

Inteligência artificial na análise de vida útil de baterias

Artificial intelligence in battery life analysis

DOI:10.34117/bjdv7n3-227

Recebimento dos originais: 11/02/2021

Aceitação para publicação: 11/03/2021

Carlos Márcio da Silva Freitas

Engenheiro eletricista (Mestrando em Sistemas Aplicados a Engenharia - IFF)

Instituição: IFF - Instituto Federal Fluminense

Endereço: R. Dr. Siqueira, 273 - Parque Dom Bosco, Campos dos Goytacazes - RJ,
28030-130

E-mail: carlos.freitas@iff.edu.br

Rogério Atem de Carvalho

Doutor em Engenharia de Produção

Instituição: IFF - Instituto Federal Fluminense

Endereço: R. Dr. Siqueira, 273 - Parque Dom Bosco, Campos dos Goytacazes - RJ,
28030-130

E-mail: ratem@iff.edu.br

RESUMO

As baterias são componentes essenciais para muitos dispositivos e sistemas eletroeletrônicos, avaliar corretamente o seu ciclo de vida é importante para evitar trocas desnecessárias e prever possíveis falhas na mesma. Embora a predição de tempo de vida útil de baterias seja uma informação útil, ela ainda é pouco explorada em equipamentos e aplicações comerciais. Objetivo: Este trabalho tem o objetivo de apresentar as principais técnicas de teste de baterias e avaliar a aplicabilidade de determinados algoritmos de inteligência artificial para uma eficiente avaliação dos dados obtidos nos testes, e consequentemente a correta previsão de vida útil desses componentes. Metodologia: Este trabalho foi feito em 2 etapas. A primeira constitui a análise das principais variáveis elétricas utilizadas para avaliação e teste de baterias. Na segunda etapa foram analisados alguns algoritmos de inteligência artificial e sua possível aplicação na previsão de vida útil de baterias, de forma que a metodologia possa ser aplicada independente do tipo de bateria utilizada. Resultados: Com base no levantamento de dados foi possível identificar os algoritmos de inteligência artificial mais adequados para o processamento das informações obtidas nas variáveis de teste e consequentemente uma correta previsão de vida útil de baterias. Conclusão: Embora exista uma grande variedade de algoritmos de inteligência computacional, apenas uma parcela é adequada para o processamento de dados temporais e a correta análise de vida útil de baterias.

Palavras-Chaves: Inteligência Artificial, Teste Elétrico, Degradação de Bateria, Previsão de Vida Útil.

ABSTRACT

Batteries are essential components for many electronic devices and systems, correctly assessing their life cycle is important to avoid unnecessary changes and to predict possible failures in the same. Although the prediction of battery life is useful

information, it is still little explored in commercial equipment and applications. Objective: This work aims to present the main battery testing techniques and evaluate the applicability of certain artificial intelligence algorithms for an efficient evaluation of the data obtained in the tests, and consequently the correct prediction of the useful life of these components. Methodology: This work was done in 2 steps. The first is the analysis of the main electrical variables used for battery evaluation and testing. In the second stage, some artificial intelligence algorithms and their possible application in the prediction of battery life were analyzed, so that the methodology can be applied regardless of the type of battery used. Results: Based on the data survey, it was possible to identify the most suitable artificial intelligence algorithms for processing the information obtained from the test variables and, consequently, a correct battery life forecast. Conclusion: Although there is a wide variety of computational intelligence algorithms, only a portion is adequate for the processing of temporal data and the correct analysis of battery life.

Keywords: Artificial Intelligence, Electrical Testing, Battery Degradation, Forecasting Life.

1 INTRODUÇÃO

A grande demanda de armazenamento de energia elétrica torna as baterias um dos principais componentes de muitos sistemas elétricos e eletrônicos modernos, (KHUMPROM, 2019).

Aplicações como carros de propulsão elétrica, sistemas de energia solar, sistemas de nobreak, partida demotores de combustão como em automóveis e grupos geradores são exemplos de aplicações dependentes de baterias. Tendo utilização em larga escala os quesitos custo, manutenção e descarte de uma bateria se tornam cada vez mais importantes, ainda deve-se lembrar que os componentes das baterias são prejudiciais ao meio ambiente e requerem tratamento e reciclagem adequados (NAZRI e PISTOIA; 2009)

VIDAL (2020) relaciona o uso de inteligência artificial para estimativa do estado da carga e taxa de envelhecimento de baterias utilizadas em veículos, e fornece uma comparação de métodos de estimativa de estado da bateria com base em abordagens de machine learning, em redes neurais avançadas, redes neurais recorrentes, máquinas de vetores de suporte, funções de base radial e redes de Hamming.

DICKSON (2019) apresenta o uso de aplicações de redes neurais para determinação da estimativa do estado de carga de baterias de lítio utilizadas em

automóveis. Para tanto o autor utiliza os ciclos de carga e descarga da bateria para treinamento da rede neural nas diferentes demandas dos ciclos de carga e descarga.

BELOVA (2019) publicaram um trabalho onde se utiliza redes neurais artificiais para monitorar a degradação de baterias utilizadas em sistemas com células de energia solar, também é abordado o estudo da degradação das células no rendimento total do sistema.

KHUMPROM (2019) apresentou o uso de algoritmos de deep Learning aplicados a determinação da saúde e da vida útil de baterias com redes neurais artificiais, ainda é feita uma comparação do algoritmo de redes neurais com o outro algoritmo de machine learning chamado máquina de vetores de suporte (SVM) e rede neural artificial regular (RANN).

ENYONG HU (2011) estuda a relação entre o teste de capacidade de baterias utilizadas em aviação com lógica fuzzy, no trabalho o autor declara que após muitos experimentos foi encontrada uma correlação entre a resistência dinâmica da bateria e a sua capacidade de armazenamento de energia, para determinar a capacidade em amperes/hora dessas baterias aeronáuticas esses dados foram utilizados pelo algoritmo de lógica fuzzy.

WEI YOU (2009) analisa a previsão de taxa de envelhecimento de baterias níquel-hidrogênio (Ni/H) utilizando redes neurais artificiais e atingiu resultados satisfatórios na previsão da capacidade da bateria.

PAREDES (2019) publicou o texto “Development of a Fuzzy Logic-Based Solar Charge Controller for Charging Lead–Acid Batteries” relatando o desenvolvimento de um carregador de baterias para sistema de energia solar baseado em lógica fuzzy. De acordo com o texto foram notadas diversas vantagens ao se utilizar lógica fuzzy no controle de carga da bateria como por exemplo menor tempo de carga e prevenção da sobre tensão na bateria, o artigo ainda descreve detalhes da construção do protótipo que utiliza um microcontrolador AVR Atmega.

CAI (2017) declara que apesar de haver muitas pesquisas sobre previsão de vida útil de baterias, ainda não existe uma solução que possa oferecer com precisão a vida útil da bateria baseado em poucas amostras da mesma. O objetivo do autor é utilizar um método híbrido otimizado orientado a dados com algoritmos como máquina de vetores de relevância (RVM) e otimização com algoritmo artificial de

exame de peixes, para melhora da precisão da estimativa de vida útil das baterias de lítio.

O ponto crítico na previsão de vida útil das baterias é a exatidão da previsão, pois diversas pesquisas apontam que essa lacuna ainda não foi dominada de forma satisfatória, tornando-se um campo de pesquisa útil e desejado pela comunidade acadêmica, e conseqüentemente empresas do setor que podem utilizar a técnica de previsão para estender a vida útil das baterias utilizadas em aplicações comerciais.

O objetivo desse documento é relacionar e analisar as técnicas mais promissoras para a análise e previsão do tempo de vida útil de baterias, baseando-se em técnicas de inteligência artificial, e testes físicos da mesma que também avaliem as características das diversas aplicações pelas quais as mesmas podem ser utilizadas.

Longe de se abranger todas as técnicas de inteligência computacional o trabalho considera apenas as principais técnicas de acordo com as características das mesmas e sua aplicabilidade na previsão de dados.

A estrutura do trabalho inicialmente apresenta as principais técnicas de teste e análise de baterias que podem ser utilizadas para obter as condições de funcionamento da mesma, em seguida é apresentado as técnicas de inteligência artificial bem como suas principais características. No final será sugerido a combinação entre qual algoritmo e quais testes físicos se apresentam mais promissores para obter a melhor otimização na obtenção do tempo de vida útil da bateria.

2 METODOLOGIA

Do ponto de vista da natureza o trabalho se classifica como uma pesquisa aplicada. Com foco qualitativo pois é de caráter exploratório. Com o objetivo de descrever as características dos sistemas de inteligência artificial aplicáveis a análise de vida útil de baterias, o presente trabalho se classifica como descritivo. (SILVA E MENEZES, 2005).

Levando em consideração que parte da pesquisa é baseada na análise de livros, artigos e conhecimentos já obtidos e divulgados pela comunidade científica a mesma se classifica como bibliográfica.

Para análise dos dados as informações foram divididas em duas partes.

Na primeira parte é feito o levantamento e análise das variáveis elétricas e tipos de testes elétricos que são utilizados para a obtenção de dados de teste da bateria.

Na segunda parte é feito o levantamento das características dos principais algoritmos de inteligência artificial que podem ser utilizados para tratamento dos dados obtidos com as informações dos testes.

2.1 FATORES ANALISADOS

Os fatores analisados para alcançar os objetivos foram:

- Variáveis elétricas e físicas da bateria;
- Tipos de testes que podem ser executados na bateria;
- Características dos principais algoritmos de inteligência artificial.

2.2 PROCEDIMENTO PARA ANÁLISE

O procedimento de análise utilizado é relacionar as principais características elétricas e tipos de teste de bateria, conhecendo a análise feita por um dispositivo de teste comumente encontrado no mercado.

Em seguida relacionar as características dos algoritmos de inteligência artificial que podem tratar os dados obtidos nos testes da bateria, de forma a encontrar os algoritmos mais indicados.

3 REFERENCIAL TEÓRICO

Para uma correta análise de dados será exposto o referencial teórico que baseia as conclusões do trabalho.

3.1 TESTES E VARIÁVEIS ELÉTRICAS

O teste e a análise de baterias sempre partem da obtenção das variáveis elétricas, físicas e químicas da mesma (HUGGINS, 2008). Para efeito de comparação e análise da degradação serão consideradas as seguintes variáveis:

Tensão elétrica;

Corrente de manutenção de carga; Corrente de descarga;

Impedância e resistência da bateria; Condutância da bateria;

Corrente de partida a Frio; Número de ciclos carga/descarga; Efeito da velocidade de descarga Tempo de serviço;

Temperatura;

Uma vez que a grande maioria das baterias são seladas e não oferecem acesso a sua solução eletrolítica, impossibilitando a coleta de amostras, a análise química não será considerada no trabalho, uma vez que o objetivo é a análise das variáveis elétricas da bateria.

Visto que a vida útil da bateria está relacionada a seu regime de utilização será analisado todo o conjunto onde a mesma está incluída, sendo formada por:

Bateria + Carregador + Circuito alimentado pela bateria.

A figura 1 representa os blocos de função sugeridos para a correta obtenção da vida útil de baterias

Figura 1- Divisão dos blocos de função do equipamento proposto.

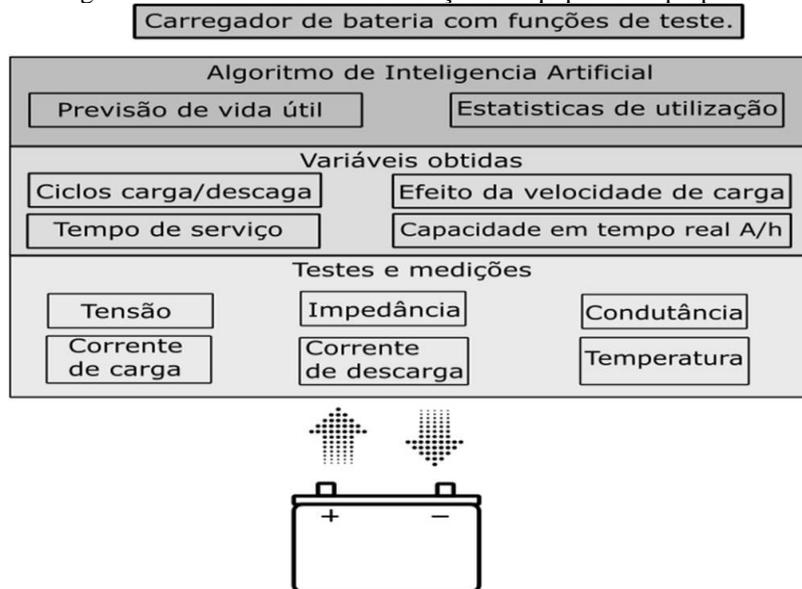
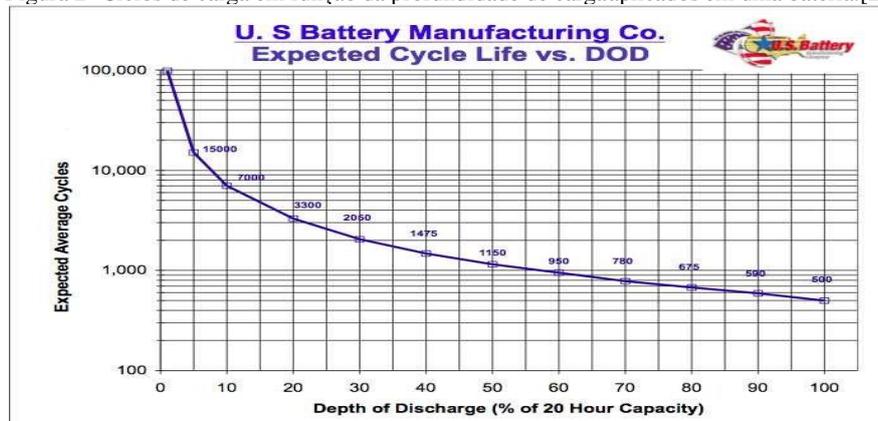


Figura 2- Ciclos de carga em função da profundidade de carga aplicados em uma bateria. [27]



A corrente de manutenção de carga é fornecida pelo carregador da bateria para que a mesma permaneça totalmente carregada até o momento em que o circuito alimentado pela bateria exija uma demanda de corrente elétrica (PAREDES 2020).

O número de ciclos carga/descarga pode variar drasticamente conforme a aplicação, como em um sistema de iluminação de emergência onde a demanda pode ocorrer apenas uma vez a cada mês, ou em sistemas de partida de motores de automóveis onde a bateria tem sua carga reduzida após cada partida do motor do automóvel, fato que pode ocorrer até dezenas de vezes por dia (VIDAL, 2020). Esse fato é importante na avaliação geral na vida útil da bateria.

Na figura 2, o gráfico demonstra a média de ciclos de carga e descarga que uma bateria pode atenderem sua vida útil, sendo a profundidade de descarga o principal fator que limita o número de ciclos.

Conforme o gráfico o número de ciclos de carga e descarga de uma bateria interfere na degradação de sua capacidade.

Entre as variáveis mais importantes para verificação do estado da bateria estão a impedância interna e a condutância, que são testes realizados de forma distinta na bateria. (I. BUCHMANN, 2020)

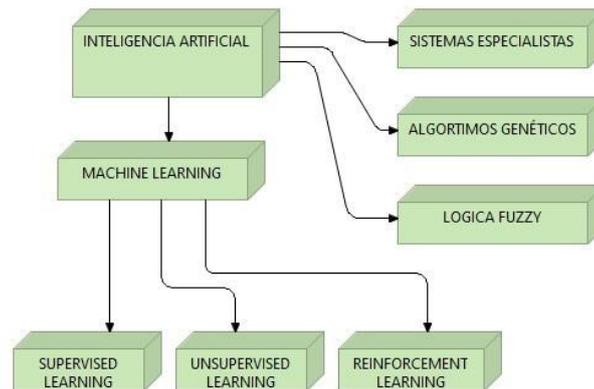
3.2 ALGORITMOS DE INTELIGÊNCIA ARTIFICIAL

Nessa parte serão avaliadas as características dos principais algoritmos de inteligência artificial que podem processar os dados apresentados na parte 1. Nos tempos atuais podem ser encontrados diversos

algoritmos de inteligência artificial, como cada um deles possui características específicas, serão tratados os que mais se adequam ao projeto proposto.

A figura 3 resume alguns dos grupos de algoritmos utilizados em inteligência artificial.

Figura 3- Classificações dos algoritmos de inteligência artificial abordados.



Uma das áreas de inteligência artificial que mais tem se desenvolvido nos últimos anos é a área de *machine learning* ou aprendizado de máquina, que na verdade é um método automatizado de construção de modelos analíticos que são capazes de reconhecer padrões e realizar previsões. Para realizar essas previsões os modelos passam por processos de aprendizagem onde recebem informaçõesúteis para criação de sua base de conhecimento que será utilizada durante as classificações e previsões desenvolvidas pelo algoritmo, funcionando de forma semelhante ao cérebro humano através da cognição (AKERKAR, RAJENDRA, 2018).

O ramo de machine learning pode ser classificado em três grandes áreas no que se refere ao tipo de supervisão que o sistema recebe durante o período de aprendizagem, sendo:

Supervised Learning

Unsupervised Learning

Reinforcement Learning.

No aprendizado supervisionado o Sistema de inteligência artificial faz o aprendizado com dados previamente classificados e rotulados, como por exemplo, um sistema de reconhecimento de imagensirá receber figuras que já estão rotuladas como carro, celular e chave, ou seja, o sistema irá ser informado sobre qual imagem ele está sendo exposto. Dessa forma o sistema irá prever os próximos dados com base em informações já apresentadas (JOSHI, 2018).

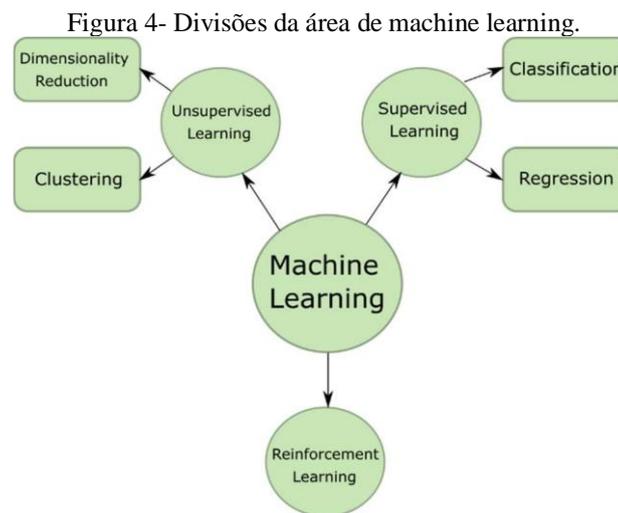
Já no aprendizado não supervisionado o sistema não possui dados classificados para utilizar naaprendizagem, e busca características dos dados de forma autônoma, ou seja, ele busca por informações em comum nos dados para efetuar a classificação dos mesmos. (AKERKAR, RAJENDRA, 2018).

Por exemplo, se um sistema não supervisionado fosse orientado para separar em 4 grupos os visitantes de um site que possuem características semelhantes, o sistema iria realizar automaticamente a separação baseando-se em características em comum dos dados como, horário de acesso, gênero, idade e local de origem e irá descobrir os principais grupos de perfis sem dados prévios de treinamento.

Outro exemplo é descobrir a associação entre produtos comprados em um supermercado, pois ao ir as compras um cliente raramente compra apenas um produto

A área de reinforcement learning ou aprendizado por reforço, possui uma abordagem um pouco diferente, onde o sistema aprende qual é a melhor decisão a ser tomada dependendo obviamente das circunstâncias encontradas. O processo se baseia no princípio da recompensa e da punição, onde toda ação tomada resulta em uma punição ou uma recompensa, esse processo ocorre milhares de vezes até que o sistema aprende a melhor ação a ser tomada nas mais diversas situações (LI, 2019).

Na figura 4 é possível observar as divisões dos algoritmos de machine learning.



3.2.1 Unsupervised Learning

3.2.1.1 Dimensionality Reduction

Os algoritmos de redução de dimensionalidade são utilizados no processo de redução do número de variáveis aleatórias em consideração, obtendo-se um conjunto de variáveis principais, em muitos casos, a maioria das variáveis é correlacionada e considerada redundante. Quanto maior o número de recursos, mais difícil é visualizar o conjunto de treinamento, dificultando os trabalhos no mesmo (JOSHI, 2018).

A redução de dimensionalidade é utilizada em visualização de big data, extração de recurso e reduz o tempo de computação e o espaço de armazenamento de dados.

3.2.1.2 Clustering

O clustering conhecido também por análise de agrupamento de dados, é o conjunto de técnicas de mineração de dados com o objetivo de agrupar dados automaticamente segundo algum padrão de associação. Essa técnica pode ser utilizada para customização de segmentos, sistemas de recomendação e para seleção de mercado alvo na área de marketing (CHOWDHARY, 2020).

3.2.2 Supervised Learning

3.2.2.1 Classification

Os algoritmos de classificação são utilizados para classificar um conjunto de dados conforme suas características e padrões previamente determinados, funciona com base no reconhecimento de padrões, como apresentado na figura 8. Um exemplo muito comum de classificação é a seleção de e-mail's, onde se pode classificar uma mensagem como spam ou como mensagem regular.

3.2.2.2 Regression

A regressão é um recurso de modelagem estatística e tem a função de estimar a relação entre duas ou mais variáveis utilizando como base dados de amostra. Um exemplo muito conhecido é o de regressão linear, onde o algoritmo traça uma reta próxima a concentração dos dados possibilitando obter informações dos intervalos de dados. (AKERKAR, RAJENDRA, 2018).

3.3 REINFORCEMENT LEARNING

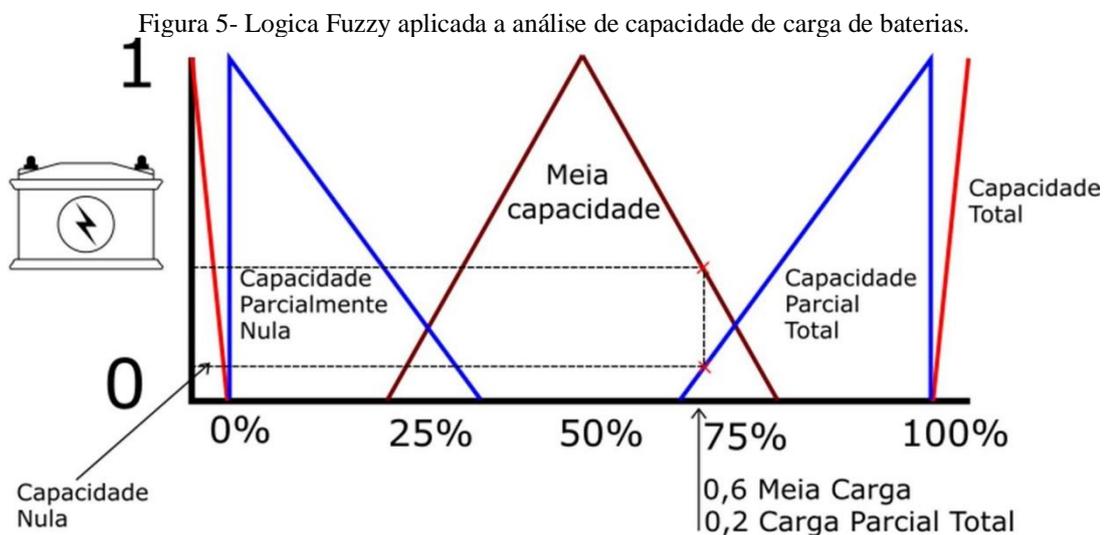
Aprendizado por reforço é um modelo de aprendizado de máquina onde o algoritmo realiza uma sequência de decisões. Pois o algoritmo utiliza um processo de tentativa e erro para encontrar uma solução para o problema e recebe recompensas ou penalidades pelas ações que executa, onde o objetivo é maximizar as recompensas. É utilizado em sistemas de decisão em tempo real, navegação de robôs, games, aquisição de habilidades e tarefas de aprendizado (JOSHI, 2018).

3.4 LOGICA FUZZY

A lógica *fuzzy* ou também conhecida como lógica difusa tem o objetivo de fazer com que as decisões tomadas pela máquina se aproximem das decisões tomadas por seres humanos no cotidiano. É uma lógica desenvolvida para lidar com conceitos de verdade parcial e capaz de capturar informações vagas representadas por linguagem natural e converter para o formato numérico. É baseada em graus de verdade ou pertinência como por exemplo a temperatura de um objeto que pode ser considerado frio, morno, quente ou muito quente, onde os graus podem variar entre 0 (falso) e 1 (verdadeiro) (PAREDES, 2020).

Portanto a Logica *fuzzy* pode ser utilizada para avaliar níveis de pertinência de uma mesma variável, não oferecendo definição exata. Sendo muito úteis pra lidar com dados incompletos e imprecisos, realizando aproximação de funções, classificação, controle e previsão de dados.

Como no exemplo da figura 5 a logica Fuzzy pode ser utilizada para determinar o estado da capacidade da bateria e A/h, descrevendo a porcentagem da capacidade que ainda resta na bateria.



No processo chamado de fuzzificação as variáveis linguísticas são definidas de forma subjetiva, e podem ser gerados diversos tipos de espaços como trapezoidal ou triangular utilizado no exemplo acima. Uma particularidade da Lógica *fuzzy* é que não possuem memória ou capacidade de aprendizado, os dados são expostos a lógica gerada inicialmente (PAREDES, 2020).

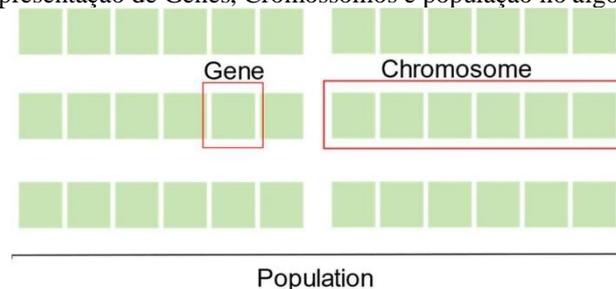
Para reduzir essa limitação é possível o desenvolvimento de sistemas híbridos onde a técnica de redes neurais pode ser combinada com a lógica *fuzzy*.

3.5 ALGORITMOS GENÉTICOS

O algoritmo genético é um eficiente método para resolver problemas de busca e otimização que se baseia na seleção natural, que busca imitar o processo da evolução das espécies. Como ocorre na mudança de geração da natureza, quanto maior a adaptação dos descendentes maior a chance dos mesmos serem escolhidos para produzir a próxima geração e assim aumentam as chances de sobrevivência (CAI, 2017).

Cada indivíduo é reconhecido como um cromossomo e por sua vez possui características consideradas como genes, um exemplo é apresentado na figura 6.

Figura 6- Representação de Genes, Cromossomos e população no algoritmo genético.



O algoritmo genético tem muitas aplicações no mundo real como filtragem e processamento de sinais, quebra de código, cinética química, robótica e processamento de imagem e até mesmo o famoso problema do vendedor ambulante.

3.6 REDES NEURAIAS ARTIFICIAIS

O conceito de redes neurais artificiais foi introduzido pela primeira vez em 1943 pelo neurofisiologista Warren McCulloch e pelo matemático Walter Pitts. Em um artigo denominado, “Um cálculo lógico de idéias imanentes à atividade nervosa”, McCulloch e Pitts apresentaram um modelo computacional simplificado de como os neurônios biológicos podem trabalhar juntos em cérebros de animais para realizar cálculos complexos (CHOWDHARY, 2020).

Desde então os algoritmos baseados em redes neurais tem sido largamente utilizados para desenvolvimento de sistemas de inteligência artificial.

3.6.1 Camadas de uma rede Neural

A camada de entrada é a primeira camada de uma rede neural artificial que recebe as informações de entrada nas formas mais variadas como textos, números, áudio e imagem. Após a camada de entrada, os dados são direcionados para uma ou várias camadas ocultas, onde são executados vários tipos de cálculos e reconhecimento de padrões desses dados. Na camada de saída obtêm-se os cálculos realizados nas camadas ocultas.

3.6.2 O Perceptron

O perceptron é um dos modelos mais básicos de redes neurais artificiais. É um classificador simples de uma camada, podendo receber n atributos em diversas camadas de entrada, porém possui apenas uma única camada de saída que produz apenas dados binário, ou seja 0 e 1 ou verdadeiro/Falso (VIDAL, 2020).

Cada atributo possui um peso na relevância do processamento do perceptron, ou seja, a variável X_1 pode ter uma consideração maior do que a segunda variável para a tomada de decisão do conjunto.

O perceptron pode ser essencialmente útil para tarefas de classificação, mais adiante será tratado outros algoritmos mais completos.

3.6.3 Rede Neural FeedForward

Nas redes neurais tipo feedforward, o fluxo de dados ocorre apenas em uma direção, sendo da camada de entrada para a camada oculta e na sequência para a camada de saída. Não há loops de feedback presentes nessa rede neural, por isso é usada em casos em que os dados não são sequenciais por natureza. Caso os dados analisados sejam sequenciais ou dependentes do tempo como o som e dados de séries temporais é mais adequado a utilização de redes neurais do tipo feedback que possuem recursos de retenção de memória (BELOVA, 2019).

Esse tipo de rede neural é usado principalmente no aprendizado supervisionado para classificação e reconhecimento de imagem.

3.6.4 Rede Neural Recorrente

Uma rede neural recorrente é um tipo de rede neural utilizada para a análise de dados sequenciais e temporais como por exemplo análise de linguagem natural, séries

temporais como a variação da bolsa de valores, a variação da temperatura ambiente ao longo de um dia e na tradução automática de áudio e legendas de vídeos. É largamente utilizada para a previsão de dados baseada no histórico de variação dos mesmos, pois é capaz de armazenar informações ao longo do tempo.

3.6.5 Redes neurais LSTM (Long Short Term Memory)

As redes neurais recorrentes possuem uma limitação chamada de vanishing gradiente que dificulta o reconhecimento de alguns tipos de padrões e o treinamento da rede em alguns casos. Para solucionar essa limitação foram desenvolvidas as redes LSTM que é uma arquitetura de rede neural recorrente (RNN) capaz de lembrar valores em intervalos temporais arbitrários, por isso é capaz de processar e prever séries temporais com intervalos de tempo de duração desconhecida extraindo informações do contexto dos dados, algo que a rede neural recorrente básica não é capaz de executar. (KHUMPROM e YODO, 2019).

Sua aplicação ocorre em reconhecimento de fala, tradução automática, análise de sentimentos e séries temporais encontradas na engenharia, economia, saúde e outros.

3.6.6 Autoencoders

Autoencoders são um tipo de redes neurais artificiais, onde a entrada é igual à saída. Eles compactam a entrada em um código de menor dimensão e em seguida reconstruem a saída dessa representação. O código é um resumo ou compactação da entrada, ou seja, os autoencodificadores são um algoritmo de redução de dimensionalidade e compactação de dados do mesmo tipo, como imagens de números manuscritos ou fotografias. É um processo não supervisionado, ou seja, basta inserir os dados na

camada de entrada da rede e a mesma se encarrega de criar os rótulos dos dados fornecidos. Vale lembrar que os dados compactados na saída não são exatamente como os mesmos fornecidos inicialmente, existe uma degradação no processo de codificação (VEERARAGHAVAN, 2017).

As principais aplicações práticas dos Autoencoders é a remoção de ruídos em dados e a redução de dimensionalidade para visualização de dados.

3.6.7 Redes neurais convolucionais

Redes Neurais Convolucionais são um tipo de algoritmo de aprendizagem profunda que realiza o aprendizado com informações extraídas de imagens através de filtros, isso lhe permite aprender os objetos presentes em uma imagem e discernir uma imagem entre outras diferentes (KHUMPROM, 2019).

Durante o treinamento inicial, os filtros podem exigir ajustes manuais mas com o progresso do treinamento, a rede é capaz de se adaptar aos recursos aprendidos e desenvolver filtros próprios.

Sua principal aplicação é no reconhecimento de imagens para classificação, segmentação e localização de objetos em imagens. Embora também possam ser utilizadas para análise de imagem de gráficos como espectrograma de áudio, análise de dados gráficos e até mesmo associado a outras redes como LSTM para reconhecimento de fala (KHUMPROM, 2019).

4 RESULTADO E DISCUSSÃO

Após a aquisição de dados elétricos básicos do acumulador, é possível estimar outros parâmetros úteis como a capacidade real de carga como apresentado na figura 14. Quando esses dados são aplicados a algoritmos de inteligência artificial e a seu devido período de aprendizagem, criam um modelo computacional que é utilizado para realizar previsões temporais das reais capacidades da bateria, como também levanta o perfil da carga alimentada pela bateria, visto que a vida útil da mesma está diretamente ligada a suas condições de utilização.

Conforme as informações apresentadas no referencial teórico é concluído que mediante a necessidade de aquisição e processamento dos dados de forma contínua no tempo, os melhores algoritmos de inteligência artificial que podem ser aplicados para determinação da vida útil de baterias são aqueles com capacidade de processamento de dados temporais, acompanhados dos algoritmos de classificação os algoritmos de dados temporais podem fornecer recursos para a previsão da vida útil das baterias bem como classificá-las em aptas ou não para continuarem em operação. Para isso os algoritmos de classificação e regressão são os mais indicados.

Para uma maior precisão desses algoritmos são utilizados com os métodos listados na tabela 1.

Tabela 1- Tipos de algoritmos de inteligência artificial indicados para a previsão da vida útil de baterias.

Algoritmo	Função	Aplicação
Logica Fuzzy	Determinação	Avaliar se a bateria ainda possui condições de utilização.
Rede Neural Recorrente	Análise temporal	Avaliar os dados através do aprendizado contínuo dos dados para a previsão de valores

Quando se utiliza as informações de teste e medição da bateria em conjunto com os algoritmos apropriados é possível atingir excelentes resultados na previsão de envelhecimento de baterias (I.BUCHMANN, 2020).

Como citado, a figura 1 representa um diagrama com as principais variáveis básicas de teste e medição que são analisadas, bem como outras variáveis que são obtidas a partir das variáveis básicas.

5 CONCLUSÃO

O objetivo do trabalho é demonstrar as técnicas de inteligência artificial mais adequadas para juntamente com informações de teste e medição, realizar a previsão da vida útil de baterias. Dessa forma, foram apresentadas as principais técnicas de análise de condições funcionais de uma bateria, onde as medições se corretamente avaliadas revelam as condições de desgaste da bateria. Diversas técnicas de inteligência artificial podem ser utilizadas, evidentemente cada uma possui características próprias que podem ou não serem mais adequadas para previsão de dados temporais, devido a esse fato, são estudadas diversas técnicas de inteligência artificial que possibilitam a análise e previsão de dados gerados por series temporais. Os algoritmos de logica *fuzzy*, regressão e redes neurais recorrentes se mostraram os mais adequados para a presente aplicação. Mediante as informações apresentadas algumas lacunas podem ser preenchidas futuramente, como uma combinação de vários algoritmos de inteligência artificial para oferecer a melhor exatidão de previsão, ou a descoberta do número de medições necessárias para realizar o treinamento do sistema e iniciar as previsões de vida útil da bateria.

REFERÊNCIAS

Akerkar, Rajendra. Artificial intelligence for business. 1st. edition ed. New York, NY: Springer Science+Business Media, 2018.

I. Buchmann. Artificial intelligence reads battery state-of-health in three minutes - IEEE Conference Publication. Disponível em: <<https://ieeexplore.ieee.org/document/905135>>. Acesso em: 29 abr. 2020.

Beard, K. W. Linden's Handbook of Batteries, Fifth Edition. 5 edition ed. New York, NY: McGraw-Hill Education, 2019.

Blanke, H. Impedance measurements on lead acid batteries for state-of-charge, state-of-health and cranking capability prognosis in electric and hybrid electric vehicles. Journal of Power Sources, v.144, ed. 2, 2005.

Belova, I. A. et al. Optimization of Artificial Neural Network Learning for Maximum Power Point Tracking After the Degradation of the Solar Battery. 2019 20th International Conference of Young Specialists on Micro/Nanotechnologies and Electron Devices (EDM). Anais... In: 2019 20TH INTERNATIONAL CONFERENCE OF YOUNG SPECIALISTS ON MICRO/NANOTECHNOLOGIES AND ELECTRON DEVICES (EDM). jun. 2019

Chowdhary, K. R. FUNDAMENTALS OF ARTIFICIAL INTELLIGENCE. Place of publication not identified: SPRINGER, INDIA, PRIVATE, 2020.

Cai, Y. et al. Prediction of lithium-ion battery remaining useful life based on hybrid data-driven method with optimized parameter. 2017 2nd International Conference on Power and Renewable Energy (ICPRE). Anais... In: 2017 2ND INTERNATIONAL CONFERENCE ON POWER AND RENEWABLE ENERGY (ICPRE). set. 2017

De Marchi, L.; Mitchell, L. Hands-on neural networks: learn how to build and train your first neural network model using Python. Birmingham, Inglaterra. Packt Publishing, 2019.

Dudney, N. J.; West, W. C.; Nanda, J. (EDS.). Handbook of Solid State Batteries: 2nd Edition. 2nd Revised ed. edition ed. New Jersey London Singapore Beijing Shanghai Hong Kong Taipei Chennai Tokyo: WSPC, 2015.

Enyong HU et al. Study on the aerial storage battery capacity testing method with the fuzzy neural network data fusion technique. 2011 2nd International Conference on Artificial Intelligence, Management Science and Electronic Commerce (AIMSEC). Anais... In: 2011 2ND INTERNATIONAL CONFERENCE ON ARTIFICIAL INTELLIGENCE,

MANAGEMENT SCIENCE AND ELECTRONIC COMMERCE (AIMSEC). ago. 2011

Géron, A. Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: concepts, tools, and techniques to build intelligent systems. Sebastopol: Canada: O'Reilly Media, 2019.

How, D. N. T. et al. State-of-Charge Estimation of Li-ion Battery in Electric Vehicles: A Deep Neural Network Approach. 2019 IEEE Industry Applications Society Annual Meeting. Anais... In: 2019 IEEE INDUSTRY APPLICATIONS SOCIETY ANNUAL MEETING. set. 2019.

Huggins, R. Advanced Batteries: Materials Science Aspects. 2009 edition ed. New York ; London: Springer, 2008.

Joshi, N.; SAFARI, AN O. M. C. Hands-On Artificial Intelligence with Java for Beginners. Birmingham, Inglaterra. PacktPublishing, 2018.

Khumprom, P.; Yodo, N. Data-driven Prognostic Model of Li-ion Battery with Deep Learning Algorithm. 2019 Annual Reliability and Maintainability Symposium (RAMS). Anais... In: 2019 ANNUAL RELIABILITY AND MAINTAINABILITY SYMPOSIUM (RAMS). jan. 2019.

Korthauer, R. (ED.). Lithium-Ion Batteries: Basics and Applications. 1st ed. 2018 edition ed. New York, NY: Springer, 2018.

LI, S. et al. Machine learning algorithm based battery modeling and management method: A Cyber-Physical System perspective. 2019 3rd Conference on Vehicle Control and Intelligence (CVCI). Anais... In: 2019 3RD CONFERENCE ON VEHICLE CONTROL AND INTELLIGENCE (CVCI). set. 2019.

Machine Learning Applied to Electrified Vehicle Battery State of Charge and State of Health Estimation: State-of-the-Art - IEEE Journals & Magazine. Disponível em: <<https://ieeexplore.ieee.org/document/9036949>>. Acesso em: 29 abr. 2020.

Nazri, G.-A.; Pistoia, G. (EDS.). Lithium Batteries: Science and Technology. 2003 edition ed. New York, NY: Springer, 2009.

Plett, G. L. Battery Management Systems: 1. Edição: Unabridged edition ed. Boston : London: Artech House Publishers, 2015.

Rahn, C. D.; Wang, C.-Y.; Rahn. Battery Systems Engineering. Edição: 1 ed. Chichester, West Sussex, United Kingdom: Wiley, 2013.

Root, M. The TAB Battery Book: An In-Depth Guide to Construction, Design, and Use. 1 edition ed. New York: McGraw-Hill Education TAB, 2010.

Silva, E. L.; MENEZES, E. M. Metodologia da pesquisa e elaboração de dissertação. 4. ed. Florianópolis, 2005.

Veeraraghavan, A. et al. Battery aging estimation with deep learning. 2017 IEEE Transportation Electrification Conference (ITEC-India). Anais... In: 2017 IEEE TRANSPORTATION ELECTRIFICATION CONFERENCE (ITEC-INDIA). dez. 2017.

You, W. et al. Predicting the Aging Rate of Capacity in Ni/H Battery Using Artificial Neural Network. 2009 Second International Symposium on Computational Intelligence and Design. Anais... In: 2009 SECOND INTERNATIONAL SYMPOSIUM ON COMPUTATIONAL INTELLIGENCE AND DESIGN. dez. 2009

Paredes Larroca, F. et al. Development of a Fuzzy Logic-Based Solar Charge Controller for Charging Lead–Acid Batteries. In: NUMMENMAA, J. et al. (Eds.). . Advances and Applications in Computer Science, Electronics and Industrial Engineering. Advances in Intelligent Systems and Computing. Cham: Springer International Publishing, 2020. v. 1078p. 168–183.

Plana-TC Manual do analisador Digital de Bateria c/ Impressora TBI-5000/I Disponível em:

<http://www.planatc.com.br/config/templates/pt_BR/manuais/MN11849.pdf>.

Acesso em: 21 maio. 2020.

How does Depth of Discharge factor into Grid Connected battery systems? | CED Greentech. Disponível em:

<<https://www.cedgreentech.com/article/how-does-depth-discharge-factor-grid-connected-battery-systems>>. Acesso em: 25