKI, H.; HOWARD, J. N. Effects of overdischarge on performance and termal stability of a Li-ion cell. **Journal of Power Sources**, v. 160, n. 2, p. 1395–1402, jan. 2006.
- MOHANRAJ, M.; JAYARAJ, S.; MURALEEDHARAN, C. Applications of artificial neural networks for refrigeration, air-conditioning and heat pump systems—a review. **Renewable and Sustainable Energy Reviews**, v. 16, n. 2, p. 1340–1358, 2012.
- OUYANG, D.; CHEN, M.; LIU, J.; WEI, R.; WENG, J.; WANG, J. Investigation of a commercial lithium-ion battery under overcharge/over-discharge failure conditions. RSC Adv., **The Royal Society of Chemistry**, v. 8, p. 33414–33424, 2018.
- SABERIOON, M.; CISAR, P.; LAURENT, L.; SOUCEK, P.; PELISSIER, P.; KERNEIS, T. Comparative performance analysis of support vector machine, random forest, logistic regression and k-nearest neighbours in rainbow trout (*oncorhynchus mykiss*) classification using image-based features. **Sensors**, v. 18, 03 2018.

WIBAWA, A.; KURNIAWAN, A.; MURTI, D.; ADIPERKASA, R. P.; PUTRA, S.; KURNIAWAN, S.; NUGRAHA, Y. Naïve bayes classifier for journal quartile classification. **International Journal of Recent Contributions from Engineering, Science & IT (iJES)**, v. 7, p. 91, 06 2019.

ZHANG, Y.; XIONG, R.; HE, H.; LIU, Z. A lstm-rnn method for the lithium-ion battery remaining useful life prediction. In: **2017 Prognostics and System Health Management Conference (PHM-Harbin)**. Harbin, China: IEEE, 2017. p. 1–4.

ZUBI, G.; DUFO-LÓPEZ, R.; CARVALHO, M.; PASAOGLU, G. The lithium-ion battery: State of the art and future perspectives. **Renewable and Sustainable Energy Reviews**, v. 89, p. 292–308, 2018.

## **APÊNDICE A - Artigo A: Diagnosing failures in lithium-ion batteries with Machine Learning techniques**

Devido a restrições de direitos de reprodução, apenas as informações públicas do artigo são apresentadas aqui.



## Engineering Failure Analysis

Available online 5 May 2023, 107309

In Press, Journal Pre-proof What's this?

# Diagnosing failures in lithium-ion batteries with Machine Learning techniques

Joelton Deonei Gotz<sup>a</sup> , Gabriel Carrico Guerrero<sup>a</sup>, José Renan Holanda de Queiroz<sup>b</sup>, Emilson Ribeiro Viana<sup>b</sup>, Milton Borsato<sup>a</sup>

Show more

Outline | Share Cite

<https://doi.org/10.1016/j.engfailanal.2023.107309>

[Get rights and content](#)

## Highlights

- Failures in lithium-ion batteries reduce the battery lifetime.
- Three groups of failures are present in LIB: mechanical, electrical, and thermal.
- Data-driven combined with Machine Learning techniques improve the detection of failures as sooner as possible and in real-time.
- Construction of a mini packing of batteries to generate data.
- Random Forest was the best model to detect failures in LIB.

## Abstract

The industry of electric cars has been rising significantly in the last few years. This significant growth is impelled by lithium-ion batteries (LIBs). LIBs are a stable technology that is the largest applied for storing energy systems in several sectors like electric mobility, laptops, and cell phones. However, LIBs are still sensible and must operate under controlled conditions to avoid failures and anomalies that can cause security and performance issues. Therefore, it is crucial to identify the possible failures in the initial stage. In order to help the precocious failure identification, some data-driven have been impelled by Machine Learning (ML) techniques to diagnose failures as soon as possible. Following this direction, this work presents the application of six classification ML models to identify failures in LIBs. In order to generate the dataset, the main parameters of eight lithium-ion 18650 cells were collected under four different cases of abuse: overcharging (OC), over-discharging (OD), external short-circuit (ESC) and overheating (OH). The confusion matrix and Sensitivity were used to evaluate and compare the models. The work shows that, on average, the models could detect a failure with the Sensitivity greater than 94% for mechanical, electrical,

and thermal failures. Furthermore, the RF model had the better performance of all, with the Sensitivity greater than 97%. In conclusion, according to the excellent results, this approach can be used in LIBs to detect failures in the initial stage. Due to the excellent results, the evolution of this study is embedded this study in the vehicle to classify abuses online to reduce the chances of security and performance issues.

## Keywords

Failures; Diagnostic; Lithium-ion batteries; Machine Learning

---

## Recommended articles

## Data availability

The data that has been used is confidential.

---

## Cited by (0)

[View full text](#)

© 2023 Elsevier Ltd. All rights reserved.

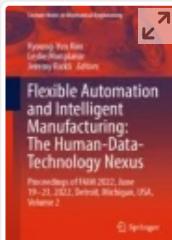


Copyright © 2023 Elsevier B.V. or its licensors or contributors.  
ScienceDirect® is a registered trademark of Elsevier B.V.



**APÊNDICE B - Artigo B: Application of Anomaly Detection Algorithms in Lithium-Ion Battery Packs - A Case Study**

Devido a restrições de direitos de reprodução, apenas as informações públicas do artigo são apresentadas aqui.



## International Conference on Flexible Automation and Intelligent Manufacturing

FAIM 2022: **Flexible Automation and Intelligent Manufacturing: The Human-Data-Technology Nexus** pp 753–760

[Home](#) > [Flexible Automation and Intelligent Manuf...](#) > Conference paper

# Application of Anomaly Detection Algorithms in Lithium-Ion Battery Packs - A Case Study

[Joelton Deonei Gotz](#) , [Gabriel Carrico Guerrero](#), [João Felipe Raffs Espolador](#), [Samuel Henrique Werlich](#), [Milton Borsato](#) & [Fernanda Cristina Corrêa](#)

Conference paper | [First Online: 04 February 2023](#)

**262** Accesses

Part of the [Lecture Notes in Mechanical Engineering](#) book series (LNME)

## Abstract

Lithium-Ion batteries (LIB) store energy for many different applications, especially in the mobility and smart grid areas. LIB has several advantages like stability, longer lifetime, and capacity compared with other technologies. Although, LIB can be dangerous, mainly if it operates in unsafe conditions due to failures that can appear and cause accidents like explosions or fire. To maintain the safe operation, an electronic system named

Battery Management System (BMS) manages and controls the main parameters to guarantee the safe operation of the LIB. Therefore, BMS collects and controls the main parameters of the LIB like the voltage, current, and temperature. Despite that, BMS has challenges predicting, preventing, and identifying unforeseen failures. How a failure can be considered an anomaly, data-driven models can identify a precocious potential failure. For this reason, this paper presents an anomaly detection system to identify an overheating failure in a LIB as earlier as possible. A LIB prototype was built to simulate the overheating failures, and three anomaly detection algorithms have been applied to drive the work. An edge-cloud computing architecture collected and stored the needed data in a dataset to elaborate the idea and demonstrate the excellent results to anticipate failures in LIB. For future works, the intention is to operate with this approach in online embedded in the vehicle with the BMS to detect a failure precociously.

## Keywords

**Lithium-ion battery      Anomaly detection**

**Machine learning      Edge-cloud computing**

---

This is a preview of subscription content, [access via your institution.](#)

---

▼ Chapter

USD 29.95

Price excludes VAT (Brazil)

- DOI: 10.1007/978-3-031-17629-6\_79

- Chapter length: 8 pages
- Instant PDF download
- Readable on all devices
- Own it forever
- Exclusive offer for individuals only
- Tax calculation will be finalised during checkout

[Buy Chapter](#)

<a href="#">eBook</a>	USD 259.00
<a href="#">Softcover Book</a>	USD 329.99

[Learn about institutional subscriptions](#)

## References

1. Hu, X., Zhang, K., Liu, K., Lin, X., Dey, S., Onori, S.: Advanced fault diagnosis for lithium-ion battery systems: a review of fault mechanisms, fault features, and diagnosis procedures. *IEEE Ind. Electron. Mag.* **14**, 65–91 (2020)
2. Jiang, J., Cong, X., Li, S., Zhang, C., Zhang, W., Jiang, Y.: A hybrid signal-based fault diagnosis method for lithium-ion batteries in electric vehicles. *IEEE Access* **9**, 19175–19186 (2021)
3. Li, X., Li, J., Abdollahi, A., Jones, T., Habeebullah, A.: Data-driven thermal anomaly detection for batteries using unsupervised shape clustering. In: 2021 IEEE 30th International Symposium on Industrial Electronics (ISIE). IEEE, Kyoto (2021)

4. Diao, W., Naqvi, I.H., Pecht, M.: Early detection of anomalous degradation behavior in lithium-ion batteries. *J. Energy Storage* **32**, 101710 (2020)

---

5. Saxena, S., Kang, M., Xing, Y., Pecht, M.: Anomaly Detection during lithium-ion battery qualification testing. In: 2018 IEEE International Conference on Prognostics and Health Management (ICPHM), pp. 1–6. IEEE, Seattle (2018)

---

6. Hannan, M.A., Hoque, M.M., Hussain, A., Yusof, Y., Ker, P.J.: State-of-the-art and energy management system of lithium-ion batteries in electric vehicle applications: issues and recommendations. *IEEE Access* **6**, 19362–19378 (2018)

---

7. Shi, W., Cao, J., Zhang, Q., Li, Y., Xu, L.: Edge computing: vision and challenges. *IEEE Internet Things J.* **3**, 637–646 (2016)

---

8. Kaplan, H., Tehrani, K., Jamshidi, M.: A fault diagnosis design based on deep learning approach for electric vehicle applications. *Energies* **14**, 6599 (2021)

---

9. Yang, R., et al.: A fractional-order model-based battery external short circuit fault diagnosis approach for all-climate electric vehicles

- 10.** Songhai, C., Ke, X., Jingwen, W., Guangzhong, D.: Voltage fault detection for lithium-ion battery pack using local outlier factor. Measurement **146**, 544–556 (2019). ISSN: 0263-2241
- 
- 11.** Liu, F.T., Ting, K.M., Zhou, Z.: Isolation forest. In: 2008 Eighth IEEE International Conference on Data Mining, pp. 413–422. IEEE, Pisa (2008)
- 
- 12.** Lee, G., Lee, K.: Online dependence clustering of multivariate streaming data using one-class SVMs. Int. J. Intell. Syst. 1–27 (2021)
- 
- 13.** Chen, Y., Zhao, Q., Lu, L.: Combining the outputs of various k-nearest neighbor anomaly detectors to form a robust ensemble model for high-dimensional geochemical anomaly detection. J. Geochem. Explor. **231**, 106875 (2021)

---

## Acknowledgments

---

This work is supported by the FUNDEP - Rota 2030.

---

## Author information

---

### Authors and Affiliations

## **Postgraduate Program in Mechanical and Materials Engineering, Curitiba, Brazil**

Joelton Deonei Gotz, Gabriel Carrico  
Guerrero, João Felipe Raffs Espolador, Samuel  
Henrique Werlich & Milton Borsato

## **Postgraduate Program in Electrical Engineering, Ponta Grossa, Brazil**

Fernanda Cristina Corrêa

Corresponding author

Correspondence to [Joelton Deonei Gotz](#).

## **Editor information**

---

### **Editors and Affiliations**

#### **Industrial and Systems Engineering, Wayne**

**State University, Detroit, MI, USA**

Kyoung-Yun Kim

#### **Industrial and Systems Engineering, Wayne**

**State University, Detroit, MI, USA**

Leslie Monplaisir

#### **Industrial and Systems Engineering, Wayne**

**State University, Detroit, MI, USA**

Jeremy Rickli

## **Rights and permissions**

---

### [Reprints and Permissions](#)

## **Copyright information**

---

© 2023 The Author(s), under exclusive license to  
Springer Nature Switzerland AG

## About this paper

---

### Cite this paper

Gotz, J.D., Guerrero, G.C., Espolador, J.F.R., Werlich, S.H., Borsato, M., Corrêa, F.C. (2023). Application of Anomaly Detection Algorithms in Lithium-Ion Battery Packs - A Case Study. In: Kim, KY., Monplaisir, L., Rickli, J. (eds) Flexible Automation and Intelligent Manufacturing: The Human-Data-Technology Nexus. FAIM 2022. Lecture Notes in Mechanical Engineering. Springer, Cham.

[https://doi.org/10.1007/978-3-031-17629-6\\_79](https://doi.org/10.1007/978-3-031-17629-6_79)

[.RIS !\[\]\(e2d6a0f151413f4a76086198b0b68027\_img.jpg\)](#) [.ENW !\[\]\(634aff8fe10b15a6440b4ed20b294624\_img.jpg\)](#) [.BIB !\[\]\(89887c3876f15f62460db21597dfc915\_img.jpg\)](#)

### DOI

[https://doi.org/10.1007/978-3-031-17629-6\\_79](https://doi.org/10.1007/978-3-031-17629-6_79)

Published	Publisher Name	Print ISBN
04 February 2023	Springer, Cham	978-3-031-17628-9
Online ISBN	eBook Packages	
978-3-031-17629-6	<a href="#">Engineering</a>	
	<a href="#">Engineering_(R0)</a>	

Not logged in - 200.134.26.15

FUNDACAO COORDENACAODE DE APERFEICOAMENTO DE PESSOAL DE NIVEL (3000197460)  
- Universidade Tecnologica Federal do Parana (3000201946) - CAPES National Consortia  
Nature Cooorden. Aperfei Pessoal Nível Superior (3901169726)

**SPRINGER NATURE**

© 2023 Springer Nature Switzerland AG. Part of [Springer Nature](#).

**APÊNDICE C -Artigo C: Reducing the Capacity Loss of Lithium-Ion Batteries with  
Machine Learning in Real-Time—A Study Case**

## Article

# Reducing the Capacity Loss of Lithium-Ion Batteries with Machine Learning in Real-Time—A Study Case

Joelton Deonei Gotz <sup>1,\*</sup>,<sup>†</sup>, José Rodolfo Galvão <sup>2,†</sup>, Samuel Henrique Werlich <sup>1,†</sup>, Alexandre Moura da Silveira <sup>3,†</sup>, Fernanda Cristina Corrêa <sup>2,†</sup> and Milton Borsato <sup>1,†</sup>

<sup>1</sup> Postgraduate Program in Mechanical and Materials Engineering (PPGEM), Federal University of Technology–Paraná (UTFPR), Curitiba 81280-340, PR, Brazil

<sup>2</sup> Graduate Program in Electrical Engineering (PPGEE), Federal University of Technology–Paraná (UTFPR), Ponta Grossa 84217-220, PR, Brazil

<sup>3</sup> Postgraduate in Mechanical Engineering (PGMEC), Federal University of Paraná (UFPR), Curitiba 81530-900, PR, Brazil

\* Correspondence: gotz@alunos.utfpr.edu.br

† These authors contributed equally to this work.

**Abstract:** Lithium-ion batteries (LIBs) are the state-of-the-art technology for energy storage systems. LIBs can store energy for longer, with higher density and power capacity than other technologies. Despite that, they are sensitive to abuses and failures. If the battery management system (BMS) operates incorrectly or some anomalies appear, performance and security issues can be observed in LIBs. BMSs are also hard-programmed, have complex circuits, and have low computational resources, which limit the use of prognoses and diagnoses systems operating in real-time and embedded in the vehicle. Therefore, some technologies, such as edge and cloud computing, data-driven approaches, and machine learning (ML) models, can be applied to help the BMS manage the LIBs. Therefore, this work presents an edge–cloud computing system composed of two ML approaches (anomaly detection and failure classification) to identify the abuses in the LIBs in real-time. To validate the work, 36 NMC cells with a nominal capacity of 2200 mAh and voltage of 3.7 V were used to build the experiments segmented into three steps. Firstly, 12 experiments under failures were realized, which resulted in a high capacity loss. Then, the data were used to build both ML models. In the second step, the anomaly approach was applied to 12 cells observing the cells' temperature anomalies. Then, the combination of IF and RF was applied to another 12 cells. The IF could reduce the capacity loss by about 45% when multiple abuses were applied to the cells. Despite that, this approach could not avoid some failures, such as overdischarging. Conversely, combining IF and RF could significantly reduce the capacity loss by 91% for the multiple abuses. The results concluded that ML could help the BMS identify failures in the first stage and reduce the capacity loss in LIBs.



**Citation:** Gotz, J.D.; Galvão, J.R.; Werlich, S.H.; Silveira, A.M.d.; Corrêa, F.C.; Borsato, M. Reducing the Capacity Loss of Lithium-Ion Batteries with Machine Learning in Real-Time—A Study Case. *Machines* **2022**, *10*, 1114. <https://doi.org/10.3390/machines10121114>

Academic Editors: Kyoung-Yun Kim, Yanchao Liu, Murat Yildirim and Jeremy Rickli

Received: 11 October 2022

Accepted: 22 November 2022

Published: 24 November 2022

**Publisher's Note:** MDPI stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.



**Copyright:** © 2022 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

## 1. Introduction

The increasing demand for electric vehicles (VEs) is promoted by the availability of power storage systems such as LIB technology. LIBs have been recognized as the most efficient technology for storing energy due to their long lifetime, low self-discharge, high energy density, and high capacity [1,2].

EV applications require a high-output-power LIB pack to power the engine system under different operating conditions. An LIB pack operating for a long time needs voltage, current, and temperature control. Due to the internal construction properties of LIBs, when they are connected in series in a module, there are minor differences in the internal resistance between LIBs [3,4].

In addition, changes in temperature, self-discharge rate, aging degradation, and voltage imbalance occur, resulting in reliability and safety issues [5]. To avoid these problems, a

battery management system (BMS) is used, responsible for monitoring the voltage, current, and temperature parameters and controlling through software and hardware [6,7].

In the literature, there are several types of BMSs, highlighting the conventional BMSs that have state-of-charge (SOC), state-of-life (SOH) algorithm, passive/active equalizer, and current, voltage, and temperature protection systems. A recent study by [8] simulated a hybrid BMS, which is active at the stack and has passive management at the module. This technique demonstrated better results when compared to other arrangements.

Typically, these BMSs are self-programmed to perform only these functions, not taking into account the degradation of LIBs over time [9]. In addition, the traditional BMS has a complex circuit and lacks the presence of online fault diagnoses and prognoses due to the limitation of computational availability in the vehicle [10].

Therefore, using ML combined with data-driven systems can be the way to solve these limitations. The data-driven systems allow the cloud–edge computing concept that can operate in real-time, collecting the data of the BMS and processing to update the thresholds according to the natural degradation of the cells [11].

In this way, the edge collects, processes, and sends the information to the cloud [11]. The cloud platform can use robust processing systems to process, build, and train complex ML algorithms that would not be possible to run in the vehicle [12]. Then, the model can be downloaded to the edge, where the trained models make inferences in real-time without latency and allow the use of diagnosis and prognosis models on board [11].

The cyber–physical BMSs would be more assertive in identifying the failures in the first stage to avoid the degradation’s velocity or even performance and security issues [2]. In the literature, it is possible to find some applications of algorithms embedded in the vehicle to diagnose and provide prognoses failures in real-time. Hence, Kim et al. [10] presented work with an IoT wireless module connected to a battery that monitors the battery and sends the data to the cloud platform. The system still supplies an onboard health monitoring battery with the application of some anomaly detection algorithms to operate cost-effectively on a large scale.

In Xia et al. [13], an algorithm was presented with hard thresholds to detect the main failures found in the LIB. Similar to our proposed work, the authors performed several experiments to generate the dataset with four known failures. Then, they built the model with the known rules and thresholds. Finally, they made a circuit to validate the model. In the same direction, Nuhic et al. [14] presented a diagnosis and prognosis model. It was an embedded data-driven model built with a support vector machine. The work’s main goal was to estimate the battery’s health in real-time. In order to detect a short-circuit on board, Naha et al. [15] developed an algorithm based on the cell’s voltage, current, and temperature. Lee et al. [16] demonstrated that the use of artificial neural networks, especially multi-layer perceptron, could predict some failures, such as thermal runaway in the pouch cells of smartphones.

Similar to the related works, this paper presents an ML system composed of two approaches (anomaly detection and classification models) to identify the abuses in the LIBs at the first moment. In this case, the idea is composed of the combination of edge–cloud computing, ML, and a BMS. As the work intends to evidence the efficacy of the ML to predict failures, the BMS is composed of an Arduino Mega, which measures the main parameters of the cell and controls two relays that change the charging and discharging process.

Then, the edge computing is connected to the BMS by the I2C protocol, which collects the data in real-time and sends them to the cloud. In the cloud, the two models are built and then downloaded to the edge. Thus, the models are fed with the data in real-time on the edge. If the models identify an anomaly or abuse, the edge sends the command to the BMS to interrupt the charging or discharging process until the failure is identified.

In order to validate the proposed idea, a methodology with three steps was proposed. In the first step, 12 cells were submitted to the main abuses found in the LIBs. These situations represent the high degradation in the cells and were used to train the ML models. In the second step, an anomaly model was applied, which could significantly reduce the

degradation of the cells. Furthermore, in the third step, a combination of anomaly detection and classification algorithms was used to mitigate the consequences of the abuses.

Therefore, in Section 2, the state-of-the-art will be presented with a description of the models used in the work. In Section 3, the experimental setup will be described. Then, a discussion about the results and, finally, the conclusion are provided.

## 2. State-of-the-Art

The high capacity, long lifetime, security, and performance of LIBs made this technology the reference for storage systems in some areas such as electric mobility [17]. Despite these characteristics, especially the high energy density, LIBs must operate in safe conditions to avoid performance and security issues [2].

The abuses in the LIBs are segmented into three groups: mechanical, electrical, and thermal. This way, vibration, a bad connection, and external short-circuit (ESC), and others are considerable mechanical abuses. On the other side, if the BMS cannot manage the equalization, the overdischarging (OD) and overcharging (OC) abuses can appear in the LIB and cause an increase in the degradation rate. Both the ESC and OC can cause overheating (OH) in the first moment, and if it is not stopped, this results in a thermal runaway (TR) failure [2]. TR is the worst failure that can be found in the LIB and can cause fires and explosions. In [18], the correlation between the temperature and time during the occurrence of TR failures was presented. In this work, the higher the temperature is, the sooner a failure takes place and the more severe the effects of TR are, such as fires and explosions.

As a solution, the BMS appears to maintain the controller conditions of the voltage, current, and temperature of the cells [2]. Despite that, the BMS is hard-programmed and operates the LIB in excellent conditions when the cells are new and in the perfect conditions of resistance and capacity. Nonetheless, the natural aging process of the LIB and, in some conditions, when the cell suffers from thermal or electrical abuse affect the efficiency of the BMS to control and equalize the cells. This results in degradation and the risk of security and performance issues [9].

To improve the efficiency of the BMS, data-driven models support the management of the LIB. Therefore, some studies combined the concept of edge and cloud computing, when the data are collected from the vehicle and sent to the cloud to be processed. The models are built and trained in the cloud, with enough powerful computational resources to process a large volume of data. Then, the models are downloaded to edge computing, coupled with the vehicle, which can process and make real-time inferences directly in the car [10,11].

Data-driven models allow the use of ML algorithms. ML can be used to identify the issues in the first stage and then avoid the velocity of the degradation. Several approaches can be used from the literature to find failures and anomalies in LIBs. Identifying anomalies is an excellent way to find failures in the battery in the initial process.

The isolation forest (IF) is one anomaly detection model that has the principle of isolating anomalies from non-failure samples. This model is based on the decision tree, which isolates the outlier data in the tree's root. Due to its working principle, this model does not work with density or distance measures. This situation allows the model to work efficiently, faster, and with lower computational costs. Despite that, it works with a small dataset. Otherwise, it is possible for the swamping and masking effects to emerge [19].

Anomaly detection will detect anomalies by observing the temperature of the cells. This approach can be valuable and easily implemented, but working alone can find the failures already in progress. Therefore, combining the IF with some classification models is essential to identify the other failures, such as OD, OC, OH, and ESC.

In the classification models, there are several different approaches. One of them is the random forest (RF). Similar to the IF, the RF works with the decision tree principle and classifications of an event or non-event. It is considered an ensemble model because it gives

weight to each output of the tree. Its ensemble learning characteristic turns this model's robustness to problems such as over-fitting and noise in the signals [20].

The following paragraph will demonstrate the experimental setup to show how ML can reduce the effects of failures in the LIB. In order to evaluate the efficacy of ML, a small circuit was built to monitor the main parameters of the cell. Then, the experiments were performed in the lithium-ion 18650 NCM cells with a nominal capacity equal to 2200 mAh and a nominal voltage of 3.7 V.

### 3. Experimental Settings

The importance of LIBs currently is equal to the need for security and performance in their operation. Therefore, it is essential to identify and diagnose issues in this technology as fast as possible. As already mentioned in this paper, the BMS plays a significant role in the management of the LIBs. Despite that, it operates with hard-programmed thresholds and needs a complex circuit to manage the main functions such as equalization, security, charging, and discharging.

Therefore, this work presents an approach composed of two ML models to help the BMS identify failures in the first stage. This way, when a failure or anomaly is detected, it interrupts the operation of the pack until the failure is solved. Coupled with ML, in this work, it is possible to identify the edge and cloud computing, which play an essential role in giving intelligence to the LIB's operation.

In order to validate the concept, some experiments were performed to force the failures in the LIBs. The system was built with a Raspberry Pi4, an electronic circuit, an Arduino Mega, some temperature sensors, the AWS cloud provider, and some lithium-ion 18650 cells.

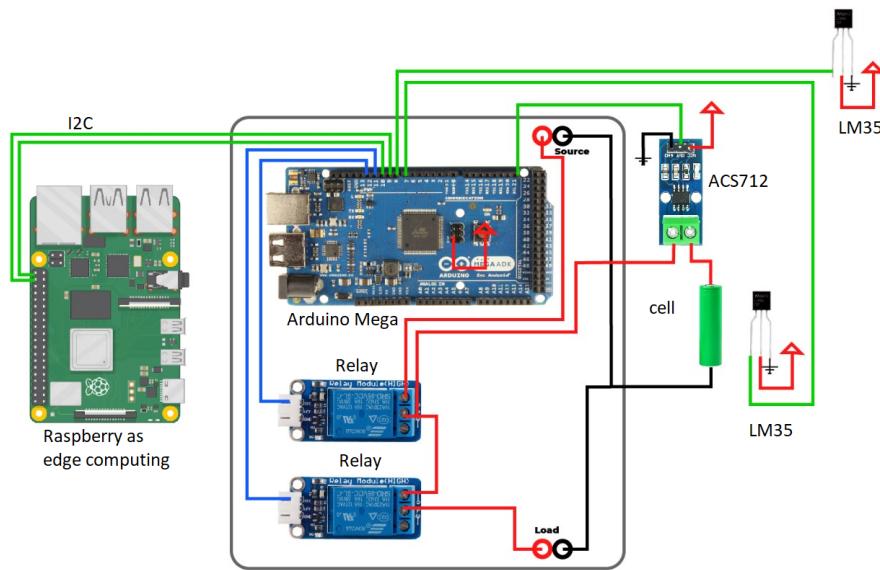
The Raspberry Pi4 operates as the edge computing and can collect and send data to the cloud by WiFi. In the cloud, the data are stored in the Amazon Simple Storage (S3) bucket from AWS.

In order to monitor and collect the data, a shield (see Figure 1) coupled with the Arduino Mega was built. The Arduino Mega measures the voltage and current of the cell in Analog Channel 0 and Analog Channel 1 as the analog input. Voltage is measured directly in Channel 0 from the Arduino, with a 10-bit resolution. On the other side, an ACS712 5A sensor was used to collect the current in the circuit. Such a type of sensor has an error equal to 1.5% at room temperature (25 °C); it works with an 80 kHz bandwidth, has an internal resistance equal to 1.2 Ω, and operates with 5 V, and the sensitivity of the output is equal to 185 mV/A.

The ambient (collected by Analog Channel 2) and cell temperature (collected by Analog Channel 3) are measured by an LM35 coupled with the Arduino. The LM35 operates at 5 V with 0.5 °C of accuracy and with a q linear transfer function that has the output sensitivity equal to 10 mV/°C.

The Arduino Mega also has two relays that control the charging and discharging process. The Arduino Mega, combined with the built circuit, operates as the BMS. It is connected to the Raspberry Pi4 by the I2C protocol.

In order to understand the impact of the failures with and without ML, the capacity of each cell involved in the test was measured before and after each experiment (see Table 1). "I confirm" In the present study, a cell's capacity was used as a parameter to indicate its health status. According to [21], both capacity and internal resistance are the direct health indicators used to reveal the cell state. In order to measure capacity, the cells were fully charged and discharged until they reached 2.75 V at a rate of 1 A. The capacity measurement was carried out three times, and the calculated mean was used in the present work.



**Figure 1.** The schematic is used to monitor and control the cell. A Raspberry Pi4 is used to work as the edge computing, which communicates with an Arduino Mega. The Arduino Mega works as the BMS. The BMS collects the temperature sensors' data and measures the cell's voltage and current.

**Table 1.** Table with the metrics from the confusion matrix.

Model	Sensitivity (%)	Specificity (%)	Accuracy (%)
IF	63	28	63
RF-ESC	100	85	86
RF-OC	100	100	100
RF-OD	89	97	95

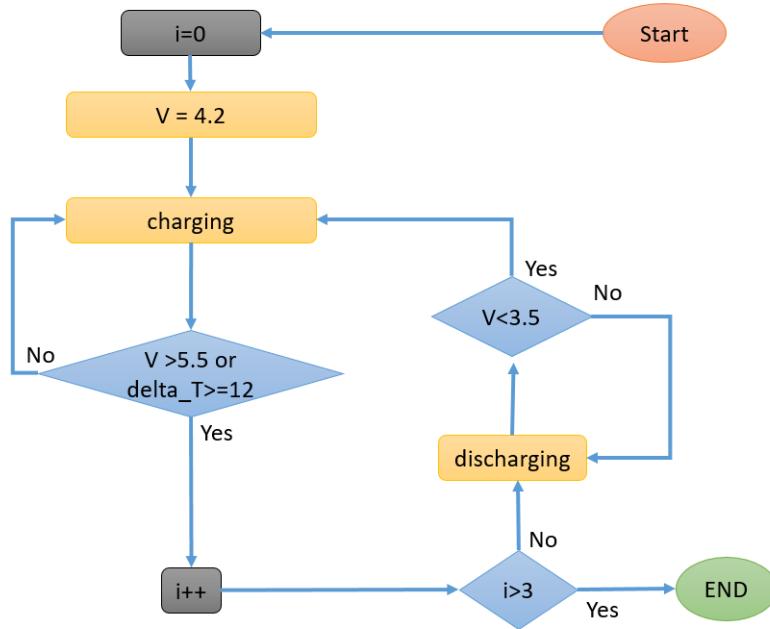
In the tests, the cells 18650 NCM ICR 22P from Samsung with a nominal voltage of 3.7 V and capacity of 2200 mAh were used. The experiments were segmented into three steps:

- The failures were applied without ML.
- The IF was applied to the cells' temperature.
- The tests were performed with a combination of the IF and RF.

In the first step, the tests without ML were performed to generate the essential database for the model's construction. Hence, the models were fed with standard and failed samples useful for learning. In order to generate the data, the tests were segmented into four groups:

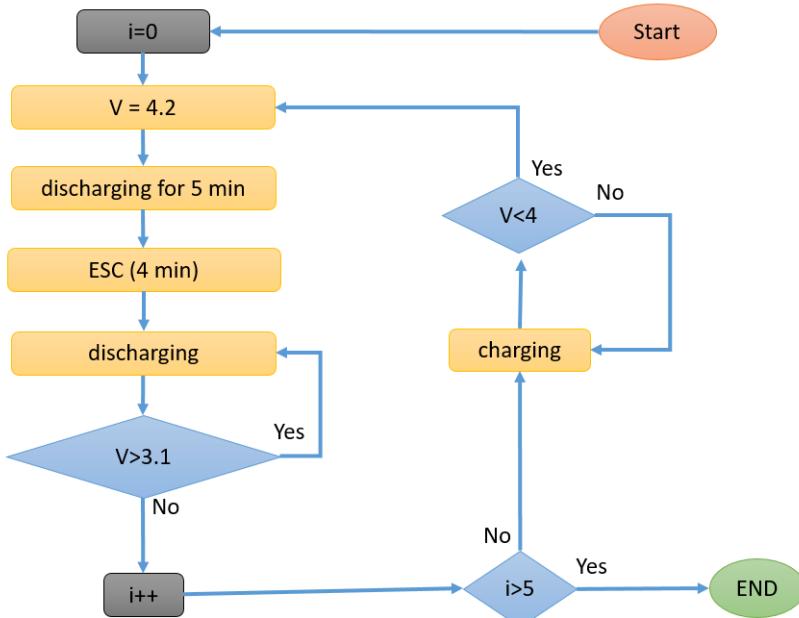
- Tests with OC abuse.
- Tests with ESC abuse.
- Tests with OD abuse.
- Tests with a mix of OD, OC, and ESC abuse.

The methodology of OC abuse is seen in Figure 2. In this experiment, the test began with the charging cycle when the voltage was greater than 4.2 V. The experiment continued charging the cell until the temperature of the cell was 12 °C higher than the environment temperature or the voltage of the cell was higher than 5.5 V. After one of these conditions happened, the discharging routine started and ran until the voltage of the cell was smaller than 3.5 V. The method was also repeated three times. The charging process was performed with a current rate of 0.5 C (1.1 A).



**Figure 2.** Methodology applied in the OC experiments.

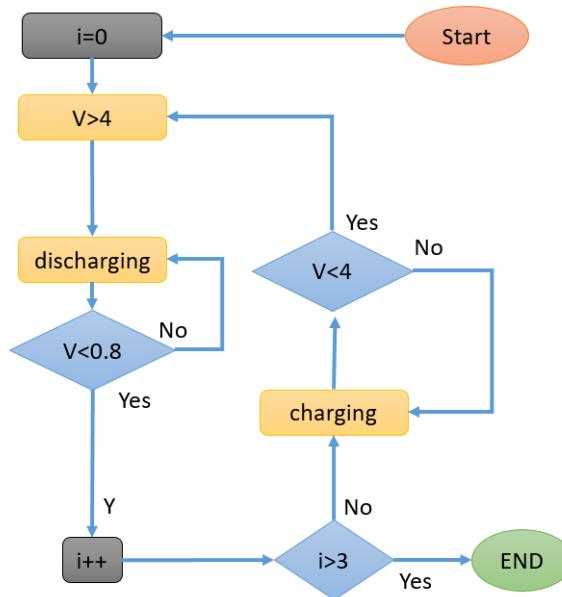
The ESC methodology is found in Figure 3. The process began with the discharging cycle when the cell's voltage was greater than or equal to 4.2 V. The discharging happened for 5 min, and an ESC was applied for 4 min. After that, the discharging continued until the voltage reached 3.1 V. After that, the charging ran until the voltage reached 4.2 V. In the other experiments, the routine was repeated three times. During the discharging process, the current rate was similar to that applied in the OD methodology.



**Figure 3.** Methodology applied in the ESC experiments.

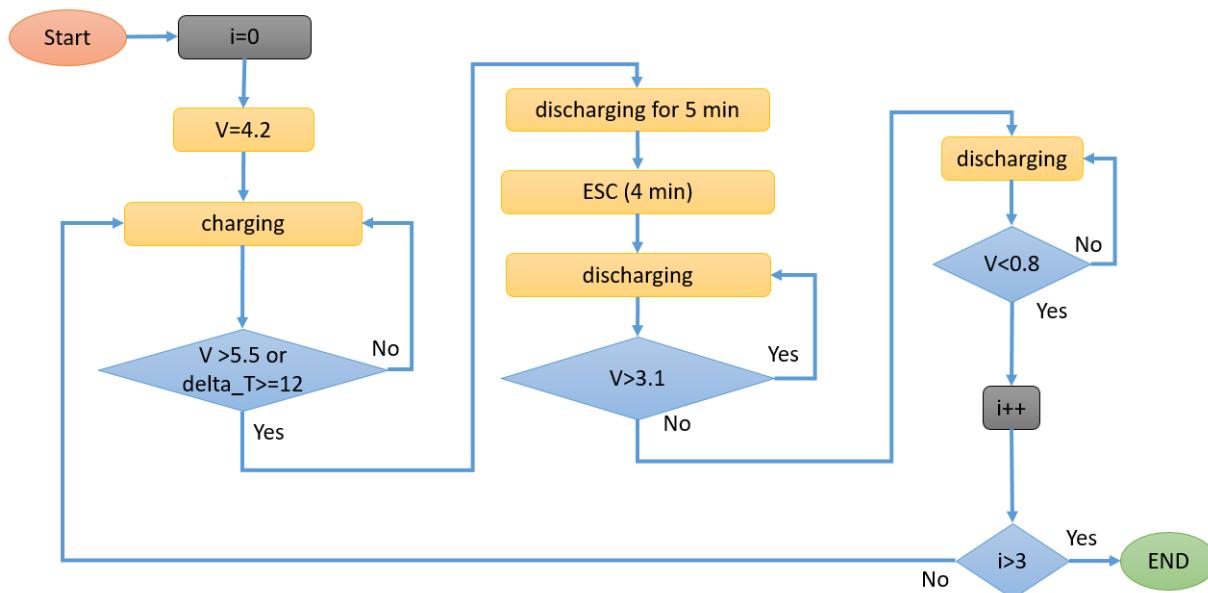
Figure 4 describes the methodology adopted to generate the data on OD abuse. In the figure, it is possible to see that the experiment began when the voltage of the cell was greater than 4 V. Then, the discharging process began and ran until the cell reached a voltage smaller than 0.8 V. Thus, the charging process ran until the voltage reached

4 V again. The process was repeated three times. The data were collected by the edge computing and sent to the cloud, where they were stored in the S3 bucket. The discharging process was performed with a 2-ohm resistance, which resulted in a current rate equal to 1 C (2.2 A) at the start, but decreasing according to the cell's voltage consumption.



**Figure 4.** Methodology applied in the OD experiments.

Finally, Figure 5 shows the methodology applied in the cell to represent the application of the three cases of abuse: OD, OC, and ESC. The test began when the cell had 4.2 V. Then, the charging cycle started and continued until the voltage reached 5.5 V or the cell's temperature was 12 °C higher than the environment temperature. After one of these conditions, the discharging operation began and ran for 5 min. In the following action, the ESC was applied for 4 min. Finally, the discharging occurred until the voltage was smaller than 0.8 V. After that, the charging process began, and the experiments were run three times.



**Figure 5.** Methodology applied in the mixing experiments.

Three experiments with different batteries for each methodology were performed without ML to generate the dataset. When the data came to the cloud, they were stored in the S3 bucket and uploaded to the Anaconda Environment. Anaconda runs on an Amazon Elastic Compute Cloud (E2C) with 16 GB of RAM. In Anaconda, a Jupyter notebook was built in the Python language to run data-engineering analyses (EDAs) for investigating the data, understanding the failures and the data, and finally, for building the models.

Two approaches were chosen for solving the problem: IF and RF. The IF was trained with the cell's temperature. In this context, abuse will be detected if the temperature rises considerably compared to good samples. The IF was built with 10 estimators and 25% of contamination.

On the other side, the EDA showed that the three cases of abuse (OD, OC, and ESC) had a high relation with the current, the voltage, the temperature, the delta temperature of the cell, and the ambient temperature (see Figure 6). Therefore, one model of the RF was built and trained for each abuse with the data from Step 1. Each RF model was built with 10 estimators and trained with the entire data of each abuse.



**Figure 6.** Pearson's graphic with the relation between the variables. The closer to 1, the stronger the relationship between the variables. On the other side, the closer to  $-1$ , the stronger the negative relationship. A score closer to zero should be ignored by the model.

In order to verify the performance of the IF and RF, the four trained models were tested on the data from the multiple abuses as described in Figure 5. This dataset contains tests of three cells under all three cases of abuse and contains a total of 24,692 samples segmented as follows: 451 samples of ESC abuse, 6036 samples of OD, 10,256 samples of OC abuse, and 7949 non-failures.

In order to evaluate the results, a confusion matrix (CM) was used as a metric. The CM is the most-used metric for classification problems [22]. With this matrix, it is possible to determine sensitivity, specificity, and accuracy. Sensitivity or true-positive (TP) indicates how well a model diagnoses failures, while specificity or true-negative (TN) indicates how well a model can identify non-failures. On the other hand, accuracy shows the total percentage of hits [23].

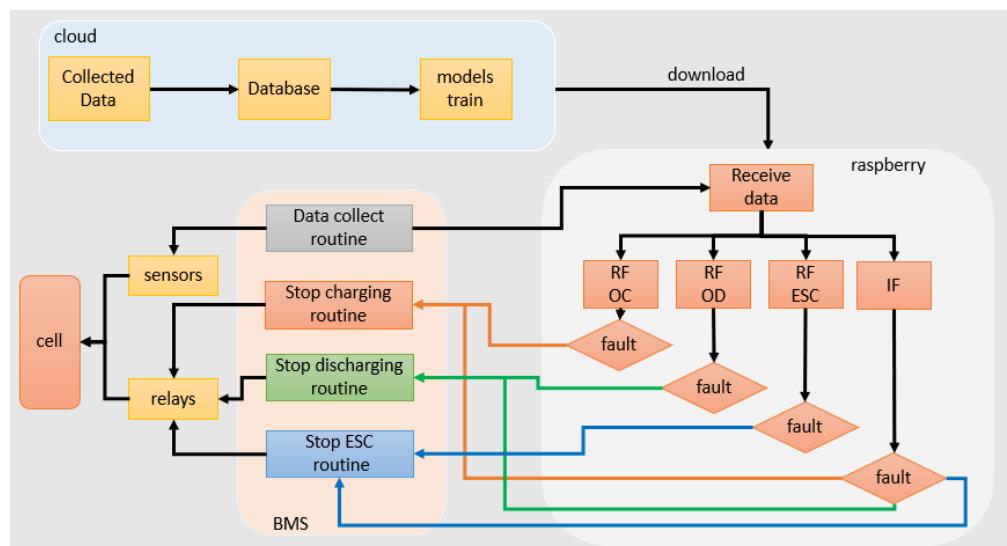
Table 1 shows that the accuracy of all models was high, but such a metric should not be used to indicate the ML efficiency. Therefore, sensitivity and specificity were used to validate the models.

Table 1 also brings the final results of the four models. According to the table, the IF could correctly identify most failures, as the sensitivity was 63%.

On the other hand, the model could not identify the non-failures correctly, and its specificity was poor. This was caused by the contamination rate, which depends on the data. In order to avoid several false positives, when the model ran in real-time and identifies the anomaly, a double-check was performed to compare the cell's temperature with the ambient temperature. If the delta is higher than  $5^{\circ}\text{C}$ , the anomaly is confirmed.

The RF could correctly identify 100% of the events for ESC and OC abuses (see Table 1). Otherwise, the non-events of ESC are the most in the dataset. In this way, since the false negatives correspond to 15%, the specificity decayed. For OD, the TP rate was 89%, while the TN rate was 97%. In summary, all models showed sufficient performance and, therefore, can be applied to reduce capacity loss in real-time.

After the ML preparation and model building, the models were downloaded to the edge computing, where the data can be processed in real-time and inferences made. Figure 7 shows the logic operation of the ML approach. The BMS collected the data from the sensors and sent them to the edge by I2C. Every incoming message fed the four models that were trained in the cloud as described previously. If a failure or anomaly is found, the edge sends a message to the BMS to stop the operation.



**Figure 7.** The logic operation of the ML models. The architecture is composed of the BMS, which measures the sensors and controls the discharging/charging cycles. The edge communicates with the BMS by the I2C protocol. The ML models are trained in the cloud to make inferences in real-time in the edge. The communication with the cloud is performed by WiFi for the edge.

In this context, in the second step, the IF model was applied to the same experiments without ML. Therefore, three tests with OD, OC, ESC, and a mix were realized, totaling 12 experiments. The capacity of the cells was measured before and after the tests. In these tests (see Figure 7), the IF is fed the temperature's value every second and processes the inference. In the case of an identified anomaly, the edge sends the message to the Arduino Mega by I2C to interrupt the charging or discharging phase. The pause happens until no anomaly is present.

Then, in the third step, the RF was applied combined with the IF. As in the previous experiments, the capacity was measured before and after the tests. The tests in the same conditions and with the same methodologies were applied in this approach. If the OC-RF finds a failure during the charging stage, the edge sends a message to the BMS to cut the circuit that controls the charging relay. Similarly, if the OD-RF identifies a failure during the discharging process, the BMS receives a message sent by I2C from the Edge and cuts the discharging cycle. The ESC is cut off if the ESC-RF detects a failure. Finally, if the IF model detects an anomaly, every process is interrupted to reduce capacity loss.

The following section shows each step's results and the ML performance for reducing the capacity loss of LIBs.

#### 4. Results and Discussion

As mentioned before, the tests were performed with the lithium-ion 18650 ICR 22P cells from Samsung that contains the NCM chemical, and the nominal capacity is equal

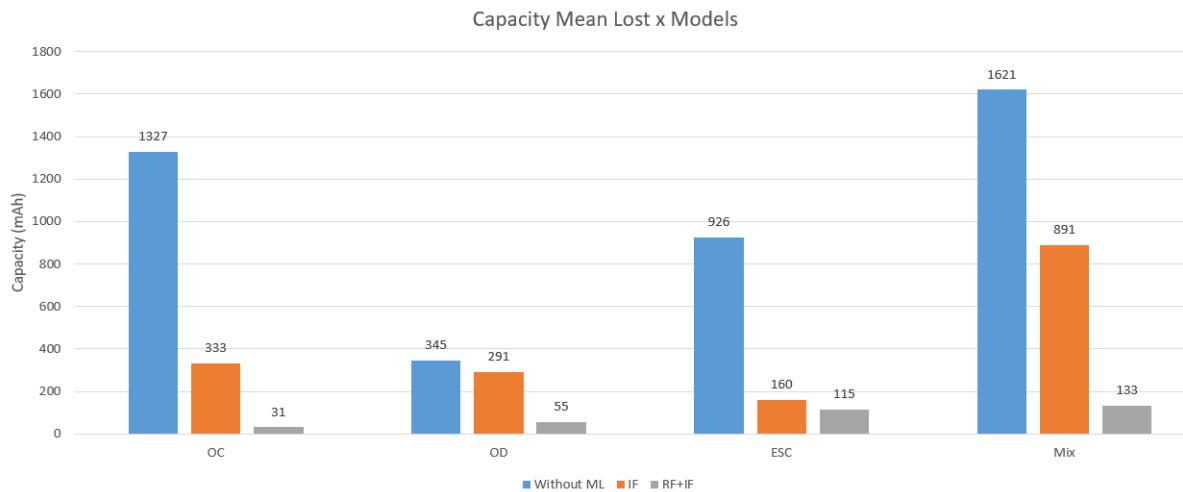
to 2200 mAh and the voltage equal to 3.7 V. A shield with Arduino Mega collects the data from the voltage, current, and temperature of the cell and the environment. The edge computing is connected to the shield by the I2C protocol and monitors the data in real-time. Then, it sends the data to the AWS cloud, where the samples are stored in the S3. After that, the data are uploaded to the Anaconda Environment, where the RF and IR are built. In addition, the capacity of each cell was measured before and after the tests to verify the impact not only of the failures, but also on the ML application.

Firstly, the tests without ML were performed. As in the last section, the experiments according to the methodology were performed three times for each cell and three cells for every failure, resulting in 12 experiments. The impact of the abuses is found in Table 2.

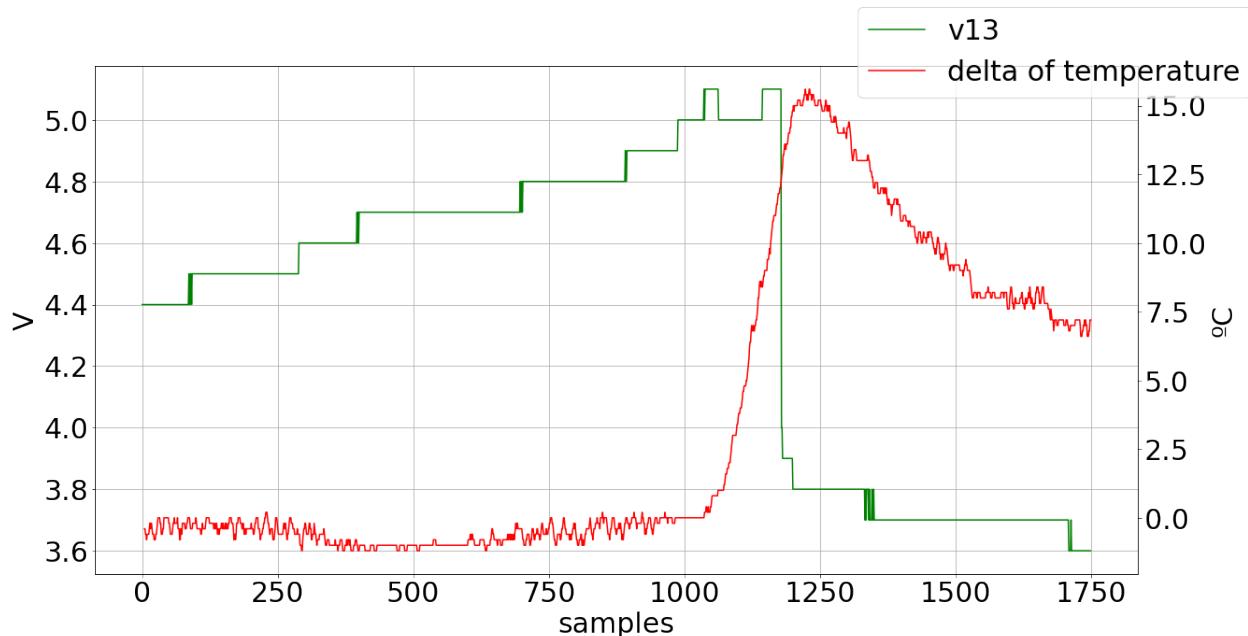
**Table 2.** Table with the capacity of the cells during, before, and after the experiments.

Item	Experiment	Capacity Initial	Capacity Final	Delta
1	OC 1	2200	883	1317
2	OC 2	2209	824	1385
3	OC 3	2380	1100	1280
4	ESC 1	1950	921	1029
5	ESC 2	2100	1100	1000
6	ESC 3	2250	1500	750
7	OD 1	1954	1550	404
8	OD 2	1980	1681	299
9	OD 3	1160	1727	333
10	Complete 1	2100	768	1332
11	Complete 2	2050	470	1580
12	Complete 3	1950	0	1950
13	IF OC 1	2312	1958	354
14	IF OC 2	2013	1665	348
15	IF OC 3	2083	1787	296
16	IF ESC 1	2335	2151	184
17	IF ESC 2	2213	2083	130
18	IF ESC 3	2191	2024	167
19	IF OD 1	1947	1657	290
20	IF OD 2	1942	1630	312
21	IF OD 3	1960	1690	270
22	IF Complete 1	1941	1040	901
23	IF Complete 2	2037	1060	977
24	IF Complete 3	2060	1265	795
25	RF OC 1	2096	2071	25
26	RF OC 2	2125	2091	34
27	RF OC 3	1951	1917	34
28	RF ESC 1	2306	2212	94
29	RF ESC 2	1942	1857	85
30	RF ESC 3	1810	1645	165
31	RF OD 1	1835	1768	67
32	RF OD 2	1766	1710	56
33	RF OD 3	1794	1752	42
34	RF General 1	1805	1643	162
35	RF General 2	2010	1895	115
36	RF General 3	1831	1710	121

As observed in Table 1 and Figure 8, OC had the worst impact on the LIB's capacity compared with the other abuses. On average, the tests with this abuse lost 1327 mAh of the cells. Figure 9 shows that the cell's temperature took a long time to rise under OC abuse. Then, the cell's temperature came to 15 °C, higher than the ambient temperature. In this way, the cell was submitted to a high voltage for a long time, resulting in the most significant lost capacity.

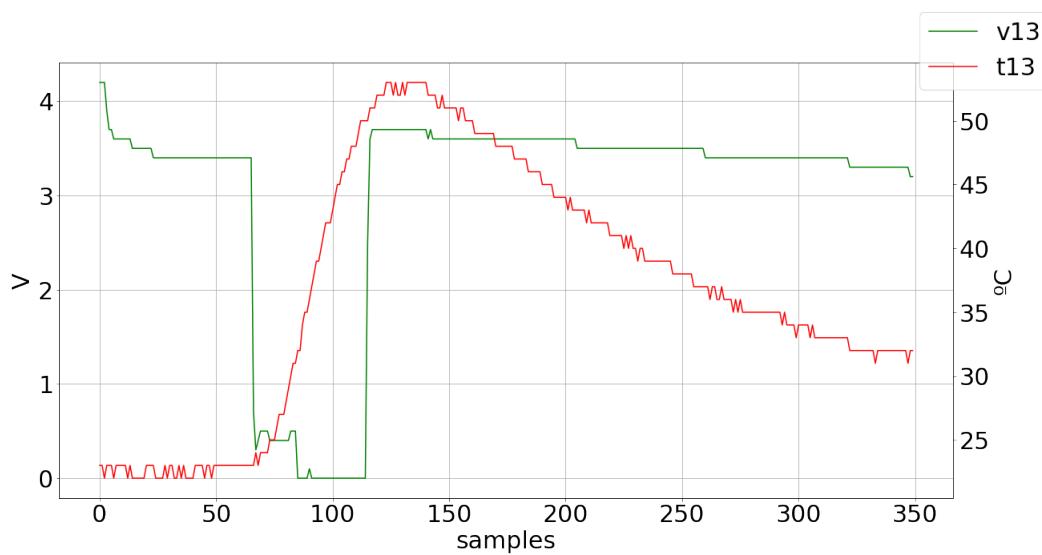


**Figure 8.** Mean lost capacity of the cells with and without ML. The capacity loss is high when no ML is applied. The IF could significantly reduce the capacity loss by observing only the cell's temperature. However, the combination of the RF and IF could reduce the chances of capacity loss in the cells, according to the experiments.



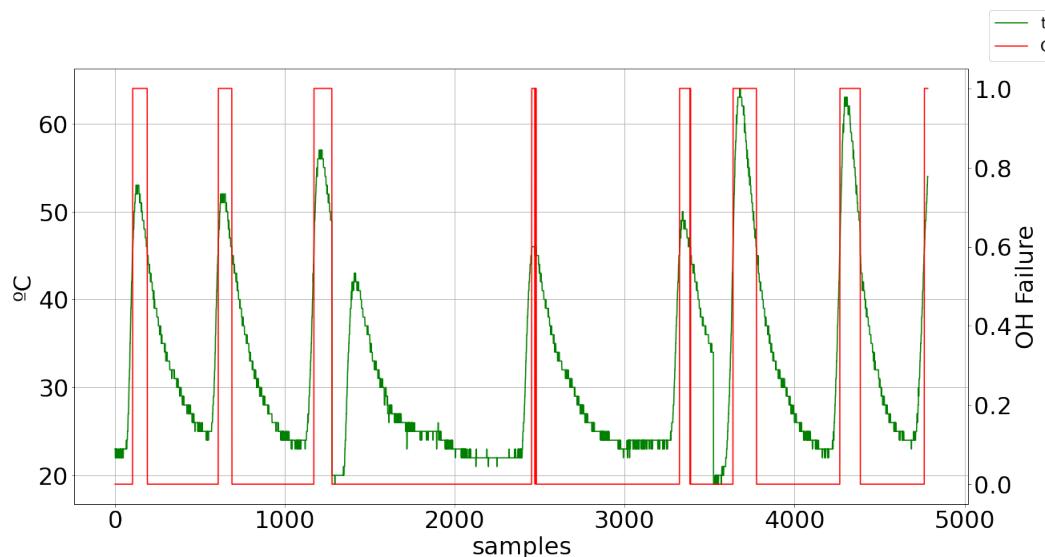
**Figure 9.** The behavior of the temperature and voltage of the cell during the OC abuse. After a long time and a voltage close to 5 V, the temperature rises.

Similar to OC, ESC also caused a rising of the temperature. Nevertheless, as observed in Figure 10, the temperature rose immediately when an ESC was applied. This behavior results in the second-worst lost capacity, as observed in Table 1 for the three experiments, and on average, the lost capacity was about 926 mAh (see Figure 8). The lost capacity was lower than OC because the cell spent less time compared with the OC abuse under the failure. Even though with only 12 min, it is possible to see a high degradation in the cell.



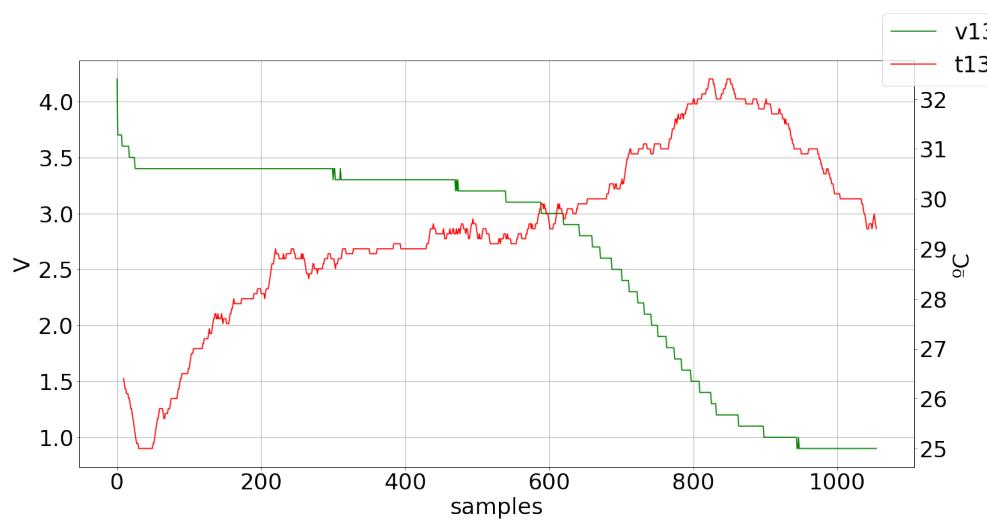
**Figure 10.** The temperature rises immediately when ESC is observed. The temperature rises immediately after the abuse is applied.

Although ESC was interrupted, the temperature rose a little due to the chemical reaction in the cell. This high-temperature resulted in an overheating failure, as observed in Figure 11, where the temperature was greater than 45 °C in some cases. As OH is the first evidence of a probable TR, it is essential to avoid this abuse.



**Figure 11.** The OH failure is present in the ESC experiments. If the cell's temperature is higher than 45 °C, an OH failure is considered. The cell's temperature does not increase in the same proportions as found in OC and ESC.

Conversely, OD had a more negligible negative impact, as observed in Table 2. On average, the failure caused 345 mAh of lost capacity (see Figure 8). The low capacity loss compared with other abuses is observed in the temperature curve. The temperature of the cell increased less compared with other failures. In some tests, the temperature increased by 8 °C. This behavior occurs in the first stage of the OD failure when the resistance of the cell increases due to the low available energy in the cell, as observed in Figure 12. Besides that, OH was never observed in the experiments with OD failures.

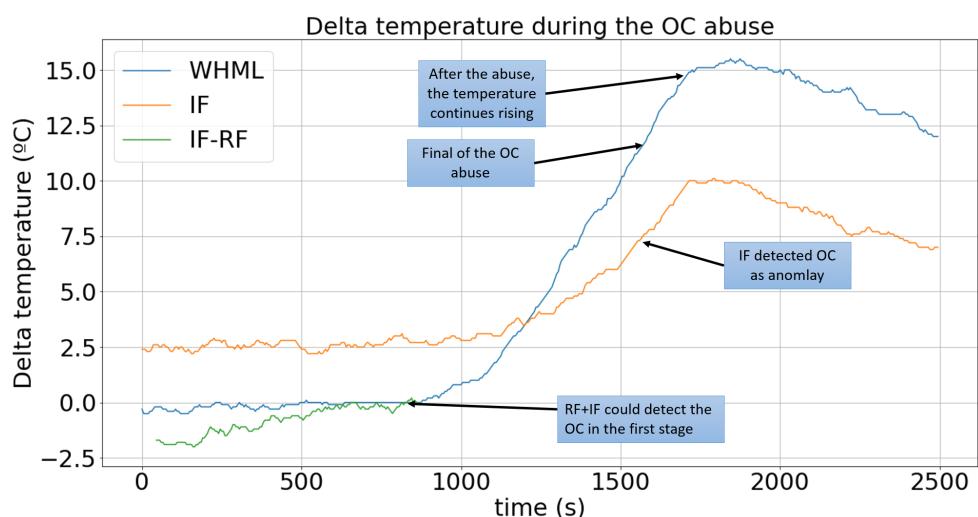


**Figure 12.** The temperature rises when the cell enters in the OD failures because the internal resistance increases.

Finally, the experiments with the combination of the three cells lost on average 1621 mAh, as observed in Figure 8. The impact was observed due to the three cases of abuse applied in the cells according to the methodology mentioned in Figure 5.

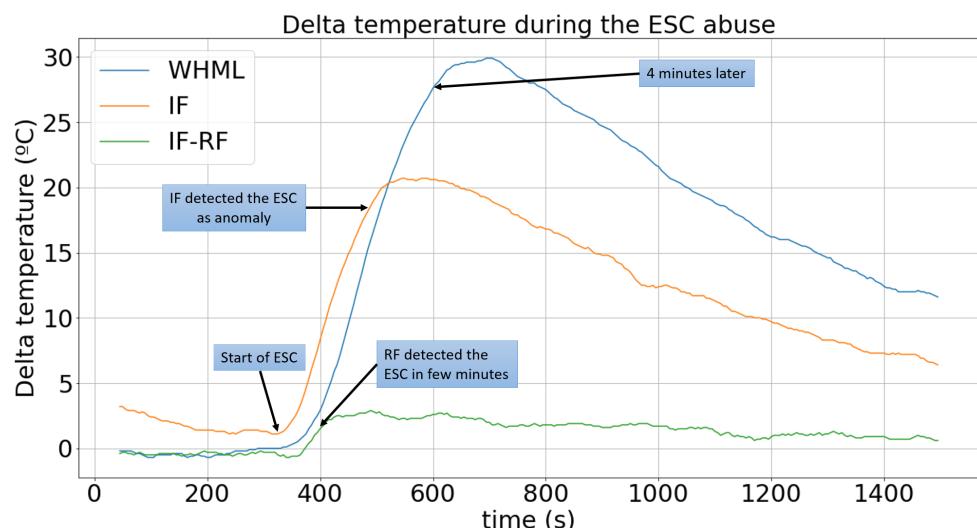
In order to elaborate on the second step, as observed in the experiments without ML, the rising temperature is the consequence of the three abuses. Due to this conclusion, the IF model was chosen to find anomalies in the temperature by applying the same abuses in the cells. The model was trained and uploaded in the edge computing. Then, a python script was written to collect the actual data and make the inferences. When the model found an anomaly, it interrupted the charging or discharging process until the anomaly was no longer observed. This approach reduced the capacity loss of the cells.

For the experiments with OC abuses, as observed in Table 2 and Figure 8, the lost average capacity decayed from 1327 to 333 mAh. This behavior happened because, when the temperature starts rising, the IF detects it and stops the charging process. The impact is observed in Figure 13, where the temperature delta is lower than the process without ML.



**Figure 13.** The behavior of the delta temperature under the OC abuse experiments without ML and with the IF and RF. The time of the IF-RF's application is shorter than the others because the model could identify the OC in the first stage.

In the ESC process, the IF could avoid the overheating failure, as observed in Figure 14. The temperature rose, but the IF could stop ESC and save the lost capacity from 926 to 160 mAh, as observed in Figure 8.



**Figure 14.** The behavior of the delta temperature under the ESC abuse experiments without ML and with the IF and RF. The combination of the IF-RF could avoid the increasing temperature in the cell. The temperature with the IF was raised until the anomaly detection model could identify it.

Finally, despite the rising temperature in OD, the IF could not identify the presence of a failure in the cell's temperature. Therefore, the lost mean capacity was similar with and without the IF, as observed in Figure 8. The experiments were performed with an ambient temperature between 20 and 25 °C. In this way, if the ambient temperature were higher, the IF could perform better and even detect the OD abuse.

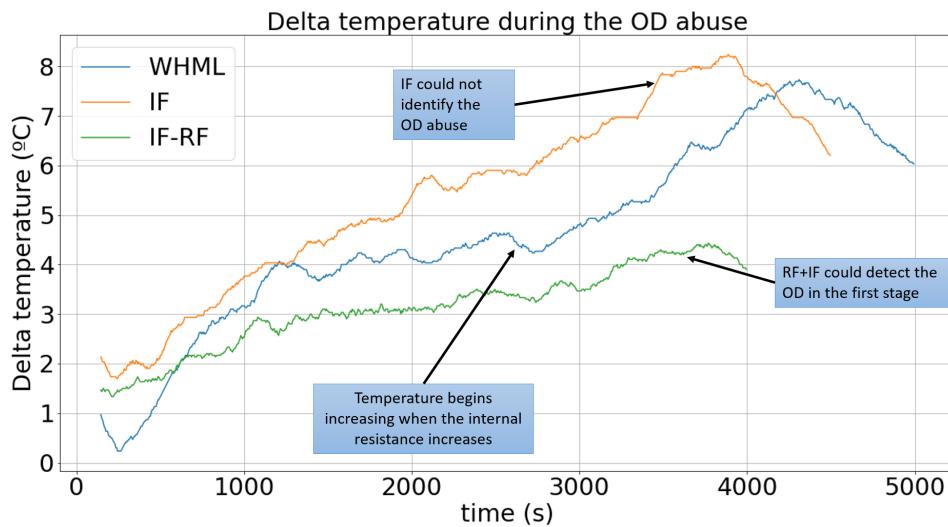
For the experiments with the three types of abuse, the IF could reduce the average capacity loss from 1621 to 891 mAh, i.e., the reduction was equal to 45%.

The IF reduced the capacity loss, but the model could identify the abuses only when the temperature was considered an anomaly, i.e., the cells suffered from abuses until the identification reduced the cell's capacity. Therefore, the RF model was trained to identify the OC, ESC, and OD abuses. According to data engineering (see Figure 6), the voltage, current, delta temperature, and cell temperature are the features needed to build and train the model.

After the training, the models were uploaded in the edge computing and, combined with the IF, made inferences in real-time. The same 12 experiments were performed, and the capacity was measured before and after the tests. The capacity loss is observed in Table 2 and the average capacity loss in Figure 8.

The combination of the IF and RF could perform exceptionally well to identify the failures in the first stage. On average (see Figure 8), the models reduced the capacity loss from 1327 to 31 mAh for the OC abuses. In the same direction, the reduction for ESC was on average from 925 to 115 mAh, for OD was from 345 to 55 mAh, and finally, for the mix of failures from 1621 to 133 mAh, i.e., the total reduction was equal to 91%.

With the RF combined with the IF, the capacity loss of OC was the lowest compared with other failures, which is the opposite of the experiments without ML. This behavior is because OC is observed before it can harm the cell. On the other side, according to Figure 14, ESC happens and increasingly softens the temperature, which causes a slight loss of capacity in the cell, but is higher than the OC abuse. The reductions in the OD abuses were also observed as observed in the delta temperature (see Figure 15).



**Figure 15.** The behavior of the delta temperature under the OD abuse experiments without ML and with the IF and RF. As the combination of the IF-RF could identify the OD abuse before the failure, the time of the abuse is shorter than the other tests.

In conclusion, as expected, the abuses in the LIB caused several consequences for the performance and security of the battery. The results showed that OC generated the most significant capacity loss compared with ESC and OD. Therefore, the IF was applied and could reduce the time of the abuses in the LIB and save the capacity of the cells significantly. Despite that, the IF could identify only the cells' anomalies, indicating that the abuses had already begun. Therefore, the combination of the IF and RF performed better in reducing the capacity loss of the batteries.

## 5. Conclusions

LIBs represent the state-of-the-art technology in capacity, storage, long lifetime, and density for storage systems. However, they must operate under controlled conditions to avoid security and performance problems.

The BMS manages the cells. Despite that, it is hard-programmed and dependent on complex hardware circuits to control the cells. This way, the natural aging process will update the cells' thresholds without communicating to the BMS, resulting in a loss of capacity of the BMS with time. Therefore, this paper presented a case study of applying the RF and IF to help BMS anticipate failures and abuses in real-time. The study case was segmented into three steps. The 18650 NMC cells with 2200 mAh were used for the tests.

Firstly, 12 experiments with OD, OC, ESC, and a combination of them were realized to generate the data for the ML training. Then, the models were built with the dataset. In the second step, only the IF was applied for 12 experiments, similar to the first step. As the IF detected the anomaly by observing the temperature, the abuse was identified with a delay, which impacted the degradation. Despite that, the degradation rate was 45% lower than Step 1.

Finally, the same 12 experiments were applied to the combination of the IF and RF. In these experiments, the reaction time of the identified abuse was almost instantaneous. This approach reduced the cells' capacity loss in about 90%. Thus, it is possible to guarantee that ML can help the BMS control the LIBs to avoid failures and prolong the batteries' lifetime. For future works, it is expected to work with an actual situation where the system can work onboard in the electric vehicle to identify failures online.

**Author Contributions:** Conceptualization, J.D.G. and M.B.; methodology, J.D.G. and M.B.; software, J.D.G.; formal analysis, J.R.G., S.H.W., F.C.C. and A.M.d.S.; investigation, J.D.G. and J.R.G.; writing—original draft preparation, J.D.G., J.R.G.; supervision, F.C.C. and M.B.; writing—review, J.D.G., J.R.G.,

A.S., S.H.W., F.C.C. and M.B.; funding acquisition, M.B. All authors have read and agreed to the published version of the manuscript.

**Funding:** This research was funded by Rota 2030 Public Call 01/2020, Agreement 27192.03.01/2020.16-00 and the APC was funded by Coordination for the Improvement of Higher Education Personnel (CAPES) Financing Code 001.

**Institutional Review Board Statement:** Not applicable.

**Informed Consent Statement:** Not applicable.

**Data Availability Statement:** Not applicable.

**Acknowledgments:** The authors thank Foundation for Research Development—FUNDEP—Rota 2030, Public Call 01/2020, Agreement 27192.03.01/2020.16-00, for their financial support.

**Conflicts of Interest:** The authors declare no conflict of interest.

**Sample Availability:** Not applicable.

## References

- Chen, W.; Liang, J.; Yang, Z.; Li, G. A Review of Lithium-Ion Battery for Electric Vehicle Applications and Beyond. *Energy Procedia* **2019**, *158*, 4363–4368. [[CrossRef](#)]
- Hu, X.; Zhang, K.; Liu, K.; Lin, X.; Dey, S.; Onori, S. Advanced Fault Diagnosis for Lithium-Ion Battery Systems: A Review of Fault Mechanisms, Fault Features, and Diagnosis Procedures. *IEEE Ind. Electron. Mag.* **2020**, *14*, 65–91. [[CrossRef](#)]
- Affanni, A.; Bellini, A.; Franceschini, G.; Guglielmi, P.; Tassoni, C. Battery choice and management for new-generation electric vehicles. *IEEE Trans. Ind. Electron.* **2005**, *52*, 1343–1349. [[CrossRef](#)]
- Aiello, O. Electromagnetic susceptibility of battery management systems' ICs for electric vehicles: Experimental study. *Electronics* **2020**, *9*, 510. [[CrossRef](#)]
- Yang, Z.Z. Development of an Active Equalizer for Lithium-Ion Batteries. *Electronics* **2022**, *11*, 2219. [[CrossRef](#)]
- Nizam, M.; Maghfiroh, H.; Rosadi, R.; Kusumaputri, K. Battery Management System Design (BMS) for Lithium Ion Batteries. *AIP Conf. Proc.* **2020**, *2217*, 030157. [[CrossRef](#)]
- Zhu, F. A Battery Management System for Li-ion Battery. *J. Eng.* **2009**, *1*, 1437–1440. [[CrossRef](#)]
- Galvão, J.R.; Calligaris, L.B.; de Souza, K.M.; Gotz, J.D.; Junior, P.B.; Corrêa, F.C. Hybrid Equalization Topology for Battery Management Systems Applied to an Electric Vehicle Model. *Batteries* **2022**, *8*, 178. [[CrossRef](#)]
- Li, X.; Li, J.; Abdollahi, A.; Jones, T. Data-driven Thermal Anomaly Detection for Batteries using Unsupervised Shape Clustering. In Proceedings of the 2021 IEEE 30th International Symposium on Industrial Electronics (ISIE), Kyoto, Japan, 20–23 June 2021. [[CrossRef](#)]
- Kim, T.; Makwana, D.; Adhikaree, A.; Vaggoda, J.S.; Lee, Y. Cloud-Based Battery Condition Monitoring and Fault Diagnosis Platform for Large-Scale Lithium-Ion Battery Energy Storage Systems. *Energies* **2018**, *11*, 125. [[CrossRef](#)]
- Yang, S.; Zhang, Z.; Cao, R.; Wang, M.; Cheng, H.; Zhang, L.; Jiang, Y.; Li, Y.; Chen, B.; Ling, H.; et al. Implementation for a cloud battery management system based on the CHAIN framework. *Energy AI* **2021**, *5*, 100088. [[CrossRef](#)]
- Shi, W.; Cao, J.; Zhang, Q.; Li, Y.; Xu, L. Edge Computing: Vision and Challenges. *IEEE Internet Things J.* **2016**, *3*, 637–646. [[CrossRef](#)]
- Xia, B.; Mi, C.; Chen, Z.; Robert, B. Multiple cell lithium-ion battery system electric fault online diagnostics. In Proceedings of the 2015 IEEE Transportation Electrification Conference and Expo (ITEC), Dearborn, MI, USA, 14–17 June 2015; pp. 1–7. [[CrossRef](#)]
- Nuhic, A.; Terzimehic, T.; Soczka-Guth, T.; Buchholz, M.; Dietmayer, K. Health diagnosis and remaining useful life prognostics of lithium-ion batteries using data-driven methods. *J. Power Sources* **2013**, *239*, 680–688. [[CrossRef](#)]
- Naha, A.; Khandelwal, A.; Hariharan, K.S.; Kaushik, A.; Yadu, A.; Kolake, S.M. On-Board Short-Circuit Detection of Li-ion Batteries Undergoing Fixed Charging Profile as in Smartphone Applications. *IEEE Trans. Ind. Electron.* **2019**, *66*, 8782–8791. [[CrossRef](#)]
- Lee, S.; Han, S.; Han, K.H.; Kim, Y.; Agarwal, S.; Hariharan, K.S.; Oh, B.; Yoon, J. Diagnosing various failures of lithium-ion batteries using artificial neural network enhanced by likelihood mapping. *J. Energy Storage* **2021**, *40*, 102768. [[CrossRef](#)]
- Chen, Y.; Kang, Y.; Zhao, Y.; Wang, L.; Liu, J.; Li, Y.; Liang, Z.; He, X.; Li, X.; Tavajohi, N.; et al. A review of lithium-ion battery safety concerns: The issues, strategies, and testing standards. *J. Energy Chem.* **2021**, *59*, 83–99. [[CrossRef](#)]
- Jeon, M.; Lee, E.; Park, H.; Yoon, H.; Keel, S. Effect of Thermal Abuse Conditions on Thermal Runaway of NCA 18650 Cylindrical Lithium-Ion Battery. *Batteries* **2022**, *8*, 196. [[CrossRef](#)]
- Liu, F.T.; Ting, K.M.; Zhou, Z.H. Isolation Forest. In Proceedings of the 2008 Eighth IEEE International Conference on Data Mining, Pisa, Italy, 15–19 December 2008; pp. 413–422. [[CrossRef](#)]
- Saberioon, M.; Císař, P.; Labbé, L.; Souček, P.; Pelissier, P.; Kerneis, T. Comparative Performance Analysis of Support Vector Machine, Random Forest, Logistic Regression and k-Nearest Neighbours in Rainbow Trout (*Oncorhynchus Mykiss*) Classification Using Image-Based Features. *Sensors* **2018**, *18*, 1027. [[CrossRef](#)] [[PubMed](#)]

21. Zhou, W.; Lu, Q.; Zheng, Y. Review on the Selection of Health Indicator for Lithium Ion Batteries. *Machines* **2022**, *10*, 512. [[CrossRef](#)]
22. Markoulidakis, I.; Rallis, I.; Georgoulas, I.; Kopsiaftis, G.; Doulamis, A.; Doulamis, N. Multiclass Confusion Matrix Reduction Method and Its Application on Net Promoter Score Classification Problem. *Technologies* **2021**, *9*, 81. [[CrossRef](#)]
23. Trevethan, R. Sensitivity, Specificity, and Predictive Values: Foundations, Pliabilities, and Pitfalls in Research and Practice. *Front. Public Health* **2017**, *5*, 307. [[CrossRef](#)] [[PubMed](#)]

## **APÊNDICE D - Artigo D: Machine Learning for Forecasting and Predicting Failures in Lithium-Ion Batteries**

Devido a restrições de direitos de reprodução, apenas as informações públicas do artigo são apresentadas aqui.



## International Conference on Flexible Automation and Intelligent Manufacturing

FAIM 2022: **Flexible Automation and Intelligent Manufacturing: The Human-Data-Technology Nexus** pp 537–545

[Home](#) > [Flexible Automation and Intelligent Manu...](#) > Conference paper

# Machine Learning for Forecasting and Predicting Failures in Lithium-Ion Batteries

[Joelton Deonei Gotz](#) , [João Felipe Raffs Espolador](#),

[Gabriel Carrico Guerrero](#), [Samuel Henrique Werlich](#), [Milton](#)

[Borsato](#) & [Fernanda Cristina Corrêa](#)

Conference paper | [First Online: 04 February 2023](#)

**260** Accesses

Part of the [Lecture Notes in Mechanical Engineering](#) book series (LNME)

## Abstract

The adoption of Lithium-ion batteries (LIB) is increasing in many different sectors such as electric mobility, electronics products, and smart grids. This trend happens because LIBs are more stable, have a longer life cycle, and store more energy than other technologies. However, a couple of failures in the LIB can cause safety issues and degradation, mainly because these failures can happen slowly and progressively. Therefore, it is essential to diagnose,

forecast, and predict failures to take action as soon as possible. Machine Learning (ML) techniques are commonly used to work with data-driven and diagnose failures in industrial machines to solve this problem. Thus, these tools also can be used in LIB products. Due to this motivation, this work developed an ML system with some different models in two steps. Firstly, the algorithm forecasted the central values from the LIB. Then, the output of the first step fed the second layer to predict and diagnose future failures. The work results indicate that a failure can be anticipated a long time before would be identified by the LIB management. Therefore, this approach can avoid failures and reduce the aging process.

## Keywords

**Lithium-ion battery      Failures**

**Machine learning      Forecast      Prediction**

---

This is a preview of subscription content, [access via your institution.](#)

---

▼ Chapter USD 29.95  
Price excludes VAT (Brazil)

- DOI: 10.1007/978-3-031-17629-6\_56
- Chapter length: 9 pages
- Instant PDF download
- Readable on all devices
- Own it forever
- Exclusive offer for individuals only
- Tax calculation will be finalised during checkout

[Buy Chapter](#)

› eBook USD 259.00

› Softcover Book USD 329.99

[Learn about institutional subscriptions](#)

## References

1. Chen, Y., et al.: A review of lithium-ion battery safety concerns: the issues, strategies, and testing standards. *J. Energy Chem.* **59**, 83–99 (2021)
2. Zhang, J., Zhang, L., Sun, F., Wang, Z.: An overview on thermal safety issues of lithium-ion batteries for electric vehicle application. *IEEE Access* **6**, 23848–23863 (2018)
3. Hu, X., Zhang, K., Liu, K., Lin, X., Dey, S., Onori, S.: Advanced fault diagnosis for lithium-ion battery systems: a review of fault mechanisms, fault features, and diagnosis procedures. *IEEE Ind. Electron. Mag.* **14**, 65–91 (2020)
4. Samanta, A., Chowdhuri, S., Williamson, S.S.: Machine learning-based data-driven fault detection/diagnosis of lithium-ion battery: a critical review. *Electronics* **10**, 1309 (2021)
5. Hannan, M.A., Hoque, M.M., Hussain, A., Yusof, Y., Ker, P.J.: State-of-the-art and energy

management system of lithium-ion batteries in electric vehicle applications: issues and recommendations. *IEEE Access* **6**, 19362–19378 (2018)

- 
6. Jiang, J., Cong, X., Li, S., Zhang, C., Zhang, W.,  
Jiang, Y.: A hybrid signal-based fault diagnosis method for lithium-ion batteries in electric vehicles. *IEEE Access* **9**, 19175–19186 (2021)
- 
7. Zraibi, B., Okar, C., Chaoui, H., Mansouri, M.: Remaining useful life assessment for lithium-ion batteries using CNN-LSTM-DNN hybrid method. *IEEE Trans. Veh. Technol.* **70**(5), 4252–4261 (2021)
- 
8. Gan, N., Sun, Z., Zhang, Z., Xu, S., Liu, P., Qin, Z.: Data-driven fault diagnosis of lithium-ion battery over-discharge in electric vehicles. *IEEE Trans. Power Electron.* **37**(4), 4575–4588 (2022)
- 
9. Huotari, M., Arora, S., Malhi, A., Främling, K.: A dynamic battery state-of-health forecasting model for electric trucks: li-ion batteries case-study. *ASME Int. Mech. Eng. Congr. Expos. Energy* **8** (2020)
- 
10. Zhang, Y., Xiong, R., He, H., Liu, Z.: A LSTM-RNN method for the lithium-ion battery remaining useful life prediction. In: 2017

Prognostics and System Health Management  
Conference (PHM-Harbin), pp. 1–4. Harbin  
(2017)

---

11. Siberian, M., Císař, P., Labbé, L., Souček, P.,  
Pelissier, P., Kerneis, T.: Comparative  
performance analysis of support vector  
machine, random forest, logistic regression  
and k-nearest neighbours in rainbow trout  
(*Oncorhynchus mykiss*) classification using  
image-based features. *Sensors* **18**, 1027 (2018)

---

## Acknowledgments

---

This work is supported by the Rota Program 2030.

---

## Author information

---

### Authors and Affiliations

**Postgraduate Program in Mechanical and  
Materials Engineering, Curitiba, Brazil**

Joelton Deonei Gotz, João Felipe Raffs  
Espolador, Gabriel Carrico Guerrero, Samuel  
Henrique Werlich & Milton Borsato

**Postgraduate Program in Electrical Engineering,  
Ponta Grossa, Brazil**

Fernanda Cristina Corrêa

### Corresponding author

Correspondence to [Joelton Deonei Gotz](#).

---

## Editor information

---

## Editors and Affiliations

**Industrial and Systems Engineering, Wayne State**

**University, Detroit, MI, USA**

Kyoung-Yun Kim

**Industrial and Systems Engineering, Wayne State**

**University, Detroit, MI, USA**

Leslie Monplaisir

**Industrial and Systems Engineering, Wayne State**

**University, Detroit, MI, USA**

Jeremy Rickli

## Rights and permissions

---

[Reprints and Permissions](#)

## Copyright information

---

© 2023 The Author(s), under exclusive license to

Springer Nature Switzerland AG

## About this paper

---

### Cite this paper

Gotz, J.D., Espolador, J.F.R., Guerrero, G.C., Werlich, S.H.,  
Borsato, M., Corrêa, F.C. (2023). Machine Learning for  
Forecasting and Predicting Failures in Lithium-Ion  
Batteries. In: Kim, KY., Monplaisir, L., Rickli, J. (eds) Flexible  
Automation and Intelligent Manufacturing: The Human-  
Data-Technology Nexus. FAIM 2022. Lecture Notes in  
Mechanical Engineering. Springer, Cham.

[https://doi.org/10.1007/978-3-031-17629-6\\_56](https://doi.org/10.1007/978-3-031-17629-6_56)

[.RIS](#) [.ENW](#) [.BIB](#)

### DOI

[https://link.springer.com/chapter/10.1007/978-3-031-17629-6\\_56](https://link.springer.com/chapter/10.1007/978-3-031-17629-6_56)

[https://doi.org/10.1007/978-3-031-17629-6\\_56](https://doi.org/10.1007/978-3-031-17629-6_56)

Published	Publisher Name	Print ISBN
04 February 2023	Springer, Cham	978-3-031- 17628-9

Online ISBN	eBook Packages
978-3-031- 17629-6	<a href="#"><u>Engineering</u></a> <a href="#"><u>Engineering_(R0)</u></a>

Not logged in - 191.177.173.183

Not affiliated

**SPRINGER NATURE**

© 2023 Springer Nature Switzerland AG. Part of [Springer Nature](#).