

Sistema FIEB



PELO FUTURO DA INOVAÇÃO

CENTRO UNIVERSITÁRIO SENAI CIMATEC

PROGRAMA DE PÓS-GRADUAÇÃO STRICTO SENSU EM MODELAGEM

COMPUTACIONAL E TECNOLOGIA INDUSTRIAL

Mestrado em Modelagem Computacional e Tecnologia Industrial

Dissertação de mestrado

Modelagem de baterias de chumbo-ácido utilizando séries temporais DFA, DCCA e ρ DCCA no contexto automotivo

Apresentada por: Roberto Coelho da Costa

Orientador: Prof. Dr. Marcelo Albano Moret Simões Gonçalves

Co-orientador: Prof. Dr. Thiago Barros Murari

Junho de 2021

Roberto Coelho da Costa

Modelagem de baterias de chumbo-ácido utilizando séries temporais DFA, DCCA e ρ DCCA no contexto automotivo

Dissertação de mestrado apresentado ao Programa de Pós-graduação Stricto Sensu em Modelagem Computacional e Tecnologia Industrial, Curso de Mestrado em Modelagem Computacional e Tecnologia Industrial do CENTRO UNIVERSITÁRIO SENAI CIMATEC, como requisito parcial para a obtenção do título de **Mestre em Modelagem Computacional e Tecnologia Industrial**.

Área de conhecimento: Interdisciplinar

Orientador: Prof. Dr. Marcelo Albano Moret Simões Gonçalves
CENTRO UNIVERSITÁRIO SENAI CIMATEC

Salvador
CENTRO UNIVERSITÁRIO SENAI CIMATEC
2021

Ficha catalográfica elaborada pela Biblioteca do Centro Universitário SENAI CIMATEC

C837m Costa, Roberto Coelho da

Modelagem de baterias de chumbo-ácido utilizando séries temporais DFA, DCCA e ρ DCCA no contexto automotivo / Roberto Coelho da Costa. – Salvador, 2021.

51 f. : il. color.

Orientador: Prof. Dr. Marcelo Albano Moret Simões Gonçalves.

Orientador: Prof. Dr. Thiago Barros Murari.

Dissertação (Mestrado em Modelagem Computacional e Tecnologia Industrial) – Programa de Pós-Graduação, Centro Universitário SENAI CIMATEC, Salvador, 2021.

Inclui referências.

1. Bateria Chumbo-Ácido. 2. Estado de saúde - Bateria. 3. Automotivo. 4. Detrended Fluctuation Analysis – DFA. 5. Detrended Cross Correlation Analysis - DCCA. I. Centro Universitário SENAI CIMATEC. II. Gonçalves, Marcelo Albano Moret Simões. III. Murari, Thiago Barros. IV. Título.

CDD 629.1

Nota sobre o estilo do PPGMCTI

Esta dissertação de mestrado foi elaborada considerando as normas de estilo (i.e. estéticas e estruturais) propostas aprovadas pelo colegiado do Programa de Pós-graduação Stricto Sensu em Modelagem Computacional e Tecnologia Industrial e estão disponíveis em formato eletrônico (*download* na Página Web http://ead.fieb.org.br/portal_faculdades/dissertacoes-e-teses-mcti.html ou solicitação via e-mail à secretaria do programa) e em formato impresso somente para consulta.

Ressalta-se que o formato proposto considera diversos itens das normas da Associação Brasileira de Normas Técnicas (ABNT), entretanto opta-se, em alguns aspectos, seguir um estilo próprio elaborado e amadurecido pelos professores do programa de pós-graduação supracitado.

CENTRO UNIVERSITÁRIO SENAI CIMATEC**Mestrado Acadêmico em Modelagem Computacional e Tecnologia Industrial**

A Banca Examinadora, constituída pelos professores abaixo listados, aprova a Defesa de Mestrado, intitulada “**Modelagem de baterias de chumbo-ácido utilizando series temporais DFA, DCCA e ρ DCCA no contexto automotivo**” apresentada no dia 30 de junho de 2021, como parte dos requisitos necessários para a obtenção do Título de Mestre em Modelagem Computacional e Tecnologia Industrial.

Orientador:

DocuSigned by:

ADA429E9E2B549F...

Prof. Dr. Marcelo Albano Moret Simões Gonçalves
SENAI CIMATEC

Coorientador:

DocuSigned by:

744BEED0A978446...

Prof. Dr. Thiago Barros Murari
FORD

Membro Interno:

DocuSigned by:

A546CA0E60DB4DA...

Prof. Dr. Alex Alisson Bandeira Santos
SENAI CIMATEC

Membro Externo:

DocuSigned by:

1F49FDC3D884423...

Prof. Dr. Geraldo Roberto Carvalho Cernicchiaro
CBPF

Membro Externo:

DocuSigned by:

D09A4D19CA374FD...

Prof. Dr. Luiz Pereira Calôba
UFRJ

Dedico este trabalho à minha família, minha esposa e meus filhos que com cuidado e carinho conseguiram me ajudar durante toda essa jornada.

Agradecimentos

Dedico meus mais sinceros agradecimentos para:

- o professor, orientador Marcelo A. Moret, “o Chefe”, que com grande conhecimento e orientação pôde ser um dos fatores mais importantes para a conclusão desse trabalho ao assumir minha orientação com muita paciência, sabedoria, disponibilidade e boa vontade em nossos encontros semanais, proporcionando reuniões produtivas de orientação, tanto na dissertação quanto nos artigos publicados;

- o professor doutor Thiago B. Murari, um grande amigo e um importante reforço na produção de artigos e na reta final desta pesquisa;

- a Ford Motor Company Brasil, em particular ao Carlos Hess, por permitir e suportar durante a execução dessa pesquisa;

- os colegas do PPG-MCTI, que se transformaram ao longo da minha jornada em grandes companheiros;

- todos os professores do PPG-MCTI, juntamente com toda equipe de secretaria.

Salvador, Brasil
30 de Junho de 2021

Roberto Coelho da Costa

Resumo

Essa dissertação apresenta uma modelagem de baterias de chumbo-ácido utilizando séries temporais DFA (análise de flutuações destendenciadas, do inglês *Detrended Fluctuation Analysis*), DCCA (análise de correlações cruzadas destendenciadas, do inglês *Detrended Cross Correlation Analysis*) e o coeficiente do DCCA, chamado de $\rho DCCA$, dentro de um uso automotivo, com o objetivo de detectar baterias com um estado de saúde deteriorado, antes da total incapacidade da bateria em dar partida no veículo. Com o aumento do uso de módulos eletrônicos e sensores dentro dos veículos, novas demandas foram adicionadas nesse uso da bateria, ao mesmo tempo que novas informações obtidas com mais sensores dentro dos carros tornam-se disponíveis como matéria prima de informação, permitindo estudar e evoluir o conhecimento ao redor do ciclo de vida da bateria, mais especificamente no momento de um maior desgaste da saúde da bateria. As falhas de baterias geram insatisfação dos clientes com a marca, muitas vezes gerando gastos extras por uma falta de diagnose correta no uso da bateria. Esse trabalho foca em aprimorar a investigação preditiva e possível proposta de um indicativo ao cliente de como está a saúde química da bateria de chumbo-ácido. Entender o comportamento da bateria do carro, em um ambiente com comunicação via nuvem com a empresa, pode permitir uma maior interação na manutenção preditiva dos consumidores, redução de tempo parado de veículo e maior satisfação do consumidor. A base do estudo apresenta a análise de séries temporais da tensão de bateria durante o momento de partida do veículo ao longo do tempo de uso, utilizando as técnicas de DFA, DCCA e $\rho DCCA$, apresentando as análises, discussões e resultados. Dentre os principais resultados, esse trabalho apresenta proposta o uso do $\rho DCCA$ como o parâmetro principal de detecção do fim de vida de bateria, ao comparar veículos com a mesma motorização, confirmando uma robustez do modelo ao comparar também baterias do mercado de reposição, trazendo uma nova aplicação para a engenharia automotiva de técnicas de sistemas complexos aplicados ao controle do estado de saúde da bateria.

Palavras-chave: Bateria Chumbo-Ácido, Estado de saúde, Automotivo, $\rho DCCA$, DFA.

Abstract

This thesis presents a lead-acid battery modelling, using temporal series studies of detrended fluctuation analysis (DFA), detrended cross correlation analysis (DCCA) and DCCA coefficient ($\rho DCCA$), in an automotive context, with main objective to detect battery state of health degradation, before a full incapacity to crank a vehicle. The number of electronic modules (ECUS) increased inside vehicles, new power demands were included inside battery offenders, while in parallel several other sensors were included in the car allowing more data availability to support new studies inside battery behavior. This is a baseline to allow investigate battery live cycle with a different approach. The dead battery issue causes a lot of customer dissatisfaction with brand, several times generating extra money spend due to lack of proper diagnosis of battery usage. This study is focused in improve the predictive diagnostics and a potential new warning to be available to drivers, showing how good is the battery state-of-health. Understanding the battery behavior inside an ambient of cloud communication, allowing a higher interaction between brand and customer for predictive diagnostic, reducing vehicle downtime and increasing customer satisfaction. The study is based on temporal series verification using the detrended fluctuation analysis (DFA), Detrended Cross Correlation Analysis (DCCA) and DCCA coefficient ($\rho DCCA$), presenting analysis, discussions and results. Inside key results, this study presents the $\rho DCCA$ being used as a key parameter to be modelling the battery end of life detection, showing a positive cross correlation when it's compared vehicles with same engine type and size. The model also withstands a comparison including aftermarket battery.

Keywords: Lead-Acid Battery, State-of-Health, Automotive, $\rho DCCA$, DFA.

Sumário

1	Introdução	1
1.1	Definição do problema	2
1.2	Objetivo Geral	2
1.2.1	Objetivos Específicos	2
1.3	Importância da pesquisa	3
1.4	Motivação	4
1.5	Limites e limitações	4
1.6	Aspectos metodológicos	4
1.7	Organização do Dissertação de mestrado	6
2	Revisão da literatura	7
2.1	Sistemas Elétricos Veiculares	7
2.1.1	Baterias de Chumbo-Ácido Automotivo	7
2.1.2	Sistemas de Partida e Recarda da Bateria	8
2.1.3	Revisão Sistemática em Saúde de Baterias	11
2.2	Modelos para Análise de Memória de longo alcance em séries não estacionárias	16
2.2.1	Estatística de Hurst, DFA, DCCA	16
2.2.2	Coefficiente de Correlação Cruzada ρ DCCA	20
3	Proposição do Modelo Computacional	22
3.1	Desenvolvimento cognitivo em torno do tema	22
3.2	Modelo proposto	25
4	Resultados e Discussões	27
4.1	Análise experimental e cenários	27
4.2	Resultados	34
4.3	Limitações	35
4.4	Discussão	36
5	Considerações finais	39
5.1	Conclusões	40
5.2	Contribuições	41
5.3	Atividades Futuras de Pesquisa	41
A	Script para cálculo do DFA,DCCA e ρDCCA no R	42
	Referências	45

Lista de Tabelas

3.1	Estatísticas de redes comparativas. Fonte: (COSTA et al., 2020)	24
3.2	Comparação dos principais vértices entre as redes. Fonte: (COSTA et al., 2020)	24
4.1	Planilha de coleta de dados dos veículos. Fonte: Próprio Autor	29

Lista de Figuras

2.1	Exemplo bateria visão explodida. Fonte: próprio autor	8
2.2	Modelo de circuito representando bateria de chumbo-ácido. Fonte: baseado em (I-KUN; INAMORI; MORIMOTO, 2014)	9
2.3	Diagrama de blocos ao redor da bateria. Fonte: próprio autor	10
2.4	Medição de tensão de um ciclo de partida até a entrada do alternador, aumentando tensão, forçando uma recarga da bateria. Fonte: próprio autor	10
2.5	Localização do BMS no veículo. Fonte: próprio autor	11
2.6	Resposta em tensão de desgastes de bateria. Fonte: (KERLEY; HYUN; HA, 2015).	13
2.7	Circuito equivalente de Thevenin para carga e descarga. Fonte: (CHAMUSCA et al., 2020)	15
2.8	Gráfico regressão e distribuição de resistência dos veículos medidos. Fonte: (CHAMUSCA et al., 2020)	16
2.9	Divisão das séries $y(t)$ e $y'(t)$ em intervalos com superposição. Fonte: Adaptado de (ZEBENDE, 2011) (NASCIMENTO FILHO, 2018).	20
3.1	Rede gerada no entorno da bateria. Fonte: (COSTA et al., 2020)	23
3.2	Fluxograma de atividades. Fonte: Próprio Autor	25
4.1	Sumário das medições filtradas de partida. Fonte: Próprio Autor	27
4.2	Comparação da medição de tensão entre veículo descarregado e carregado. Fonte: Próprio Autor	28
4.3	Sumário dos DFA. Fonte: Próprio Autor.	30
4.4	Sumário dos DCCA (1). Fonte: Próprio Autor.	31
4.5	Sumário dos DCCA (2). Fonte: Próprio Autor.	32
4.6	Sumário dos DCCA (3). Fonte: Próprio Autor.	33
4.7	Junção dos $\rho DCCA$. Fonte: Próprio Autor	34
4.8	Análise do $\rho DCCA$ separando por motores e estado de bateria. Fonte: Próprio Autor.	35
4.9	Análise do $\rho DCCA$ separando por motores diferentes e estado de bateria. Fonte: Próprio Autor.	36

Lista de Siglas

ρ DCCA	Coeficiente do DCCA , p.5
BCM	<i>Body Control Module</i> , p.11
BMS	<i>Battery Monitor Sensor</i> , p.4
DCCA	<i>Detrented Cross Correlation Analysis</i> , p.5
DCR	<i>Direct Current Resistance</i> , p.12
DFA	<i>Detrented Fluctuation Analysis</i> , p.5
ECU	<i>Electronic Control Units</i> , p.9
EFB	<i>Enhanced Flooded Battery</i> , p.7
EIS	<i>electrochemical impedance spectroscopy</i> , p.12
FIFO	<i>First In First Out</i> , p.8
LIN	<i>Local Interconnect Network</i> , p.10
MIS	<i>Month In Service</i> , p.28
OCV	<i>Open Circuit Voltage</i> , p.11
PCM	<i>Powertrain Control Module</i> , p.10
PWM	<i>Pulse Width Modulation</i> , p.10
R	Linguagem de programação R , p.5
SLI	<i>Starting-Lighting-Ignition</i> , p.4
SOC	<i>State of Charge</i> , p.8
SOH	<i>State Of Health</i> , p.1
TIS	<i>Time In Service</i> , p.28
TRL	<i>technology readiness level</i> , p.41

Introdução

O uso de veículos automotores está presente no dia a dia das pessoas, permitindo deslocamento para trabalho ou lazer, seja de forma planejada ou emergencial. Dentro desses ciclos de uso, um dos pontos fundamentais para o início dessa jornada é conseguir dar partida no carro, ou seja, remover o motor a combustão da condição de inércia que ele se encontra.

Ao analisar um funcionamento simplificado do sistema, precisa-se de um motor elétrico, chamado comumente de motor de partida ou motor de arranque, encaixado na cremalheira do veículo, permitindo que, no momento de ativação desse motor elétrico por uma bateria, faça com que o motor a combustão comece a rotacionar. Baseando-se no movimento de rotação do motor, o módulo de controle do motor coordena a injeção de combustível e controla as faíscas nos cilindros do motor, para que a energia gerada pelas combustões internas mantenha o motor em rotação. Nesse momento, o motor elétrico de partida pode ser desativado (CHUMCHAL; KURZWEIL, 2017). No momento seguinte, entra em cena o alternador, ligado diretamente a correia auxiliar do veículo, convertendo rotação do eixo do motor em tensão e corrente elétrica, permitindo que o sistema fique estável e a bateria, que sofreu uma demanda extra durante a partida, possa ser também recarregada (GELBKE; MONDOLONI, 2017).

Nessa perspectiva de funcionamento de motores a combustão, a bateria automotiva entra como um dos problemas enfrentados pelos motoristas ao longo do uso, quando ela deixa de funcionar, não permitindo que o motor a combustão saia de sua condição de inércia pelo motor de partida. A bateria vai apresentando desgastes ao longo do uso, até um momento que deixa de servir para sua função principal (CULPIN; RAND, 1991).

Existe um outro uso secundário da bateria, necessária para manter os módulos eletrônicos dos veículos em funcionamento mesmo sem a presença do alternador. Nessas condições, a bateria precisa prover energia para o funcionamento dos módulos eletrônicos, sem a presença do alternador. Muitas vezes esse se torna um ponto crítico de controle e projeto das fabricantes de veículo para o melhor ajuste do design (GELBKE; MONDOLONI, 2017) (CHUMCHAL; KURZWEIL, 2017).

Nesse contexto, ter o conhecimento do estado de saúde (SOH - *State of Health*) da bateria é de extrema importância para otimizar o uso do veículo, permitindo balancear o uso da bateria entre a capacidade de dar a partida e manter os módulos eletrônicos funcionando com motor a combustão desligado, inclusive em uma condição de desgaste natural presente nas baterias ao longo do tempo/uso.

1.1 Definição do problema

Analisando o uso de baterias em aplicações automotivas, um dos pontos que mais incomodam os motoristas está relacionado com a perda de capacidade de dar partida nos veículos. Essa perda da capacidade de dar partida em si é natural e esperada para baterias que estejam com a saúde da bateria (SOH) deteriorada.

Nesse caso, ao detalhar a definição de problema, pode-se apresentar como sendo presente em veículos equipados com motores de combustão interna, ao apresentar uma situação de desgaste da saúde da bateria de chumbo-ácido, no qual nenhuma informação prévia do desgaste foi disponibilizada para o motorista, permitindo que a troca fosse feita, antes que a mesma esteja completamente incapacitada de executar a função primária da bateria de dar partida no motor de combustão.

Com todo esse contexto, o problema declarado passa a ser em como fazer a detecção desse desgaste da saúde da bateria de chumbo-ácido utilizada em veículos automotivos de combustão interna, antes da completa deterioração da saúde da bateria.

1.2 Objetivo Geral

O presente trabalho tem como objetivo desenvolver um modelo computacional para avaliar o desgaste de baterias automotivas ao longo do uso do veículo.

1.2.1 Objetivos Específicos

Os objetivos específicos estão relacionados com os tópicos abaixo:

- Mapear os parâmetros de impacto no gerenciamento de bateria;
- Identificar parâmetros com maior impacto estatístico em ambientes já estudados;
- Desenvolver proposta de modelo computacional para predição de fim de vida útil de baterias de chumbo-ácido automotivo;

1.3 Importância da pesquisa

Dentro da história de utilização de veículos a combustão, a bateria sempre esteve presente para auxiliar a partida dos motores (GELBKE; MONDOLONI, 2017). Da mesma forma, sempre houve reclamações que a bateria deixou de funcionar sem uma informação prévia para o motorista. Esse desgaste da bateria é natural e esperado, mas a falta de informação ao motorista torna esse evento bem desgastante para os envolvidos (MÜRKEN et al., 2018).

O programa de governo conhecido como ROTA2030 apresenta incentivo para a indústria automotiva Brasileira, tendo como um dos pilares a melhoria da eficiência energética, com metas de redução do consumo médio de combustível nos veículos (INDUSTRIAL, 2018). Para melhorar os níveis de consumo de combustível, diversas das tecnologias trazem um impacto para as baterias dos veículos. Por exemplo, a tecnologia *Start-Stop*, no qual o veículo recebe uma programação para auto desligar o motor em momentos que o veículo pare, auto ligando quando o motorista apresenta intenção de voltar a aumentar a velocidade, gera um aumento significativo na quantidade de partidas que o veículo executa, gerando uma necessidade de uma bateria especial (CHUMCHAL; KURZWEIL, 2017). Um outro ponto importante que, para melhorar o consumo dos veículos, diversas montadoras começam a trazer mais opções de veículos híbridos e elétricos, o que termina por também trazer interfaces diferentes com as baterias de chumbo-ácido, chegando a um limite de veículos puramente elétricos utilizarem normalmente bateria de íons de lítio, ao invés de chumbo-ácido para melhorar a relação entre capacidade e peso da bateria, tendo sempre uma contrapartida que essa bateria de íons de lítio são de um preço muito acima da bateria de chumbo-ácido (GELBKE; MONDOLONI, 2017).

O trabalho de Shaheen, Totte e Stocker (2018) apresentou uma perspectiva sobre o futuro da mobilidade, prevendo uma direção de desenvolvimento para veículos autônomos, compartilhados e com emissões zero. Com relação as previsões de emissões zero, também foi indicado uma taxa de crescimento nesse tipo de motorização desde 2013.

Com o aumento do uso de módulos eletrônicos e sensores dentro dos veículos, novas funcionalidades e expectativas de interação foram criadas, ao mesmo tempo que novas informações tornam-se disponíveis, como matéria prima, na forma de dados. Esse ambiente de novas informações permite estudar e evoluir o entendimento sobre a saúde da bateria de um método diferente (CHUMCHAL; KURZWEIL, 2017).

As falhas de baterias geram insatisfação dos clientes com a marca, muitas vezes gerando gastos extras por uma falta de diagnóstico correta no uso da bateria. Esse trabalho foca em aprimorar essa investigação preditiva do estado de saúde da bateria de chumbo-ácido, permitindo criar uma nova linha de desenvolvimento para alertar essa informação ao cliente de como está a saúde química da bateria no uso automotivo, permitindo um melhor planejamento de troca da bateria.

Enquanto usuários de veículos, a visão desse projeto propicia informação adicional, de forma preditiva, de quanto tempo mais o usuário possa utilizar a bateria, sem ter que trocar a mesma. Dessa forma, pode-se executar uma troca planejada, evitando situações indesejadas de veículos parados por falha na bateria sem aviso prévio, evitando possíveis situações de riscos e vulnerabilidade para o motorista.

1.4 Motivação

Entender o comportamento da bateria do carro, em um ambiente com comunicação via nuvem com a empresa, pode permitir uma maior interação na manutenção preditiva dos consumidores, redução de tempo parado de veículo e maior satisfação do consumidor, aproveitando que os veículos modernos são fabricados e equipados com sensores adicionais para monitoramento da bateria, como por exemplo o *Battery Monitor Sensor* (BMS, em português sensor de monitoramento da bateria) que executa medições de temperatura, corrente elétrica e tensão da bateria.

1.5 Limites e limitações

Dentro desse contexto de projeto, o escopo de trabalho fica limitado a veículos da marca *Ford Motor Company*, com motores a combustão de gasolina/álcool (*Flex Fuel*) e baterias do tipo SLI (*Starting-Lighting-Ignition*, em português partida-iluminação-ignição, normalmente utilizada em veículos de combustão interna convencional).

Veículos de outra montadora estão fora do escopo do projeto. Veículos com motores a Diesel estão fora do escopo de projeto.

Esse trabalho não pretende entrar em detalhes do processo químico de fabricação da bateria, focando na sua aplicação em veículos e interações com sensores existentes nos veículos.

Baterias que apresentam mortalidade prematura, ou seja, com pouco tempo de uso pelo cliente, estão fora do escopo desse projeto. Foco do projeto está em baterias com desgastes naturais ao longo do tempo.

1.6 Aspectos metodológicos

Após a definição do tema para realização da presente pesquisa e construção desta dissertação, refletido nesse capítulo 1, foi iniciada uma revisão da literatura, apresentada no capítulo 2,

objetivando identificar trabalhos anteriores sobre o tema, visando levantar os pontos significativos, além de obter as lacunas que orientam a condução deste trabalho, permitindo um melhor planejamento de atividades. O planejamento da modelagem computacional é apresentado dentro do capítulo 3. Na sequência, entrou-se na fase experimental dentro do capítulo 4, com levantamento e estudo dos dados, evoluindo dentro dos testes estatísticos. No capítulo 5 foram feitas as considerações finais, incluindo as principais conclusões, contribuições e propostas de atividades futuras.

Esse trabalho de dissertação seguiu 4 macro fases: introdução, referencial teórico, contendo descrições do sistema veicular envolvido com o gerenciamento de energia elétrica e detalhamento de séries temporais, proposição do modelo computacional juntamente com sua experimentação e resultados/conclusões.

Dentro da fase introdução, foi tratado o ponto de vista do cliente com relação ao problema de morte da bateria, comentando sobre insatisfações devido a esse fim de vida da bateria. Detalhado um pouco sobre o ponto de vista da montadora em relação a essas falhas com bateria.

Dentro da fase de referencial teórico, na seção do sistema veicular, objetiva-se detalhar o sistema de funcionamento do veículo, desde uma visão macro da geração da bateria de chumbo-ácido dentro do processo produtivo do fornecedor, passando pela logística de distribuição dos veículos, detalhar a entrega para o cliente e acompanhamento pós-venda, até o fim de vida da bateria. Nessa fase também é detalhada as comunicações existentes entre os sensores e módulos veiculares, permitindo os meios de aquisição dos dados trabalhados, detalhando a funcionalidade e confirmação dos dados lógicos com os dados físicos presente no veículo. Na seção de séries temporais, foram detalhados o histórico das séries temporais de longo alcance, passando pela estatística de Hurst, detalhando sobre *Detrended Fluctuation Analysis* (DFA, em português análises de flutuações destendenciadas), *Detrended Cross Correlation Analysis* (DCCA, em português análises de correlações cruzadas destendenciadas) e o coeficiente do DCCA (ρ_{DCCA}).

Na fase do trabalho experimental, foram apresentados os métodos e equipamentos utilizados para a aquisição dos dados e detalhamentos da prática executada para a aquisição dos dados. Foram considerados tempos diferentes de uso de baterias, passando por baterias com pouco tempo de uso em veículos, baterias com um uso intermediário e baterias com um estado de saúde já deteriorado. Posteriormente também foi detalhado o ajuste dos dados e estudos estatísticos feitos com esses dados com o suporte do software RStudio (responsável por interpretação da linguagem R) com alguns pacotes específicos, criação de *scripts* na linguagem R para geração de gráficos e tabelas de resultados.

Na fase de resultado/conclusões, tem-se como objetivo detalhar os resultados alcançados, indicando os principais achados, detalhando as conclusões e contribuições alcançadas e gerando uma lista de oportunidades de atividades futuras de pesquisa.

1.7 Organização do Dissertação de mestrado

Este documento apresenta 5 capítulos e está estruturado da seguinte forma:

- **Capítulo 1 - Introdução:** Contextualiza o âmbito, no qual a pesquisa proposta está inserida. Apresenta, portanto, a definição do problema, objetivos e justificativas da pesquisa e como este dissertação de mestrado está estruturado;
- **Capítulo 2 - Revisão Sistemática:** Neste capítulo discorre-se uma revisão sistemática com o objetivo caracterizar a produção científica sobre interfaces de estudo da saúde da bateria, conhecido como *State of Health* (SOH) adicionando um foco com estudo de séries temporais de longo alcance DFA (*detrended fluctuation analysis*), DCCA (*detrended cross correlation analysis*) e ρ DCCA (coeficiente do DCCA);
- **Capítulo 3 - Proposição do modelo computacional:** Nesse capítulo é apresentado um desenvolvimento cognitivo sobre o tema, gerando um escopo detalhado de conhecimento, juntamente com o método utilizado para o detalhamento do modelo computacional proposto;
- **Capítulo 4 - Resultados e Discussões:** Nesse capítulo é explorado as medições veiculares do perfil da bateria ao longo do tempo, juntamente com o tratamento dos dados e cálculos para os coeficientes estatísticos que deram base para as conclusões do trabalho;
- **Capítulo 5 - Considerações Finais:** Apresenta as conclusões, contribuições e algumas sugestões de atividades de pesquisa a serem desenvolvidas no futuro.

Revisão da literatura

Esse capítulo está ajustado para 2 blocos de informações teóricas: (1) Sistemas ligados ao veículo; (2) Estudos para séries temporais de longo alcance.

2.1 *Sistemas Elétricos Veiculares*

2.1.1 *Baterias de Chumbo-Ácido Automotivo*

As baterias de chumbo-ácido automotivas não apresentaram muitas mudanças disruptivas nos últimos 90 anos. O que se espera das baterias, com relação ao projeto e tecnologias de processo produtivo são basicamente (GELBKE; MONDOLONI, 2017):

- uma expectativa de vida média variando entre 2 e 7 anos (dependendo das condições climáticas);
- uma alta confiabilidade e robustez, minimizando falhas com baixo tempo em uso;
- uma capacidade de partidas em ambientes frios, onde normalmente o motor de partida demanda um torque maior para rotacionar o motor a combustão;
- atender os requisitos acima com o mínimo de uso de material, peso e custo.

As baterias convencionais são conhecidas como *Starting-Lighting-Ignition* (SLI), enquanto que algumas baterias aprimoradas para suportar uma maior quantidade de ciclagem são chamadas de EFB (*Enhanced Flooded Battery*) e consideram diversas melhorias incrementais na bateria, sem perder a sua base de funcionamento (GELBKE; MONDOLONI, 2017). As baterias EFB são usualmente utilizadas junto a veículos com tecnologia *Stop-Start*, a qual permite que motor a combustão seja desligado em momentos que o veículo pare, voltando a funcionar quando o motorista deseja voltar a movimentar o carro, permitindo um melhor desempenho no consumo de combustível, principalmente em ciclos urbanos.

Ao detalhar a bateria, ela é formada por uma caixa de material plástico isolante, contendo células de baterias em série dentro da caixa, conforme exemplificado na figura 2.1. Cada célula dessa é formada por placas de chumbo positiva e negativa, juntamente com uma pasta grudada na placa e um isolante. as terminações das células dentro da caixa então são soldadas, formando diversas células de baterias em série. Nesse momento a bateria é completada com ácido sulfúrico diluído,

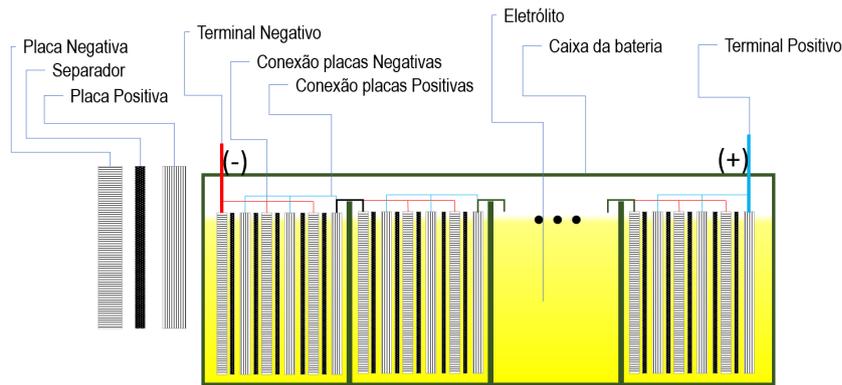


Figura 2.1: Exemplo bateria visão explodida. Fonte: próprio autor

com concentrações típicas entre 1.26 kg/L e 1.30 kg/L. Após preencher a bateria com o ácido sulfúrico, a mesma é selada, mantendo somente um respiro para aliviar gases gerados (GELBKE; MONDOLONI, 2017).

A bateria então é levada para uma estação de formação onde o sistema passa a ser carregado, aumentando o estado de carga da bateria (do inglês *State of Charge* - SOC) da bateria para 100%.

As pesquisas e desenvolvimentos para baterias nos últimos anos tem como foco crescer a produtividade, juntamente com redução de consumo de chumbo, crescimento de durabilidade e desempenho de partidas a frio (GELBKE; MONDOLONI, 2017).

Após a bateria pronta, ela é enviada para as montadoras e pontos de trocas de bateria para mercado de reposição. Dentro da montadora, normalmente é feito um controle de *First In First Out* (FIFO), forçando que existam sempre baterias mais novas dentro da planta de montagem, garantindo que as baterias não fiquem descarregadas antes da montagem nos veículos.

As baterias automotivas podem ser representadas por modelos compostos por uma fonte de tensão de circuito aberto (OCV - *Open Circuit Voltage*), resistores e capacitores internos, conforme apresentado por I-Kun, Inamori e Morimoto (2014) e reproduzido na figura 2.2, onde as variações medidas de corrente e tensão, tanto na descarga, quanto na carga, da bateria permitem estimar a variação do resistor R1. As variações de resultado desse resistor interno foram utilizadas para estimar a deterioração da saúde da bateria ao longo do tempo.

2.1.2 Sistemas de Partida e Recarga da Bateria

No entorno do uso da bateria de chumbo-ácido em veículos atuais, tem-se alguns subsistemas desenvolvimentos que detalham o controle e gerenciamento das informações obtidas da bateria. Pode-se dividi-los em 2 grupos: (1) Sistema de Partida; (2) Sistema de recarga. Estes 2 sistemas

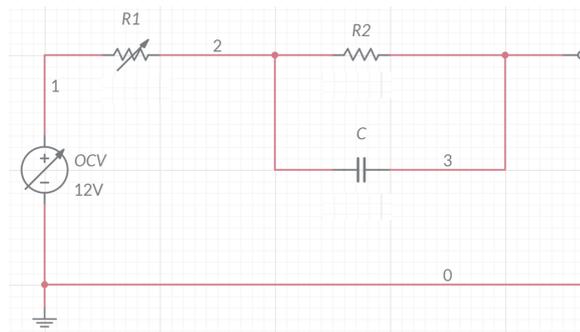


Figura 2.2: Modelo de circuito representando bateria de chumbo-ácido. Fonte: baseado em (I-KUN; INAMORI; MORIMOTO, 2014)

macros são suportados por diversos módulos eletrônicos, conhecidos como *Electronic Control Units* (ECU), e sensores.

O sistema de partida tem como principais componentes, além da bateria, o motor de partida e o motor a combustão (CHUMCHAL; KURZWEIL, 2017). No momento em que o motorista faz a requisição da partida do veículo (girando a chave na ignição ou apertando o botão de partida), o motor de partida é eletricamente ativado, se encaixando na cremalheira do motor a combustão e convertendo corrente elétrica em torque, permitindo que o motor comece a girar. No primeiro instante que o motor de partida atraca com o motor, o mesmo está parado, exigindo um torque máximo do motor de partida para tirar o motor a combustão da inércia. Esse ponto de maior torque também é o ponto de maior demanda de corrente elétrica. Essa alta demanda de corrente, faz com que os resistores internos presentes no modelo da bateria operem como um divisor de tensão, aumentando a queda de tensão disponível para o motor de partida. Essa queda na tensão da bateria é variável ao longo do tempo, tendo uma correlação direta com o torque requerido e sendo maior em baterias com maior desgaste ou baterias descarregadas (aumento observado na representação do modelo da resistência interna da bateria). No momento que o motor sai da inércia, o torque requerido começa a variar, com isso a corrente e a tensão apresentam variações (GELBKE; MONDOLONI, 2017). O motor de partida continua ativado até que a ECU de controle do motor consegue realizar leituras de rotação suficiente para começar a injetar combustível e forçar que a combustão interna do motor mantenha o mesmo em rotação. Quando isso acontece, o motor de partida é desativado, voltando para uma posição de repouso, desacoplando da cremalheira do veículo (CHUMCHAL; KURZWEIL, 2017).

Considerando ainda momentos em que o veículo está com o motor a combustão desligado, a bateria precisa alimentar as cargas elétricas, forçando uma descarga gradual da mesma. Normalmente esse consumo de carga é pequeno e monitorado pelas montadoras. As ECUs costumam ser os consumidores de energia para permitir algumas tarefas específicas, como por exemplo monitoramento de alarme no veículo. Em alguns casos, instalações *aftermarket* terminam por aumentar esse consumo de energia descarregando a bateria. Com uma previsão de aumento do número de ECUs, além de tendências de conectar os veículos a internet, essa é uma situação de preocupação no gerenciamento da carga das baterias automotivas (GELBKE; MONDOLONI,

2017) (CHUMCHAL; KURZWEIL, 2017).

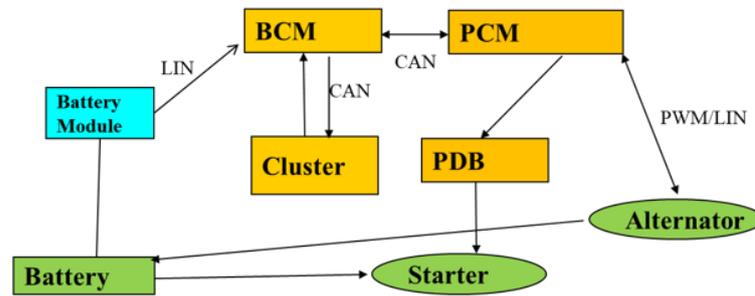


Figura 2.3: Diagrama de blocos ao redor da bateria. Fonte: próprio autor

No momento em que o veículo a combustão está ligado, ou seja, a ECU de controle do motor, também chamada de PCM (*Powertrain Control Module*) está gerenciando a injeção de combustível, entrada de ar e faísca do motor, entra em cena o alternador, aumentando a tensão elétrica do sistema, como pode ser visto na porção mais à direita da figura 2.4. O alternador é um gerador, que transforma rotação do motor em tensão e corrente elétrica, permitindo suprir todas as cargas elétricas do veículo e também recarregar a bateria do veículo. Nesse momento, quando mais tempo o veículo permanecer ligado, melhor para a bateria. O alternador pode ser controlado pela PCM através de comunicação *Pulse Width Modulation* (PWM) ou *Local Interconnect Network* (LIN). Na comunicação LIN, a PCM comunica para informar qual o nível de tensão o alternador precisa operar, além de obter retorno do controlador do alternador caso alguma falha esteja acontecendo dentro do mesmo, permitindo alertar ao motorista da necessidade de reparo, mesmo antes que a carga da bateria seja toda consumida em uma condição de falha do alternador. Parte dessa comunicação de dados pode ser sumarizada dentro da figura 2.3 entre a PCM e o Alternador.

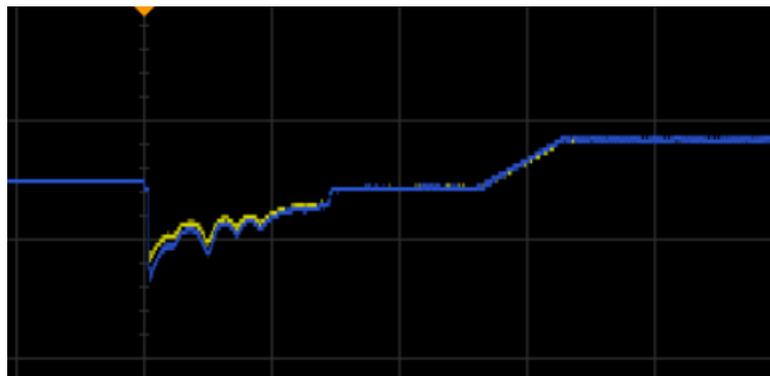


Figura 2.4: Medição de tensão de um ciclo de partida até a entrada do alternador, aumentando tensão, forçando uma recarga da bateria. Fonte: próprio autor

No intuito de monitorar o estado da bateria, muitas montadoras utilizam de sensores na proximidade dela. Esse sensor é conhecido como o *Battery Monitor Sensor* (BMS) (CHUMCHAL; KURZWEIL, 2017), possível de ser visualizado na figura 2.5. O BMS normalmente monitora corrente, temperatura e tensão da bateria. Em algumas aplicações, o BMS é posicionado diretamente no terminal negativo da bateria e comunica-se, através de um protocolo LIN com outra

ECU, em alguns casos com a ECU de controle de carroceria, conhecida como *Body Control Module* (BCM) conforme ilustrado na figura 2.3 (CHUMCHAL; KURZWEIL, 2017).



Figura 2.5: Localização do BMS no veículo. Fonte: próprio autor

O protocolo de comunicação LIN é baseado em uma comunicação seriada, suportando velocidades de transmissões de até 20 kBit/s, através de uma interface com um único fio de 12V. O protocolo LIN foi projetado para controlar componentes mais simples do veículo, como por exemplo os retrovisores, vidros elétricos, travamento de portas entre outros (DENUTO et al., 2001)

A partir dessa obtenção de dados da bateria pelo BMS e compartilhamento com a BCM, diversas estratégias de controle foram desenvolvidas e implementadas como, por exemplo, inferir o estado de carga da bateria (do inglês *State of Charge* - SOC) a partir de uma combinação da tensão e do delta de corrente que entra e sai da bateria, anteriormente o SOC era obtido através da medição da tensão da bateria com circuito aberto (OCV - *Open Circuit Voltage*), foi possível também permitir que o alternador seja desativado em determinados momentos que exista uma maior demanda do motor a combustão por torque, outro exemplo importante foi permitir a ativação ou não do sistema *Stop-Start*¹ a partir do SOC da bateria entre diversos outros exemplos (GELBKE; MONDOLONI, 2017) (CHUMCHAL; KURZWEIL, 2017).

2.1.3 Revisão Sistemática em Saúde de Baterias

As informações presentes até o momento trazem como alguns modelos de veículos funcionam, como referência. Ao analisar sobre saúde de bateria, foi feita uma pesquisa sistemática encima do tópico, focando em como responder uma pergunta chave de pesquisa: Qual o melhor modelo

¹*Stop-Start*: Sistema permite desligar e religar o carro em momentos que o veículo fica parado, por exemplo em engarrafamentos e semáforos fechados, religando de forma automática no momento de necessidade de movimento

para prever o fim de vida de baterias automotivas de chumbo-ácido e se é possível prever o fim de vida de bateria utilizando séries temporais.

Nesse contexto, essa pesquisa considerou as seguintes palavras chaves para inclusão: *lead-acid battery*, *SOH - state of health* e *automotive/vehicle*. Posteriormente, alguns termos foram considerados para remoção de artigos: itens relacionados com baterias de íons de lítio (*lithium-ion*) ou baterias de uso estacionário (*stationary usage*) ou uso em aplicações de energia solar ou veículos puramente elétricos (*battery electric vehicles*). As pesquisas foram feitas utilizando a seguinte frase de pesquisa com os devidos operadores de pesquisa: $\langle (SoH OR "State of Health") AND "Lead-Acid Battery" AND (automotive OR vehicle) \rangle$. Foi obtido como resultado 463 artigos dentro do *ScienceDirect* e 15 artigos dentro do IEEE, antes da aplicação dos filtros de remoção. Posteriormente foi feita uma leitura dinâmica dentro dos resumos e são apresentados abaixo os principais autores e um resumo das contribuições identificadas.

Considerando um aprimoramento das características elétricas da bateria, [May \(2004\)](#) apresentou uma proposta de monitoramento de baterias em condições de *Stop-Start*, no qual executava monitoramento do SOC, SOH, *Open Circuit Voltage*, queda de tensão na partida e resposta de tensão aplicada a pequenas cargas, chegando a uma conclusão que o SOC e SOH são críticos para padrões de confiabilidade serem alcançados. Já [Blanke et al. \(2005\)](#) utilizaram-se da corrente, do cálculo dos *ripple* de tensão aquisitados com um medidor EIS (*electrochemical impedance spectroscopy*) para diferentes faixas de frequências para realização de prognóstico de baterias, chegando a uma conclusão que a medição da impedância é uma ferramenta interessante para a medição dos estados da bateria.

No estudo apresentado por [Okoshi et al. \(2006\)](#), o foco era em melhorar a precisão da inferência do SOC, utilizando-se a resistência direta da corrente (*Direct Current Resistance - DCR*), melhorando assim a tabela de correlação entre o SOC e o DCR.

Já o [Zhang et al. \(2011\)](#) focaram seus estudos no monitoramento do SOH da bateria durante os momentos de partida do motor a combustão, apresentando uma nova modelagem para a bateria, considerando a resistência interna da bateria e a queda de tensão durante o momento de partida. [Zhang et al. \(2011\)](#) conseguiram melhores desempenhos de diagnósticos da bateria, quando compararam ao método convencional da época que era baseado em resistência. Eles apresentaram também como sugestões de trabalhos futuros o uso de métodos de detecção estatísticas como um tópico interessante para o tema.

[Ushiyama e Morimoto \(2011\)](#) mantiveram seu estudo também dentro de estimativas de SOH das baterias de chumbo ácido, nesse artigo mais precisamente considerando formas de onda das tensões e correntes elétricas nos terminais da bateria durante a operação. [Ushiyama e Morimoto \(2011\)](#) fizeram suas estimativas de SOH considerando mudanças nas resistências e capacitância internas da bateria.

Sabendo das limitações apresentada na medição do SOH por inferência, [Marcos et al. \(2012\)](#) propõem uma medição do SOH e do SOC através da densidade do eletrólito medido com o auxílio de fibra ótica inserida na bateria. Um dos pontos negativos dessa pesquisa, quando se coloca o presente trabalho em comparação a pesquisa dessa dissertação, é a necessidade de ser um método invasivo na bateria, para conseguir obter e medir a densidade do eletrólito.

[Li et al. \(2014\)](#) apresentaram uma proposta de estimativas do SOC e SOH utilizando um método dinâmico baseado em dados, aplicando um *Symbolic Dynamic Filtering* juntamente com uma máquina D-Markov e um PFSA (*probabilistic finite state automaton*). [Li et al. \(2014\)](#) consideraram como parâmetros corrente e voltagem em uma série temporal, conseguindo como resultado um método baseado em dados dinâmicos como uma alternativa aos métodos baseados em modelos de bateria. [Li et al. \(2015\)](#) também apresaram um trabalho relacionando séries temporais de corrente da bateria, juntamente com tensão, apresentando uma continuação na linha de pesquisa apresentada por [Li et al. \(2014\)](#).

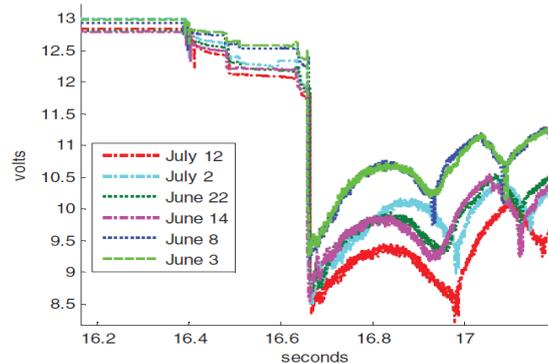


Figura 2.6: Resposta em tensão de desgastes de bateria. Fonte: ([KERLEY; HYUN; HA, 2015](#)).

Dentre os trabalhos avaliados, o artigo de [Kerley, Hyun e Ha \(2015\)](#) apresentou um sistema de medição do SOH baseando-se na curva de queda de tensão da bateria durante um evento de partida, monitorando as primeiras 2 quedas de tensão apresentadas ao longo do tempo, conforme demonstra a figura 2.6, juntamente com a temperatura e o SOC da bateria. O algoritmo apresentado conseguiu levantar "avisos" de deterioração do SOH da bateria, mas ainda com necessidades de aumentar a confiabilidade no sistema. Essa foi uma aplicação em ambiente controlado, como proposta de pesquisas futura, [Kerley, Hyun e Ha \(2015\)](#) sugeriram a aplicação do algoritmo no mundo real, juntamente com testes de campo.

No artigo apresentado por [Pilatowicz et al. \(2016\)](#) foi apresentado um modelo baseado na equação de Butler-Volmer com habilidade de predição da resposta da tensão da bateria com precisão considerando uma gama grande correntes de descarga da bateria, SOC e temperaturas. O modelo foi capaz de prever a queda de tensão da bateria mesmo em um ambiente dinâmico de cargas elétricas e condições de operações, mesmo considerando condições de baixo SOC da bateria.

Hyun (2016) fez uma proposta para a estimativa do SOH da bateria durante o momento de partida, utilizando somente SOC, temperatura da bateria e os dois primeiros deltas de queda tensão da bateria, do momento de repouso até o primeiro vale da queda de tensão, e entre o primeiro e o segundo vale da queda de tensão. Obtiveram como resultado um sistema que consegue estimar um SOH sem a necessidade de um sensor de corrente instalado no veículo.

No trabalho de Bressanini, Busarello e Peres (2017) foi apresentado um projeto e implementação de modelo de estimador de SOH e SOC, baseando o SOH na resistência interna da bateria, enquanto o SOC foi baseado no método de contagem de Coulomb, durante as etapas de carga e descarga da bateria. Para o SOC da bateria, foi considerada nas medições das correntes que entram e saem da bateria, enquanto o SOH foi considerado nos momentos em que a bateria começou a ser carregada.

Kwiecien et al. (2017) apresentaram uma visão que as tecnologias ligadas a bateria de chumbo-ácido de uso automotivo ainda apresentam diversos desafios e que devem continuar evoluindo nas próximas 2 décadas. É apresentada também a importância dos sensores de baterias (BMS) para permitir monitorar em tempo real a tensão, corrente e temperatura da bateria, alinhado com implementação de algoritmos adaptativos e muito trabalho de parametrização como um dos caminhos de evolução. Kwiecien et al. (2017) ainda mencionam que a determinação da capacidade disponível da bateria ao longo da vida da bateria, que é ligado diretamente ao SOH, ainda é um problema não resolvido.

Zhang, Du e Salman (2017) apresentaram um trabalho focado em modelagem da bateria. Neste caso, a diferença ficou na explicação do fenômeno térmico e elétrico da bateria, da mesma forma que a evolução das principais falhas das baterias, seguido pela aplicação de uma escala temporal dupla (*two-time-scale*) de um método estimador baseado no modelo da bateria. O algoritmo da esfera mais macro da série temporal vai monitorando a bateria e ajustando os parâmetros do modelo da esfera mais próxima. Como conclusão, o sistema de algoritmo híbrido foi capaz de monitorar a bateria e ir se auto ajustando ao longo do tempo.

Analisando por uma outra perspectiva, mas dentro da mesma linha de interesse, Kumar, Khare e Chaturvedi (2018) apresentaram um estimador de SOC e SOH da bateria baseado em abordagem *Neuro-Fuzzy* e modelos estatísticos, aplicando em um FPGA (*Field-Programmable Gate Array*) dentro de um sistema de BMS. O modelo considerou o tempo de consumo, a corrente elétrica drenada, tensão elétrica nos terminais, temperatura e a resistência interna da bateria. Kumar, Khare e Chaturvedi (2018) conseguiram uma outra opção para o sistema de BMS, considerando como vantagens um baixo custo não recorrente de engenharia, baixo consumo e alta velocidade de processamento, além de lógicas reconfiguráveis, grande capacidade de armazenamento e interfaces mais flexíveis.

Wassiliadis et al. (2018) aprofundaram os estudos dentro do filtro de Kalman, com o uso de

um filtro duplo estendido de Kalman para estimar o SOC e o SOH dentro de um estudo de caso para análise do ciclo de vida da bateria. Foram utilizados como parâmetros a resistência ôhmica da bateria e as estimativas de capacidade. Apresentaram como conclusão que o método é necessário para melhorar a acurácia do modelo e robustecer os filtros, especialmente em baterias já envelhecidas.

Dentro das evoluções também é importante citar o trabalho de [Khaleghi et al. \(2019\)](#), os quais propuseram um algoritmo baseado em dados em múltiplas condições para fazer a estimativa do SOH utilizando aplicações de cargas conhecidas. Foi utilizado um ciclo de direção chamado de *Worldwide Light Duty Driving Test Cycle* (WLTC) dentro do laboratório para fazer as aquisições simulando um uso real. Foram utilizados indicadores obtidos através das medições nos domínios do tempo e da frequência sobre a tensão e corrente com intervalos de tempo definidos, permitindo uma investigação em tempo real da degradação do SOH da bateria. Todos os dados foram alimentados em uma regressão Gaussiana para o processo de estimativa do SOH.

[Li et al. \(2020\)](#) apresentaram um artigo de um sistema de gerenciamento de bateria baseado em processamento na nuvem, considerando um *Digital Twin* para o SOH e SOC da bateria. Considerando um contexto que dados das baterias estarão disponíveis via a *Internet of Things*, tornando essa iniciativa viável. Para esse trabalho, foram utilizados modelos de circuito equivalente, modelos eletromecânicos e modelos de *machine learning*, considerando os prós e contras de cada um dos modelos.

[Calborean et al. \(2020\)](#) apresentaram uma nova abordagem do uso de um EIS (*Electrochemical Impedance Spectroscopy*) para predição da vida útil das células da bateria dentro de certas condições de envelhecimento. As flutuações foram monitoradas durante as sequências de cargas e descargas em 2 níveis de SOC. E ao estudar as frequências de ressonância das baterias durante o envelhecimento, foi possível encontrar uma tendência para o SOH da bateria.

Uma proposta de modelo de bateria utilizando OCV (*open circuit voltage*), dois resistores e um capacitor foi apresentado por [Chamusca et al. \(2020\)](#), com o objetivo de estimar o SOH da bateria, conforme figura 2.7, baseado na degradação da resistência interna para realizar a estimativa do SOH, partindo de medições feitas pelas ECUs (*electronic control units*) de veículos da Ford Motor Company.

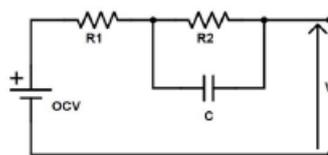


Figura 2.7: Circuito equivalente de Thevenin para carga e descarga. Fonte: ([CHAMUSCA et al., 2020](#))

Os dados levantados permitiram chegar a uma média de resistência interna de bateria nova de $27,6\text{m}\Omega$, o que foi considerado como SOH de 100%, enquanto baterias com resistência interna a

partir de $40m\Omega$ foram considerados como 0% de SOH. O método proposto apresentou limitações quando o SOC (*state of charge*) da bateria estava abaixo de 80 %, além de dados de regressão dispersos, como pode ser visto na figura 2.8 entre os comparativos de SOH e tempo necessário para a partida.

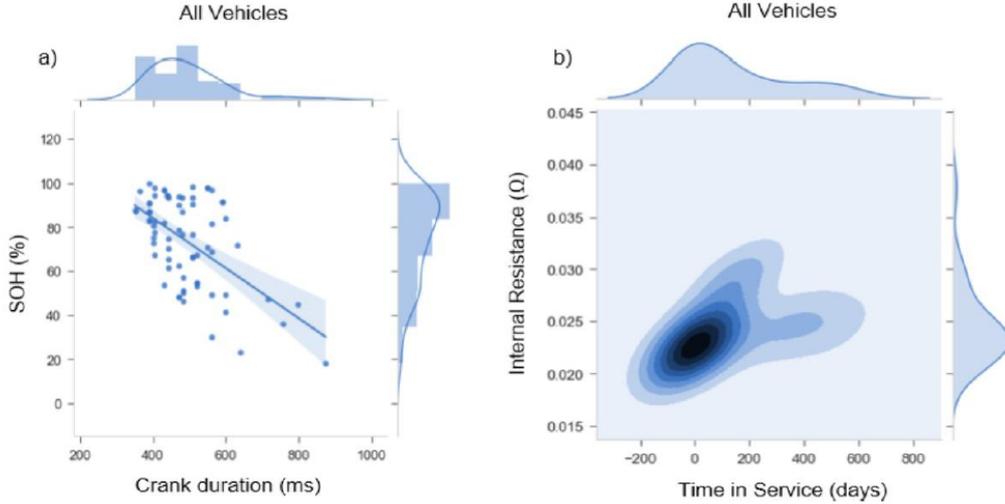


Figura 2.8: Gráfico regressão e distribuição de resistência dos veículos medidos. Fonte: (CHAMUSCA et al., 2020)

2.2 Modelos para Análise de Memória de longo alcance em séries não estacionárias

Quando é feita uma análise da evolução das estatísticas aplicadas a séries temporais, é importante passar pela estatística de Hurst, que ficou conhecido como R/S (HURST, 1951), detalhar sobre DFA, DCCA e $\rho DCCA$.

2.2.1 Estatística de Hurst, DFA, DCCA

O engenheiro Harold E. Hurst (1880 - 1978) desenvolveu uma proposta originalmente chamada de *rescaled range analysis*, chamada em português de análise estatística de R/S, durante sua passagem pelo Egito. O método tem como o primeiro passo a divisão da série temporal (\bar{x}_i) em segmentos, sem sobreposição, chamados de v , com um tamanho na unidade de tempo chamado de s , produzindo um número total de segmentos $N_s = \text{int}(N/s)$ (HURST, 1951).

No segundo passo do método de Hurst, o perfil dos dados é calculado para cada segmento, sendo $v = 0, \dots, N_s - 1$.

$$Y_v = \sum_{i=1}^j (\tilde{x}_{vs+i} - \langle \tilde{x}_{v+i} \rangle_s) = \sum_{i=1}^j \tilde{x}_{vs+i} - \frac{j}{s} \sum_{i=1}^s \tilde{x}_{vs+i} \quad (2.1)$$

Ao executar as subtrações das médias locais, as tendências constantes por parte dos dados são eliminadas.

No terceiro passo, as diferenças entre os valores mínimo e máximo dos intervalos $R_v(s)$ (*Range*) e o desvio padrão $S_v(s)$ em cada segmento são calculados.

$$R_v = \max_{j=1}^s Y_v(j) - \min_{j=1}^s Y_v(j) \quad (2.2)$$

$$S_v = \sqrt{\frac{1}{s} \sum_{j=1}^s Y_v^2(j)} \quad (2.3)$$

E para completar, o *Rescaled Range* é calculado sobre todos os segmentos para obtenção da função de flutuação $F(s)$.

$$F_{RS}(s) = \frac{1}{N_s} \sum_{v=0}^{N_s-1} \frac{R_v(s)}{S_v(s)} \sim S^H, S \gg 1 \quad (2.4)$$

Onde o H é o expoente de Hurst. Os valores de H são limitados entre $0 < H < 2$, e algumas imprecisões significativas são esperadas perto dos limites. Como H pode ser aumentado ou diminuído de 1 se os dados estiverem integrados ou diferenciados, respectivamente, sendo possível encontrar uma forma de calcular H pelo *rescaled range*, desde que os dados sejam estacionários. Para valores de H entre 0 e 0,5 indicam comportamento anti-correlacionado de longo alcance dos dados, enquanto valores de H maiores que 0,5 indicam comportamentos positivamente correlacionados no longo alcance, e quando o valor é igual a 0,5 a série é denominada browniana ou descorrelacionada.

O *Detrended Fluctuation Analysis* (DFA), foi um método proposto por Peng et al. (1994) para avaliar propriedades auto afins em séries temporais, ou seja analisar correlações de longo alcance em séries temporais não-estacionárias, analisando o comportamento das flutuações da curva ao longo do tempo. O método DFA é uma evolução da estatística de Hurst. A principal vantagem do DFA é permitir a identificação de auto-afinidade e correlações de longo alcance em sinais com tendências polinomiais. Além dessas vantagens, o DFA tem a capacidade de detectar falsas correlações em séries temporais não estacionárias (HU et al., 2001).

O DFA vem sendo aplicado em diversas áreas de interesse, podendo incluir nos últimos anos na área médica (WANG; SHAO; KIM, 2020b) (DAVID et al., 2020b), incluindo COVID-19 (MENSI; VO; KANG, 2021) e análise de dengue (NASCIMENTO FILHO, 2018), sistemas celulares (HENRICE JR et al., 2017), mercado financeiro (YANG; LI; YANG, 2017) (ZHU;

ZHANG, 2018) (CHENG; LIU; ZHU, 2019) (MENSI; HAMDI; YOON, 2018) (MENSI et al., 2018), análise do ambiente (MORATÓ et al., 2020) (BALKISSOON; FOX; LUPO, 2020), reconhecimento de voz (HE; ZHAO, 2017) (ZHAO; HE, 2016), análise de combustíveis (DAVID et al., 2020a) e diversos outros.

Para entender o uso do DFA, Peng et al. (1994) definiram 3 passos de desenvolvimento do modelo. Considerando como dado de entrada uma série temporal original, identificada como r_i , onde $i = 1, 2, \dots, N$, onde N é o número total de pontos dessa série temporal. Nesse momento a série temporal é integrada utilizando a equação abaixo:

$$y(k) = \sum_{i=1}^k [r_i - \langle r \rangle] \quad (2.5)$$

onde $\langle r \rangle$ é a média de todos os pontos da série temporal r_i . $y(k)$ também é conhecido como série integrada. Essa primeira etapa permite eliminar grande número de oscilações e obtenção de uma série estacionária.

No próximo passo, a série integrada é dividida em janelas/intervalos de igual tamanho de amplitude (box) n , não sobrepostos, em alguns casos podendo também apresentar sobreposição (PRASS; PUMI, 2019). Para cada intervalo gerado de tamanho n é ajustado um polinômio de grau ≥ 1 da $y(k)$, trazendo a tendência local para cada intervalo, e sendo identificada para cada janela como $y_n(k)$. Nesse momento, é feita uma subtração para cada ponto da sua tendência local, ou seja $y(k) - y_n(k)$, dentro de cada uma das janelas. Nesse momento, para um dado n de tamanho de janela, o sinal integrado tem com a tendência removida é dado por $F(n)$, que normalmente cresce com o aumento do tamanho da janela n , e é representado pela equação abaixo:

$$F(n) = \sqrt{\frac{1}{N} \sum_{k=1}^N [y(k) - y_n(k)]^2} \quad (2.6)$$

Esses cálculos devem ser guardados e repetidos para diferentes tamanhos de janela n além de poderem ser modelados para polinômios de maior ordem (PERAZZO; FERNÁNDEZ; WILLSHAW, 2004).

No terceiro passo, é verificado se a função $F(n)$ comporta-se como uma lei de potência, dentro de uma relação $F(n) \sim n^\alpha$, onde α é o expoente de correlação de longo alcance e o α pode ser obtido através da obtenção do coeficiente de inclinação em um gráfico $\log(n) - \log(F(n))$.

O expoente de correlação α representa um parâmetro de auto-afinidade, demonstrando as pro-

priedades de correlação de longo alcance de uma série temporal. A interpretação física deve levar em consideração o comportamento do expoente tendo o campo de variação classificado conforme abaixo:

- $0 < \alpha < 0,5$ - Anti-correlacionado, também chamado de anti-persistente;
- $0,5 < \alpha < 1$ - Correlacionado, comportamento persistente;
- $\alpha = 0,5$ - Sem memória, parecido como um ruído branco;
- $\alpha = 1$ - Um comportamento de ruído rosa;
- $1 < \alpha < 1,5$ - Processo sub-difusivo;
- $\alpha = 1,5$ - Ruído marrom;
- $\alpha > 1,5$ - É apresentado um processo super-difusivo.

Com o interesse de acompanhar e identificar correlações cruzadas entre duas séries temporais, é possível fazer uma generalização do DFA, aplicando para 2 séries com o mesmo número de observações N . Essa tratativa foi chamada de DCCA e é possível executá-la seguindo os passos proposto por [Podobnik e Stanley \(2008\)](#).

O DCCA vem sendo utilizado em diversas áreas do conhecimento como, por exemplo, em indicadores de criminalidade ([SILVA FILHO, 2016](#)), mercado de ações/criptomoedas/*commodities* ([YANG; LI; YANG, 2017](#)) ([MENSI et al., 2018](#)) ([ZHOU et al., 2019](#)) ([RUAN; CUI; FAN, 2020](#)) ([FERREIRA; KRISTOUFEK; PEREIRA, 2020](#)) ([RUAN et al., 2019](#)) ([LI; LU; LIU, 2020](#)) ([GUEDES et al., 2017](#)) ([OKORIE; LIN, 2021](#)), impactos da COVID-19 ([WANG; SHAO; KIM, 2020a](#)), propriedades moleculares ([CHEN; ZHU; JIA, 2020](#)), mercado de petróleo ([ZHU et al., 2019](#)) ([CAI et al., 2019](#)), condições climáticas em geral ([STAN et al., 2020](#)) ([WANG; SHAO; KIM, 2020c](#)) ([ADARSH et al., 2020](#)) e diversos outros.

Partindo da posse de 2 séries temporais de igual tamanho, podendo ser identificadas como " $y(t)$ " e " $y'(t)$ ", sendo $t = 1, 2, \dots, N$, com o mesmo tamanho N , é feita uma integração das duas séries, obtendo duas novas séries conforme equação 2.7.

$$R(t) = \sum_{i=1}^t y(i), R'(t) = \sum_{i=1}^t y'(i), t = 1, 2, \dots, N \quad (2.7)$$

Após essa primeira integração, as funções resultantes $R(t)$ e $R'(t)$ são divididas em $N - n$ intervalos, também chamado de box ou janela, sobreposto de igual tamanho, em que cada intervalo contém $n + 1$ valores e em cada intervalo que se inicia em i e termina em $i + n$ com n

variando entre: $4 \leq n \leq N/4$, como exemplificado na figura 2.9. Também deve ser calculado qual a tendência local para cada uma das janelas geradas utilizando um ajuste dos mínimos quadrados de cada série $\tilde{R}_{K,i}$ e $\tilde{R}'_{K,i}$ onde $i \leq K \leq (i + n)$.

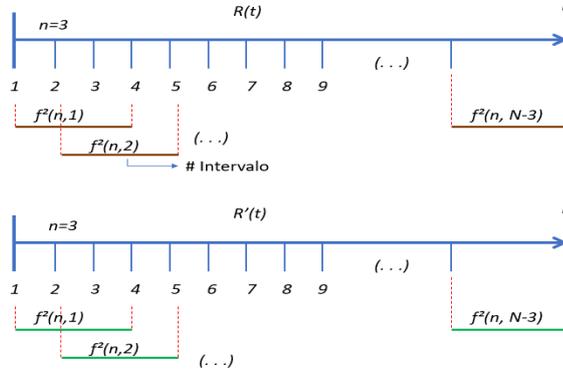


Figura 2.9: Divisão das séries $y(t)$ e $y'(t)$ em intervalos com superposição. Fonte: Adaptado de (ZEBENDE, 2011) (NASCIMENTO FILHO, 2018).

A partir dos cálculos evoluídos até o momento, é feito o cálculo também da covariância dos resultados em cada intervalo:

$$f_{DCCA}^2(n, i) = \frac{1}{n+1} \sum_{k=i}^{i+n} (R_k - \tilde{R}_{k,i})(R'_k - \tilde{R}'_{k,i}) \quad (2.8)$$

E na sequência é determinada a função de correlação expressada conforme equação abaixo:

$$F_{DCCA}^2(n) = \frac{1}{N-n} \sum_{i=1}^{N-n} f_{DCCA}^2(n, i) \quad (2.9)$$

Seguindo os passos apresentados até aqui, fazendo uma análise de 2 séries iguais, é possível obter o mesmo resultado do método DFA apresentado por Peng et al. (1994). Com o procedimento sendo repetido para diferentes tamanhos de janela n é possível verificar a existência de uma lei de potência $F_{DCCA} \propto n^\lambda$

2.2.2 Coeficiente de Correlação Cruzada $\rho DCCA$

O método $\rho DCCA$ foi proposto por Zebende (2011) e mede o grau de correlação cruzada entre séries temporais, baseando-se nas teorias de auto-correlação presentes no trabalho de Peng et al. (1994) e os estudos de correlação cruzada determinado pelo método de Podobnik e Stanley (2008). O método $\rho DCCA$ vem sendo aplicado em diversos campos de pesquisa como, por exemplo, mercado de valores (LIU; LIN; LI, 2021) (PEREIRA et al., 2019) (FERREIRA et al., 2018)

(MOHTI et al., 2019) e muitos outros, varejo de combustível (NASCIMENTO FILHO, 2018), estudos médicos (CHEN et al., 2018), políticas públicas (ROHIT; MITRA, 2018) (BASHIR et al., 2019) (AZEVEDO et al., 2021), análise de combustíveis (MURARI et al., 2019) propriedades moleculares (LIANG; LIU; ZHANG, 2017), condições climáticas diversas (ZEBENDE et al., 2018) (SHIN et al., 2019) (SHEN, 2019), análises em ligação com óleo (FERREIRA et al., 2019) (ZHAI et al., 2019), análise em energia elétrica (PAIVA; RIVERA-CASTRO; ANDRADE, 2018), topologias de transporte (LI; SHI; CAO, 2018) entre diversos outros.

O coeficiente de correlação cruzada ρ_{DCCA} é calculado conforme a equação abaixo:

$$\rho_{DCCA}(n) = \frac{F_{DCCA}^2(n)}{F_{DFA\{y\}}(n) * F_{DFA\{y'\}}(n)} \quad (2.10)$$

onde $F_{DFA\{y\}}(n)$ significa o cálculo do DCCA de uma série versus ela mesma.

O ρ_{DCCA} é um coeficiente adimensional com intervalo de variação entre -1 e $+1$, seguindo com as seguintes interpretações possíveis:

- $\rho_{DCCA} = 0 \Rightarrow$ Significa que não existe correlação cruzada entre as séries analisadas;
- $\rho_{DCCA} = +1 \Rightarrow$ Significa que existe perfeita correlação cruzada;
- $\rho_{DCCA} = -1 \Rightarrow$ Significa perfeitamente anti-correlacionado.

O próximo capítulo apresenta como foi a metodologia utilizada para esse trabalho, incluindo os parâmetros escolhidos para a experimentação.

Proposição do Modelo Computacional

Para definição do modelo computacional, é importante ressaltar algumas escolhas que foram feitas para essa aplicação.

O objetivo desse trabalho tem relação com a identificações do estado da bateria de chumbo-ácido em uso automotivo. Ao fazer um sumario de todos os estudos feitos com bateria na academia, correlacionando essa informação com o que se tem de sensores em veículos e a tratativa de séries temporais, o escopo de experimentação escolhido a ser seguido envolveu a análise da tensão da bateria de chumbo-ácido dentro do período em que o veículo é solicitado a dar a partida, com todas as variações acompanhadas ao longo do tempo.

Ao comparar com que existe de sensores dentro dos veículos Ford, esse dado de tensão é possível de ser feito direto no terminal da bateria com o uso do BMS (*Battery Monitor Sensor*), tornando esse um escopo factível de ser realizado. Esses dados de tensão são processados e enviados para a BCM (*Body Control Module*) através de uma comunicação LIN. Esses dados podem ser acessados pela montadora através de comunicação CAN via portas de diagnóstico e, caso o veículo seja equipado com um modem, através da nuvem de dados da própria montadora.

3.1 Desenvolvimento cognitivo em torno do tema

Para aferir que os conhecimentos adquiridos sobre o tema apresentam uma relevância cognitiva de conhecimento e refletem os conhecimentos abordados na academia, foi feito um estudo utilizando as teorias de rede no entorno do tema e apresentado no artigo de [Costa et al. \(2020\)](#). O objetivo foi delinear as interfaces da bateria de chumbo-ácido no uso de um veículo a combustão, carregados em um mapa conceitual, comparando com os resultados de uma rede *benchmark*, gerada a partir dos resumos de artigos relacionados sobre os estudos de saúde da bateria. Esse estudo foi elaborado com uma criação de um mapa conceitual, tendo a bateria de chumbo-ácido como o ponto central, incluindo aspectos do design interno da bateria, integração da bateria com os sensores, atuadores e módulos do veículo, seguindo até o fluxo de informações para obtenções e processamento dos dados. seguindo para análises e estudos estatísticos que poderiam ser feitos. Esse mapa conceitual foi utilizado como dado de entrada para criação de uma rede, contendo vértices e arestas dentro de um formato de arquivo de rede. A rede de *benchmark* foi gerada a partir dos resumos de 22 artigos selecionados, seguindo o método adotado por [Pereira et al. \(2011\)](#), incluindo um dicionário de controle para ajustes nos resumos, fazendo remoções de palavras sem valor para rede, da mesma forma que junções de palavras que fazem sentido juntas no contexto da pesquisa.

Symbol	Statistical studies	Actual Graph	Random Graph (Based on Actual)	Abstract Graph	Random Graph (Based on Abstracts)
$n = V $	Total Nodes	80	80	783	783
$m = E $	Total Edges	420	373	9982	9902
$\langle k \rangle$	Average Degree	10.5	4.662	25.497	12.646
D	Network Diameter	5	4	12	3
Δ	Graph Density	0.133	0.118	0.033	0.032
C_{ws}	Avg. Clustering Coefficient	0.342	0.121	0.801	0.032
L	Avg. Path Length	2.441	2.18	2.232	2.395
C	Transitivity	0.281	0.118	0.255	0.032
E_{global}	Global Efficiency	0.477	0.509	0.467	0.445
E_{local}	Local Efficiency	0.492	-	0.385	-

Tabela 3.1: Estatísticas de redes comparativas. Fonte: (COSTA et al., 2020)

verificado a existência de uma relação entre os termos utilizados nos 10 e 20 primeiros vértices das redes. Nesse contexto, foram observadas diversas similaridades nas comparações, apresentando inclusive 15 similaridades de significados dentro dos 20 primeiros conceitos (Vértices) com maior grau. Na tabela 3.2 é apresentado esses resultados comparativos.

Com esses resultados apresentados, o nível de confiança para seguir para os próximos passos foi declarado como satisfatório, permitindo um nível técnico de profundidade sobre o tema para seguir os próximos passos.

Top 10 Comparison (Based on Degree)				Top 20 Comparison (Based on Degree)			
Actual Graph		Abstracts Graph		Actual Graph		Abstracts Graph	
Battery	35	battery	556	Battery	35	battery	556
Data	31	stateofhealth	272	Data	31	stateofhealth	272
Body Module	29	vehicle	221	Body Module	29	vehicle	221
Batt Sensor	25	leadacid	204	Batt Sensor	25	leadacid	204
Electrical Loads	20	stateofcharge	199	Electrical Loads	20	stateofcharge	199
Key-off Load	19	system	194	Key-off Load	19	system	194
Temp	17	base	186	Temp	17	base	186
Engine Module	15	method	179	Engine Module	15	method	179
Alternator	15	model	167	Alternator	15	model	167
Batt SoHealth	14	time	164	Batt SoHealth	14	time	164
				Multivare Analyses	14	current	157
				Crank Combustion engine	14	monitor	150
				Temporal Series	14	state	131
				Neural Network	14	present	128
				Tecnical Specification	14	real	125
				Hypotheses tests	14	age	125
				Models	14	algorithm	123
				Analyse of Variance	14	power	122
				Starter Motor	14	voltage	117
				Batt Resistance	14	storage	114

Tabela 3.2: Comparação dos principais vértices entre as redes. Fonte: (COSTA et al., 2020)

Uma vez que a aquisição de dados se apresenta como possível, e a maturidade de conhecimento cognitivo forneceu uma base satisfatória, o foco desse trabalho passou a ser nas medições e avaliações, conforme as próximas sessões desse capítulo.

3.2 Modelo proposto

O modelo proposto considera o fluxograma da figura 3.2.

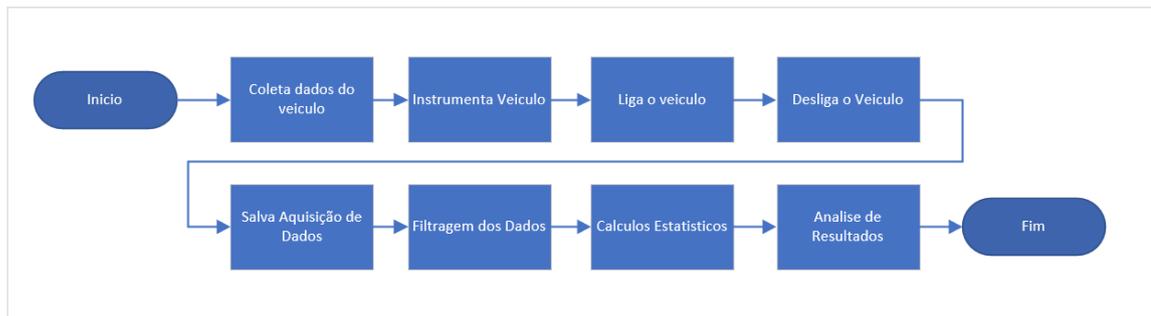


Figura 3.2: Fluxograma de atividades. Fonte: Próprio Autor

Na etapa de "coleta de dados do veículo", são levantados o modelo do veículo e da bateria, tempo de uso daquela bateria dentro do veículo.

Para a etapa de "instrumentação do veículo", foi utilizado um osciloscópio digital PicoScope 2204A da série 2000, com uma banda de passagem de 10MHz, e resolução de 8 bits a 100MS/s, ligado a um laptop, o qual tinha instalado o aplicativo PicoScope 6, versão 6.14.23.5207. A ponta de prova foi posicionada diretamente nos terminais da bateria para a aquisição de tensão. O setup utilizado para as aquisições foi de +/- 20V e 100 ms/div, com um trigger para quedas de tensão abaixo de 10V. A taxa de amostragem no sistema BMS-BCM disponível nos veículos estava provendo 1 medição a cada 30ms, o que representa uma média de 45 pontos de medição por partida. Para o cálculo do DFA/DCCA/ ρ DCCA é requerido uma quantidade muito maior de dados na série temporal, por esse motivo foi utilizado o osciloscópio que, com um ajuste para 1ms, foi capaz de apresentar 1300 pontos de medição. A mudança da taxa de amostragem do sistema BMS-BCM deve ser considerada no planejamento de implementação de trabalhos futuros.

Após a instrumentação, é executada as etapas de "Ligar o Veículo" e "Desligar o Veículo". Nessa etapa, foi feito uma pré-condição de repouso da bateria, antes da partida, de pelo menos 12 horas com o veículo em repouso após o uso do veículo ligado. Nessa etapa, é feito as coletas das séries temporais de tensão a serem avaliadas nas etapas seguintes.

Na etapa "Salva Aquisição de Dados", os dados são gravados tanto em formato típico do

aplicativo PicoScope como também em formato .csv, trazendo todas as medições realizadas.

Na etapa "Filtragem dos dados" os dados são tratados para representar somente a zona de interesse para os cálculos estatísticos de séries temporais, mantendo o ponto inicial de todas as medidas alinhadas no mesmo momento, ou seja o ponto zero antes das quedas de tensão, permitindo monitorar cada *ms* das medições, mantendo um mesmo tamanho de série temporal, o que é uma necessidade para os cálculos de DCCA.

Para a etapa "Cálculos Estatísticos", foram considerados como dados de entradas as medições filtradas da curva de tensão da bateria durante o momento de partida. Os cálculos do DFA, DCCA e ρ DCCA foram feitos utilizando o RStudio versão 1.3.1056, tendo os seguintes pacotes carregados: Pacote 'DCCA' versão 0.1.1; Pacote 'GMZTests' versão 0.1.3. Todos os passos foram consolidados no *script* do R presente no apêndice A dessa dissertação. Alguns valores posteriormente também foram exportados para o Microsoft Excel para criação de gráficos dos valores combinados de diversas medições.

Na etapa de "Análise de Resultados" foram apresentadas as avaliações estatísticas dos resultados e as principais descobertas do método, incluindo também propostas de retroalimentações possíveis para evolução contínua do modelo.

Resultados e Discussões

4.1 Análise experimental e cenários

Na aquisição dos dados e posterior filtragem das séries temporais de tensão, foi possível chegar com o conjunto de curvas descritas na figura 4.1. É possível observar uma queda de tensão no momento da partida, sendo maior no momento inicial, onde o motor ainda está parado, demandando uma maior corrente da bateria, sendo refletido em um maior queda de tensão inicial. No decorrer do trecho, quando o motor sai da inercia, percebe-se uma tendência de aumento na tensão, até o momento em que a tensão retorna acima dos 12V, característico de motor a combustão em funcionamento.

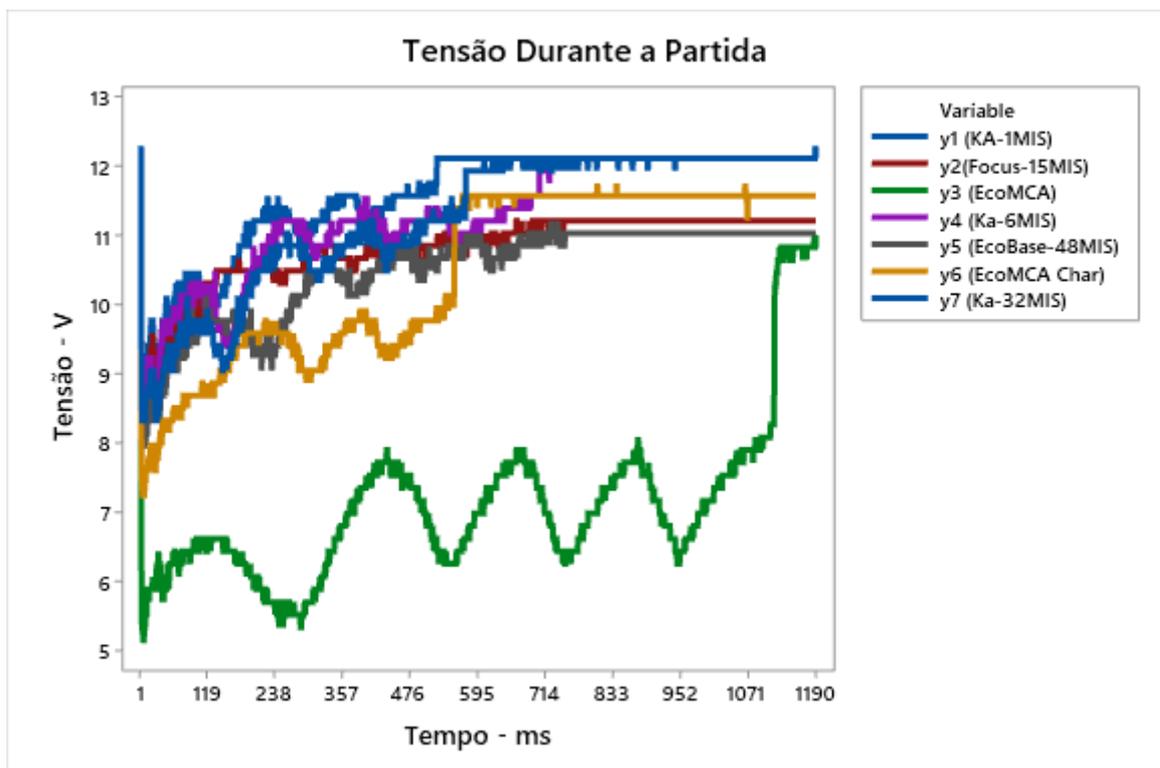


Figura 4.1: Sumario das medições filtradas de partida. Fonte: Próprio Autor

Os veículos foram identificados da seguinte forma:

- Y1 = Ford Ka 1.5L com 1 mês de uso da bateria;
- Y2 = Ford Focus 2.0L com 15 meses de uso da bateria;
- Y3 = Ford EcoSport 2.0L com SOH deteriorado;

- Y4 = Ford Ka 1.5L com 6 meses de uso da bateria;
- Y5 = Ford EcoSport 2.0L com bateria original trocada e em uso da bateria *aftermarket*;
- Y6 = Ford EcoSport 2.0L com SOH deteriorado e feita uma recarga do SOC antes da medição;
- Y7 = Ford Ka 1.5L com 32 meses de uso da bateria;

As curvas Y3 e Y6 refletem momentos de partida do mesmo veículo. Diferença entre elas está no SOC (*State of Charge*) do Y6 ser muito maior que o Y3, conforme figura 4.2, apresentando uma diferença na profundidade da queda de tensão inicial juntamente com um tempo menor para retornar acima de 12V na curva Y6.

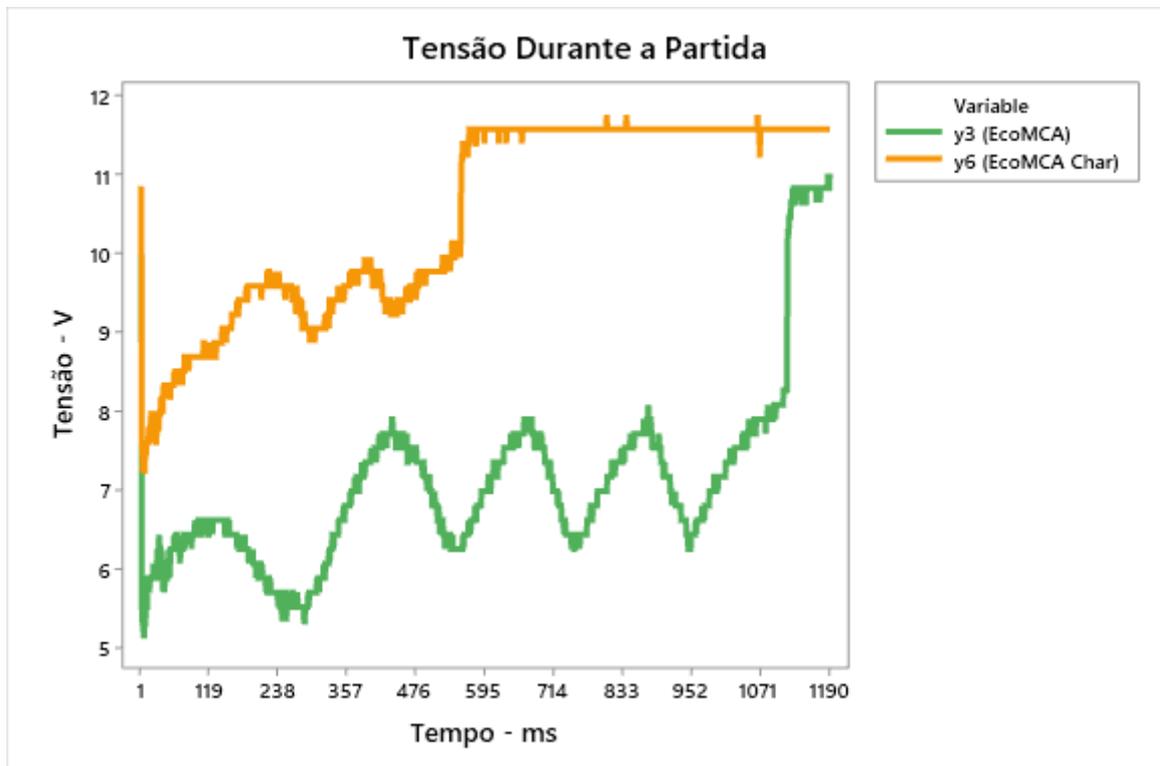


Figura 4.2: Comparação da medição de tensão entre veículo descarregado e carregado. Fonte: Próprio Autor

Dentro das análises experimentais, foram considerados inicialmente alguns veículos da Ford, como o Ford Focus, Ford EcoSport e o Ford Ka. Cada um deles com um tempo de uso de bateria e também com seu motor específico, seguindo as primeiras 4 colunas da tabela 4.1. Com as aquisições dos dados executada, os dados foram tratados e calculados no RStudio. Os resultados iniciais de DFA podem ser vistos nas últimas 3 colunas da tabela 4.1

Onde entende-se na tabela 4.1 que TIS significa *Time In Service* da bateria em meses. Algumas vezes também chamado de MIS (*Month In Service*).

Identificação	Veículo	Motor	TIS	α DFA	R ²	Residual Std. Error
Y1	Ka RC	1.5L	1	1.285	0.9809	0.1046
Y2	Focus SB	2.0L	15	1.236	0.9816	0.1054
Y3	Eco FMC	2.0L	18	1.49	0.9965	0.04949
Y4	Ka RC	1.5L	6	1.338	0.9817	0.1137
Y5	EcoBase ACC	2.0L	48	1.238	0.9652	0.1465
Y6	Eco FMC Charg	2.0L	18	1.433	0.9861	0.1331
Y7	Ka AB	1.5L	32	1.334	0.9818	0.1425

Tabela 4.1: Planilha de coleta de dados dos veículos. Fonte: Próprio Autor

Os gráficos de DFA podem ser observados na figura 4.3.

As amostras apresentam um comportamento subdifusivo, ao fazer análise dos resultados do DFA, tendo todos os α entre 1 e 1,5.

Para as análises de DCCA, foi feita uma combinação de todas as amostras medidas entre si, fazendo um ajuste de tempo entre as amostras, limitando o tempo de medição até 1,18 segundos apresentando uma variação de $1ms$ por medição. Essa técnica de redução de amostra foi implementada por [Zebende, Brito e Castro \(2020\)](#), onde eles confirmaram que mesmo com remoção de alguns termos o resultado manteve-se válido.

Ao analisar os resultados do α do DCCA, foi possível observar um comportamento superdifusivo para as correlações cruzadas. As figuras 4.4, 4.5 e 4.6 refletem como as correlações cruzadas se comportaram. Ponto interessante que em três das combinações estudadas, os valores de F_{DCCA} foram todos negativos, sendo necessário fazer uma inversão de todos os valores para poder calcular o α do DCCA. Foi observado ainda em 5 casos que, com determinados tamanhos de janela, alguns valores do F_{DCCA} também deram negativos, e foram removidos para o cálculo do α do DCCA. O R^2 apresentou valores sempre acima de 90%, chegando em valores máximos acima de 99%, com erros residuais abaixo de 0,6.

Ao calcular e analisar os valores do ρ_{DCCA} foi possível observar curvas ao longo do crescimento das janelas (box) com uma forma de dispersão, com valores chegando próximo a 0,75 com uma curva rápida de crescimento já em pequenos tamanhos de janela, enquanto também é possível ver crescimentos mais lentos com tamanhos de janela a partir de $150ms$, indicando certo grau de correlação cruzada. Por outro lado, também é possível observar valores que não apresentam uma tendência de crescimento, não apresentando correlações cruzadas.

Para detalhar o comportamento das curvas de ρ_{DCCA} , foi feita uma junção de todos os resultados em um único gráfico, juntamente com um intervalo de confiança apresentado por [Podobnik et al. \(2011\)](#) e implementado do pacote GMZTests do R. O resultado pode ser observado dentro da figura 4.7. Para entender as comparações foi executada o ajuste de nomes a seguir:

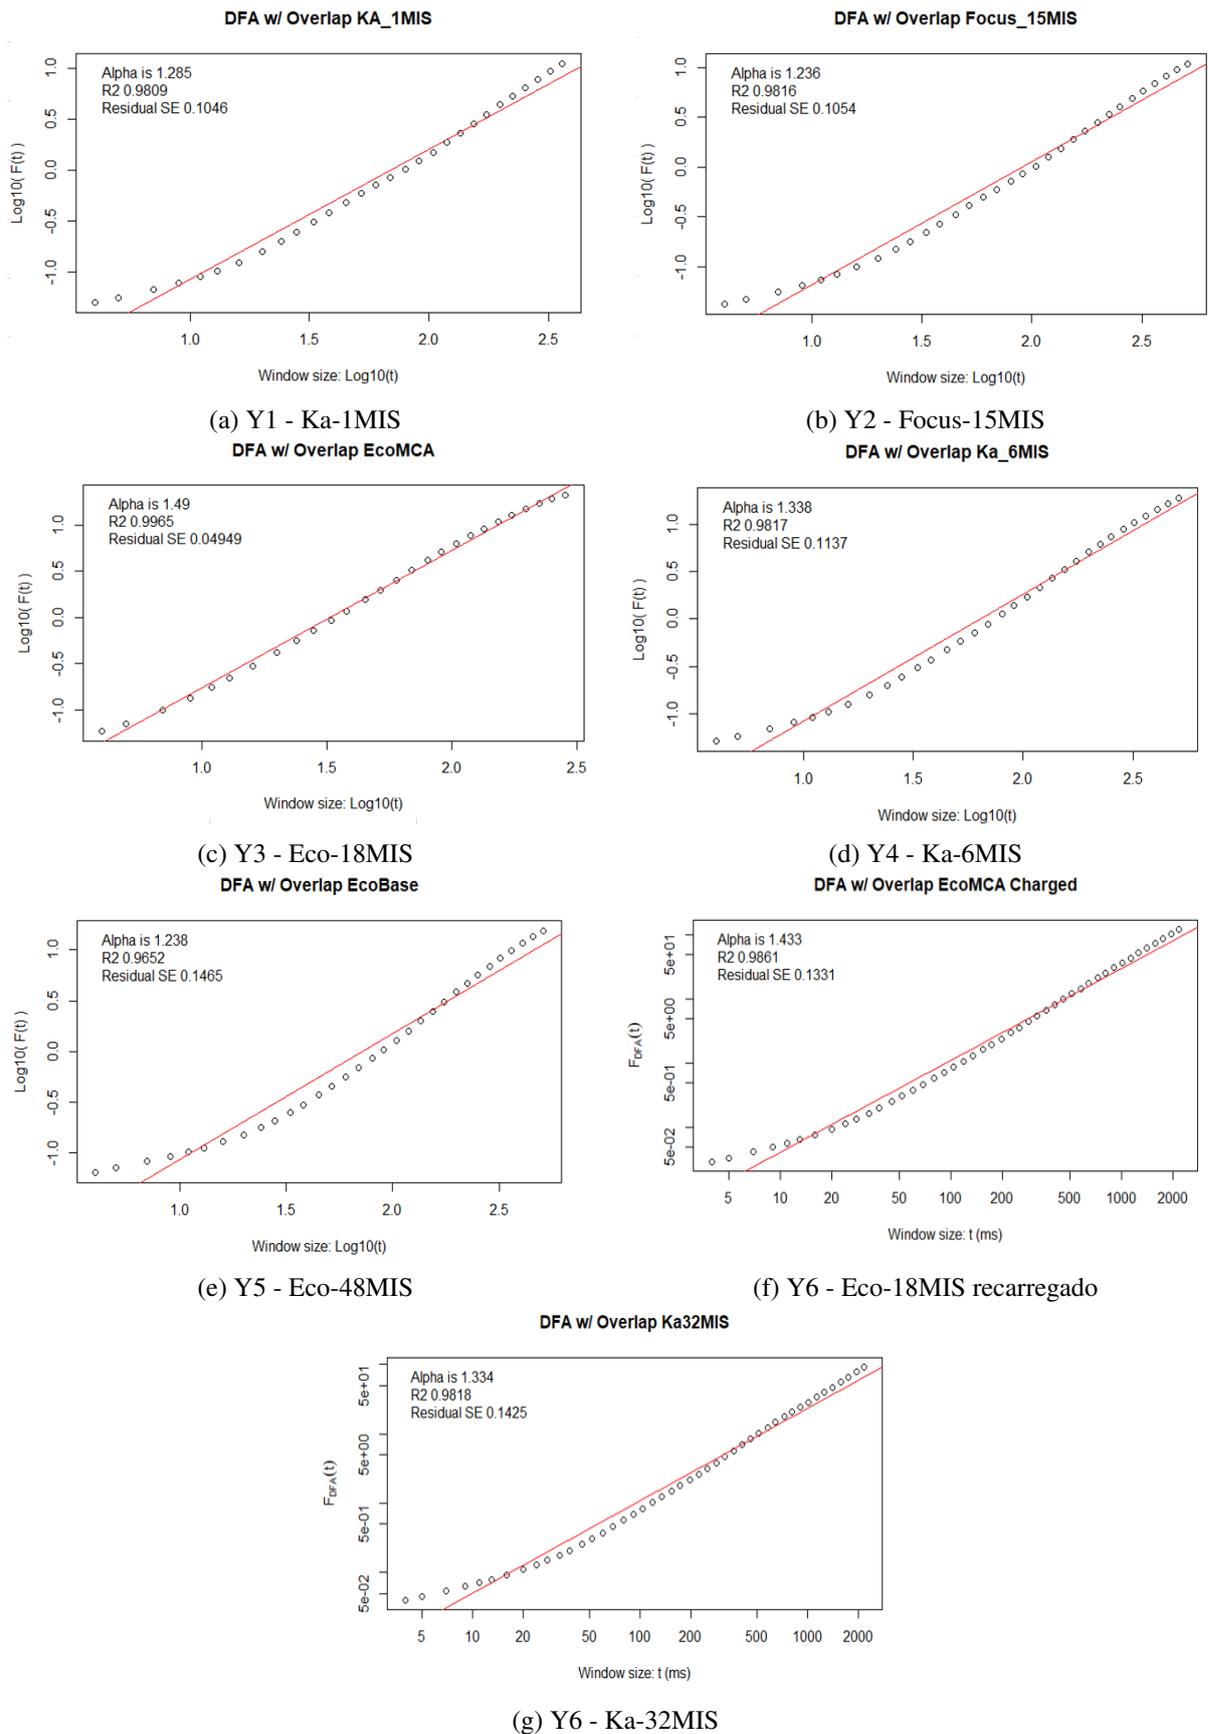


Figura 4.3: Sumário dos DFA. Fonte: Próprio Autor.

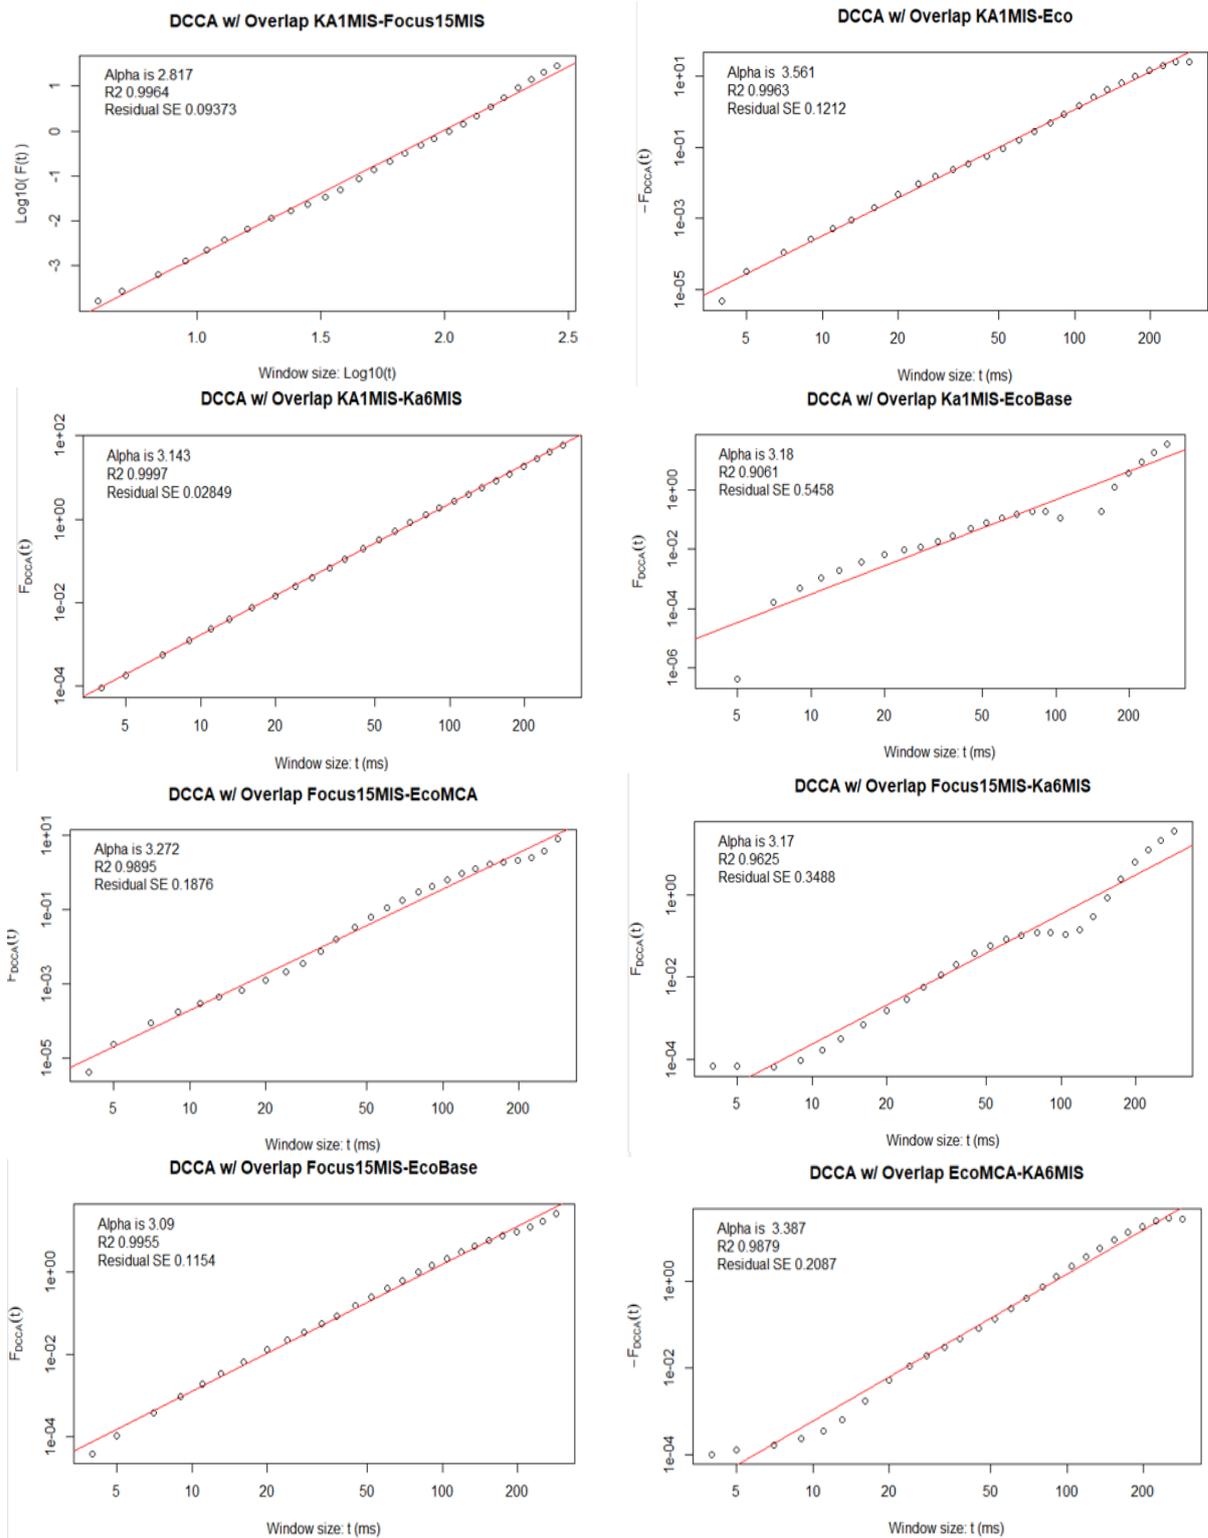


Figura 4.4: Sumário dos DCCA (1). Fonte: Próprio Autor.

- Y1 = Ford Ka 1.5L com 1 mês de uso da bateria;
- Y2 = Ford Focus 2.0L com 15 meses de uso da bateria;
- Y3 = Ford EcoSport 2.0L com SOH deteriorado
- Y4 = Ford Ka 1.5L com 6 meses de uso da bateria;

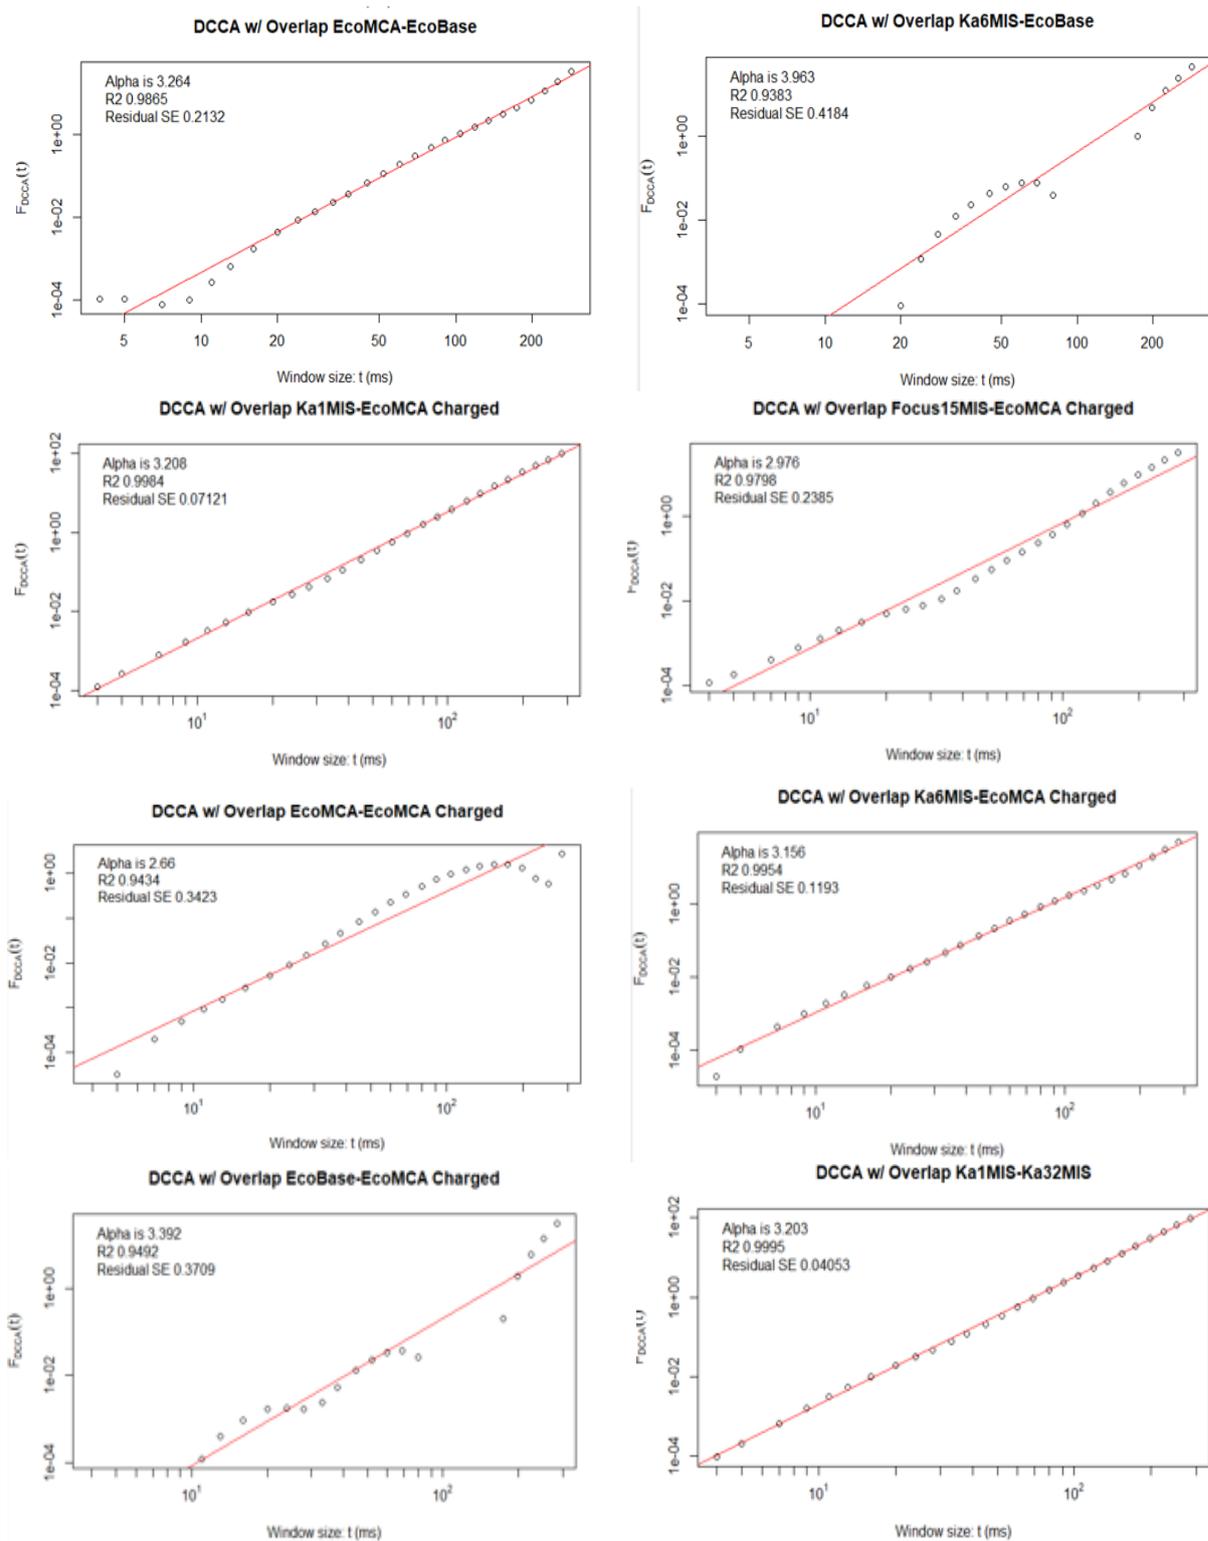


Figura 4.5: Sumário dos DCCA (2). Fonte: Próprio Autor.

Y5 = Ford EcoSport 2.0L com bateria original trocada e em uso da bateria *aftermarket*;

Y6 = Ford EcoSport 2.0L com SOH deteriorado e feita uma recarga do SOC antes da medição;

Y7 = Ford Ka 1.5L com 32 meses de uso da bateria.

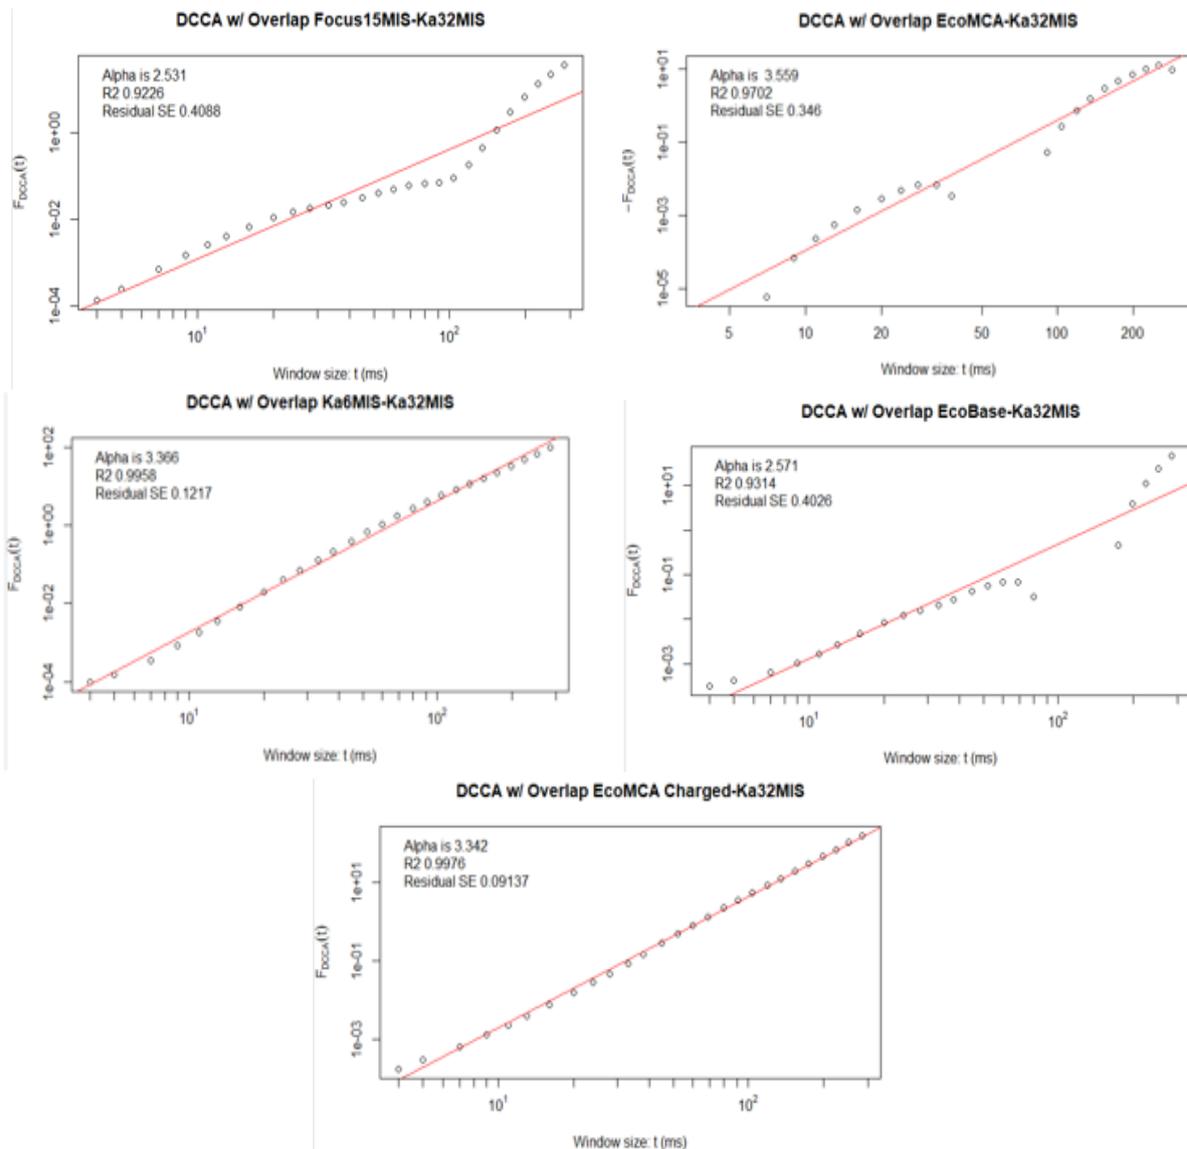


Figura 4.6: Sumário dos DCCA (3). Fonte: Próprio Autor.

Dentro das observações iniciais, é possível notar uma pseudo formação de 3 grupos nesse fluxo de crescimento do ρ_{DCCA} . O primeiro grupo formado pelos pares "Y1-Y4" e "Y2-Y5". Ao analisar esse primeiro grupo, observa-se um crescimento rápido do coeficiente de correlação cruzada, mantendo-se assim nos demais crescimento de janela, chegando a valores máximos de 0,58 e 0,72. Ao fazer uma análise nas características dos veículos e os resultados, percebemos que nos 2 casos existe uma semelhança no motor utilizado, no caso de "Y1-Y4" o motor 1.5L e 2.0L para "Y2-Y5".

Um segundo grupo de similaridade pode ser observado entre os pares "Y1-Y5", "Y4-Y5", "Y2-Y4" e "Y1-Y2". Nesse grupo, observa-se um início do coeficiente subindo pouco, seguido por uma queda do valor entre 100 e 150 ms de tamanho de janela, e na sequência uma subida seguindo o aumento da janela, chegando a valores do ρ_{DCCA} acima de 0,48. Complementando as análises do indicador com as características dos veículos, notou-se que esse comportamento

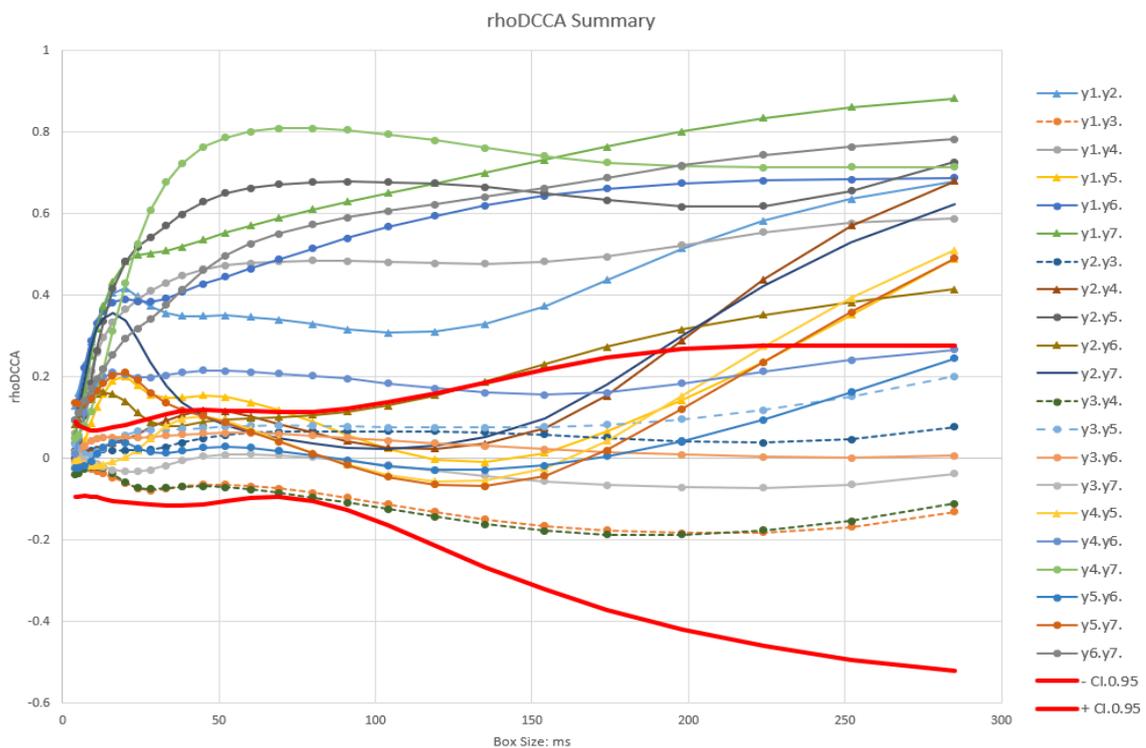


Figura 4.7: Junção dos $\rho DCCA$. Fonte: Próprio Autor

foi característico de comparações entre motores de combustão com diferentes características, ou seja, quando foi comparado veículos 1.5L versus 2.0L, com baterias ainda em funcionamento.

O terceiro grupo identificado tem os seguintes pares como representantes: "Y1-Y3", "Y2-Y3", "Y3-Y4" e "Y3-Y5". A característica principal desse grupo é o fato de os coeficientes sempre estarem dentro do intervalo de confiança de 95%, seguindo com valores baixos e próximos a zero, indicando uma não existência de correlação cruzada entre as séries analisadas. Ao fazer uma análise física para essas curvas, notou-se uma persistência sempre da curva "Y3" versus as demais medidas. O veículo "Y3" apresentava uma bateria mais gasta e com dificuldades de partida realmente durante as experimentações.

4.2 Resultados

Conforme descrito a seguir, foi feita uma separação das amostras, utilizando o motor como fator separador. Nessa etapa, os veículos com motor 1.5L foram comparados com outros veículos com motores 1.5L (figura 4.8a), enquanto que os motores 2.0L foram comparados com os demais motores 2.0L (figura 4.8b). Todas as comparações feitas entre motores 1.5L versus motores 2.0L foram então descartadas nessa etapa da análise e podem ser observadas em detalhes na seção 4.3.

Dentro do comparativo presente nos veículos 1.5L é possível observar uma tendência de cresci-

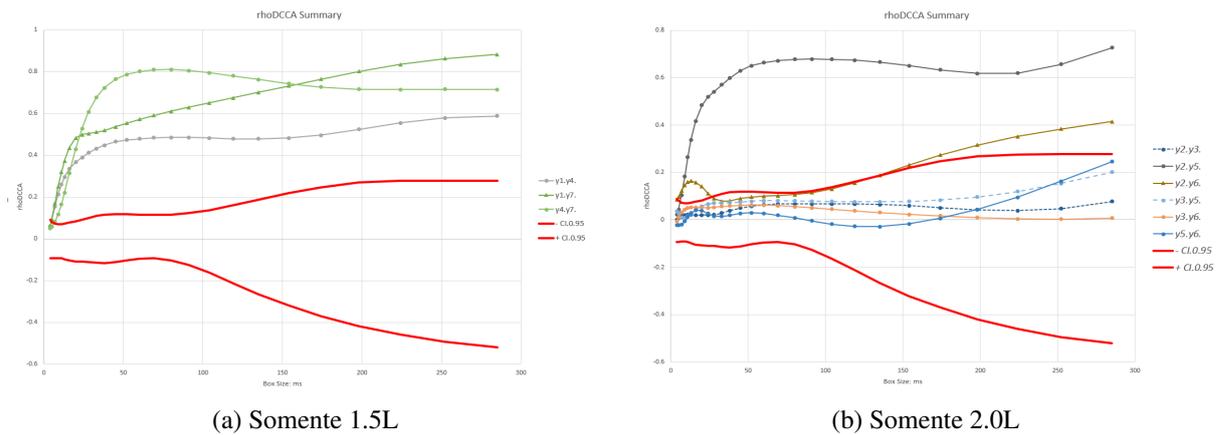


Figura 4.8: Análise do $\rho DCCA$ separando por motores e estado de bateria. Fonte: Próprio Autor.

mento na correlação cruzada entre as curvas de partida, já obtendo valores acima do intervalo de confiança com tamanhos de janela abaixo de 50 e se mantendo no lado positivo até os maiores tamanhos de janela. Ao observar a condição física de resposta do motor, em nenhuma das partidas foi apresentada falha ou algo que pudesse apresentar uma degradação da saúde da bateria, falha essa como por exemplo comparando visualmente as quedas de tensão no osciloscópio similar ao apresentado por Kerley, Hyun e Ha (2015) e apresentado na figura 2.6. As principais diferenças entre as baterias nesse sub-grupo estavam relacionadas ao tempo de uso da bateria, apresentando baterias com 1 mês de uso (Y1), seguido uma bateria com 6 meses de uso (Y4) e uma bateria com 32 meses de uso (Y7).

Nos comparativos dos motores 2.0L, foi observado um comportamento diferente. A curva entre "Y2-Y5" apresenta similaridade das curvas dos motores 1.5L, apresentando valores acima do intervalo de confiança já com tamanhos de janelas menores que 50 e se mantendo assim até o final. Comparando com o comportamento físico, essas 2 curvas representam motores 2.0L funcionando sem problemas durante a partida, com diferença somente no tempo de uso da bateria, tendo a curva "Y2" com 15 meses de uso enquanto a "Y5" apresentava um veículo com 48 meses, já com a bateria trocada por uma de mercado (*Aftermarket*). As demais curvas desse subgrupo apresentam uma característica do $\rho DCCA$ variando dentro, ou muito próximo, dos intervalos de confiança, apresentando baixa correlação cruzada. Nesse subconjunto é possível notar sempre a presença das curvas "Y3" ou "Y6". O veículo "Y3" apresenta uma bateria com o SOH deteriorado, ainda capaz de executar a partida, enquanto o veículo "Y6" representa o mesmo veículo com uma recarga e seguido de uma partida, sem respeitar um intervalo de 12 horas de repouso, ou seja, com SOC alto dentro de uma bateria com SOH baixo.

4.3 Limitações

Ao fazer a análise do $\rho DCCA$, comparando veículo com motor 1.5L versus 2.0L, ou seja forçando uma comparação cruzada entre conjuntos de partidas diferentes, foram obtidos resultados

não conclusivos, apresentando um conjunto de dados calculados sem valor no efeito observado, como podem ser vistos nas figuras 4.9a e 4.9b

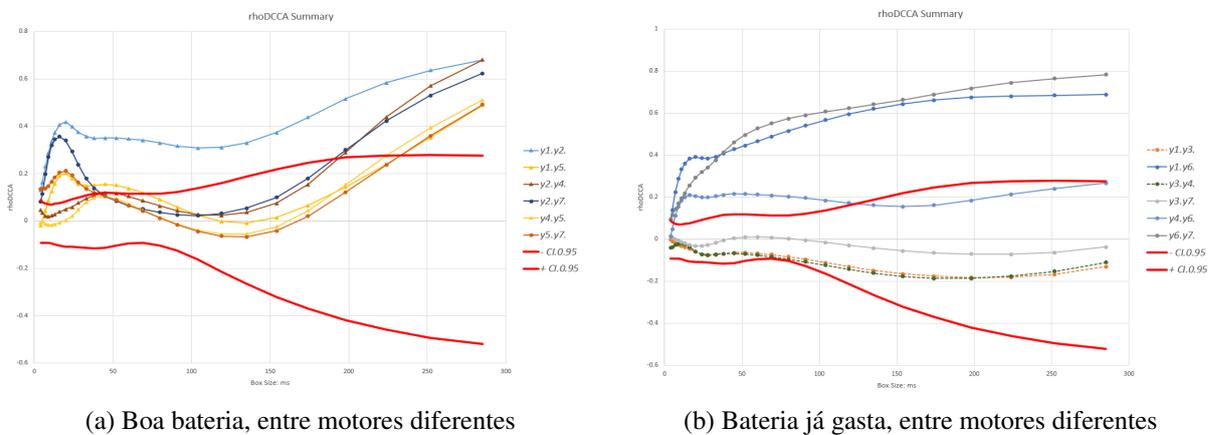


Figura 4.9: Análise do $\rho DCCA$ separando por motores diferentes e estado de bateria. Fonte: Próprio Autor.

Nessa análise, não se pôde observar uma tendência clara do $\rho DCCA$ que possa auxiliar em uma conclusão. Pode-se observar uma tendência de subida para comparação entre baterias boas, mas ao comparar com baterias com o SOH desgastado, a dispersão de resultados foi muito grande. Dessa forma, para manter um nível reduzido de dispersão para baterias gastas, essas comparações foram consideradas como limitações do modelo.

Essa limitação reforça que para trabalhos futuros de implementação embarcada nas ECUs do veículo, a estratégia deve considerar análises comparativas dentro do mesmo veículo, considerando um armazenamento dos dados da curva do momento de primeira partida do veículo com a bateria nova para ser utilizado como referência no uso do $\rho DCCA$, seguido de medições sistemáticas ao longo da vida. Importante considerar uma potencial atualização dessa curva de referência no momento que a bateria é desconectada e trocada. É preciso confirmar que nesse momento de desconexão e reconexão que tipo de bateria foi alocada no veículo, ou seja comparar se a curva de partida atinge níveis de queda de tensão compatíveis com o de uma bateria nova ou se foi colocada uma outra bateria gasta, ou até a mesma bateria existente no carro.

4.4 Discussão

O primeiro ponto de destaque tem relação com a preparação do veículo a ser testado. Deixar o veículo em repouso de pelo menos 12 horas, mostrou-se interessante, mas não totalmente mandatória, removendo um dos ruídos conhecidos em baterias de chumbo-ácido no uso automotivo chamado de tensão residual. Essa importância pôde ser confirmada quando as curvas de tensão Y3 e Y6 são apresentadas na figura 4.2, apresentando a curva "Y6" com valores maiores que a curva "Y3" durante as quedas de tensão no momento da partida, no entanto quando foi observada as avaliações do $\rho DCCA$ de veículos com SOH satisfatórios versus as curvas Y6 ou

Y3 mostrou-se predominantemente a não existência de correlação cruzada, como apresentado na figura 4.8b, o que demonstrou uma robustez do modelo nessa avaliação.

Um segundo ponto importante de destacar é a importância dos tratamentos dos dados antes da execução dos testes estatísticos. Foi definida uma taxa de amostragem de 1 ms, fazendo uma redução no tamanho dos dados dentro da janela de aquisição feita inicialmente com o osciloscópio, o que permitiu um alinhamento mais simples entre o ponto zero de cada uma das séries temporais medidas, permitindo manter o mesmo *trigger* entre todas as aquisições. Essa taxa de amostragem também se torna importante definir para permitir um estudo de implementação dentro das limitações de velocidade de comunicações existentes entre a BCM e o BMS dentro do veículo, através de uma comunicação LIN, ficando como tema para definição em próximas pesquisas e desenvolvimentos, levando em consideração um balanço entre processamento, tamanho de *buffer*, definição de qual ECU receberá a lógica implementada e a velocidade máxima de transferência do protocolo LIN versus o tamanho do dado coletado.

O trabalho apresentado por [Chamusca et al. \(2020\)](#) trouxe informações importantes sobre a variação da resistência interna da bateria, utilizando dados gravados nos módulos eletrônicos dos veículos, no entanto esses dados não foram suficientes para detecção com uma maior acurácia da deterioração do SOH da bateria, conforme apresentado na figura 2.8 na distribuição de resistência por tempo em serviço. Os estudos com séries temporais, baseado na variação de tensão, apresentado nessa dissertação se apresenta como uma alternativa nessa detecção ao longo do uso. Isso não descarta a possibilidade de estudos futuros utilizando uma junção dessas informações.

Foi observado um comportamento subdifusivo em todas as curvas de partidas, sempre com valores do α do DFA entre 1 e 1,5. Enquanto foi observado um comportamento superdifusivo em todos os valores do α do DCCA, sendo que em 3 dos casos foi necessário calcular o α do $-F_{DCCA}$.

Os cálculos e gráficos gerados do ρ_{DCCA} apresentaram uma maior relevância para essa pesquisa. Ao analisar graficamente o comportamento da mudança do coeficiente para cada tamanho de janela, diversas conclusões foram alcançadas e algumas limitações do modelo foram observadas. Começando pelas limitações, o modelo não se mostrou robusto para comparar curvas de partidas entre motores diferentes, trazendo curvas com interpretações controversas, principalmente quando foi feita a comparação com veículos com baterias com o estado de saúde deteriorado, vide figura 4.9b. Por outro lado, quando a comparação foi feita entre veículos com a mesma motorização, o resultado de existência ou não existência de correlação cruzada seguiu a definição do estado de saúde da bateria, como observado nas figuras 4.8a e 4.8b.

Esse trabalho se caracteriza como a primeira aplicação envolvendo o uso do ρ_{DCCA} dentro da engenharia automotiva para análise de desgaste de baterias, norteando uma possibilidade de

controle para a indústria automotiva. Com esse trabalho, é possível confirmar que o uso das técnicas de sistemas complexos pode ser adicionado como uma ferramenta de investigações e resoluções de problemas, trazendo a base estatística para auxílio a tomada de decisão.

Considerações finais

Esse trabalho tem como objetivo avaliar o estado de saúde (SOH) de baterias de chumbo-ácido, utilizando séries temporais. Esse objetivo foi alcançado nesse trabalho, principalmente nas avaliações utilizando o $\rho DCCA$.

O uso das teorias de sistemas complexos pode adicionar valor dentro do fluxo de investigação e desenvolvimento de produtos industriais. No caso desse trabalho, a utilização das teorias de rede no momento inicial refletido no artigo publicado por [Costa et al. \(2020\)](#), ajudando a confirmar que um nível de conhecimento satisfatório sobre o tema, incluindo o uso no veículo e os estudos acadêmicos realizados, foi de muito valor para robustecer a confiança que o trabalho estava seguindo na direção correta, mesmo sem ter completado o total de aquisição de dados necessários para realizar os cálculos e análises estatísticas do DFA, DCCA e $\rho DCCA$. Essa fase inicial ajudou na definição do momento mais relevante para fazer a aquisição das curvas da bateria, no caso desse estudo o momento da partida do motor a combustão.

Os valores observados de DFA mostraram que a curva de tensão durante a partida do veículo apresenta um comportamento subdifusivo, independente do estado de saúde (SOH) da bateria. Já os valores observados de DCCA apresentaram um comportamento superdifusivo.

O comparativo do $\rho DCCA$ entre uma bateria com SOH com sinais de deterioração e uma sem sinais de deterioração, dentro de uma mesma motorização não apresentou existência de correlação cruzada, enquanto as comparações entre baterias com SOH satisfatório apresentaram correlação cruzada desde pequenos tamanhos de janela. Essa diferença de comportamento permitiu segregar baterias com SOH satisfatório versus baterias com SOH desgastados, próximo ao fim de vida útil, mesmo a bateria ainda sendo capaz de partir o motor a combustão.

Esse estudo apresenta limitações. Ele não foi capaz de apresentar uma diferenciação clara de comportamento do $\rho DCCA$ no comparativo entre veículos com motorizações diferentes.

Existem ainda muitos passos para o aprimoramento desse estudo e obtenção de uma modelagem mais precisa, que estão relatados na seção [5.3](#).

A metodologia adotada nesse trabalho se caracterizou como a primeira aplicação envolvendo o $\rho DCCA$ dentro da engenharia automotiva para avaliação de baterias, norteando a possibilidades de monitoramento de especificações de engenharia com técnicas de sistemas complexos.

5.1 Conclusões

Nesse trabalho foi confirmado que ao utilizar os estudos de séries temporais de longo alcance, sendo mais específico o $\rho DCCA$, é possível criar um modelo que possa diferenciar o *State of Health* de baterias satisfatórias versus baterias com o SOH já desgastado, no uso automotivo.

No estudo foi apresentado que obter um conhecimento satisfatório do tema, antes de partir para aquisição de dados, fez toda a diferença, evitando retrabalhos na fase de aquisição de dados. Para essa preparação vale apenas destacar o estudo cognitivo do tema, a definição do momento de medição da série temporal da tensão da bateria, a definição de quais condições prévias da medição seriam necessárias, além do ajuste da taxa de amostragem para a tensão da bateria, preparação e validação de um *script* em R, monitorar o ambiente para possíveis anomalias que pudessem atrapalhar o estudo entre diversos outros pensamentos ligados ao planejamento.

Na análise individual de cada veículo medido, foi observado um α do DFA subdifusivo, com um R^2 acima de 0,96 e valores de erros residuais abaixo de 0,15. Os valores de α das baterias com SOH desgastado apresentaram uma tendência de ser maior, estando com um α acima de 1,4, ainda dentro da faixa de comportamento subdifusivo.

Ao analisar as curvas do coeficiente do DCCA, esse é o momento que começa a ficar mais intuitiva as observações. Primeiramente, ao adicionar todas as combinações possíveis, essa conclusão ainda não é possível, pois existem muitos fatores geradores de ruído misturado as curvas. Ao fazer um detalhamento de comparações entre motores iguais, aparece uma tendência de diferença entre baterias com SOH satisfatória e desgastadas. A comparação cruzada entre veículos com baterias satisfatória apresenta correlação cruzada positiva, enquanto a comparação entre veículos com pelo menos um dos dois com bateria com o SOH desgastado apresenta a ausência de correlação cruzada, ficando predominantemente dentro do intervalo de confiança. Nesse momento, foi possível observar que uma bateria do mercado de reposição, ainda com um SOH satisfatória, também seguiu essa tendência da curva do $\rho DCCA$.

Uma tentativa de generalização do estudo também foi feita, ao verificar a correlação cruzada entre motorizações diferentes, no entanto os resultados dessa linha de investigação não foram suficientes para explicar uma diferenciação de baterias com SOH satisfatório e desgastado, entrando como uma limitação do uso do modelo.

Analisando por uma outra perspectiva, a abordagem feita nessa dissertação, no qual juntou os conhecimentos do meio automotivo com técnicas desenvolvidas para análises de séries temporais, se encaixa como uma das primeiras aplicações das técnicas de sistemas complexos dentro de estudos de engenharia automotiva.

5.2 Contribuições

Os resultados alcançados apresentam uma inovação metodológica focando em investigações preditivas, para investigações no âmbito da engenharia. Sabe-se que esse é o passo inicial, abrindo espaço para muitas outras investigações e evoluções dos estudos preditivos baseado em séries temporais.

Do ponto de vista de trabalhos técnicos, a pesquisa apresenta um novo caminho para desenvolvimento de algoritmos de controle para um gerenciamento mais aprimorado de baterias. Ainda tendo muita coisa a ser feita, antes de ofertar como uma nova funcionalidade dentro dos veículos.

Essa pesquisa também apresenta um caminho tecnológico a ser seguido para adição de um indicador de saúde de bateria em veículos, podendo permitir um alerta ao motorista do veículo de como está a saúde da bateria no que diz respeito a capacidade de partir o veículo, possibilitando um planejamento de troca da mesma, antes que ela alcance o seu completo fim de vida útil.

5.3 Atividades Futuras de Pesquisa

A pesquisa pode continuar com o intuito de entender os resultados da partida sobre diferentes fontes de ruído como, por exemplo, em condições temperatura ambiente diferentes, levando o veículo para testes em temperaturas negativas. Nessa pesquisa os testes foram feitos com temperaturas variando entre 25°C e 32°C. Outro ruído interessante é entender as variações nas curvas de partida para diferentes níveis de estado de carga da bateria (SOC). Outra oportunidade de atividade é correlacionar os valores do ρ DCCA, juntamente com valores de resistência interna da bateria (baseado na tensão e corrente elétrica), permitindo uma análise ao longo do tempo da variação desses indicadores.

Importante destacar que precisa ser feito um estudo de implementação nas ECUs do veículo, detalhando a taxa de amostragem de aquisição, velocidade de transferência, tratamento e cálculo dos dados, incluindo estratégia de informação para o motorista do veículo. Esse detalhamento permitirá a evolução dessa linha de pesquisa com crescimento do nível TRL (*technology readiness level*) dessa proposta.

Essa metodologia também se mostra promissora para outros usos, além do automotivo, em que baterias de chumbo-ácido possam ser utilizadas para comando de motores elétricos. Nesses outros equipamentos, também se espera uma curva de queda de tensão no momento de acionamento do motor, removendo o mesmo da inércia. Vale destacar que todo delineamento precisa ser ajustado nessa linha.

Script para cálculo do DFA, DCCA e ρ DCCA no R

```

# -----
# Calcular DFA, DCCA e rhoDCCA de uma serie Temporal -----
# Autor: Roberto C Costa, 01/AUG/2020 -----
# Ultima atualizacao: 29/JAN/2021 -----
# -----
# Instalacao de pacotes para trabalhar com DFA/DCCA -----

# setRepositories() # Define repositórios para pesquisar
chooseCRANmirror() # Escolhido Brazil
# ap <- available.packages()

install.packages("DCCA")
library(DCCA)

install.packages("GMZTests")
library(GMZTests)

##### DCCA Package -----
# Input Data:
y1 <- scan()
boxsize <- scan()

#### DFA calculation inside DCCA package
F2.dfa <- F2dfa(y1, m = boxsize, nu = 0, overlap = TRUE)
# EF2dfa(m = 3, nu = 0, G, K = NULL)
F.dfa <- sqrt(F2.dfa) # Precisa obter a raiz para comparar com o EXE

# Plotando grafico DFA
linear1 <- lm(log10(F.dfa) ~ log10(boxsize))
plot(boxsize, F.dfa, log = 'xy',
      main="DFA_w/_Overlap_Adj_EcoBase",
      ylab=expression(F[DFA](t)), xlab="Window_size:_t_(ms)")
abline(lm(log10(F.dfa) ~ log10(boxsize)), col="red") # adiciona linha
legend("topleft", bty="n", legend=c(paste("Alpha_is", format(linear1$coefficients[2],
      digits=4)), # Add Alpha
      paste("R2", format(summary(linear1)$r.squared, digits=4)),
      # Add R-square
      paste("Residual_SE", format(summary(linear1)$sigma, digits=4))))
# Add Residual Std. Error

# Estudo Calculo do Erro
summary(linear1)
sigma(linear1) # Residual Standard Error
summary(linear1)$sigma # Residual Std. Error
summary(linear1)$r.squared # R2
summary(linear1)$adj.r.squared # R2 adjusted

# Exportando tabela como dataframe
temp <- data.frame(
  boxsize,
  F2.dfa,
  F.dfa,
  log10(boxsize),

```

```

log10(F.dfa))

##### DCCA no package DCCA
y1 = scan() #Ka 1MIS
y2 = scan() #focus 15MIS
y3 = scan() #ecoMCA deadBatt
y4 = scan() #ka 6MIS
y5 = scan() #EcoBase
boxsize <- scan()

F.dcca = Fdcca(y1, y2, m = boxsize, nu = 0, overlap = TRUE)
F.dcca <- data.frame(F.dcca)

# Plotando grafico para dados positivos
linear2 <- lm(log10(F.dcca$F.dcca) ~ log10(boxsize))
#plot (boxsize, F.dcca$F.dcca)
plot(boxsize, F.dcca$F.dcca, log = 'xy', xaxt = "n",
      main="DCCA_w/_Overlap_Ka1MIS-EcoBase",
      ylab=expression(F[DCCA](t)), xlab="Window_size:_t_(ms)")
abline(lm(log10(F.dcca$F.dcca) ~ log10(boxsize)), col="red") # adiciona linha
legend("topleft", bty="n", legend=c(paste("Alpha_is", format(linear2$coefficients[2],
      digits=4)), # Add Alpha
      paste("R2", format(summary(linear2)$r.squared, digits=4)),
      # Add R-square
      paste("Residual_SE", format(summary(linear2)$sigma, digits=4))))
      # Add Residual Std. Erro

# Adicionar marcas logaritimas
at.x <- outer(1:9, 10^(0:log10(100)))
lab.x <- ifelse(log10(at.x) %% 1 == 0,
              sapply(at.x, function(i)
                    as.expression(bquote(10^(log10(i))))), NA)
axis(1, at = at.x, labels = lab.x, las = 1)

# Plotando para dados negativos
linear2 <- lm(log10(-F.dcca$F.dcca) ~ log10(boxsize))
plot(boxsize, -F.dcca$F.dcca, log = 'xy',
      ylab = expression(-F[DCCA](t)), xlab="Window_size:_t_(ms)")
title(main="DCCA_w/_Overlap_Ka1MIS-EcoBase")
abline(lm(log10(-F.dcca$F.dcca) ~ log10(boxsize)), col="red") # adiciona linha
legend("topleft", bty="n", legend=c(paste("Alpha_is_",
      format(linear2$coefficients[2], digits=4)),
      # Add Alpha
      paste("R2", format(summary(linear2)$r.squared, digits=4)),
      # Add R-square
      paste("Residual_SE", format(summary(linear2)$sigma, digits=4))))
      # Add Residual Std. Erro

#Exportando tabela
tempDCCA_FOCUS <-data.frame(
  boxsize,
  F.dcca,
  log10(boxsize),
  log10(F.dcca))

##### rhoDCCA no packate DCCA
#y1 = raw$KA
#y2 = raw$KA
rho.all <- data.frame(boxsize)

```

```
rho.dccam = rhodcca(y4, y5, m = boxsize, nu = 0, overlap = TRUE)
rho.dccam <- data.frame(rho.dccam)
  colnames(rho.dccam)[4] <-"y4,y5"
rho.all <- data.frame(rho.all, rho.dccam$`y4,y5`)

# Plotando grafico _ Adicionar marcas logaritimias
plot(boxsize, rho.dccam$rhodcca, main = expression(paste(rho,
"DCCA_w/_Overlap:_Ka6MIS-EcoBase")),
  ylab=expression(paste(rho, "DCCA")), xlab="Window_size:_t_(ms)",
  log = 'x', xaxt = 'n', type = 'o')
at.x <- outer(1:9, 10^(0:log10(100)))
lab.x <- ifelse(log10(at.x) %% 1 == 0,
  sapply(at.x, function(i)
    as.expression(bquote(10^(log10(i))))), NA)
axis(1, at = at.x, labels = lab.x, las = 1)

# Plot rhoDCCA
plot(rho.all$boxsize, rho.all$rho.dccam..y1.y2., type = 'o', col=1, ylim = c(-1,1))
lines(rho.all$boxsize, rho.all$rho.dccam..y1.y3., type = 'o', col=2)
lines(rho.all$boxsize, rho.all$rho.dccam..y1.y4., type = 'o', col=3)
lines(rho.all$boxsize, rho.all$rho.dccam..y1.y5., type = 'o', col=4)
lines(rho.all$boxsize, rho.all$rho.dccam..y2.y3., type = 'o', col=5)
lines(rho.all$boxsize, rho.all$rho.dccam..y2.y4., type = 'o', col=6)
lines(rho.all$boxsize, rho.all$rho.dccam..y2.y5., type = 'o', col=7)
lines(rho.all$boxsize, rho.all$rho.dccam..y3.y4., type = 'o', col=8)
lines(rho.all$boxsize, rho.all$rho.dccam..y3.y5., type = 'o', col=9)
lines(rho.all$boxsize, rho.all$rho.dccam..y4.y5., type = 'o', col=10)

# Remocao provisoria para rodar um novo estudo
rm(list = 'F.dcca')
rm(list = 'linear1')
rm(list = 'linear2')
rm(list = 'F.dfa')
rm(list = 'F2.dfa')
rm(list = 'x')
rm(list = 'y')
rm(list = 'boxsize')
rm(list = 'rho.dccam')

# END Package DCCA

##### GMZ Tests. -----
GMZ <- rhodcca.test(N=1192, k=4, nu=0, rep=10)
GMZ1 <-data.frame(GMZ$CI_0.95)
GMZ1
```

Referências Bibliográficas

- ADARSH, S. et al. Multifractal description of daily rainfall fields over India. **Journal of Hydrology**, Elsevier, v. 586, p. 124913, 2020. [2.2.1](#)
- AZEVEDO, G. A. et al. Sustainable urban mobility analysis for elderly and disabled people in São Paulo. **Scientific reports**, Nature Publishing Group, v. 11, n. 1, p. 1–10, 2021. [2.2.2](#)
- BALKISSOON, S.; FOX, N.; LUPO, A. Fractal characteristics of tall tower wind speeds in Missouri. **Renewable Energy**, Elsevier, v. 154, p. 1346–1356, 2020. [2.2.1](#)
- BASHIR, U. et al. Differential market reactions to pre and post Brexit referendum. **Physica A: Statistical Mechanics and its Applications**, Elsevier, v. 515, p. 151–158, 2019. [2.2.2](#)
- BLANKE, H. et al. 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**, Elsevier, v. 144, n. 2, p. 418–425, 2005. [2.1.3](#)
- BRESSANINI, G. L.; BUSARELLO, T. D.; PERES, A. Design and implementation of lead-acid battery state-of-health and state-of-charge measurements. In: IEEE. **2017 Brazilian Power Electronics Conference (COBEP)**. [S.l.], 2017. p. 1–6. [2.1.3](#)
- CAI, Y. et al. Exploring the dynamic relationship between crude oil price and implied volatility indices: A MF-DCCA approach. **Physica A: Statistical Mechanics and its Applications**, Elsevier, v. 536, p. 120973, 2019. [2.2.1](#)
- CALBOREAN, A. et al. Resonance frequency analysis of lead-acid cells: An EIS approach to predict the state-of-health. **Journal of Energy Storage**, Elsevier, v. 27, p. 101143, 2020. [2.1.3](#)
- CHAMUSCA, I. et al. Development of a method for identifying the state of health in automotive batteries of the lead-acid type. 2020. 10.5151/siintec2020-DEVELOPMENTOFAMETHOD. ([document](#)), [2.1.3](#), [2.7](#), [2.8](#), [4.4](#)
- CHEN, H.; ZHU, L.; JIA, G. MF-DCCA between molecular properties and aqueous solubility. **Physica A: Statistical Mechanics and its Applications**, Elsevier, v. 556, p. 124708, 2020. [2.2.1](#)
- CHEN, Y. et al. DCCA cross-correlation coefficients reveals the change of both synchronization and oscillation in EEG of Alzheimer disease patients. **Physica A: Statistical Mechanics and its Applications**, Elsevier, v. 490, p. 171–184, 2018. [2.2.2](#)
- CHENG, Q.; LIU, X.; ZHU, X. Cryptocurrency momentum effect: DFA and MF-DFA analysis. **Physica A: Statistical Mechanics and its Applications**, Elsevier, v. 526, p. 120847, 2019. [2.2.1](#)
- CHUMCHAL, C.; KURZWEIL, D. Lead–acid battery operation in micro-hybrid and electrified vehicles. In: **Lead-Acid Batteries for Future Automobiles**. [S.l.]: Elsevier, 2017. p. 395–414. [1](#), [1.3](#), [2.1.2](#), [2.1.2](#), [2.1.2](#)
- COSTA, R. C. et al. Modeling battery live cycle data with temporal series: A network theory approach. 2020. 10.5151/siintec2020-MODELINGBATTERY. ([document](#)), [3.1](#), [3.1](#), [3.1](#), [3.2](#), [5](#)

- CULPIN, B.; RAND, D. Failure modes of lead/acid batteries. **Journal of power sources**, Elsevier, v. 36, n. 4, p. 415–438, 1991. [1](#)
- DAVID, S. et al. Measuring the Brazilian ethanol and gasoline market efficiency using DFA-Hurst and fractal dimension. **Energy Economics**, v. 85, p. 104614, 2020. ISSN 0140-9883. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0140988319304098>. [2.2.1](#)
- DAVID, S. et al. A combined measure to differentiate EEG signals using fractal dimension and MF DFA-Hurst. **Communications in Nonlinear Science and Numerical Simulation**, v. 84, p. 105170, 2020. ISSN 1007-5704. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1007570420300058>. [2.2.1](#)
- DENUTO, J. V. et al. LIN bus and its potential for use in distributed multiplex applications. **SAE transactions**, JSTOR, p. 135–142, 2001. [2.1.2](#)
- FERREIRA, P.; KRISTOUFEK, L.; PEREIRA, E. J. d. A. L. DCCA and DMCA correlations of cryptocurrency markets. **Physica A: Statistical Mechanics and its Applications**, Elsevier, v. 545, p. 123803, 2020. [2.2.1](#)
- FERREIRA, P. et al. Are renewable energy stocks a possibility to diversify portfolios considering an environmentally friendly approach? the view of DCCA correlation coefficient. **Physica A: Statistical Mechanics and its Applications**, Elsevier, v. 512, p. 675–681, 2018. [2.2.2](#)
- FERREIRA, P. et al. Detrended correlation coefficients between oil and stock markets: The effect of the 2008 crisis. **Physica A: Statistical Mechanics and its Applications**, Elsevier, v. 517, p. 86–96, 2019. [2.2.2](#)
- GELBKE, M.; MONDOLONI, C. Flooded starting-lighting-ignition (SLI) and enhanced flooded batteries (EFBs): state-of-the-art. **Lead-Acid Batteries for Future Automobiles**, Elsevier, p. 149–184, 2017. [1](#), [1.3](#), [2.1.1](#), [2.1.1](#), [2.1.2](#), [2.1.2](#)
- GUEDES, E. et al. DCCA cross-correlation in blue-chips companies: A view of the 2008 financial crisis in the eurozone. **Physica A: Statistical Mechanics and its Applications**, Elsevier, v. 479, p. 38–47, 2017. [2.2.1](#)
- HE, S.; ZHAO, H. Automatic syllable segmentation algorithm of Chinese speech based on MF-DFA. **Speech communication**, Elsevier, v. 92, p. 42–51, 2017. [2.2.1](#)
- HENRICE JR, E. et al. Support to the identification of anomalies in an external neutron source using Hurst exponents. **Progress in Nuclear Energy**, Elsevier, v. 99, p. 119–126, 2017. [2.2.1](#)
- HU, K. et al. Effect of trends on detrended fluctuation analysis. **Physical Review E**, APS, v. 64, n. 1, p. 011114, 2001. [2.2.1](#)
- HURST, H. E. Long-term storage capacity of reservoirs. **Transactions of the American society of civil engineers**, American Society of Civil Engineers, v. 116, n. 1, p. 770–799, 1951. [2.2](#), [2.2.1](#)
- HYUN, J. H. **State of Health Estimation System for Lead-Acid Car Batteries Through Cranking Voltage Monitoring**. Tese (Doutorado) — Virginia Tech, 2016. [2.1.3](#)
- I-KUN, T.; INAMORI, M.; MORIMOTO, M. SOH estimation of lead acid battery by artificial deterioration. In: **2014 17th International Conference on Electrical Machines and Systems (ICEMS)**. [S.l.: s.n.], 2014. p. 861–864. ([document](#)), [2.1.1](#), [2.2](#)

- INDUSTRIAL, S. de Desenvolvimento e C. 2018. Acessado em: 22-Mar-2021. Disponível em: <<https://www.gov.br/produktividade-e-comercio-exterior/pt-br/assuntos/noticias/mdic/competitividade-industrial/rota-2030>>. 1.3
- KERLEY, R.; HYUN, J. H.; HA, D. S. Automotive lead-acid battery state-of-health monitoring system. In: IEEE. **IECON 2015-41st Annual Conference of the IEEE Industrial Electronics Society**. [S.l.], 2015. p. 003934–003938. (document), 2.6, 2.1.3, 4.2
- KHALEGHI, S. et al. Developing a real-time data-driven battery health diagnosis method, using time and frequency domain condition indicators. **Applied Energy**, Elsevier, v. 255, p. 113813, 2019. 2.1.3
- KUMAR, B.; KHARE, N.; CHATURVEDI, P. FPGA-based design of advanced BMS implementing SoC/SoH estimators. **Microelectronics Reliability**, Elsevier, v. 84, p. 66–74, 2018. 2.1.3
- KWIECIEN, M. et al. Current research topics for lead–acid batteries. In: **Lead-Acid Batteries for Future Automobiles**. [S.l.]: Elsevier, 2017. p. 133–146. 2.1.3
- LI, J.; SHI, Y.; CAO, G. Topology structure based on detrended cross-correlation coefficient of exchange rate network of the belt and road countries. **Physica A: Statistical Mechanics and its Applications**, Elsevier, v. 509, p. 1140–1151, 2018. 2.2.2
- LI, S.; LU, X.; LIU, X. Dynamic relationship between Chinese RMB exchange rate index and market anxiety: A new perspective based on MF-DCCA. **Physica A: Statistical Mechanics and Its Applications**, Elsevier, v. 541, p. 123405, 2020. 2.2.1
- LI, W. et al. Digital twin for battery systems: Cloud battery management system with online state-of-charge and state-of-health estimation. **Journal of Energy Storage**, Elsevier, v. 30, p. 101557, 2020. 2.1.3
- LI, Y. et al. Identification of the battery state-of-health parameter from input–output pairs of time series data. **Journal of Power Sources**, Elsevier, v. 285, p. 235–246, 2015. 2.1.3
- LI, Y. et al. Real-time estimation of lead-acid battery parameters: A dynamic data-driven approach. **Journal of Power Sources**, Elsevier, v. 268, p. 758–764, 2014. 2.1.3
- LIANG, Y.; LIU, S.; ZHANG, S. Geary autocorrelation and DCCA coefficient: Application to predict apoptosis protein subcellular localization via PSSM. **Physica A: Statistical Mechanics and its Applications**, Elsevier, v. 467, p. 296–306, 2017. 2.2.2
- LIU, X.; LIN, A.; LI, S. Classification of international stock markets through MDS based on hurst-surface distance. **Physica A: Statistical Mechanics and its Applications**, Elsevier, v. 566, p. 125585, 2021. 2.2.2
- MARCOS, J. et al. Fiber optic sensors for diagnosis and maintenance in lead-acid batteries. **IFAC Proceedings Volumes**, Elsevier, v. 45, n. 31, p. 85–90, 2012. 2.1.3
- MAY, G. Valve-regulated lead-acid batteries for stop-and-go applications. **Journal of power sources**, Elsevier, v. 133, n. 1, p. 110–115, 2004. 2.1.3
- MENSI, W. et al. Modeling cross-correlations and efficiency of islamic and conventional banks from Saudi Arabia: Evidence from MF-DFA and MF-DXA approaches. **Physica A: Statistical Mechanics and its Applications**, Elsevier, v. 502, p. 576–589, 2018. 2.2.1, 2.2.1

- MENSI, W.; HAMDI, A.; YOON, S.-M. Modelling multifractality and efficiency of GCC stock markets using the MF-DFA approach: A comparative analysis of global, regional and Islamic markets. **Physica A: Statistical Mechanics and its Applications**, Elsevier, v. 503, p. 1107–1116, 2018. [2.2.1](#)
- MENSI, W.; VO, X. V.; KANG, S. H. Upside-downside multifractality and efficiency of green bonds: The roles of global factors and COVID-19. **Finance Research Letters**, Elsevier, p. 101995, 2021. [2.2.1](#)
- MOHTI, W. et al. Financial contagion analysis in frontier markets: Evidence from the US subprime and the Eurozone debt crises. **Physica A: Statistical Mechanics and its Applications**, Elsevier, v. 525, p. 1388–1398, 2019. [2.2.2](#)
- MORATÓ, M. et al. Application of generalized hurst dimension rose plot in terrain altitude analysis. **Applied Mathematical Modelling**, Elsevier, v. 81, p. 624–640, 2020. [2.2.1](#)
- MURARI, T. B. et al. Comparative analysis between hydrous ethanol and gasoline c pricing in Brazilian retail market. **Sustainability**, Multidisciplinary Digital Publishing Institute, v. 11, n. 17, p. 4719, 2019. [2.2.2](#)
- MÜRKEN, M. et al. Analysis of automotive lead-acid batteries exchange rate on the base of field data acquisition. In: IEEE. **2018 IEEE International Conference on Electrical Systems for Aircraft, Railway, Ship Propulsion and Road Vehicles & International Transportation Electrification Conference (ESARS-ITEC)**. [S.l.], 2018. p. 1–6. [1.3](#)
- NASCIMENTO FILHO, A. S. Sistemas dinâmicos complexos: teorias e aplicações nas áreas da física, economia e biologia. Centro Universitário SENAI CIMATEC, 2018. ([document](#)), [2.2.1](#), [2.9](#), [2.2.2](#)
- OKORIE, D. I.; LIN, B. Stock markets and the COVID-19 fractal contagion effects. **Finance Research Letters**, Elsevier, v. 38, p. 101640, 2021. [2.2.1](#)
- OKOSHI, T. et al. Battery condition monitoring (BCM) technologies about lead–acid batteries. **Journal of power sources**, Elsevier, v. 158, n. 2, p. 874–878, 2006. [2.1.3](#)
- PAIVA, A. S. S.; RIVERA-CASTRO, M. A.; ANDRADE, R. F. S. DCCA analysis of renewable and conventional energy prices. **Physica A: Statistical Mechanics and its Applications**, Elsevier, v. 490, p. 1408–1414, 2018. [2.2.2](#)
- PENG, C.-K. et al. Mosaic organization of DNA nucleotides. **Physical review e**, APS, v. 49, n. 2, p. 1685, 1994. [2.2.1](#), [2.2.1](#), [2.2.2](#)
- PERAZZO, C.; FERNÁNDEZ, E.; WILLSHAW, P. Determinación de correlaciones a largo plazo utilizando DFA. **Procesamiento de Senales e Imágenes: Teoria y Aplicaciones. Buenos Aires: National Technological University**, p. 297–312, 2004. [2.2.1](#)
- PEREIRA, E. J. d. A. L. et al. Multiscale network for 20 stock markets using DCCA. **Physica A: Statistical Mechanics and its Applications**, Elsevier, v. 529, p. 121542, 2019. [2.2.2](#)
- PEREIRA, H. B. d. B. et al. Semantic networks based on titles of scientific papers. **Physica A: Statistical Mechanics and its Applications**, Elsevier, v. 390, n. 6, p. 1192–1197, 2011. [3.1](#)
- PIŁATOWICZ, G. et al. Determination of the lead-acid battery’s dynamic response using Butler-Volmer equation for advanced battery management systems in automotive applications. **Journal of Power Sources**, Elsevier, v. 331, p. 348–359, 2016. [2.1.3](#)

- PODOBNIK, B. et al. Statistical tests for power-law cross-correlated processes. **Physical Review E**, APS, v. 84, n. 6, p. 066118, 2011. [4.1](#)
- PODOBNIK, B.; STANLEY, H. E. Detrended cross-correlation analysis: a new method for analyzing two nonstationary time series. **Physical review letters**, APS, v. 100, n. 8, p. 084102, 2008. [2.2.1](#), [2.2.2](#)
- PRASS, T. S.; PUMI, G. On the behavior of the DFA and DCCA in trend-stationary processes. **arXiv e-prints**, p. arXiv-1910, 2019. [2.2.1](#)
- ROHIT, A.; MITRA, S. K. The co-movement of monetary policy and its time-varying nature: A DCCA approach. **Physica A: Statistical Mechanics and its Applications**, Elsevier, v. 492, p. 1439-1448, 2018. [2.2.2](#)
- RUAN, Q. et al. The effects of exchange rate regime reform on RMB markets: A new perspective based on MF-DCCA. **Physica A: Statistical Mechanics and its Applications**, Elsevier, v. 522, p. 122-134, 2019. [2.2.1](#)
- RUAN, Q.; CUI, H.; FAN, L. China's soybean crush spread: Nonlinear analysis based on MF-DCCA. **Physica A: Statistical Mechanics and its Applications**, Elsevier, v. 554, p. 123899, 2020. [2.2.1](#)
- SHAHEEN, S.; TOTTE, H.; STOCKER, A. Future of mobility white paper. 2018. [1.3](#)
- SHEN, C. The influence of a scaling exponent on ρ DCCA: A spatial cross-correlation pattern of precipitation records over eastern China. **Physica A: Statistical Mechanics and its Applications**, v. 516, p. 579-590, 2019. ISSN 0378-4371. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0378437118314006>. [2.2.2](#)
- SHIN, K.-H. et al. Neural network and regression methods for optimizations between two meteorological factors. **Physica A: Statistical Mechanics and its Applications**, Elsevier, v. 523, p. 778-796, 2019. [2.2.2](#)
- SILVA FILHO, A. M. d. Correlação de longo alcance em indicadores de criminalidade de Salvador/BA: DFA e DCCA. Brasil, 2016. [2.2.1](#)
- STAN, C. et al. Investigation of multifractal cross-correlation surfaces of Hurst exponents for some atmospheric pollutants. **Physica A: Statistical Mechanics and its Applications**, Elsevier, v. 545, p. 123799, 2020. [2.2.1](#)
- USHIYAMA, K.; MORIMOTO, M. SOH estimation of lead acid battery for automobile. In: IEEE. **2011 IEEE Ninth International Conference on Power Electronics and Drive Systems**. [S.l.], 2011. p. 739-744. [2.1.3](#)
- WANG, J.; SHAO, W.; KIM, J. Analysis of the impact of COVID-19 on the correlations between crude oil and agricultural futures. **Chaos, Solitons & Fractals**, Elsevier, v. 136, p. 109896, 2020. [2.2.1](#)
- WANG, J.; SHAO, W.; KIM, J. Combining MF-DFA and LSSVM for retina images classification. **Biomedical Signal Processing and Control**, v. 60, p. 101943, 2020. ISSN 1746-8094. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1746809420300999>. [2.2.1](#)
- WANG, J.; SHAO, W.; KIM, J. Multifractal detrended cross-correlation analysis between respiratory diseases and haze in South Korea. **Chaos, Solitons & Fractals**, Elsevier, v. 135, p. 109781, 2020. [2.2.1](#)

- WASSILIADIS, N. et al. Revisiting the dual extended Kalman filter for battery state-of-charge and state-of-health estimation: A use-case life cycle analysis. **Journal of Energy Storage**, Elsevier, v. 19, p. 73–87, 2018. [2.1.3](#)
- YANG, Y.; LI, J.; YANG, Y. The cross-correlation analysis of multi property of stock markets based on MM-DFA. **Physica A: Statistical Mechanics and its Applications**, Elsevier, v. 481, p. 23–33, 2017. [2.2.1](#), [2.2.1](#)
- ZEBENDE, G.; BRITO, A.; CASTRO, A. DCCA cross-correlation analysis in time-series with removed parts. **Physica A: Statistical Mechanics and its Applications**, Elsevier, v. 545, p. 123472, 2020. [4.1](#)
- ZEBENDE, G. et al. ρ DCCA applied between air temperature and relative humidity: An hour/hour view. **Physica A: Statistical Mechanics and its Applications**, Elsevier, v. 494, p. 17–26, 2018. [2.2.2](#)
- ZEBENDE, G. F. DCCA cross-correlation coefficient: Quantifying level of cross-correlation. **Physica A: Statistical Mechanics and its Applications**, Elsevier, v. 390, n. 4, p. 614–618, 2011. ([document](#)), [2.9](#), [2.2.2](#)
- ZHAI, L.-S. et al. Instability of horizontal oil-water flows based on the signal-dependent complex admittance representations. **Experimental Thermal and Fluid Science**, v. 103, p. 337–346, 2019. ISSN 0894-1777. Disponível em: <https://www.sciencedirect.com/science/article/pii/S089417771830712X>. [2.2.2](#)
- ZHANG, X. et al. Parity-relation-based state-of-health monitoring of lead acid batteries for automotive applications. **Control Engineering Practice**, Elsevier, v. 19, n. 6, p. 555–563, 2011. [2.1.3](#)
- ZHANG, Y.; DU, X.; SALMAN, M. Battery state estimation with a self-evolving electrochemical ageing model. **International Journal of Electrical Power & Energy Systems**, Elsevier, v. 85, p. 178–189, 2017. [2.1.3](#)
- ZHAO, H.; HE, S. Analysis of speech signals' characteristics based on MF-DFA with moving overlapping windows. **Physica A: Statistical Mechanics and its Applications**, Elsevier, v. 442, p. 343–349, 2016. [2.2.1](#)
- ZHOU, Y. et al. The informativeness of options-trading activities: Non-linear analysis based on MF-DCCA and granger test. **Physica A: Statistical Mechanics and its Applications**, Elsevier, v. 534, p. 122269, 2019. [2.2.1](#)
- ZHU, H.; ZHANG, W. Multifractal property of Chinese stock market in the CSI 800 index based on MF-DFA approach. **Physica A: Statistical Mechanics and its Applications**, Elsevier, v. 490, p. 497–503, 2018. [2.2.1](#)
- ZHU, P. et al. Portfolio strategy of international crude oil markets: A study based on multiwavelet denoising-integration MF-DCCA method. **Physica A: Statistical Mechanics and its Applications**, Elsevier, v. 535, p. 122515, 2019. [2.2.1](#)