



Pós-Graduação em Ciência da Computação

Diogo Medeiros de Almeida

Modelos Híbridos de Séries Temporais Aplicados ao Sistema Automotivo *On-Board* *Diagnostics*



Universidade Federal de Pernambuco

posgraduacao@cin.ufpe.br

<http://cin.ufpe.br/~posgraduacao>

Recife

2018

Diogo Medeiros de Almeida

Modelos Híbridos de Séries Temporais Aplicados ao Sistema Automotivo *On-Board Diagnostics*

Este trabalho foi apresentado à Pós-Graduação em Ciência da Computação do Centro de Informática da Universidade Federal de Pernambuco como requisito parcial para obtenção do grau de Mestre em Ciência da Computação.

Área Concentração: Inteligência Computacional.

Orientador: Prof. Dr. Daniel Carvalho da Cunha.

Coorientador: Prof. Dr. Paulo Salgado Gomes de Mattos Neto.

Recife
2018

Catálogo na fonte
Bibliotecária Monick Raquel Silvestre da S. Portes, CRB4-1217

A447m Almeida, Diogo Medeiros de
Modelos híbridos de séries temporais aplicados ao sistema automotivo *On-Board Diagnostics* / Diogo Medeiros de Almeida. – 2018.
74 f.: il., fig., tab.

Orientador: Daniel Carvalho da Cunha.
Dissertação (Mestrado) – Universidade Federal de Pernambuco. CIn, Ciência da Computação, Recife, 2018.
Inclui referências.

1. Inteligência artificial. 2. Análise de séries temporais. I. Cunha, Daniel Carvalho da (orientador). II. Título.

006.3 CDD (23. ed.) UFPE- MEI 2018-136

Diogo Medeiros de Almeida

**Modelos Híbridos de Séries Temporais Aplicados ao Sistema
Automotivo On-Board Diagnostics**

Dissertação de Mestrado apresentada ao
Programa de Pós-Graduação em Ciência da
Computação da Universidade Federal de
Pernambuco, como requisito parcial para a
obtenção do título de Mestre em Ciência da
Computação

Aprovado em: 07/08/2018.

BANCA EXAMINADORA

Prof. Dr. George Darmiton da Cunha Cavalcanti
Centro de Informática/UFPE

Prof. Dr. Manoel Henrique da Nóbrega Marinho
Escola Politécnica da Universidade de Pernambuco

Prof. Dr. Daniel Carvalho da Cunha
Centro de Informática / UFPE
(Orientador)

Dedico este trabalho aos meus pais, Cauby Almeida Filho e Maria do Carmo Almeida, por sempre acreditarem em mim e por terem abdicado de suas vidas em prol das realizações e da felicidade de seus filhos. Ao meu irmão, Cauby Almeida Neto, por seu incentivo e apoio. À minha querida namorada, Emanuele Gomes, por sua compreensão, carinho e apoio.

AGRADECIMENTOS

Quero agradecer em primeiro lugar a Deus, ser supremo, fonte de força inesgotável por ter me dado força, perseverança e paciência, qualidades mais do que necessárias para concluir esse mestrado.

Agradeço muito especialmente aos meus pais, Cauby Almeida Filho e Maria do Carmo Almeida, pelo interesse em me ver concluir o mestrado, e por serem minha eterna inspiração para continuar na luta por um objetivo na vida.

Agradeço ao meu irmão, Cauby Almeida Neto, por sempre me incentivar a crescer profissionalmente.

Agradeço ao meu orientador, professor Dr. Daniel Cunha, e ao meu coorientador, professor Dr. Paulo Mattos, que acreditaram em minha pessoa e me concederam as melhores diretrizes para esta pesquisa.

Aos amigos e familiares que sempre confiaram no meu potencial, especialmente à minha querida namorada, Emanuele Gomes, por todo o seu apoio.

À Universidade Federal de Pernambuco, sobretudo ao Centro de Informática, por oferecer toda a infraestrutura necessária para minha formação.

A todos aqueles que acreditam em sonhos.

RESUMO

Uma característica desejada dos sistemas de diagnóstico automotivo é fazer previsões de falhas para evitar problemas inesperadas no veículo, minimizar os custos de reparo e assegurar um automóvel mais seguro aos motoristas. Para prognosticar falhas automotivas é necessário um sistema que inicialmente seja capaz de prever dados automotivos para posteriormente avaliar com um classificador se o dado do preditor é um evento anormal ou não. Com base nisso, o objetivo deste trabalho é realizar um estudo sobre o preditor desse sistema a partir da análise de modelos híbridos inteligentes de séries temporais para prever dados em tempo real de três sensores veiculares: temperatura do líquido de arrefecimento do motor, relação Ar-Combustível (A/C) na combustão interna do motor e tensão da bateria do automóvel. Os resultados mostraram que, em geral, combinar previsores da série temporal com previsores dos resíduos é uma abordagem que merece atenção e deve ser considerada no contexto dos dados automotivos. Além disso, a combinação alternativa de modelos não lineares para a série com modelos lineares para os resíduos sugere uma proposta a ser investigada em outras aplicações.

Palavras-chaves: Análise de Séries Temporais. Modelos de Previsão. Sistemas Híbridos Inteligentes. Veículos Rodoviários. *On-Board Diagnostics* (OBD).

ABSTRACT

A desired characteristic of the automotive diagnostics systems is to make fault predictions to prevent unexpected car breakdowns, avoiding financial losses and physical damages to the drivers. To detect automotive failures preliminarily, it is necessary a system that is initially able to predict motor data to afterward evaluate with a classifier whether the predicted data is an abnormal event or not. Based on that, the objective of this work is to perform a study on the predictor of this system. For this, hybrid time series models are applied to forecast real-time information from three in-vehicle sensors: engine coolant temperature, Air Fuel Ratio (AFR) internal combustion and automobile battery voltage. Results showed that, in general, combining forecasters from the residual modeling deserves attention and should be considered in the context of automotive data. In addition, the alternative combination of nonlinear with linear models suggests a proposal to be investigated in other applications.

Key-words: Time series analysis. Forecasting models. Hybrid intelligent systems. Road vehicles. On-Board Diagnostics (OBD).

LISTA DE ILUSTRAÇÕES

Figura 1 – Lâmpada indicadora de mau funcionamento utilizada nos painéis de instrumentos dos veículos para alertar avarias no motor.	23
Figura 2 – Pinagem do conector padrão OBD-II encontrado em todos os veículos produzidos nos EUA a partir de 1996.	24
Figura 3 – Evolução da temperatura do líquido de arrefecimento de um motor veicular no decorrer do tempo.	31
Figura 4 – Evolução A/C na combustão interna do motor no decorrer do tempo. .	32
Figura 5 – Evolução da tensão da bateria automotiva no decorrer do tempo. . .	33
Figura 6 – Evolução da temperatura de um motor veicular no decorrer do tempo.	35
Figura 7 – Função de autocorrelação da série temporal da temperatura do motor veicular.	36
Figura 8 – Diagrama de uma generalização do modelo híbrido de previsão de séries temporais a partir da combinação linear proposta em (ZHANG, 2003). .	45
Figura 9 – Diagrama do modelo híbrido de previsão de séries temporais baseado na combinação não linear proposta em (de MATTOS NETO; CAVALCANTI; MADEIRO, 2017).	47
Figura 10 – Configuração experimental usada para construir o banco de dados automotivo usado neste trabalho.	48
Figura 11 – Função de autocorrelação da série temporal da temperatura do motor veicular.	55
Figura 12 – Função de autocorrelação da série temporal da A/C na combustão interna do motor.	56
Figura 13 – Função de autocorrelação da série temporal da tensão da bateria automotiva.	57
Figura 14 – Resultados de previsão para série temporal normalizada da temperatura do líquido de arrefecimento do motor considerando 100 amostras contínuas do conjunto de teste.	60
Figura 15 – Resultados de previsão para série temporal da A/C na combustão interna do motor considerando 100 amostras contínuas do conjunto de teste.	63
Figura 16 – Resultados da previsão para série temporal da tensão da bateria do automóvel considerando 100 amostras contínuas do conjunto de teste. .	66

LISTA DE TABELAS

Tabela 2 – Funções dos pinos do conector padrão OBD-II.	24
Tabela 3 – Modos do padrão SAE J1979.	25
Tabela 4 – Informações sobre os comandos OBD-II e ELM327 utilizados na coleta dos dados automotivos.	26
Tabela 5 – Resumo estatístico da temperatura do líquido de arrefecimento.	31
Tabela 6 – Resumo estatístico da A/C na combustão interna do motor.	32
Tabela 7 – Resumo estatístico da tensão da bateria automotiva.	33
Tabela 8 – Abordagens de previsão utilizados neste trabalho com os métodos correspondentes e os respectivos acrônimos.	50
Tabela 9 – Medidas de avaliação obtidas para o conjunto de teste da série de temperatura do líquido de arrefecimento do motor.	57
Tabela 10 – Relações percentuais para todas as métricas de avaliação considerando o conjunto de testes da série de temperatura do líquido de arrefecimento do motor.	59
Tabela 11 – Métricas de desempenho relativas aplicadas nas abordagens com os melhores desempenhos de acordo com seus respectivos modelos iniciais para a temperatura do líquido de arrefecimento do motor no conjunto de teste.	59
Tabela 12 – Parâmetros selecionados no busca em grade para o modelo híbrido CL_{LA} e resultado do teste dos postos sinalizados de Wilcoxon no conjunto de teste da série temporal temperatura do líquido de arrefecimento do motor.	60
Tabela 13 – Medidas de avaliação obtidas para o conjunto de teste da série da A/C na combustão interna do motor.	61
Tabela 14 – Relações percentuais para todas as métricas de avaliação considerando o conjunto de testes da série da A/C na combustão interna do motor.	62
Tabela 15 – Métricas de desempenho relativas aplicadas nas abordagens com os melhores desempenhos de acordo com seus respectivos modelos iniciais para o A/C na combustão internada do motor no conjunto de teste.	62
Tabela 16 – Parâmetros selecionados no busca em grade para o modelo híbrido CL_{MA} e resultado do teste dos postos sinalizados de Wilcoxon no conjunto de teste da série temporal A/C.	63
Tabela 17 – Medidas de avaliação obtidas para o conjunto de teste da série de tensão da bateria.	64
Tabela 18 – Razões percentuais para todas as medidas de avaliação considerando o conjunto de testes da série de tensão da bateria.	65

Tabela 19 – Métricas de desempenho relativas aplicadas nas abordagens com os melhores desempenhos de acordo com seus respectivos modelos iniciais para a tensão da bateria automotiva no conjunto de teste.	65
Tabela 20 – Parâmetros selecionados no busca em grade para o modelo híbrido CNL- S_{MA} e resultado do teste dos postos sinalizados de Wilcoxon no conjunto de teste da serie temporal tensão da bateria automotiva. . . .	66

LISTA DE ABREVIATURAS E SIGLAS

ϵ-SVR	<i>ϵ-Support Vector Regression</i>
A/C	Relação Ar-Combustível
ADF	<i>Augmented Dickey Fuller</i>
AFR	Air Fuel Ratio
AR	<i>Autoregressive</i>
ARIMA	<i>Auto Regressive Integrated Moving-Average</i>
ARMA	<i>Autoregressive Moving Average</i>
ARV	<i>Average Relative Variance</i>
ASCII	<i>American Standard Code for Information Interchange</i>
CARB	<i>California Air Resources Board</i>
CL	Combinados Linearmente
CNL	Combinados Não Linearmente
CPMN	Controle Preditivo com Modelo Não Linear
CSS	<i>Conditional Sum of Squares</i>
DTCs	<i>Diagnostic Trouble Codes</i>
ECU	<i>Electronic Control Unit</i>
EPA	<i>Environmental Protection Agency</i>
ISO	<i>International Organization for Standardization</i>
KKT	Karush-Kuhn-Tucker
km/h	<i>Kilometres per Hour</i>
kPa	<i>Kilopascal</i>
LS-SVM	<i>Least Squares Support Vector Machine</i>
MA	<i>Moving Average</i>
MAE	<i>Mean Absolute Error</i>
MAPE	<i>Mean Absolute Percentage Error</i>
MASE	<i>Mean Absolute Scaled Error</i>
MIL	<i>Malfunction Indicator Lamp</i>
MLE	<i>Maximum Likelihood Estimator</i>

MLP	<i>Multilayer Perceptron</i>
MSE	<i>Mean Squared Error</i>
NoLiC	<i>Nonlinear Combination</i>
OBD	<i>On-Board Diagnostics</i>
OBD-I	<i>On-Board Diagnostics First Generation</i>
OBD-II	<i>On-Board Diagnostics Second Generation</i>
OEM	<i>Original Equipment Manufacturer</i>
PID	<i>Parameter Identification</i>
POCID	<i>Prediction Of Change In Direction</i>
PQ	Programação Quadrática
RBF	<i>Radial-Basis Function</i>
RBFN	<i>Radial Basis Function Network</i>
RMSE	<i>Root Mean Squared Error</i>
RNA	Rede Neural Artificial
RPM	Rotações por Minuto
RPROP	<i>Resilient Propagation</i>
SAE	<i>Society of Automotive Engineers</i>
SNNS	<i>Stuttgart Neural Network Simulator</i>
SOC	<i>State Of Charge</i>
SRM	<i>Structural Risk Minimization</i>
SRV	<i>Support Vector Regression</i>
SSE	<i>Sum of Squared Errors</i>
STL	<i>Seasonal Trend Decomposition using Loess</i>
SVM	<i>Support Vector Machine</i>

LISTA DE SÍMBOLOS

∇	Primeira diferença da série temporal
y_t	Valor da série temporal no tempo t
ϕ_i	i -ésimo parâmetro na formulação do modelo AR
ε_t	Ruído branco no tempo t
θ_j	j -ésimo parâmetro na formulação do modelo MA
τ_j	j -ésimo peso de conexão da camada oculta na formulação do modelo MLP
β_{ij}	Peso de conexão entre i -ésimo neurônios da camada de entrada e j -ésimo neurônios da camada oculta na formulação do modelo MLP
e^x	Exponencial natural
$\mathbf{v}$	Vetor de todos os parâmetros na formulação do modelo MLP
Δ_0	Valor inicial de atualização na formulação do RPROP
Δ_{max}	Valor máximo para o tamanho do passo na formulação do RPROP
μ	Expoente de decaimento de peso na formulação do RPROP
o_i	Valor objetivo do i -ésimo neurônio da função de erro na formulação do RPROP
r_i	Resposta do i -ésimo neurônio da função de erro na formulação do RPROP
π_{ij}	Peso entre i -ésimo e j -ésimo neurônios da função de erro na formulação do RPROP
$\mathbf{x}_k$	k -ésimo vetor de entrada do conjunto de dados
y_k	k -ésimo valor de saída do conjunto de dados
$\langle \cdot, \cdot \rangle$	Produto escalar
ω	Vetor de pesos na formulação do modelo ϵ -SVR
$\varphi(\cdot)$	Função não linear na formulação do modelo ϵ -SVR

b	<i>bias</i>
C	Parâmetro de regularização na formulação de otimização do modelo ϵ -SVR
ϵ	Limite para a margem de tolerância na formulação do modelo ϵ -SVR
ξ_k^+	k-ésima penalidade acima do ϵ -tubo na formulação do modelo ϵ -SVR
ξ_k^-	k-ésima penalidade abaixo do ϵ -tubo na formulação do modelo ϵ -SVR
α^+	Multiplicador de Lagrange na formulação do modelo ϵ -SVR
α^-	Multiplicador de Lagrange na formulação do modelo ϵ -SVR
η^+	Multiplicador de Lagrange na formulação do modelo ϵ -SVR
η^-	Multiplicador de Lagrange na formulação do modelo ϵ -SVR
∂	Derivada parcial
σ	Desvio padrão na formulação do <i>kernel</i> RBF
λ	Inverso do desvio padrão na formulação do <i>kernel</i> RBF
γ	Parâmetro de regularização na formulação de otimização no modelo de regressão LS-SVM
e_k	k-ésimo erro na formulação de otimização no modelo de regressão LS-SVM
$\vec{1}$	Vetor linha de números 1
$\vec{1}^T$	Matriz transposta de $\vec{1}$
I	Matriz identidade
L_t	Componente linear da série temporal no tempo t
N_t	Componente não linear da série temporal no tempo t
$\hat{y}_t$	Estimativa do modelo de previsão no tempo t
$\hat{L}_t$	Previsão do modelo linear no tempo t
$\hat{N}_t$	Previsão do modelo não linear no tempo t
e_t	t-ésimo erro do modelo de previsão
Y	Vetor que representa a série temporal

E	Vetor que representa a série de erros ou resíduos
$m_i(\cdot)$	i -ésimo modelo de previsão
R_i	Relação percentual na métrica i entre o modelo híbrido e o respectivo modelo monolítico.
H_0	Hipótese nula
H_1	Hipótese alternativa
h_k	k -ésima observação do modelo híbrido
i_k	k -ésima observação do modelo individual
D_k	k -ésima diferença entre observações pareadas no teste de Wilcoxon
θ_D	Estimação da mediana amostral das diferenças no teste de Wilcoxon
ψ_k	k -ésima variável indicadora no teste de Wilcoxon
P_k	k -ésimo Posto (ordenação) no teste de Wilcoxon
T^+	Estatística do teste de Wilcoxon

SUMÁRIO

1	INTRODUÇÃO	18
1.1	Contextualização e Motivação	18
1.2	Objetivos Geral e Específicos	20
1.3	Contribuições	21
1.4	Estrutura do Documento	21
2	COMUNICAÇÃO COM O VEÍCULO	22
2.1	O Sistema de Diagnóstico de Bordo	22
2.2	A Leitura dos Dados Automotivos	23
2.2.1	O Microcontrolador ELM327	24
2.2.2	Os Comandos OBD-II	25
2.2.3	Os Sensores Acessíveis no Automóvel Utilizado na Coletada de Dados	26
2.3	Os Dados Automotivos Selecionados	29
2.4	Análise dos Dados Coletados	30
2.4.1	O Efeito de Diferentes Condições de Condução do Automóvel	30
2.4.2	Temperatura do Líquido de Arrefecimento do Motor	30
2.4.3	A/C na Combustão Interna do Motor	31
2.4.4	Tensão da Bateria Automotiva	32
2.5	Resumo do Capítulo	33
3	MODELOS DE PREVISÃO DE SÉRIES TEMPORAIS	34
3.1	Séries Temporais	34
3.2	Modelos de Previsão de Séries Temporais	37
3.2.1	Modelo ARIMA	37
3.2.2	Modelo MLP	38
3.2.3	Modelo SVM	40
3.2.4	Modelo LS-SVM	43
3.3	Modelos Híbridos	44
3.3.1	Modelos Híbridos Combinados Linearmente	44
3.3.2	Modelos Híbridos Combinados Não Linearmente	46
3.4	Resumo do Capítulo	47
4	EXPERIMENTOS E RESULTADOS	48
4.1	Configuração Experimental	48
4.1.1	Métricas de Avaliação	51
4.1.2	Métrica de Relação Percentual	52

4.1.3	Métricas de Desempenho Relativas	53
4.1.4	Teste Estatístico de Hipótese	53
4.2	Resultados	55
4.2.1	Temperatura do Líquido de Arrefecimento do Motor	57
4.2.2	A/C na Combustão Interna do Motor	61
4.2.3	Tensão da Bateria do Automóvel	64
4.3	Resumo do Capítulo	67
5	CONCLUSÕES	68
5.1	Contribuições	68
5.2	Dificuldades Encontradas	69
5.3	Trabalhos Futuros	69
	REFERÊNCIAS	71

1 INTRODUÇÃO

Este capítulo fornece uma contextualização sobre o estudo abordado nesta dissertação e a motivação para o desenvolvimento da pesquisa. Além disso, os principais objetivos do trabalho são apresentados, assim como a estrutura do restante do documento.

1.1 Contextualização e Motivação

A evolução da indústria automotiva é sem dúvida um dos eventos mais inspiradores e importantes no mundo tecnológico moderno. Várias novas tecnologias, como *powertrain* e comunicações, foram integradas aos automóveis, transformando os veículos em máquinas mais eficientes e complexas. A eletrônica automotiva e as ferramentas baseadas em *software* para controle e monitoramento foram aprimoradas consideravelmente no projeto de veículos modernos e em seus sistemas de diagnóstico de bordo, ou do inglês, OBD (AHSAN; STOYANOV; BAILEY, 2016).

O sistema OBD é um sistema de autodiagnóstico que permite acesso ao status de vários subsistemas do veículo para o proprietário do automóvel ou técnico de reparo automotivo, além de ter a capacidade de gerar notificações quando alguns parâmetros estão fora da faixa normal de operação (SANTINI, 2011). Esse processo não é perfeito, pois quando uma falha ocorre, esta pode iniciar algumas falhas induzidas, que podem passar despercebidas pelo motorista. Além disso, o sistema OBD não é capaz de prever possíveis problemas que venham ocorrer no automóvel, ou seja, é um sistema não inteligente.

Uma prática comum, geralmente seguida no setor do automotivo, é a chamada manutenção periódica do carro. Nesse contexto, o carro deve ser submetido periodicamente a uma rotina de serviços e manutenção. O problema associado a este modelo de manutenção automotiva é que ninguém tem certeza se alguma peça ou fluido realmente precisa ser substituída/trocado. Isso normalmente leva a peças ou fluidos, que estão em boas condições, serem substituídas/trocados, resultando em custos de serviço desnecessários. Outro problema é que se qualquer parte necessitar de serviço imediato, isto pode passar despercebido e vir a resultar em uma avaria no veículo (DHALL; SOLANKI, 2017).

Assim, uma característica desejada nos sistemas de diagnóstico automotivo é a previsão de falhas para evitar avarias inesperadas, minimizar as perdas financeiras do proprietário, e garantir um automóvel mais confiável e seguro para o motorista. Um sistema OBD com capacidade de previsão pode fornecer alertas de falhas com antecipação em tempo real, reduzindo os custos de manutenção, já que apenas os componentes danificados seriam substituídos ou reparados (DHALL; SOLANKI, 2017).

Na área automotiva, a utilização de sistemas preditivos é uma prática bem conhecida.

Por exemplo, sistemas capazes de prever a carga de baterias de veículos podem ser encontrados em (WANG et al., 2017; PATTIPATI; SANKAVARAM; PATTIPATI, 2011). O método mais comum é estimar o estado de carga, ou do inglês, *State Of Charge* (SOC), que é definido como a capacidade disponível em uma bateria e é expresso por uma porcentagem da capacidade nominal real (ou estimada) (PATTIPATI; SANKAVARAM; PATTIPATI, 2011). Em (SANZ et al., 2017), é apresentado um Controle Preditivo com Modelo Não Linear (CPMN) para o gerenciamento térmico dos componentes elétricos do circuito de refrigeração em um veículo elétrico híbrido. Outro CPMN para a Relação Ar-Combustível (A/C) na combustão interna de um motor foi implementado e avaliado em (SHI et al., 2015) a partir da combinação de um modelo volterra modificado e uma rede de função de base radial, ou do inglês, *Radial Basis Function Network* (RBFN). Esta combinação do modelo volterra com a RBFN tem o objetivo de melhorar a precisão e superar as limitações de cada modelo individualmente. Em todas as referências mencionadas anteriormente, existe um complexo processo de medição, já que muitos sensores são essenciais em cada sistema preditivo, e modelos matemáticos não triviais são necessários para obter resultados precisos.

Em (BYTTNER; ROGNVALDSSON; SVENSSON, 2011), é sugerida uma estratégia de detecção de falhas para encontrar falhas que não são predefinidas em um grupo de veículos. A estratégia baseia-se em encontrar fortes relações entre os valores dos sensores nos veículos. Os modelos resultantes de vários veículos são então comparados e os automóveis que não estão em consenso com o grupo de veículos são marcados como potencialmente defeituosos. Este método provou ser eficaz para encontrar falhas em automóveis da frota, mas não é capaz de identificá-las antes de ocorrerem.

Para prognosticar falhas automotivas, é necessário um sistema que inicialmente seja capaz de prever dados do motor com precisão para posteriormente avaliar com um classificador acurado, se o dado do previsor é um evento anormal ou não. Assim sendo, a motivação deste trabalho está em realizar um estudo sobre o preditor desse sistema aplicando-se uma análise de séries temporais para prever dados de um sistema automotivo em termos de três importantes sensores: temperatura do líquido arrefecimento do motor, a A/C na combustão interna do motor e a tensão da bateria do automóvel. Entre os diferentes sensores disponíveis em um automóvel, estes três estão em partes importantes e que mais comumente apresentam avarias, ou seja, o monitoramento preciso dessas três informações é fundamental para o funcionamento apropriado do veículo.

Em (WANG; JAGARWAL; WAGNER, 2015), é descrito que o sistema de resfriamento em motores a combustão tem o objetivo de manter o melhor desempenho do veículo, pois se o motor funcionar muito quente, poderão ocorrer combustões anormais. Consequencialmente, haverá o desperdício de combustível e emissões de escapamento acentuadas. Além disso, a alta temperatura do motor aumenta a perda de eletrólitos da bateria e reduz a sua vida útil (KERSHAW; HALDERMAN, 2007). Em (EBRAHIMI et al., 2014; KIM; RIZZONI;

UTKIN, 1998), é comentado que a maior economia de combustível e a menor emissão de gases de escape nos motores a combustão dependem significativamente do controle preciso da A/C. Em (KERSHAW; HALDERMAN, 2007), é explicado que a alta tensão no sistema elétrico automotivo superaquece o eletrólito da bateria, encurta sua vida útil e também danifica os componentes de injeção de combustível e do sistemas de controle do motor. Por outro lado, a baixa tensão faz com que a bateria fique sulfatada. Por estes motivos, essas três informações foram selecionadas para a construção do banco de dados automotivo, que será utilizado para verificar a capacidade de previsão de modelos monolíticos e híbridos conhecidos na literatura.

1.2 Objetivos Geral e Específicos

O objetivo geral deste trabalho é fazer um comparativo entre modelos de previsão de séries temporais para analisar a capacidade de predição de informações que chegam em tempo real de três sensores importantes para o funcionamento do motor veicular. Para este fim, dados reais de um automóvel foram coletados através do sistema de diagnóstico de bordo de segunda geração, ou do inglês, *On-Board Diagnostics Second Generation* (OBD-II) e experimentos foram realizados baseando-se em modelos de previsão de séries temporais monolíticos e híbridos já conhecidos, como também em novas alternativas de combinações. Nas avaliações, há quatro modelos monolíticos: autorregressivo integrado de média móvel, ou do inglês, *Auto Regressive Integrated Moving-Average* (ARIMA), Rede Neural Artificial (RNA), máquina de vetores de suporte, ou do inglês, *Support Vector Machine* (SVM) e máquina de vetores de suporte por mínimos quadrados, ou do inglês, *Least Squares Support Vector Machine* (LS-SVM). Além destes, há dezesseis sistemas híbridos que são compostos da combinação linear ou não linear dos quatro modelos monolíticos mencionados anteriormente. O objetivo das combinações é melhorar a precisão e superar as limitações de cada modelo de previsão individualmente.

Para atingir o objetivo geral, foi necessário, primeiramente, realizar um estudo sobre o funcionamento de um motor automotivo, selecionar sensores de partes importantes do automóvel que mais comumente apresentam avarias, e construir um banco de dados com as informações destes sensores, quais sejam: temperatura do líquido arrefecimento do motor, a A/C na combustão interna do motor e a tensão da bateria do automóvel. Posteriormente, foi preciso investigar o estado da arte de modelos de previsão de séries temporais monolíticos e híbridos. Salienta-se que, os modelos híbridos deste trabalho empregam uma modelagem no erro residual para aprimorar a previsão, sempre assumindo que uma série é composta por padrões lineares e não lineares. Em seguida, os modelos monolíticos e híbridos foram aplicados no banco de dados composto pelas séries temporais automotivas coletadas. Por fim, foram avaliados os resultados das simulações computacionais utilizando métricas de desempenho, avaliação relativas, ganho percentual e um teste

de hipótese estatístico.

1.3 Contribuições

Este trabalho expõe um tema pouco explorado na literatura, previsão de dados automotivos por meio de séries temporais. Apesar de muitos trabalhos tratarem do assunto sobre previsão de séries temporais, há poucos estudos na aplicação em dados automotivos. Logo, esta é uma pesquisa que poderá servir de referência inicial para quem quiser se desbravar nessa área.

Os resultados experimentais com três conjuntos de dados reais de um automóvel mostram que, em geral, os sistemas híbridos superaram os modelos monolíticos considerando quatro medidas de avaliação e um teste estatístico adotados neste trabalho. É importante destacar a acurácia superior alcançada pelos sistemas híbridos que utilizam uma modelagem não linear para a série e linear para os resíduos.

1.4 Estrutura do Documento

No Capítulo 2, é apresentado, de forma geral, como foi realizada a coleta dos dados por meio dos sensores automotivos, e também são descritos detalhes sobre as informações coletadas. O Capítulo 3 apresenta a teoria de séries temporais, descreve como é possível estimar valores futuros a partir do conhecimento do histórico de uma variável até o presente, e são apresentados os modelos monolíticos e híbridos utilizados neste trabalho. No Capítulo 4, são descritos os experimentos realizados desde a coleta de dados aos modelos de previsão, e também são discutidos os resultados obtidos. Por fim, no Capítulo 5 são apresentadas as conclusões, contribuições e dificuldades encontradas, além de sugestões de trabalhos futuros.

2 COMUNICAÇÃO COM O VEÍCULO

Gravações de dados de motores dos fabricantes de automóveis são altamente confidenciais e, portanto, não há um compartilhamento com a comunidade científica. Logo, neste capítulo, são apresentados os fundamentos para a leitura e coleta dos dados dos sensores de um automóvel. Inicialmente, é narrada a origem do sistema OBD e a motivação para o monitoramento do motor do veículo. Posteriormente, é explicado como é realizada a leitura das mensagens OBD através do adaptador *Bluetooth* ELM327, escolhido por sua simplicidade de utilização e facilidade de ser encontrado no mercado. O microcontrolador ELM327 possui um *hardware* e *software* completo para fazer a comunicação com o veículo através do conector OBD. Adiante, é descrita a função de cada sensor, e quais foram escolhidos para as simulações computacionais, devido ao grau de importância para o funcionamento apropriado do automóvel. Além disso, no final do capítulo, é realizada uma breve análise nos dados coletados.

2.1 O Sistema de Diagnóstico de Bordo

O sistema OBD é um sistema de autodiagnóstico disponível na maioria dos automóveis que circulam atualmente. Foi desenvolvido para detectar falhas nos veículos, cujo desempenho possa aumentar as emissões de poluentes ao ponto destas excederem os limites preestabelecidos por leis ambientais (MCCORD, 2011). Tais normas foram inicialmente estabelecidas pela *California Air Resources Board* (CARB) e pela *Environmental Protection Agency* (EPA), órgãos norte-americanos responsáveis por regulamentações ambientais.

O sistema de diagnóstico de bordo de primeira geração, ou do inglês, *On-Board Diagnostics First Generation* (OBD-I), foi desenvolvido na década de 1980, sendo considerado um grande avanço para a época, apesar de ser um sistema de diagnóstico primitivo e rudimentar. Isto se comprovou em meados da década de 1990, quando o sistema OBD-I já não tinha mais recursos suficientes para atender as leis de emissões vigentes (CONCEPCION, 2011). Outra grave deficiência do sistema OBD-I era a sua falta de uniformidade, pois cada fabricante possuía seus próprios protocolos e ferramentas. Por exemplo, cada montadora de automóveis usava diferentes códigos de diagnósticos de falha, em inglês, *Diagnostic Trouble Codes* (DTCs) e, portanto, diferentes erros eram atribuídos ao mesmo código, o que gerou uma enorme confusão em toda a indústria de serviços automotivos (MCCORD, 2011).

Em virtude das disparidades existentes entre as diferentes versões dos sistemas OBD-I, bem como de suas limitações, o sistema OBD-II foi proposto em 1996 nos Estados Unidos. O sistema OBD-II foi estabelecido como uma solução radical para o controle de emissão

de veículos (SANTINI, 2011). Devido ao forte envolvimento da *International Organization for Standardization* (ISO) e da *Society of Automotive Engineers* (SAE), as regras do OBD-II foram bem definidas. Cada fabricante de equipamento original, ou do inglês, *Original Equipment Manufacturer* (OEM), desde então, tem que cumprir com as normas do OBD-II, instituídas pela ISO e pela SAE. Os benefícios do desenvolvimento do sistema OBD-II não se limitaram a garantir que os sistemas automotivos sejam executados dentro das especificações. A padronização também simplificou para um técnico automotivo ou proprietário do veículo a tarefa de ler e entender um conjunto único de informações para diagnosticar uma potencial falha no automóvel (MCCORD, 2011).

Uma das atribuições do sistema OBD é armazenar códigos de diagnósticos quando alguns parâmetros automotivos estão fora da faixa de funcionamento normal. Além disso, se um problema for detectado, o sistema deve acender uma luz de advertência no painel de instrumentos do veículo para alertar o motorista (CARB, 2018). Esta lâmpada de aviso normalmente contém a frase *Check Engine* ou *Service Engine Soon* (ver Figura 1) e é conhecida como lâmpada indicadora de mau funcionamento, ou do inglês, *Malfunction Indicator Lamp* (MIL).



Figura 1 – Lâmpada indicadora de mau funcionamento utilizada nos painéis de instrumentos dos veículos para alertar avarias no motor.

Fonte: *Website* da CARB (CARB, 2018).

Esse processo de notificação nem sempre é perfeito e, geralmente, quando ocorre uma falha no veículo que passa despercebida pelo sistema OBD, esta pode desencadear uma série de falhas induzidas, que também são armazenadas. Por esse motivo, é desejável um sistema inteligente e robusto capaz de reconhecer erros de forma precisa e antecipada, com o objetivo de garantir um automóvel mais seguro e confiável, que evite quebras inesperadas e minimize os prejuízos financeiros ao motorista.

2.2 A Leitura dos Dados Automotivos

Outra função do sistema OBD-II é a possibilidade de acesso a rede interna de comunicação do veículo através de um conector disponibilizado ao condutor. A localização do conector OBD-II é determinada por lei e deve estar dentro de 1 pé (30,48 cm) do console central do automóvel. Na maioria dos veículos, o conector é colocado sob o painel de instrumentos ou também atrás do cinzeiro (CONCEPCION, 2011). A Figura 2 ilustra a pinagem do conector

padrão OBD-II, enquanto a Tabela 2 ilustra a função dos pinos. Por exemplo, o termo fabricante significa que o pino é reservado para funções do fabricante do automóvel. Os demais pinos servem para comunicação com o sistema OBD, são obrigatórios e não podem ser alterados.

Assim, a partir deste conector, tem-se acesso aos sensores eletrônicos que estão distribuídos na rede interna do veículo e, através da leitura destes sensores, dados podem ser coletados para a realização de estudos científicos na área automotiva. O armazenamento dos dados pode ser realizado em computadores pessoais ou *smartphones*. Para isto, é recomendável a utilização do microcontrolador ELM327, que facilita o estabelecimento da comunicação entre o sistema OBD e os dispositivos de armazenamento.




Figura 2 – Pinagem do conector padrão OBD-II encontrado em todos os veículos produzidos nos EUA a partir de 1996.

Fonte: Website da empresa AutoTap, especializada na leitura de dados OBD-II (AUTOTAP, 2011).

Tabela 2 – Funções dos pinos do conector padrão OBD-II.

Pino	Função	Pino	Função
1	Fabricante	9	Fabricante
2	J1850 <i>Bus+</i>	10	J1850 <i>Bus-</i>
3	Fabricante	11	Fabricante
4	<i>Chassis Ground</i>	12	Fabricante
5	<i>Signal Ground</i>	13	Fabricante
6	CAN <i>High</i> (J-2284)	14	CAN <i>Low</i> (J-2284)
7	ISO 9141-2 <i>K Line</i>	15	ISO 9141-2 <i>L Line</i>
8	Fabricante	16	Bateria +12V

2.2.1 O Microcontrolador ELM327

O ELM327 é um microcontrolador desenvolvido para fazer a comunicação entre o sistema OBD-II e computadores pessoais (ELM ELECTRONICS INC, 2014). Dígitos hexadecimais (de 0 a 9 e de A a F) são utilizados para todos os dados do ELM327, e este é o formato de dados mais utilizado nos padrões OBD-II. O microcontrolador ELM327 pode ser considerado um protocolo interpretador que permite acesso às mensagens do sistema OBD, pois este dispositivo assegura que os dígitos são recebidos, convertidos em *bytes* e depois enviados para a porta OBD-II (ELM ELECTRONICS INC, 2014).

Tabela 3 – Modos do padrão SAE J1979.

Modo	Descrição
'01'	Mostrar dados atuais
'02'	Mostrar dados do quadro congelado
'03'	Mostrar códigos de problemas de diagnóstico
'04'	Apagar códigos de problemas e valores armazenados
'05'	Resultados dos testes, sensores de oxigênio
'06'	Resultados do teste, monitorados de forma não contínua
'07'	Mostrar códigos de problemas pendentes
'08'	Modo de controle especial
'09'	Solicitar informações do veículo

O microcontrolador ELM327 oferece suporte não apenas a comandos internos próprios, mas também a comandos OBD-II. Os comandos internos do ELM327 começam com o prefixo 'AT'. Destaca-se um comando muito importante, o 'AT SP', utilizado para encontrar o protocolo do barramento de comunicação do automóvel (ELM ELECTRONICS INC, 2014). Se os *bytes* enviados para o ELM327 não começarem com 'AT', os *bytes* serão considerados comandos OBD-II para o veículo. Antes de serem transmitidos, o conjunto de *bytes American Standard Code for Information Interchange* (ASCII) recebidos pelo microcontrolador ELM327 são testados para assegurar que são dígitos hexadecimais válidos. Posteriormente, são convertidos em *bytes* e, por fim, enviados ao automóvel (ELM ELECTRONICS INC, 2014).

2.2.2 Os Comandos OBD-II

O padrão OBD-II especifica que as requisições para o veículo sigam um formato. O primeiro byte, chamado de modo, descreve o tipo de dado requisitado, enquanto que o segundo byte e os demais, chamados de parâmetros de identificação, ou do inglês, *Parameter Identification* (PID), especificam a real informação requisitada. Por exemplo, o padrão SAE J1979 define 9 modos e são apresentados na Tabela 3. Já os PIDs são definidos na norma ISO 15031-5 (ELM ELECTRONICS INC, 2014) e podem ser:

- PID numérico: É geralmente usado quando se deseja representar um sinal analógico, definido por uma gama específica de valores e resolução, por exemplo, a temperatura do motor do veículo;
- Estado codificado: É tipicamente utilizado quando se deseja representar um número de estados bem definidos. Por exemplo, para representar a posição da marcha de um câmbio automático: P - *Park*, R - *Reverse*, N - *Neutral*, D - *Drive*, L - *Low*;
- *Bit* mapeado: É tipicamente utilizado para representar estados discretos, por exemplo, quando a porta está aberta ou fechada, se determinado sistema está ligado

ou desligado. Portanto, ele é utilizado quando se precisa descrever o estado de um sistema que possui apenas 2 tipos de estados: *on* ou *off*;

- Empacotado: É um grupo de dados cuja combinação apresenta uma determinada classificação, por exemplo, a identificação do veículo, versão do *software* etc.

No estudo aqui apresentado, foi utilizado o modo '01' do padrão OBD-II para obter os dados dos sensores automotivos em tempo real. A norma ISO 15031-5 descreve muitos PIDs numéricos, mas nem todos são suportados por todos os veículos e nem por todas as classificações do sistema OBD-II.

2.2.3 Os Sensores Acessíveis no Automóvel Utilizado na Coletada de Dados

Na Tabela 4, são apresentadas informações sobre os comandos de leitura de dados suportados pelo automóvel utilizado nesta pesquisa. Há um comando interno do ELM327, responsável pela coleta da tensão da bateria do automóvel em tempo real, e dez comandos OBD-II com seus respectivos PID numéricos. A letra 'A' representa o primeiro byte e 'B' representa o segundo byte da resposta. O veículo é um Fiat Palio *Fire* 1.0 8V *Flex* 2007.

A seguir, estão dispostas informações sobre cada sensor automotivo acessível no Fiat Palio *Fire* 1.0 8V *Flex* 2007 a partir do sistema OBD-II.

Tensão da Bateria Automotiva Baterias automotivas são projetadas para ligar o motor (KERSHAW; HALDERMAN, 2007). Com o carro em funcionamento, a tensão nos

Tabela 4 – Informações sobre os comandos OBD-II e ELM327 utilizados na coleta dos dados automotivos.

Descrição	Comando OBD-II	Comando ELM327	Mínimo	Máximo	Unidade	Fórmula
Tensão da bateria do automóvel	-	'AT RV'	-	-	<i>Volts</i>	-
Carga no motor	'01 04'	-	0	100	%	$A \div 2,55$
Temperatura do líquido de arrefecimento do motor	'01 05'	-	-40	215	$^{\circ}C$	$A - 40$
Ajuste de combustível de curto prazo	'01 06'	-	-100	99,2	%	$(A \div 1,28) - 100$
Ajuste de combustível de longo prazo	'01 07'	-	-100	99,2	%	$(A \div 1,28) - 100$
Pressão no coletor de admissão	'01 0B'	-	0	255	kPa	A
Rotação do motor	'01 0C'	-	0	16.383,75	RPM	$(256 \cdot A + B) \div 4$
Velocidade do automóvel	'01 0D'	-	0	255	km/h	A
Temperatura do ar no interior da ingestão	'01 0F'	-	-40	-215	$^{\circ}C$	$A - 40$
Posição do pedal de aceleração	'01 11'	-	0	100	%	$A \div 2,55$
A/C na combustão interna do motor	'01 14'	-	0	1,275	<i>Volts</i>	$A \div 200$

terminais da bateria é determinada pelo alternador e o regulador de tensão automotivo. O alternador em conjunto com o regulador de tensão têm a função de fornecer a corrente de carga para a bateria, além de prover as demais demandas elétricas do veículo: luzes, ar condicionado e acessórios de energia. Para a corrente de carga entrar na bateria, a tensão de carga deve ser maior que a força contra-eletromotriz da bateria, adicionada a queda de tensão causada pela resistência interna da bateria (KERSHAW; HALDERMAN, 2007). Por exemplo, para baterias automotivas de 12,6 Volts, os sistemas de carregamento de corrente alternada devem ter uma tensão superior a esta, geralmente, são regulados para produzir uma saída máxima de 14,5 volts (KERSHAW; HALDERMAN, 2007). Assim, com o comando 'AT RV' do ELM327, é possível obter, em tempo real, a tensão nos terminais da bateria com o carro em funcionamento.

Carga no Motor A carga no motor é uma medida da quantidade de ar e combustível que entram no motor comparado com o máximo teórico. O comando OBD-II '01 04' fornece em percentagem a carga no motor automotivo em tempo real.

Temperatura do Líquido de Arrefecimento do Motor O líquido de arrefecimento em conjunto com o radiador, ventoinha do radiador e válvula termostática são responsáveis pela manutenção da temperatura do motor (WANG; JAGARWAL; WAGNER, 2015). O líquido percorre a parte interna do motor, sem entrar em contato direto com os componentes de combustão. No radiador, a mistura que ficou quente transfere seu calor para o ar. Toda a dinâmica do líquido é realizada por mangueiras e tubos, e quem controla esse fluxo é a válvula termostática (WANG; JAGARWAL; WAGNER, 2015): ela bloqueia a água quando o motor esfria, e libera quando o motor ultrapassa determinada temperatura. Quando o carro é ligado, a bomba d'água tem a função de colocar o líquido em movimento pelo sistema, e quando o carro está desligado, o reservatório de água armazena o líquido. O padrão OBD-II fornece a opção de obter, em tempo real, a temperatura do líquido de arrefecimento do motor em graus Celsius, a partir do comando '01 05'.

Ajuste de Combustível de Curto Prazo Refere-se ao ajuste dinâmico ou instantâneo realizado na relação ar-combustível da mistura admitida. Procura manter a A/C numa taxa ótima. O comando OBD-II '01 06' fornece em percentagem o ajuste da mistura em tempo real, valores positivos indicam uma mistura com combustível em excesso, e valores negativos, indicam o oposto.

Ajuste de Combustível de Longo Prazo Refere-se ao ajuste gradual e mais lento, em relação ao de curto prazo, que permite compensar mudanças que ocorrem ao longo do tempo. Leva em consideração o desgaste natural do motor, e reflete a tendência do parâmetro STFT. O comando OBD-II '01 07' fornece em percentagem o ajuste da mistura

em tempo real, valores positivos indicam uma mistura com combustível em excesso, e valores negativos, indicam o oposto.

Pressão no Coletor de Admissão A pressão do coletor é uma medida da carga do motor. É usada para calcular a taxa de fluxo de massa de ar, que por sua vez determina o combustível a ser injetado para uma combustão ideal. O padrão OBD-II fornece a opção de obter, em tempo real, a pressão no coletor de admissão do motor em *Kilopascal* (kPa), a partir do comando '01 0B'.

Rotação do Motor Corresponde ao número de ciclos do motor. O padrão OBD-II fornece a opção de obter, em tempo real, a rotação do motor em Rotações por Minuto (RPM), a partir do comando '01 0C'.

Velocidade do Automóvel Refere-se a velocidade linear do automóvel. O comando OBD-II '01 0D' fornece em quilômetros por hora, ou do inglês, *Kilometres per Hour* (km/h), a velocidade do veículo em tempo real.

Temperatura do Ar no Interior da Ingestão É a temperatura do ar que entra no motor. É uma informação importante para estimar a densidade do ar de modo a equilibrar a mistura de ar e combustível na combustão. Ar mais frio é mais denso que o ar quente, então o ar frio requer mais combustível para manter a mesma A/C. O padrão OBD-II fornece a opção de obter, em tempo real, a temperatura do ar no interior da ingestão em graus Celsius, a partir do comando '01 0F'.

Posição do Pedal de Aceleração O comando OBD-II '01 11' exibe um valor em percentagem da posição da válvula borboleta, que é diretamente proporcional à posição do pedal do acelerador. 100% indica que a válvula está totalmente aberta (pedal apertado até o limite), e 0% que está totalmente fechada (pedal livre).

A/C na Combustão Interna do Motor É a relação entre a quantidade de ar e combustível na combustão interna do motor. A mistura estequiométrica é a mistura onde a A/C é a ideal para que ocorra a combustão. Conforme relatado em (KIM; RIZZONI; UT-KIN, 1998), o objetivo do controle A/C é manter a relação ar-combustível o mais próximo possível da relação estequiométrica sob várias condições operacionais. O padrão OBD-II fornece a opção de obter, em tempo real, a A/C na combustão interna do motor em volts, a partir do comando '01 14'. Desta forma, há um mapeamento entre valores de tensão e a relação ar-combustível.

2.3 Os Dados Automotivos Seleccionados

Entre os onze dados descritos anteriormente, existem três que são responsáveis por monitorar partes importantes do automóvel que costumam apresentar avarias: tensão da bateria automotiva, temperatura do líquido de arrefecimento do motor e A/C na combustão interna do motor. Nos parágrafos a seguir são relatados os motivos da relevância de cada sensor em separado. Os dados foram analisado em separado, porque na literatura foram encontradas muitas pesquisas sobre essas três informações veiculares em separado, não foram encontrados artigos que falassem em detalhes qual é a correlação entre essas três variáveis automotivas. Isto não impede que em trabalhos futuros, o classificador que receber as previsões de dados desses três sensores seja multivariado.

Segundo (KERSHAW; HALDERMAN, 2007), a alta tensão no sistema elétrico automotivo superaquece o eletrólito da bateria, encurta sua vida útil e também danifica os componentes que dependem de eletrônica de estado sólido, por exemplo, a injeção de combustível e sistemas de controle do motor. Por outro lado, a baixa tensão faz com que a bateria fique sulfatada. Consequentemente, o sistema elétrico deve ser mantido dentro dos limites de tensão especificados pelo fabricante para que o veículo tenha um desempenho adequado. Conforme relatado anteriormente, neste trabalho, a leitura da tensão nos terminais da bateria com o carro em funcionamento, foi obtida a partir de um comando interno do microcontrolador ELM327. Este microcontrolador é alimentando pelo sistema elétrico do automóvel, e por isso é capaz de informar a tensão da bateria em tempo real.

Em (WANG; JAGARWAL; WAGNER, 2015), é descrito que o sistema de resfriamento em motores a gasolina e diesel tem um papel importante na manutenção da temperatura desejada do motor, e tem o objetivo de manter o melhor desempenho do veículo. Se o motor funcionar muito quente, poderão ocorrer combustões anormais, levando o desperdício de combustível e emissões de escapamento acentuadas. E ainda, é explicado em (KERSHAW; HALDERMAN, 2007), que valores extremos de temperatura afetam a vida útil e o desempenho da bateria de diversas maneiras. A alta temperatura, causada por sobrecarga ou calor excessivo do motor, aumenta a perda de eletrólitos e reduz a vida útil da bateria. Neste trabalho, a temperatura do líquido de arrefecimento do motor, foi obtida a partir de um comando OBD-II, que permite acesso a dados de um sensor de temperatura que está dentro do motor automotivo. Os sensores originais de temperatura de motores da Fiat, geralmente, são fabricados pela empresa Magneti Marelli.

De acordo com (EBRAHIMI et al., 2014), a maior economia de combustível e a menor emissão de gases de escape para motores a combustão dependem significativamente do controle preciso da A/C. Ao manter a A/C próximo da relação estequiométrica, o conversor catalítico opera próximo à sua máxima eficiência de conversão, e as emissões de escape podem ser minimizadas. Neste trabalho, a leitura dos dados A/C foi realizada através de um comando OBD-II, que permite acesso ao sensor A/C do motor veicular. Os sensores originais A/C de motores da Fiat, geralmente, são fabricados pela empresa Bosch.

2.4 Análise dos Dados Coletados

Mais detalhes de como foi realizada a coleta dos dados serão apresentados no capítulo de experimentos e resultados. Porém, este capítulo é responsável por tratar os assuntos da leitura e coleta de dados automotivos. Por este motivo, nesta seção, antecipadamente são introduzidos os gráficos no tempo e algumas estatísticas dos dados coletados para esta pesquisa. Contudo, antes é discutido o efeito que diferentes condições de condução do veículo podem causar nos dados automotivos. Este é um detalhe importante, visto que os dados automotivos utilizados nesta pesquisa foram coletados pelo autor deste trabalho.

2.4.1 O Efeito de Diferentes Condições de Condução do Automóvel

Em (THEISSLER, 2013), verifica-se que o modo de condução do motorista poder fazer uma diferença significativa nos dados automotivos coletados. Segundo Theissler, uma maneira de lidar com isso no contexto de algoritmos de aprendizagem de máquina, é treinar e testar em conjunto de dados automotivos de um mesmo condutor, isso é viável na fase de pesquisa e desenvolvimento de um veículo, quando os engenheiros dirigem os próprios veículos. Porém, para testar uma frota de veículos, os automóveis de teste são conduzidos por vários motoristas. Nesse caso, o conjunto de treinamento deve conter dados de vários pilotos com diferentes comportamentos de direção para serem representativos. Sendo assim, motoristas de teste profissionais podem ser instruídos para imitar diferentes comportamentos de direção, portanto, um conjunto de treinamento representativo pode ser obtido de um número limitado de motoristas de teste (THEISSLER, 2013).

Theissler ainda examina que diferentes automóveis do mesmo modelo não apresentam diferenças significativas nos dados. Isso quer dizer que ao treinar um algoritmo de aprendizagem de máquina em um modelo de automóvel, este algoritmo servirá para testar os demais modelos idênticos do fabricante.

Nos experimentos para esta dissertação, o conjunto de dados foi obtido de dois condutores em um mesmo automóvel. A seguir são analisados os dados coletados.

2.4.2 Temperatura do Líquido de Arrefecimento do Motor

Na Figura 3 está ilustrada a curva da temperatura do líquido de arrefecimento de um motor no decorrer do tempo. Na Tabela 5 é apresentado um resumo estatístico. A média da temperatura é 81,91 °C, isto demonstra que o motor do automóvel funciona numa temperatura acima da temperatura ambiente. Os valores próximos de 40,0 °C indicam os momentos em que o veículo estava frio, ou seja, desligado por muito tempo e foi ligado, por isso que a temperatura está menos quente. Os valores acima de 80,0 °C indicam os momentos em que o sistema de arrefecimento entra em ação para diminuir o aumento da temperatura do motor, e pode-se observar que, 95,95 °C foi a temperatura máxima. É im-




Figura 3 – Evolução da temperatura do líquido de arrefecimento de um motor veicular no decorrer do tempo.

Tabela 5 – Resumo estatístico da temperatura do líquido de arrefecimento.

Mínimo	1º Quartil	Mediana	Média	3º Quartil	Máximo
39,25 °C	80,33 °C	85,50 °C	81,91 °C	87,56 °C	95,95 °C

portante observar que, no momento em que o automóvel é ligado, a temperatura ambiente influencia diretamente na temperatura inicial do líquido de arrefecimento. Porém, depois que o motor começa a trabalhar, ele entra em um processo de aquecimento, e procura se manter numa faixa temperatura ideal de funcionamento. Neste exemplo, acima dos 80,0 °C e abaixo dos 95,0 °C.

2.4.3 A/C na Combustão Interna do Motor

Na Figura 4 está ilustrada a curva A/C na combustão interna do um motor no decorrer do tempo. Na Tabela 6 é apresentado um resumo estatístico. Assim, de acordo com a Tabela 6, a A/C tem um valor médio 0,5981 Volts. Neste caso, esta seria aproximadamente a tensão correspondente a relação estequiométrica, pois o motor sempre procura manter a A/C próxima da relação estequiométrica. O valor mínimo foi de 0,4258 Volts, e o valor máximo 0,7115 Volts. Estes valores variam no decorrer do tempo, pois o motor




Figura 4 – Evolução A/C na combustão interna do motor no decorrer do tempo.

Tabela 6 – Resumo estatístico da A/C na combustão interna do motor.

Mínimo	1º Quartil	Mediana	Média	3º Quartil	Máximo
0,4258 V	0,5744 V	0,5998 V	0,5981 V	0,6245 V	0,7115 V

altera a quantidade de combustível a ser utilizada na combustão de acordo com diferentes fatores, entre eles, a aceleração, temperatura e tensão do sistema elétrico do motor a cada momento.

2.4.4 Tensão da Bateria Automotiva

Na Figura 5 está ilustrada a curva da tensão da bateria do motor no decorrer do tempo. Na Tabela 7 é apresentado um resumo estatístico. É possível observar que o valor da tensão da bateria está na faixa entre 12,36 Volts e 13,60 Volts, com valor médio de 13,17 Volts. O valor não é constante, porque, continuamente, os sistemas eletrônicos e elétricos do automóvel consomem energia elétrica com diferentes necessidades de potência a cada momento. Por isso, a tensão do sistema elétrico do veículo é variante no decorrer do tempo.




Figura 5 – Evolução da tensão da bateria automotiva no decorrer do tempo.

Tabela 7 – Resumo estatístico da tensão da bateria automotiva.

Mínimo	1º Quartil	Mediana	Média	3º Quartil	Máximo
12,36 V	13,04 V	13,20 V	13,17 V	13,36V	13,60 V

2.5 Resumo do Capítulo

Neste capítulo, foram tratadas informações sobre a leitura e coleta dos dados automotivos, como também, quais dados são os mais relevantes para o monitoramento de problemas automotivos. Desta forma, foi realizada uma análise de três informações do veículo: temperatura do líquido de arrefecimento, A/C na combustão interna do motor e tensão da bateria automotiva.

Assim, com base no conhecimento sobre os dados selecionados e estudados neste capítulo, foi possível dar andamento ao estudo para a realização de simulações computacionais com dados veiculares. No capítulo a seguir, são detalhados os conceitos teóricos dos modelos de previsão de séries temporais utilizados na pesquisa.

3 MODELOS DE PREVISÃO DE SÉRIES TEMPORAIS

Este capítulo expõe a teoria de séries temporais e descreve como é possível estimar valores futuros a partir do conhecimento do histórico de uma variável até o presente. São apresentados os modelos ARIMA, RNA, SVM e LS-SVM. Posteriormente, são descritos os modelos híbridos formulados a partir de combinações lineares e não lineares dos modelos mencionados anteriormente.

3.1 Séries Temporais

Uma série temporal é um conjunto de observações ordenadas no tempo que apresentam dependência entre instantes de tempo. De uma maneira um pouco mais formal, uma série temporal é uma realização de um processo estocástico, ou seja, é uma coleção de variáveis aleatórias indexadas por um conjunto de índices, que representa a evolução temporal de um sistema (BARROS, 2004).

Os principais objetivos do estudo de séries temporais são a análise e a previsão da série temporal, que nos permite encontrar estimativas de valores futuros a partir de valores passados e presentes da série (BARROS, 2004). Este tema tem uma ampla aplicabilidade em diversas áreas de pesquisa, como tecnologia de sistemas de controle (CAIRANO et al., 2014), energia sustentável (WAN et al., 2014), engenharia de dados (MALIK et al., 2014), informática em saúde (ZHU et al., 2017) e outros ramos da ciência aplicada que envolve registros ou medições temporais (ver (de MATTOS NETO; CAVALCANTI; MADEIRO, 2017) e referências contidas).

A dependência serial entre os valores da série é um aspecto essencial para a geração de previsões de valores futuros da série. Estas previsões teriam um alto grau de aleatoriedade, se não houvesse dependência serial. Diferentes séries possuem diferentes graus de previsibilidade. Por exemplo, é mais fácil prever uma série de temperaturas médias mensais do que a taxa mensal de inflação. Então, não se pode garantir que a previsão será sempre precisa, visto que tudo depende das características da série que está sendo analisada (BARROS, 2004). Vale salientar que o nível de incerteza aumenta com o horizonte de previsão. Isto é intuitivamente razoável, uma vez que é sempre mais difícil prever um futuro mais distante.

Basicamente, a predição de valores futuros de uma série temporal é realizada a partir dos seguintes conceitos:

- Utilizar o passado e o presente para descrever a trajetória mais provável da série no

futuro;

- O passado traz informações relevantes sobre o que irá ocorrer no futuro, pois existe correlação entre as variáveis em diversos instantes;
- Sempre existe incerteza associada às previsões, mas pode-se ter uma boa ideia de quais serão os valores mais prováveis no futuro;

O primeiro procedimento a se fazer ao estudar uma série temporal é construir um gráfico para exibir visualmente a evolução da série ao longo do tempo (BARROS, 2004). Este procedimento simples costuma ser bastante esclarecedor e permite identificar o modo de evolução da tendência da série: se existe sazonalidade, se há *outliers* etc. A Figura 6 ilustra o gráfico de uma série temporal com trezentas amostras, que representa a temperatura de um motor veicular no decorrer do tempo. Para entender o comportamento da grandeza ao longo do tempo, pode-se utilizar um método de decomposição conhecido como *Seasonal Trend Decomposition using Loess* (STL) (CLEVELAND et al., 1990), pois habitualmente o comportamento da série temporal é resultado de um conjunto de componentes, quais sejam, a sazonalidade, a tendência e os componentes aleatórios.




Figura 6 – Evolução da temperatura de um motor veicular no decorrer do tempo.

A sazonalidade explica o comportamento cíclico ao longo de um ano, ou intervalo menor, das grandezas envolvidas. Muitas vezes, a sazonalidade é resultado das variações

em função das estações do ano, como, por exemplo, o consumo de energia elétrica. Um meio de identificar sazonalidade (padrões de repetição) em uma série temporal é por meio de sua função de autocorrelação, definida como a correlação cruzada de um sinal consigo mesmo. A Figura 7 ilustra o gráfico da função de autocorrelação da série temporal que foi exibida na Figura 6. As linhas pontilhadas indicam o intervalo de confiança no nível de 95%. Valores fora deste intervalo podem ser considerados uma indicação de padrão de repetição. É possível notar que na defasagem 16, que é o retardo da série em 16 unidades de tempo, há uma amplitude acima do limite do intervalo de confiança com valor próximo de 1,0. Isto indica evidência de sazonalidade na série temporal com frequência igual a 16.




Figura 7 – Função de autocorrelação da série temporal da temperatura do motor veicular.

A tendência em uma série temporal se refere ao seu comportamento em relação ao tempo. É definida como um padrão de crescimento ou decrescimento da variável em análise em um certo período de tempo. Pode ser consequência do aumento da população, por exemplo, a receita de vendas de uma empresa tende a crescer por causa do aumento da população.

Os componentes aleatórios são as variações remanescentes após remover os efeitos sazonais e de tendência de uma série (CLEVELAND et al., 1990). Esse componentes não são precisamente uma realização de um processo aleatório, mas sim uma estimativa dessa realização. É uma estimativa porque é obtida da série temporal original usando estimativas da tendência e efeitos sazonais (COWPERTWAIT; METCALFE, 2009).

3.2 Modelos de Previsão de Séries Temporais

Nesta secção serão introduzidos os modelos de previsão de séries temporais utilizados neste trabalho.

3.2.1 Modelo ARIMA

O modelo ARIMA está entre os modelos lineares mais utilizados para previsão de séries temporais. Inicialmente, sua popularidade surgiu por causa das suas propriedades estatísticas e a conhecida metodologia Box-Jenkins, muito utilizada no processo de construção deste modelo (ZHANG, 2003). Devido as características lineares, o ARIMA é um modelo de fácil interpretação e que requer pouco recurso computacional, o que o torna, ainda nos dias de hoje, bastante atrativo na modelagem e previsão de séries temporais.

Para descrever a formulação do modelo ARIMA em detalhes, é necessário antes introduzir dois conceitos importantes: o ruído branco e a estacionariedade. Ruído branco é um tipo de sinal cujas amostras são variáveis aleatórias independentes, identicamente distribuídas, com média zero e variância constante. O termo ruído é utilizado porque essas propriedades quase sempre são indesejadas em um sinal. Já estacionariedade, é uma propriedade que indica que o processo possui a média, variância e função de autocorrelação constantes no decorrer do tempo.

Uma forma de validar os requisitos para a estacionariedade é a partir de testes de hipótese, que consistem em verificar se a função que representa a série contém raiz unitária nos operadores de retardo, pois isto indica um processo com médias que mudam com o tempo, e assinala a não estacionariedade. Testes de hipótese para a presença de raiz unitária foram introduzidos por Dickey e Fuller em 1979 (BROCKWELL; DAVIS, 2002). Um exemplo, é o teste de Dickey-Fuller aumentado, ou do inglês, *Augmented Dickey Fuller* (ADF), que é comumente usado para testar a estacionariedade em séries temporais financeiras (LI et al., 2017). Caso o teste ADF indique a não estacionariedade, é possível fazer um procedimento para transformar uma série não estacionária em uma série estacionária: obtêm-se as diferenças entre os valores das amostras da série não estacionária. Por exemplo, a Equação (3.1) apresenta uma série diferenciada $W(t)$ a partir de uma série $Z(t)$.

$$W(t) = \nabla Z(t) = Z(t) - Z(t - 1). \quad (3.1)$$

A partir dos conceitos definidos anteriormente, é possível introduzir a formulação do modelo autorregressivo de média móvel, ou do inglês, *Autoregressive Moving Average* (ARMA), muito utilizado para análise de séries temporais e também popularizado por Box e Jenkins (BOX; JENKINS; REINSEL, 2008). Este modelo somente é adequado para séries estacionárias e é obtido a partir da adição de termos autorregressivos, ou do inglês, *Autoregressive* (AR) e médias móveis, ou do inglês, *Moving Average* (MA). Assim, o valor

futuro de uma variável é assumido como uma função linear de várias observações passadas, que são os termos AR, e erros aleatórios (ruído branco), que são os termos MA. Por isso, o processo que gera a série temporal em um modelo ARMA tem a forma (COWPERTWAIT; METCALFE, 2009):

$$y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} \quad (3.2)$$

em que, y_t e ε_t são o valor real da série e o erro aleatório no tempo t , respectivamente. ϕ_i ($i = 1, 2, \dots, p$) e θ_j ($j = 1, 2, \dots, q$) são os parâmetros do modelo, tal que p e q são inteiros referentes às ordens dos termos AR e MA, respectivamente. Os erros aleatórios ε_t são assumidos como independentes e identicamente distribuídos com média zero e variância constante (ruído branco).

Determinados os valores de p e q , o objetivo seguinte é a estimação dos parâmetros ϕ_i ($i = 1, 2, \dots, p$) e θ_j ($j = 1, 2, \dots, q$). Geralmente, são utilizados os estimadores de máxima verossimilhança, ou do inglês, *Maximum Likelihood Estimator* (MLE), ou soma condicional de quadrados, ou do inglês, *Conditional Sum of Squares* (CSS). No método MLE, os valores dos parâmetros são estimados de forma que maximizem a probabilidade de que o processo ARMA produza os dados que foram realmente observados. Já o método CCS, ajusta o modelo minimizando a soma condicional dos quadrados e as estimativas são condicionais no pressuposto de que os erros passados não observados são iguais a zero. Enquanto o MLE é considerado um método mais preciso, o CSS apresenta um custo computacional menor.

Quando os dados temporais não são estacionários, a recomendação, conforme mencionado anteriormente, é tomar as diferenças até que a estacionariedade seja alcançada e, em seguida, prossegue-se ajustando um modelo ARMA aos dados diferenciados. Um modelo para um processo cuja d -ésima diferença segue um modelo ARMA (p, q) é chamado de processo ARIMA de ordem (p, d, q) , ou ARIMA (p, d, q) (PETRIS; PETRONE; CAMPAGNOLI, 2009). Embora um modelo ARIMA seja bastante flexível na modelagem de uma ampla gama de séries temporais, sua principal limitação é a forma linear presumida do modelo. Ou seja, uma estrutura de autocorrelação linear é assumida antes que o modelo seja ajustado aos dados. Portanto, um modelo ARIMA não é capaz de modelar padrões não lineares (ZHANG, 2004). Neste contexto, modelos não lineares são uma alternativa para análise e previsão de séries temporais (ZHU; WEI, 2013).

3.2.2 Modelo MLP

No caso de modelos não lineares, as abordagens baseadas em RNA têm alcançado resultados significativos em relação à precisão (de MATTOS NETO; CAVALCANTI; MADEIRO, 2017). Entre essas abordagens, a perceptron multicamada, ou do inglês, *Multilayer Perceptron* (MLP) com uma única camada oculta é a mais comumente usada (ZHANG, 2003).

A MLP é uma RNA *feedforward* que mapeia dados de entrada para um ou mais conjuntos de saídas. No caso particular da previsão de série temporal univariada, os dados de entrada são as defasagens no tempo e a saída desejada é o valor futuro. O modelo MLP é uma RNA composta por pelo menos três camadas (entrada, oculta e saída) conectadas totalmente e diretamente em apenas uma direção. Embora existam novos e promissores modelos de RNA na literatura, a MLP ainda é uma ferramenta amplamente utilizada no desenvolvimento de sistemas inteligentes para modelagem de séries temporais complexas do mundo real, devido a sua precisão e simplicidade (GUO et al., 2018; ZHANG, 2003). A relação entre a saída (y_t) e as entradas ($y_{t-1}, y_{t-2}, \dots, y_{t-p}$) da MLP com uma única camada oculta tem a seguinte representação matemática (ZHANG, 2003):

$$y_t = \tau_0 + \sum_{j=1}^q \tau_j g \left(\beta_{0j} + \sum_{i=1}^p \beta_{ij} y_{t-i} \right) + \varepsilon_t \quad (3.3)$$

em que τ_j ($j = 0, 1, 2, \dots, q$) e β_{ij} ($i = 0, 1, 2, \dots, p, j = 1, 2, \dots, q$) são os parâmetros do modelo normalmente chamados de pesos de conexão, p é o número de nós de entrada e q é o número de nós ocultos. A função logística é frequentemente usada como função de transferência da camada oculta e é dada por (ZHANG, 2003):

$$g(x) = \frac{1}{1 + e^{-x}}. \quad (3.4)$$

Desta forma, o modelo RNA definido em (3.3) realiza um mapeamento não linear a partir das observações passadas ($y_{t-1}, y_{t-2}, \dots, y_{t-p}$) para obter o valor futuro y_t (ZHANG, 2003):

$$y_t = f(y_{t-1}, y_{t-2}, \dots, y_{t-p}; \mathbf{v}) + \varepsilon_t, \quad (3.5)$$

em que $\mathbf{v}$ é um vetor de todos os parâmetros e f é uma função determinada pela estrutura da rede e pesos de conexão. Desta forma, a MLP é equivalente a um modelo autorregressivo não linear.

Uma vez que a estrutura da rede é especificada, o próximo passo é o treinamento. Assim, os pesos de conexão são estimados de forma que um critério geral de precisão, como erro quadrático médio, seja minimizado (ZHANG, 2003). Um algoritmo muito popular para essa etapa é o *backpropagation*. Neste algoritmo, a minimização da função de erro é realizada usando uma técnica de gradiente descendente. As correções necessárias aos pesos da rede para cada momento t são obtidas calculando-se a derivada parcial da função de erro em relação a cada peso de conexão (BARBALATA; LEUSTEAN, 2004). Contudo, esse método é considerado instável por não possuir uma atualização de peso apropriada, resultando em oscilações e passos desnecessários para alcançar uma solução aceitável (RIEDMILLER; BRAUN, 1993).

Uma alternativa ao *backpropagation* é o algoritmo *Resilient Propagation* (RPROP), que propõe uma convergência mais rápida. O RPROP é um esquema de aprendizado eficiente, que realiza uma adaptação direta da etapa de peso com base em informações do

gradiente local. Uma diferença crucial para o *backpropagation*, é que o esforço de adaptação não é comprometido pelo comportamento do gradiente (RIEDMILLER; BRAUN, 1993). O princípio básico do algoritmo RPROP é eliminar a influência prejudicial do tamanho da derivada parcial na etapa de peso. Como consequência, apenas o sinal da derivada é considerado para indicar a direção da atualização de peso (BARBALATA; LEUSTEAN, 2004). Além disso, diferentemente do *backpropagation*, no algoritmo RPROP cada peso de conexão tem seu valor de atualização individual, que determina apenas o tamanho da atualização do peso (RIEDMILLER; BRAUN, 1993). Portanto, o RPROP é um algoritmo com um tratamento mais sofisticado e apropriado para a atualização dos pesos da rede, bem como, mais aprimorado para alcançar uma solução aceitável.

O algoritmo RPROP usa três parâmetros, quais sejam, valor inicial de atualização Δ_0 , valor máximo para o tamanho do passo Δ_{max} , e o expoente de decaimento de peso μ (ZELL et al., 2008). Quando o aprendizado é iniciado, todos os valores de atualização são definidos para um valor inicial Δ_0 . Para evitar que os pesos se tornem muito grandes, o peso máximo determinado pelo tamanho do valor de atualização é limitado. O limite superior é definido pelo segundo parâmetro do RPROP, Δ_{max} . O parâmetro de decaimento de peso μ determina a relação de dois objetivos: reduzir o erro de saída da rede neural (a meta padrão) e reduzir o tamanho dos pesos (para melhorar a generalização) (ZELL et al., 2008). A formulação da função de erro E é dada por:

$$E = \sum_{k=1}^n (o_k - r_k)^2 + 10^{-\mu} \sum_{i,j} \pi_{ij}^2 \quad (3.6)$$

em que o_k e r_k são o valor objetivo e a resposta do k -ésimo valor de saída da MLP, respectivamente; n é o número de amostras no conjunto de treinamento; π_{ij} é o peso de conexão entre o i -ésimo e j -ésimo neurônios das diferentes camadas da MLP.

3.2.3 Modelo SVM

O modelo SVM utiliza a técnica de minimização do risco estrutural, ou do inglês, *Structural Risk Minimization* (SRM), o que significa que minimiza um limite superior do erro de generalização (ZHU; WEI, 2013). Essa minimização pode resultar em resistência ao problema de *overfitting*. Na previsão de séries temporais, a regressão SVM, também chamada de regressão por vetores de suporte, ou do inglês, *Support Vector Regression* (SRV), tem obtido excelentes desempenhos em aplicações do mundo real (SOUALHI; MEDJAHHER; ZERHOUNI, 2015; GUO et al., 2018). Uma vantagem do SVM em relação a outros métodos de inteligência artificial é que um ótimo global pode ser obtido, já que a formulação do problema é geralmente convexa (LANGONE et al., 2015). Contudo, o processo de treinamento do SVM pode levar muito tempo, pois utiliza Programação Quadrática (PQ).

O modelo ϵ -*Support Vector Regression* (ϵ -SVR) está entre os tipos de SRV mais utilizados. O ϵ -SVR utiliza uma margem de tolerância ϵ , que pode ser violada por meio de duas variáveis de folga ξ_k^+ e ξ_k^- . A seguir, é introduzida a formulação.

De acordo com (WANG; HU, 2005), dado o conjunto de dados

$$D = \{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_k, y_k), \dots, (\mathbf{x}_n, y_n)\}, \mathbf{x}_k \in R^n, y_k \in R \quad (3.7)$$

em que $\mathbf{x}_k$ é a variável de entrada e y_k é a variável de saída, e objetivando aproximá-lo a uma função não linear:

$$f(\mathbf{x}) = \langle \boldsymbol{\omega}, \varphi(\mathbf{x}) \rangle + b \quad (3.8)$$

em que $\langle \cdot, \cdot \rangle$ denota o produto escalar; $\boldsymbol{\omega} \in R^{n_h}$ é o vetor peso; $\varphi(\cdot) : R^n \rightarrow R^{n_h}$ é a função não linear que mapeia o espaço de entrada para o chamado espaço característico de alta dimensão onde a regressão linear é executada; b é o *bias*. A dimensão n_h deste espaço é implicitamente definida, o que significa que pode ser de dimensão infinita (WANG; HU, 2005).

O problema de otimização do ϵ -SVR é dado por:

$$\min \frac{1}{2} \|\boldsymbol{\omega}\|^2 + C \sum_{k=1}^n (\xi_k^+ + \xi_k^-) \quad (3.9)$$

com as restrições:

$$\begin{cases} y_k - \langle \boldsymbol{\omega}, \varphi(\mathbf{x}_k) \rangle - b \leq \epsilon + \xi_k^+ \\ \langle \boldsymbol{\omega}, \varphi(\mathbf{x}_k) \rangle + b - y_k \leq \epsilon + \xi_k^- \\ \xi_k^+, \xi_k^- \geq 0 \end{cases} \quad (3.10)$$

e a função de perda ϵ -insensível

$$|y - f(\mathbf{x}, \boldsymbol{\omega})|_\epsilon = \begin{cases} 0, & \text{se } |y - f(\mathbf{x}, \boldsymbol{\omega})| \leq \epsilon \\ |y - f(\mathbf{x}, \boldsymbol{\omega})| - \epsilon, & \text{caso contrário.} \end{cases} \quad (3.11)$$

em que $|\cdot|_\epsilon$ é a chamada função de perda ϵ -insensível, e ϵ é uma margem de tolerância ajustada para tolerar o desvio da regressão dos valores reais. Segundo (SMOLA; SCHÖLKOPF, 2004), a região limitada por $|y - f(\mathbf{x}, \boldsymbol{\omega})| \leq \epsilon$ é chamada de tubo ϵ -insensível. As observações que estão fora do tubo, recebem uma das duas variáveis de penalidade, dependendo de estarem acima ξ_k^+ ou abaixo ξ_k^- do tubo. O parâmetro $C > 0$ determina o equilíbrio entre o excesso de ajustes de f e o grau em que os desvios são maiores do que os tolerados (penalidades ξ_k^+ e ξ_k^-) na formulação de otimização. Um valor menor de C tolera um desvio maior (WANG; HU, 2005).

De acordo com (WANG; HU, 2005), ao reformular o problema de otimização como uma Lagrangiana L_{svm} , tem-se:

$$\begin{aligned} L_{svm} = & \frac{1}{2} \|\boldsymbol{\omega}\|^2 + C \sum_{k=1}^n (\xi_k^+ + \xi_k^-) \\ & - \sum_{k=1}^n \alpha_k^+ (\epsilon + \xi_k^+ - y_k + \langle \boldsymbol{\omega}, \varphi(\mathbf{x}_k) \rangle + b) \\ & - \sum_{k=1}^n \alpha_k^- (\epsilon + \xi_k^- + y_k - \langle \boldsymbol{\omega}, \varphi(\mathbf{x}_k) \rangle - b) \\ & - \sum_{k=1}^n (\eta_k^+ \xi_k^+ + \eta_k^- \xi_k^-) \end{aligned} \quad (3.12)$$

em que $\alpha^+, \alpha^-, \eta_k^+, \eta_k^- \geq 0$ são multiplicadores de Lagrange. Para encontrar o ponto de sela, obtém-se as derivadas parciais de L_{svm} com relação as variáveis $(\boldsymbol{\omega}, b, \xi_k^+, \xi_k^-)$ (WANG; HU, 2005):

$$\begin{cases} \frac{\partial L_{svm}}{\partial w} = 0 \rightarrow w = \sum_{k=1}^n (\alpha_k^+ - \alpha_k^-) \varphi(\mathbf{x}_k) \\ \frac{\partial L_{svm}}{\partial b} = 0 \rightarrow \sum_{i=1}^n (\alpha_k^- - \alpha_k^+) = 0 \\ \frac{\partial L_{svm}}{\partial \xi_k^+} = 0 \rightarrow C - \alpha_k^+ - \eta_k^+ = 0 \\ \frac{\partial L_{svm}}{\partial \xi_k^-} = 0 \rightarrow C - \alpha_k^- - \eta_k^- = 0 \end{cases} \quad (3.13)$$

As condições para otimalidade produzem a seguinte problema na forma dual (WANG; HU, 2005):

$$\max_{\alpha_k^+, \alpha_k^-} Q = \sum_{k=1}^n (\alpha_k^+ - \alpha_k^-) y_k - \epsilon \sum_{k=1}^n (\alpha_k^+ - \alpha_k^-) - \frac{1}{2} \sum_{k,j=1}^n (\alpha_k^+ - \alpha_k^-) (\alpha_j^+ - \alpha_j^-) K(\mathbf{x}_k, \mathbf{x}_j) \quad (3.14)$$

α_k^+ e α_k^- são obtidos pela aplicação de um PQ *solver* em 3.14 com as restrições:

$$\begin{aligned} 0 \leq \alpha_k^+, \alpha_k^- \leq C, k = 1, \dots, n. \\ \sum_{k=1}^n (\alpha_k^+ - \alpha_k^-) = 0 \forall k. \end{aligned} \quad (3.15)$$

De acordo com (WANG; HU, 2005), no final, ao aplicar a condição de Mercer, o ϵ -SVR para estimativa de função não linear toma a forma:

$$f(x) = \sum_{k=1}^n (\alpha_k^+ - \alpha_k^-) K(\mathbf{x}, \mathbf{x}_k) + b \quad (3.16)$$

em que $K(x, x_k)$ é chamada de função *kernel*. Na prática, entre as funções *kernel* mais utilizadas está a função de base radial, ou do inglês, *Radial-Basis Function* (RBF), conhecida também como Gaussiana. A RBF tem a forma de uma função de base radial, ou mais especificamente, uma função gaussiana, e é formulada a seguir:

$$K(\mathbf{x}, \mathbf{x}_k) = \exp(-\lambda \|\mathbf{x} - \mathbf{x}_k\|^2), k = 1, \dots, n. \quad (3.17)$$

em que λ é o inverso do desvio padrão σ do *kernel* RBF:

$$\lambda = \frac{1}{2\sigma} \quad (3.18)$$

O parâmetro b em (3.16) pode ser calculado a partir das condições de Karush-Kuhn-Tucker (KKT). Portanto, de (WANG; HU, 2005):

$$\begin{aligned} b &= y_k - \langle \boldsymbol{\omega}, \varphi(\mathbf{x}_k) \rangle - \epsilon, \alpha_k^+ \in (0, C) \\ b &= y_k - \langle \boldsymbol{\omega}, \varphi(\mathbf{x}_k) \rangle + \epsilon, \alpha_k^- \in (0, C) \end{aligned} \quad (3.19)$$

3.2.4 Modelo LS-SVM

Uma variante da técnica SVM, chamada LS-SVM, foi proposta em (SUYKENNS; VAN-DEWALLE, 1999) com uma formulação baseada em mínimos quadrados. Como resultado, uma abordagem direta é usada para resolver problemas mais rapidamente, resolvendo um conjunto de equações lineares, em vez de programação quadrática. Desde então, o LS-SVM tem sido utilizado com sucesso no reconhecimento de padrões e na regressão não linear para lidar com problemas de estimativa. De acordo com (LANGONE et al., 2015), o modelo LS-SVM é uma técnica de inteligência computacional caracterizada por uma capacidade de generalização de alta qualidade, flexibilidade no design do modelo e um procedimento claro para a seleção de modelos.

A partir de (WANG; HU, 2005), e considerando o conjunto de dados definido pela expressão (3.7), o LS-SVM estabelece o seguinte problema de otimização:

$$\min_{\omega, b, e} J(\omega, e) = \frac{1}{2} \|\omega\|^2 + \frac{1}{2} \gamma \sum_{k=1}^n e_k^2 \quad (3.20)$$

com as restrições:

$$y_k = \langle \omega, \varphi(\mathbf{x}_k) \rangle + b + e_k, k = 1, \dots, n. \quad (3.21)$$

em que $\gamma \geq 0$ é uma constante de regularização. Um valor menor de γ pode evitar o *overfitting* em caso de dados ruidosos (WANG; HU, 2005). É notável que há um ajuste da soma do quadrado dos erros, ou do inglês, *Sum of Squared Errors* (SSE). Além de um termo de regularização γ na função custo, que também é um procedimento padrão no treinamento de redes neurais *feedforward* e está relacionado a *ridge regression* (WANG; HU, 2005). Reformulando (3.20) e (3.21) como uma Lagrangiana L_{ls-svm} , obtém-se a formulação dual (ZHU; WEI, 2013):

$$L_{ls-svm} = J(\omega, e) - \sum_{i=1}^n \alpha_k \{ \langle \omega, \varphi(\mathbf{x}_k) \rangle + b - e_k - y_k \} \quad (3.22)$$

em que $\alpha_k \in R$ é o multiplicador de Lagrange. As condições para otimalidade são dadas através derivadas parciais de L_{ls-svm} com relação as variáveis $(\omega, b, e_k, \alpha_k)$ (WANG; HU, 2005):

$$\begin{cases} \frac{\partial L}{\partial \omega} = 0 \rightarrow & \omega = \sum_{k=1}^n \alpha_k \varphi(\mathbf{x}_k) \\ \frac{\partial L}{\partial b} = 0 \rightarrow & \sum_{k=1}^n \alpha_k = 0 \\ \frac{\partial L}{\partial e_k} = 0 \rightarrow & \alpha_k = \gamma e_k \\ \frac{\partial L}{\partial \alpha_i} = 0 \rightarrow & \langle \omega, \varphi(\mathbf{x}_k) \rangle + b + e_k - y_k = 0 \end{cases} \quad (3.23)$$

De acordo com (WANG; HU, 2005; ZHU; WEI, 2013), ao eliminar ω e e_k , as equações podem ser alteradas para as equações lineares:

$$\begin{bmatrix} b \\ \alpha \end{bmatrix} = \begin{bmatrix} 0 & \mathbf{\tilde{I}}^T \\ \mathbf{\tilde{I}} & \Omega + \gamma^{-1} \mathbf{I} \end{bmatrix}^{-1} \begin{bmatrix} 0 \\ \mathbf{y} \end{bmatrix} \quad (3.24)$$

em que $\mathbf{y} = [y_1, y_2, \dots, y_n]$, $\mathbf{\bar{1}} = [1, 1, \dots, 1]$, $\boldsymbol{\alpha} = [\alpha_1, \alpha_2, \dots, \alpha_n]$, e a condição Mercer é aplicada a matriz $\boldsymbol{\Omega}$ com $\Omega_{lm} = \langle \phi(x_l) \rangle \langle \phi(x_m) \rangle = K(\mathbf{x}_l, \mathbf{x}_m)$, $l, m = 1, 2, \dots, n$ (ZHU; WEI, 2013). Assim, o modelo LS-SVM pode ser obtido a partir da formulação (WANG; HU, 2005; ZHU; WEI, 2013):

$$f(x) = \sum_{k=1}^n \alpha_k K(\mathbf{x}, \mathbf{x}_k) + b \quad (3.25)$$

em que α_k e b são soluções de (3.24) e $K(\mathbf{x}, \mathbf{x}_k)$ é a função *kernel* RBF de (3.17).

3.3 Modelos Híbridos

Séries temporais do mundo real geralmente apresentam padrões lineares e não lineares agregados de alguma maneira. Assim, o uso de apenas um tipo de modelagem (linear ou não linear) pode não ser adequado, levando a resultados com baixa precisão (de MATTOS NETO; CAVALCANTI; MADEIRO, 2017). Portanto, para modelar dados do mundo real, é aconselhável que modelos híbridos sejam utilizados, isto é, modelos de séries temporais compostos de diferentes combinações de preditores. Uma opção é utilizar um primeiro preditor para prever a série de dados original e um segundo para corrigir o que o primeiro modelo não conseguiu mapear na série. Desta forma, o segundo preditor executa a modelagem da série de erros. Esses erros são também conhecidos como resíduos e são definidos como a diferença entre a série de dados e a previsão do primeiro modelo. Alguns trabalhos, também, usam mais de um preditor para executar a modelagem de série de erros em várias etapas (de MATTOS NETO; CAVALCANTI; MADEIRO, 2017).

3.3.1 Modelos Híbridos Combinados Linearmente

Uma primeira abordagem para mesclar diferentes métodos de previsão de séries temporais é a partir de modelos Combinados Linearmente (CL). Em (ZHANG, 2003), há uma proposta de uma abordagem híbrida para a previsão de séries temporais usando os modelos ARIMA e ANN, uma vez que nem o ARIMA nem o ANN, separadamente, são modelos universais adequados para todas as circunstâncias. O ARIMA é utilizado para analisar a parte linear do problema, enquanto o modelo RNA é aplicado para investigar os resíduos do modelo ARIMA. Como o modelo ARIMA não pode capturar a estrutura não linear dos dados, os resíduos do modelo linear conterão padrões não lineares, caso eles existam.

Assim, é razoável considerar que uma série temporal no período t , ou seja, y_t , é composta por duas componentes, uma linear e outra não linear, tal que (ZHANG, 2003):

$$y_t = L_t + N_t, \quad (3.26)$$

em que L_t é componente linear e N_t é a componente não linear no período t . O modelo ARIMA é responsável por modelar a série e, então, o seu resíduo no período t , ou seja,

e_t , conterà apenas padrões não lineares, tal que:

$$e_t = y_t - \hat{L}_t, \quad (3.27)$$

em que $\hat{L}_t$ é a previsão do modelo ARIMA no período t . Ao modelar estes resíduos utilizando RNAs, podem ser descobertos relacionamentos não lineares. Logo, o modelo RNA para o resíduo e_t é dado por:

$$e_t = f(e_{t-1}, e_{t-2}, \dots, e_{t-n}) + \varepsilon_t, \quad (3.28)$$

em que f é uma função não linear determinada pela ANN, n é o número de nós de entrada e ε_t é o erro aleatório no tempo t . Ao simbolizar a previsão dada por (3.28) como $\hat{N}_t$, a previsão do modelo híbrido CL no período t será

$$\hat{y}_t = \hat{L}_t + \hat{N}_t. \quad (3.29)$$

Uma generalização do modelo híbrido proposto em (ZHANG, 2003) é exibida na Figura 8, em que a série temporal $Y = [y_{t-k}, \dots, y_{t-2}, y_{t-1}]$, a série de resíduos $E = [e_{t-n}, \dots, e_{t-2}, e_{t-1}]$, com k e n sendo a quantidade de retardos determinados pelos modelos m_0 e m_1 , respectivamente. O resíduo e_t no instante t do modelo m_0 é obtido por meio de

$$e_t = y_t - m_0(Y), \quad (3.30)$$

em que $m_0(Y)$ é a previsão da série Y a partir do modelo m_0 . Finalmente, $m_1(E)$ é a previsão dos resíduos E usando o modelo m_1




Figura 8 – Diagrama de uma generalização do modelo híbrido de previsão de séries temporais a partir da combinação linear proposta em (ZHANG, 2003).

Logo, a previsão $\hat{y}_t$ no instante t desta abordagem híbrida de estimativa em dois estágios é dada por:

$$\hat{y}_t = m_0(Y) + m_1(E). \quad (3.31)$$

Em (ZHU; WEI, 2013), Zhu e Wei apresentaram modelos híbridos incorporando ARIMA com LS-SVM para previsão de preço de carbono. Entre os modelos propostos em (ZHU;

WEI, 2013), existe um baseado em (ZHANG, 2003), que consiste no modelo ARIMA como m_0 para modelar padrões lineares e o modelo LS-SVM como m_1 para capturar padrões não lineares. Essa metodologia híbrida melhorou a precisão da previsão, pois o LS-SVM foi capaz de mapear os padrões não lineares do carbono.

Em (ALMEIDA; CUNHA; de MATTOS NETO, 2016), é proposto um sistema inteligente para prever dados automotivos com a utilização de um modelo híbrido de séries temporais baseado em (ZHANG, 2003). O modelo híbrido com ARIMA e MLP mostrou desempenho superior aos modelos monolíticos aplicados individualmente em conjuntos de dados automotivos coletados por meio do sistema OBD-II.

O principal problema que trata dos modelos híbridos de séries temporais combinados linearmente é a suposição de que a relação entre a previsão da série temporal e seu erro residual é aditiva. Essa suposição pode limitar a precisão do sistema híbrido ou até mesmo degradar seu desempenho em relação à previsão m_0 . Esse comportamento pode acontecer se, por exemplo, o acoplamento entre m_0 e m_1 for não linear (KHASHEI; BIJARI, 2011).

3.3.2 Modelos Híbridos Combinados Não Linearmente

Modelos de previsão de séries temporais híbridos Combinados Não Linearmente (CNL) já são conhecidos na literatura (de MATTOS NETO; CAVALCANTI; MADEIRO, 2017; ZHU; WEI, 2013; KHASHEI; BIJARI, 2011). Por exemplo, um novo segundo estágio de treinamento para modelagem não linear foi proposto em (KHASHEI; BIJARI, 2011) para superar as limitações dos modelos híbridos aditivos. Desta forma, a previsão combinada $\hat{y}_t$ é uma função não linear especificada por uma RNA (modelo m_1), onde as entradas são $m_0(Y)$, a série de resíduos E (de m_0) e a própria série temporal Y . Em (ZHU; WEI, 2013), Zhu e Wei, além de apresentarem modelos CL, também propõem modelos híbridos CNL para previsão de preços do carbono. Dentre os modelos, um obteve previsões mais precisas aplicando LS-SVM em vez da RNA (modelo m_1) como um combinador não linear da série Y e dos resíduos E (de m_0).

A modelagem apropriada de padrões lineares e não lineares em séries temporais é um grande desafio. Em outras palavras, a melhor função para combinar $m_0(Y)$ e $m_1(E)$ ainda não é bem conhecida. Com base nisso, uma nova arquitetura mais geral foi proposta em (de MATTOS NETO; CAVALCANTI; MADEIRO, 2017), em que um método de combinação não linear intitulado de *Nonlinear Combination* (NoLiC) é utilizado para mesclar os previsores. A Figura 9 exibe um diagrama desta abordagem híbrida de previsão de três estágios, onde cada modelo individual é denotado por m_0 , m_1 , e m_2 .

A estratégia proposta em (de MATTOS NETO; CAVALCANTI; MADEIRO, 2017) é baseada na combinação não linear da previsão da séries temporal original e de seus resíduos. Primeiramente, o modelo de previsão m_0 é treinado usando a série temporal univariada Y . Em seguida, a série de resíduos E é usada para treinar o modelo de previsão m_1 . Finalmente, o modelo de previsão m_2 é treinado usando a saída dos dois modelos previamente




Figura 9 – Diagrama do modelo híbrido de previsão de séries temporais baseado na combinação não linear proposta em (de MATTOS NETO; CAVALCANTI; MADEIRO, 2017).

treinados m_0 e m_1 . Desta forma, m_2 é um modelo não linear responsável por obter a melhor função que combina a previsão $m_0(Y)$ da série temporal Y e a previsão $m_1(E)$ da série de erros E . Assim, a saída $\hat{y}_t$ no instante t do método NoLiC é representada por:

$$\hat{y}_t = m_2(m_0(Y), m_1(E)) \quad (3.32)$$

3.4 Resumo do Capítulo

Neste capítulo, foram explanados os conceitos teóricos dos modelos de previsão utilizados nesta pesquisa. Modelos monolíticos e híbridos foram apresentados. Entre os modelos híbridos, há dois tipos de combinações: a linear e a não linear.

Desta forma, por meio destes modelos, foi possível realizar simulações computacionais para prever dados automotivos. Estas simulações são examinadas no capítulo a seguir.

4 EXPERIMENTOS E RESULTADOS

Nesse capítulo, serão apresentados os experimentos executados na pesquisa. Inicialmente é descrito como a base de dados automotiva foi obtida para a execução dos experimentos. Posteriormente, é explicado como foi realizada a estimação dos parâmetros dos modelos e também são apresentadas as métricas de avaliação. A seguir são exibidos os resultados com um estudo comparativo entre diferentes modelos de previsão de séries temporais monolíticos e híbridos com técnicas de combinação linear e não linear de previsores.

4.1 Configuração Experimental




Figura 10 – Configuração experimental usada para construir o banco de dados automotivo usado neste trabalho.

A Figura 10 ilustra a configuração experimental implementada para construir o banco de dados automotivo usado neste trabalho. Por meio de um adaptador OBD-II baseado no microcontrolador ELM327, os dados veiculares foram obtidos a partir de um Fiat Palio *Fire* 1.0 8V *Flex* 2007. Os sensores automotivos utilizados nesta pesquisa foram temperatura do líquido de arrefecimento do motor, o A/C na combustão interna do motor e tensão da bateria do automóvel. Após a leitura dos dados, o adaptador OBD-II envia

as informações para o aplicativo ComuniCar¹ por meio de uma interface *Bluetooth*.

A coleta de dados foi realizada durante o primeiro trimestre de 2017. As rotas foram percorridas em um carro nas vias urbanas de Recife-PE e Maceió-AL, assim como na rodovia interestadual entre essas duas cidades. Dois condutores dirigiram o automóvel. Foi importante ter dados de rotas distintas do automóvel e de condutores diferentes com o objetivo de obter diferentes comportamentos da operação do motor, por exemplo, velocidade, tempo de condução e carga de operação. Desta forma, procurou-se coletar dados com diferentes comportamentos a fim de obter uma representação mais realista e completa do motor automotivo. Em (THEISLER, 2013), simulações indicam que o algoritmo de aprendizagem de máquina tem melhor desempenho no conjunto de teste quando treinado com dados automotivos compostos de diferentes tipos de vias.

Assim, um banco de dados foi construído com aproximadamente 60.000 amostras de cada sensor do Fiat Palio Fire 1.0 8V Flex 2007. Para diminuir o tamanho do banco de dados sem perder significativamente as informações, a granularidade dos dados foi aumentada. Assim, a cada vinte amostras, a média foi calculada, resultando em um total de 3.096 amostras para cada série temporal com intervalos de tempo de 80 segundos entre pontos consecutivos. Ademais, a média também tem a capacidade de mitigar a influência de *outliers*. Posteriormente, cada série temporal foi completamente normalizada no intervalo $[0, 1]$ e dividida em três subconjuntos: 50% para treinamento, 25% para validação e 25% para teste. O conjunto de treinamento foi usado para aprendizagem, o conjunto de validação para seleção de parâmetros, e o conjunto de teste para obter o poder preditivo realista do modelo em dados que não participaram do treinamento, nem da seleção de parâmetros. Inicialmente, algumas simulações com outras proporções de conjuntos também foram aplicadas, por exemplo, 70%/15%/15%. Contudo, de acordo com a distribuição dos dados e resultados iniciais, verificou-se que 50%/25%/25% era a proporção mais adequada, além disso, essa mesma proporção é sugerida em (PRECHELT et al., 1994). Os modelos monolíticos ARIMA, MLP, SVM e LS-SVM foram aplicados nos dados, e com relação aos modelos híbridos, com CL ou CNL, numerosas configurações foram utilizadas. A Tabela 8 ilustra os previsores empregados e suas respectivas siglas. Todas as simulações foram realizadas para previsão de um passo à frente, conforme é comumente utilizado na literatura em trabalhos comparativos de desempenho de modelos de previsão.

As simulações foram executadas no RStudio, um ambiente de desenvolvimento integrado para a linguagem *R*. Foram utilizadas as seguintes bibliotecas:

- *Forecast* - Fornece métodos e ferramentas para exibir e analisar previsões de séries temporais univariadas, além da modelagem ARIMA (HYNDMAN et al., 2017).

¹ ComuniCar é uma aplicação móvel usada para comunicação entre um *smartphone* e a unidade de controle eletrônico, do inglês, *Electronic Control Unit* (ECU), veicular. Este aplicativo foi desenvolvido como projeto final de graduação de alguns alunos do curso de graduação em Engenharia da Computação da UFPE, incluindo o autor dessa dissertação.

- RSNNS - Contém muitas implementações para RNA's a partir de toda a funcionalidade algorítmica e flexibilidade do pacote *Stuttgart Neural Network Simulator* (SNNS) (BERGMEIR; BENÍTEZ, 2017).
- E1071 - Fornece todas as implementações do popular pacote LibSVM, muito utilizado para modelagem do SVM (MEYER et al., 2017).
- *LiquidSVM* - É uma implementação de SVMs desenvolvida por pesquisadores da universidade de Stuttgart. Entre as funcionalidades estão funções para a realização de simulações com o LS-SVM (STEINWART; THOMANN, 2017).

Tabela 8 – Abordagens de previsão utilizados neste trabalho com os métodos correspondentes e os respectivos acrônimos.

Abordagem	Método	Acrônimo
Modelo monolítico	ARIMA	A
	MLP	M
	SVM	S
	LS-SVM	L
Modelo híbrido CL	ARIMA+MLP (ZHANG, 2003)	CL_{AM}
	ARIMA+LS-SVM (ZHU; WEI, 2013)	CL_{AL}
	MLP+ARIMA	CL_{MA}
	LS-SVM+ARIMA	CL_{LA}
Modelo híbrido CNL	MLP (ARIMA,MLP)	$CNL-M_{AM}$
	MLP (ARIMA,LS-SVM)	$CNL-M_{AL}$
	LS-SVM (ARIMA,MLP)	$CNL-L_{AM}$
	LS-SVM (ARIMA,LS-SVM)	$CNL-L_{AL}$
	SVM (ARIMA,MLP)	$CNL-S_{AM}$
	SVM (ARIMA,LS-SVM)	$CNL-S_{AL}$
	MLP (MLP,ARIMA)	$CNL-M_{MA}$
	LS-SVM (MLP,ARIMA)	$CNL-L_{MA}$
	SVM (MLP,ARIMA)	$CNL-S_{MA}$
	MLP (LS-SVM,ARIMA)	$CNL-M_{LA}$
	LS-SVM (LS-SVM,ARIMA)	$CNL-L_{LA}$
	SVM (LS-SVM,ARIMA)	$CNL-S_{LA}$

A abordagem busca em grade foi aplicada para estimativa de parâmetros. De acordo com (HSU; CHANG; LIN, 2016), há motivações para justificar a escolha da técnica busca em grade. Para começar, nem sempre é seguro usar métodos que evitem fazer uma pesquisa exaustiva de parâmetros por aproximações ou heurísticas. Ou seja, algoritmos inteligentes de busca podem falhar em encontrar a solução ótima deparando-se com um ótimo local em vez do ótimo global. Além disso, a execução do busca em grade pode ser facilmente paralelizada quando os parâmetros são independentes.

Neste trabalho, a técnica de busca em grade foi selecionada levando em consideração o tempo de execução de cada modelo único. Para o modelo ARIMA, o parâmetro inteiro d é escolhido no intervalo $[0, 2]$ de acordo com o teste de hipótese ADF para identificar a estacionariedade, enquanto p e q são obtidos no intervalo $[1, 2, \dots, 21]$. Para o ajuste do modelo ARIMA foi aplicado o método CSS.

Quanto ao modelo MLP, os parâmetros são selecionados no intervalo $[1, 3, 5, \dots, 21]$ para os nós de entrada, e $[1, 5, 9, \dots, 21]$ para os nós da camada oculta. As funções de ativação são logística e identidade para os nós ocultos e de saída, respectivamente. O método de aprendizagem é o RPROP com número máximo de iterações (2000), valor de atualização inicial (0), limite máximo para o tamanho do passo (30) e o parâmetro de decaimento de peso α no intervalo $[1, 3, 5, \dots, 11]$.

O tipo do SVM é o ϵ -regressão com o *kernel* RBF. A entrada usa o método de janela deslizante cuja largura é selecionada no intervalo $[1, 3, 5, \dots, 21]$. O parâmetro C da formulação de otimização é ajustado no intervalo $[2^0, 2^1, \dots, 2^{10}]$, enquanto que a região de tolerância ϵ e o parâmetro λ do *kernel* RBF são selecionados no intervalo $[2^{-10}, 2^{-9}, \dots, 2^0]$.

Para a regressão LS-SVM, o *kernel* também é o RBF e a largura da janela para a entrada é obtida no intervalo $[1, 3, 5, \dots, 21]$. Os parâmetros γ da formulação de otimização e o λ do *kernel* RBF são estabelecidos no intervalo $[2^{-15}, 2^{-14}, \dots, 2^{15}]$.

Finalmente, para os modelos CNL, assume-se que o modelo não linear m_2 tem duas entradas, correspondentes às saídas dos modelos m_0 e m_1 , conforme proposto por (de MATOS NETO; CAVALCANTI; MADEIRO, 2017). Os outros parâmetros de m_2 são os mesmos descritos anteriormente para os modelos MLP, SVM, ou LS-SVM.

4.1.1 Métricas de Avaliação

Para cada série temporal de dados automotivos, a seleção dos parâmetros dos modelos indicados na Tabela 8 é realizada de acordo com a menor raiz do erro quadrático médio, ou do inglês, *Root Mean Squared Error* (RMSE), no conjunto de validação. A RMSE é definida pela Equação (4.1), quanto menor o seu valor, melhor a previsão do modelo.

$$RMSE = \sqrt{\left(\frac{\sum_{t=1}^n (y_t - \hat{y}_t)^2}{n} \right)} \quad (4.1)$$

em que n é o tamanho da série, y_t é o valor real da série temporal no período t e $\hat{y}_t$ é o valor previsto no período t .

No cálculo da métrica RMSE, os erros são elevados ao quadrado antes de serem obtidos, portanto, a RMSE fornece um peso maior para erros grandes. Por essa razão, não é recomendável utilizar unicamente a RMSE como uma medida conclusiva para comparação de diferentes modelos de previsão. Dessa forma, para estimar o desempenho real dos modelos no conjunto de teste, além da RMSE, são adotadas outras quatro métricas: erro absoluto médio, ou do inglês, *Mean Absolute Error* (MAE), erro absoluto médio

percentual, ou do inglês, *Mean Absolute Percentage Error* (MAPE) e previsão de mudança na direção, ou do inglês, *Prediction Of Change In Direction* (POCID). Para as métricas MAE e MAPE, quanto menores seus valores, melhor a precisão do modelo. No caso da POCID, quanto maior o valor, melhor o desempenho do modelo.

A MAE é definida por:

$$MAE = \frac{\sum_{t=1}^n |y_t - \hat{y}_t|}{n} \quad (4.2)$$

Na métrica MAE, cada erro contribui para a métrica proporcionalmente ao valor absoluto do erro.

A seguir é apresentada a formulação da métrica MAPE:

$$MAPE = \frac{100}{n} \cdot \sum_{t=1}^n \frac{|y_t - \hat{y}_t|}{y_t} \quad (4.3)$$

A MAPE é uma das medidas de precisão de previsão mais amplamente utilizadas, devido as suas vantagens de independência de escalas e interpretabilidade. No entanto, tem sido criticado porque coloca penalidades mais pesadas em erros negativos do que em erros positivos (HYNDMAN; ATHANASOPOULOS, 2013). Em outras palavras, na métrica MAPE uma imprecisão de -0.1 gera um erro mais significativo do que uma imprecisão de $+0.1$.

A métrica POCID é definida por:

$$POCID = 100 \frac{\sum_{t=1}^n Tend_t}{n} \quad (4.4)$$

$$Tend_t = \begin{cases} 1, & \text{se } (y_t - y_{t-1})(\hat{y}_t - \hat{y}_{t-1}) > 0; \\ 0, & \text{caso contrário.} \end{cases}$$

Com a métrica POCID é possível identificar modelos mais acurados com relação a previsão de tendência da série. Um valor $POCID > 50$, indica que o modelo de previsão acertou mais do que errou a tendência da série. Porém, se $POCID < 50$, então o modelo de previsão errou mais do que acertou a tendência da série. O caso ideal é $POCID = 100$, este valor indica que o modelo sempre acertou a tendência da série.

4.1.2 Métrica de Relação Percentual

Para comparar a acurácia de modelos híbridos e monolíticos utilizando uma métrica de avaliação específica, foi definida uma relação percentual R_i tal que:

$$R_i = \left(\frac{d_i}{i_{ms}} \right) \cdot 100\%, \quad (4.5)$$

$$d_i = \begin{cases} i_{sh} - i_{ms}, & \text{se } i = \text{POCID}; \\ i_{ms} - i_{sh}, & \text{caso contrário.} \end{cases}$$

em que i_{sh} e i_{ms} representam o valor obtido na métrica i do modelo híbrido e do modelo monolítico, respectivamente. Por exemplo, R_{RMSE} indica a relação percentual dada por (4.5), considerando os modelos híbrido e monolítico referentes à métrica RMSE. Quanto maior o valor de R_i , melhor a acurácia do modelo híbrido com relação ao modelo monolítico.

4.1.3 Métricas de Desempenho Relativas

Após a seleção dos modelos com os melhores desempenhos nas métricas de avaliação, foram aplicadas métricas de desempenho relativas. Assim, é possível comparar o desempenho de um modelo de previsão com alguns métodos de previsão que são extremamente simples e surpreendentemente eficazes (HYNDMAN; ATHANASOPOULOS, 2018). Métricas de desempenho relativas realizam uma avaliação da seguinte forma, se o valor da métrica for igual a 1, o modelo de previsão analisado é equivalente ao método comparativo. No entanto, se seu valor for menor ou maior que 1, o desempenho do modelo examinado é melhor ou pior que o método comparativo, respectivamente. Desta forma, foram utilizadas duas métricas: erro médio absoluto escalonado, ou do inglês, *Mean Absolute Scaled Error* (MASE) e variância relativa média, ou do inglês, *Average Relative Variance* (ARV).

A métrica MASE é definida a seguir:

$$MASE = \frac{\sum_{t=1}^n |y_t - \hat{y}_t|}{\frac{n}{n-1} \sum_{t=2}^n |y_t - y_{t-1}|} \quad (4.6)$$

A MASE é uma métrica de desempenho relativa que faz uma comparação entre a MAE do modelo de previsão e a MAE da previsão ingênua (*random walk*) (HYNDMAN; KOEHLER, 2006). Como a previsão ingênua é ótima quando os dados seguem um passeio aleatório, então a previsão ingênua também é chamada de previsão de passeio aleatório (*random walk*). (HYNDMAN; ATHANASOPOULOS, 2018). A previsão ingênua assume que a previsão no período seguinte será igual ao valor do período mais recente, ou seja, é um dos previsores mais simples que existem (HYNDMAN; ATHANASOPOULOS, 2018).

A seguir, é apresentada a métrica ARV:

$$ARV = \frac{\sum_{t=1}^n (y_t - \hat{y}_t)^2}{\sum_{t=1}^n (y_t - \bar{Y})^2} \quad (4.7)$$

A ARV é uma métrica de desempenho relativa entre a medida de erro quadrático médio, ou do inglês, *Mean Squared Error* (MSE) do modelo de previsão e a MSE da média de série.

Essas métricas de desempenho relativas são calculadas a partir das métricas de avaliação MAE e MSE, e por esse motivo estão sendo avaliadas em separado da seção 4.1.1. O objetivo não é identificar o menor erro, mas sim, de comparar o desempenho de um modelo de previsão com alguns métodos de previsão conhecidos na literatura: *random walk* e a média da série.

4.1.4 Teste Estatístico de Hipótese

Após as avaliações anteriores, o modelo que evidencia melhor desempenho é selecionado. O objetivo agora é provar estatisticamente que os erros de previsão do modelo híbrido

escolhido são menores do que os erros do respectivo modelo monolítico. Assim, foram tomados os valores absolutos dos erros de previsão, pois quanto menores forem as amplitudes desses erros absolutos, menores serão os erros de previsão para o modelo.

O teste dos postos sinalizados de Wilcoxon, ou do inglês, *Wilcoxon Signed Rank Test* (WILCOXON, 1945), trata-se de um teste estatístico de hipótese não paramétrico para duas amostras pareadas. Portanto, as amostras são tomadas em pares, e o foco é testar se as distribuições são iguais em localização, isto é, saber se uma população tende a ter valores maiores do que a outra, ou se elas têm a mesma distribuição. É um dos testes mais comumente adotados para avaliar as capacidades preditivas de dois modelos diferentes e para determinar se existem diferenças estatisticamente significativas entre os resultados (ZHANG et al., 2012; LU; LEE; CHIU, 2009; JU; HONG, 2013).

Logo, foram estabelecidas as seguintes hipóteses para um teste unilateral:

- H_0 : (Amostras dos erros absolutos de previsão do modelo híbrido) = (Amostras dos erros absolutos de previsão do modelo individual) $\rightarrow$ A diferença entre os pares segue uma distribuição simétrica em torno de zero.
- H_1 : (Amostras dos erros absolutos de previsão do modelo híbrido) < (Amostras dos erros absolutos de previsão do modelo individual) $\rightarrow$ A diferença entre os pares segue uma distribuição com valores menores que zero.

Na estatística do teste dos postos sinalizados de Wilcoxon, os dados originais são previamente convertidos em postos (ordenações). A vantagem é que, com isso, a suposição de normalidade das amostras não é necessária, permitindo mais generalidade aos resultados. É importante ressaltar que *outliers* perdem sua influência nessa abordagem, sendo apenas o maior valor da amostra.

Para aplicar o teste, considera-se observações pareadas: $\{(h_1, i_1), \dots, (h_n, i_n)\}$, em que h_k são observações dos erros absolutos de previsão do modelo híbrido e i_k observações dos erros absolutos de previsão do modelo individual, para $k = 1, 2, \dots, n$. Defini-se $D_k = h_k - i_k$. Assim, obtém-se a amostra $D_1, D_2, \dots, D_n$, resultante das diferenças entre os valores de cada par. Formula-se então para o teste Wilcoxon a hipótese nula $H_0 : \theta_D = 0$, em que o parâmetro θ_D é a estimação da mediana amostral das diferenças.

Ordena-se de forma crescente o novo conjunto de dados $\{|D_1|, |D_2|, \dots, |D_n|\}$ (valores absolutos, ou seja, não se considera o sinal do elemento D_k) e associa-se a cada valor D_k o posto R_k correspondente. Para um teste unilateral, em que a hipótese alternativa é que a mediana amostral das diferenças é menor que 0, define-se a seguir as variáveis indicadoras ψ_k , $k = 1, 2, \dots, n$, dadas por:

$$\psi_k = \begin{cases} 1, & \text{se } D_k > 0 \\ 0, & \text{se } D_k < 0 \end{cases}$$

ou seja, se $H_k - I_k > 0$, então $\psi_k = 1$, caso contrário, $\psi_k = 0$.

Logo após, obtêm-se os n produtos $P_1\psi_k, \dots, P_n\psi_n$. Cada produto $P_k\psi_k$ é chamado posto positivo de D_k . Neste caso, se $D_k > 0$, $P_k\psi_k$ é igual ao posto P_k correspondente e se $D_k < 0$, $P_k\psi_k$ é igual a 0.

Assim, define-se a estatística T^+ como a soma dos postos que têm sinal positivo, ou seja,

$$T^+ = \sum_{k=1}^n P_k\psi_k$$

O valor crítico é extraído da tabela de Wilcoxon. A hipótese nula é rejeitada se o valor- $p < \alpha$, em que α denota o nível de significância estatística. Tradicionalmente, resultados com nível de significância de 0,05 ou menor são considerados estatisticamente relevantes.

4.2 Resultados




Figura 11 – Função de autocorrelação da série temporal da temperatura do motor veicular.

Nesta secção serão apresentados e discutidos os resultados das simulações computacionais nos dados automotivos que foram estudados na secção 2.4: temperatura do líquido de arrefecimento do motor, A/C na combustão interna do motor e tensão da bateria automotiva. Antes, o gráfico da função de autocorrelação de cada série será apresentado a

seguir, a fim de se observar as dependências relevantes entre os instantes de tempo nos dados automotivos.

A/C na Combustão Interna do Motor




Figura 12 – Função de autocorrelação da série temporal da A/C na combustão interna do motor.

A Figura 11 ilustra a função de autocorrelação da série temporal da temperatura do líquido de arrefecimento do motor. Há um grande pico no atraso 1 seguido por uma pequena onda decrescente que alterna entre correlações positivas e negativas.

No gráfico da Figura 12 é apresentada a função de autocorrelação da série temporal da A/C na combustão interna do motor. Nota-se correlações significativas no primeiro e segundo atraso, seguidas por correlações que não são tão significativas, mas sempre positivas.

Por fim, a Figura 13 exibe a função de autocorrelação da série temporal da tensão da bateria automotiva. Observa-se correlações bastante significativas no início e aparenta-se haver um decaimento exponencial no seus valores. Esta é a série com o maior índice de autocorrelação, ou seja, há uma maior dependência temporal entre as amostras.




Figura 13 – Função de autocorrelação da série temporal da tensão da bateria automotiva.

4.2.1 Temperatura do Líquido de Arrefecimento do Motor

Tabela 9 – Medidas de avaliação obtidas para o conjunto de teste da série de temperatura do líquido de arrefecimento do motor.

Modelo Inicial	Abordagem	RMSE	MAE	MAPE	POCID
-	ARIMA	0,10403	0,05931	13,60	56,79
-	MLP	0,10469	0,06096	13,23	57,01
-	SVM	0,10660	0,05291	12,39	56,36
-	LS-SVM	0,10319	0,05964	12,99	58,57
ARIMA	CL _{AM} (ZHANG, 2003)	0,10126	0,05796	12,77	56,75
	CL _{AL} (ZHU; WEI, 2013)	0,10126	0,05828	12,91	56,49
	CNL-M _{AM}	0,10198	0,05779	12,74	56,75
	CNL-M _{AL}	0,10102	0,05763	12,87	56,62
	CNL-L _{AM}	0,10101	0,05706	12,72	56,49
	CNL-L _{AL}	0,10102	0,05718	12,90	55,97
	CNL-S _{AM}	0,10218	0,05931	12,93	57,14
	CNL-S _{AL}	0,10223	0,06125	13,09	56,36
MLP	CL _{MA}	0,10068	0,05636	12,63	58,70
	CNL-M _{MA}	0,10066	0,05625	12,61	58,83
	CNL-L _{MA}	0,10040	0,05357	12,40	56,88
	CNL-S _{MA}	0,09940	0,05552	12,52	58,96
LS-SVM	CL _{LA}	0,09961	0,05433	12,29	57,40
	CNL-M _{LA}	0,09963	0,05444	12,39	58,31
	CNL-L _{LA}	0,09923	0,05455	12,33	58,05
	CNL-S _{LA}	0,09825	0,05585	12,48	57,53

A Tabela 9 ilustra as métricas RMSE, MAE, MAPE e POCID para o conjunto de teste da série da temperatura do líquido de arrefecimento do motor. Inicialmente, cada métrica de avaliação é apresentada para todos os modelos monolíticos, ARIMA, MLP, SVM e LS-SVM. A melhor medida para cada métrica é destacada em negrito. Já que os modelos híbridos utilizam um único modelo no estágio inicial, um modelo é escolhido da classe de modelos monolíticos. Dos quatro modelos monolíticos adotados neste trabalho, três deles são selecionados para compor os modelos híbridos. Os modelos ARIMA e MLP são escolhas naturais, pois são amplamente utilizados na literatura e possuem características diferentes (BOX; JENKINS; REINSEL, 2008; ZHANG, 2003). Considerando que os modelos híbridos que usam o SVM como modelo m_0 ou m_1 apresentaram desempenho inferior aos modelos combinados usando LS-SVM, foi decidido escolher o LS-SVM como o terceiro modelo inicial na arquitetura híbrida. Apesar disso, o modelo SVM funcionou satisfatoriamente como modelo m_2 e, em alguns casos, alcançou uma acurácia melhor do que o LS-SVM. Assim, os resultados de todos os combinadores não lineares (MLP, SVM e LS-SVM) usados como modelo m_2 são apresentados.

Entre os modelos monolíticos, o SVM e o LS-SVM atingem os melhores resultados em duas das quatro métricas, MAE e MAPE para o SVM, e RMSE e POCID para o LS-SVM. Com relação aos modelos híbridos, a melhor configuração é selecionada de acordo com o modelo inicial usado, que pode ser ARIMA, MLP ou LS-SVM. Da mesma forma que os modelos monolíticos, a melhor medida para cada métrica também é destacada em negrito para os híbridos.

Em primeiro lugar, o modelo ARIMA é selecionado como estágio inicial. Neste caso, dois modelos CL e seis modelos híbridos CNL são investigados. O modelo híbrido CNL- L_{AM} atinge o melhor desempenho em três medidas de avaliação (RMSE, MAE e MAPE). No segundo caso, o MLP é escolhido como modelo inicial. Três modelos híbridos CNL e um CL são implementados. O modelo CNL- L_{MA} obtém o melhor desempenho em duas métricas (MAE e MAPE) e o CNL- S_{MA} em RMSE e POCID. Finalmente, quando o modelo LS-SVM é adotado como o modelo inicial, três modelos híbridos CNL e um CL também são testados como no caso anterior. O melhor modelo é o CL- L_A em duas métricas (MAE e MAPE).

A Tabela 10 ilustra a relação percentual R_i em termos das quatro medidas de avaliação para o conjunto de teste da série da temperatura do líquido de arrefecimento do motor. Valores positivos nas métricas indicam que o modelo híbrido obteve um ganho percentual positivo com relação ao modelo monolítico correspondente. Por outro lado, valores negativos nas métricas indicam que o modelo híbrido apresenta um aumento percentual no erro. A relação R_m (última coluna da Tabela 10) indica o valor médio aritmético do ganho percentual nas quatro métricas de avaliação consideradas. É importante enfatizar que R_m não é utilizado para comparar modelos híbridos entre si. Na verdade, esse parâmetro é uma maneira de verificar se um modelo híbrido é melhor ou não do que o modelo

Tabela 10 – Relações percentuais para todas as métricas de avaliação considerando o conjunto de testes da série de temperatura do líquido de arrefecimento do motor.

Modelo Inicial	Abordagem	R_i (%)				
		RMSE	MAE	MAPE	POCID	m
ARIMA	CL_{AM} (ZHANG, 2003)	2,66	2,29	6,14	-0,07	2,75
	CL_{AL} (ZHU; WEI, 2013)	2,66	1,75	5,09	-0,53	2,24
	CNL- M_{AM}	1,97	2,57	6,34	-0,07	2,70
	CNL- M_{AL}	2,89	2,83	5,37	-0,30	2,70
	CNL- L_{AM}	2,90	3,79	6,51	-0,53	3,17
	CNL- L_{AL}	2,89	3,59	5,14	-1,44	2,55
	CNL- S_{AM}	1,78	0,00	4,93	0,62	1,83
	CNL- S_{AL}	1,73	-3,26	3,74	-0,75	0,36
MLP	CL_{MA}	3,83	7,55	4,60	2,96	4,73
	CNL- M_{MA}	3,84	7,73	4,69	3,19	4,87
	CNL- L_{MA}	4,09	12,13	6,27	-0,23	5,57
	CNL- S_{MA}	5,05	8,92	5,40	3,42	5,70
LS-SVM	CL_{LA}	3,47	8,90	5,38	-2,00	3,94
	CNL- M_{LA}	3,45	8,71	4,59	-0,44	4,08
	CNL- L_{LA}	3,84	8,52	5,06	-0,89	4,13
	CNL- S_{LA}	4,79	6,35	3,93	-1,77	3,32

monolítico correspondente. Por meio da Tabela 10, pode-se verificar que todos os modelos híbridos apresentam valores positivos de R_m , isto indica uma diminuição percentual na média dos erros de previsão de todos os modelos híbridos quando comparados aos respectivos modelos monolíticos. Por exemplo, o maior ganho percentual em termos de R_m é alcançado pelo modelo CNL- S_{MA} que tem um ganho percentual médio de 5,70% em relação ao modelo MLP considerando as quatro métricas de avaliação. Em geral, pode-se afirmar que, para o conjunto de teste da série de temperatura do líquido de arrefecimento do motor, a modelagem combinada (linear ou não linear) é melhor do que a utilização de modelos monolíticos.

Tabela 11 – Métricas de desempenho relativas aplicadas nas abordagens com os melhores desempenhos de acordo com seus respectivos modelos iniciais para a temperatura do líquido de arrefecimento do motor no conjunto de teste.

Modelo Inicial	Abordagem	MASE	ARV
ARIMA	CNL- L_{AM}	0,9618	0,4321
MLP	CNL- L_{MA}	0,9028	0,4269
	CNL- S_{MA}	0,9358	0,4184
LS-SVM	CL_{LA}	0,9156	0,4202

Na Tabela 11, são apresentados os resultados das métricas de desempenho relativas MASE e ARV para os modelos com melhor desempenho selecionados na Tabela 9. Os modelos escolhidos possuem métricas MASE e ARV menores do que 1, indicando que seus desempenhos são melhores do que a previsão ingênua e a média aritmética da série

temporal.

Tabela 12 – Parâmetros selecionados no busca em grade para o modelo híbrido CL_{LA} e resultado do teste dos postos sinalizados de Wilcoxon no conjunto de teste da série temporal temperatura do líquido de arrefecimento do motor.

m_0	Lags na entrada	λ	γ
LS-SVM	3	$9,775625 \cdot 10^4$	0,25
m_1	p	d	q
ARIMA	17	1	14
Teste dos postos sinalizados de Wilcoxon		Valor – p $4,572 \cdot 10^{-11} < 0,05$	

Temperatura do Líquido de Arrefecimento




Figura 14 – Resultados de previsão para série temporal normalizada da temperatura do líquido de arrefecimento do motor considerando 100 amostras contínuas do conjunto de teste.

O modelo CL_{LA} está entre os modelos destacados com melhor desempenho na Tabela 9, além disso, foi superior a todos os demais modelos na métrica MAPE. Os parâmetros ótimos do modelo híbrido CL_{LA} são apresentados na Tabela 12. Na primeira linha, há informações sobre o modelo m_0 . Na segunda linha, estão descritos detalhes sobre o modelo m_1 . Na última linha, é exibido o resultado do teste de hipótese unilateral dos postos sinalizados de Wilcoxon, que obteve o *valor – p* = $4,572 \cdot 10^{-11}$. Desta forma, rejeita-se a hipótese nula H_0 , pois o *valor – p* < 0,05. A hipótese nula H_0 afirma que erros absolutos

de previsão do modelo híbrido e monolítico são iguais. Assim, tem-se uma evidência forte de que os erros de previsão do modelo híbrido CL_{LA} são menores que os erros de predição do respectivo modelo monolítico LS-SVM.

A Figura 14 ilustra a previsão de 100 amostras contínuas do conjunto de teste da temperatura do líquido de arrefecimento do motor para ilustrar as vantagens da modelagem combinada. É possível observar o desempenho superior dos sistemas híbridos em termos de acurácia. As previsões dos modelos LS-SVM, CL_{LA} e CNL- S_{LA} são exibidas e pode ser visto que os modelos combinados são mais precisos que o LS-SVM. Com base nisso, pode-se dizer que a modelagem combinada é mais acurada do que a modelagem monolítica para a série de temperatura do líquido de arrefecimento do motor.

4.2.2 A/C na Combustão Interna do Motor

Tabela 13 – Medidas de avaliação obtidas para o conjunto de teste da série da A/C na combustão interna do motor.

Modelo Inicial	Abordagem	RMSE	MAE	MAPE	POCID
-	ARIMA	0,10417	0,08126	15,67	40,49
-	MLP	0,10623	0,08313	16,05	37,90
-	SVM	0,10587	0,08159	16,10	37,23
-	LS-SVM	0,10546	0,08180	15,85	38,43
ARIMA	CL_{AM} (ZHANG, 2003)	0,10381	0,08093	15,54	41,58
	CL_{AL} (ZHU; WEI, 2013)	0,10375	0,08086	15,54	42,23
	CNL- M_{AM}	0,10420	0,08144	15,62	41,58
	CNL- M_{AL}	0,10423	0,08150	15,64	41,84
	CNL- L_{AM}	0,10436	0,08133	15,57	41,06
	CNL- L_{AL}	0,10367	0,08070	15,47	41,45
	CNL- S_{AM}	0,10409	0,08117	15,63	41,58
	CNL- S_{AL}	0,10402	0,08111	15,59	41,45
MLP	CL_{MA}	0,10371	0,07970	15,45	40,82
	CNL- M_{MA}	0,10390	0,07983	15,73	39,76
	CNL- L_{MA}	0,10412	0,08030	15,64	40,03
	CNL- S_{MA}	0,10403	0,07976	15,76	38,96
LS-SVM	CL_{LA}	0,10462	0,08042	15,58	42,95
	CNL- M_{LA}	0,10460	0,08036	15,64	42,02
	CNL- L_{LA}	0,10463	0,08050	15,57	41,89
	CNL- S_{LA}	0,10449	0,08023	15,71	42,02

Para o conjunto de testes da série A/C, as medidas de avaliação são exibidas na Tabela 13. Entre os previsores individuais, o modelo ARIMA fornece os melhores valores em todas as métricas. Em relação aos sistemas híbridos, a melhor configuração também é selecionada de acordo com o modelo inicial utilizado, do mesmo modo que foi realizado com o primeiro conjunto de testes. Para o modelo ARIMA como estágio inicial, o modelo híbrido CNL- L_{AL} atinge os menores erros para o RMSE e em outras duas medidas (MAE e MAPE). Quando a abordagem MLP é adotada como modelo inicial, o modelo híbrido CL_{MA} apresenta os melhores resultados em todas as métricas. No caso do LS-SVM como

modelo inicial, a abordagem CNL- S_{LA} obtém os melhores valores para as métricas RMSE e MAE.

Tabela 14 – Relações percentuais para todas as métricas de avaliação considerando o conjunto de testes da série da A/C na combustão interna do motor.

Modelo Inicial	Abordagem	R_i (%)				
		RMSE	MAE	MAPE	POCID	m
ARIMA	CL_{AM} (ZHANG, 2003)	0,35	0,41	0,81	2,69	1,06
	CL_{AL} (ZHU; WEI, 2013)	0,41	0,48	0,83	4,29	1,50
	CNL- M_{AM}	-0,03	-0,23	0,29	2,69	0,68
	CNL- M_{AL}	-0,06	-0,29	0,16	3,33	0,78
	CNL- L_{AM}	-0,18	-0,09	0,62	1,41	0,44
	CNL- L_{AL}	0,48	0,69	1,23	2,37	1,19
	CNL- S_{AM}	0,08	0,11	0,21	2,69	0,77
	CNL- S_{AL}	0,15	0,18	0,46	2,37	0,79
MLP	CL_{MA}	2,37	4,12	3,76	7,72	4,49
	CNL- M_{MA}	2,20	3,97	2,04	4,91	3,28
	CNL- L_{MA}	1,99	3,40	2,59	5,61	3,40
	CNL- S_{MA}	2,07	4,05	1,82	2,81	2,69
LS-SVM	CL_{LA}	0,80	1,70	1,72	11,76	3,99
	CNL- M_{LA}	0,82	1,77	1,34	9,34	3,32
	CNL- L_{LA}	0,79	1,59	1,76	9,00	3,29
	CNL- S_{LA}	0,93	1,93	0,89	9,34	3,27

Tabela 15 – Métricas de desempenho relativas aplicadas nas abordagens com os melhores desempenhos de acordo com seus respectivos modelos iniciais para o A/C na combustão internada do motor no conjunto de teste.

Modelo Inicial	Abordagem	MASE	ARV
ARIMA	CNL- L_{AL}	0,8699	0,5912
MLP	CL_{MA}	0,8686	0,5829
LS-SVM	CNL- S_{LA}	0,8743	0,5916

A Tabela 14 exhibe a relação percentual R_i para o conjunto de teste da série que representa a A/C do motor. É observado que todos os modelos híbridos são mais eficientes que seus respectivos modelos individuais, isto é percebido pelos valores positivos de R_m . O que indica que a combinação de modelos é uma boa estratégia para prever dados do A/C na combustão interna do motor, similarmente à primeira série temporal considerada neste trabalho.

Na Tabela 15, são apresentados os resultados das métricas de desempenho relativas MASE e ARV para os modelos com melhor desempenho selecionados na Tabela 13. Neste caso também, os valores das medidas são menores que 1, evidenciando que eles apresentam desempenho melhor do que a previsão ingênua e a média aritmética da série temporal.

O modelo CL_{MA} está entre os modelos apontados com melhor desempenho na Tabela 13 e apresentou os menores erros com relação a todos os demais modelos em duas de quatro métricas de avaliação (MAE e MAPE). Na Tabela 16 são exibidos os parâmetros

estimados na busca em grade para o modelo híbrido CL_{MA} nas duas primeiras linhas. O resultado do teste de hipótese dos postos sinalizados de Wilcoxon também é apresentado na última linha. O *valor* $-p = 8,441 \cdot 10^{-4} < 0,05$ rejeita a hipótese nula. Assim, há evidência forte para concluir que os erros de previsão do modelo híbrido CL_{MA} são menores que os erros de predição do respectivo modelo monolítico MLP.




Figura 15 – Resultados de previsão para série temporal da A/C na combustão interna do motor considerando 100 amostras contínuas do conjunto de teste.

Tabela 16 – Parâmetros selecionados no busca em grade para o modelo híbrido CL_{MA} e resultado do teste dos postos sinalizados de Wilcoxon no conjunto de teste da série temporal A/C.

m_0	Nós na camada de entrada	Nós na camada oculta	Expoente de <i>weight-decay</i> α
MLP	21	21	1
m_1	p	d	q
ARIMA	13	1	19
Teste dos postos sinalizados de Wilcoxon	$\text{Valor} - p$ $8,441 \cdot 10^{-4} < 0,05$		

A Figura 15 ilustra a previsão de 100 amostras contínuas aleatórias do conjunto de teste da série temporal A/C na combustão interna do motor automotivo. São apresentadas as previsões dos modelos híbridos CL_{MA} e $CNL-M_{MA}$ e seu respectivo modelo monolítico

(MLP). Pode-se observar que os modelos híbridos são capazes de melhorar a previsão do MLP, minimizando os erros de previsão para a série A/C.

4.2.3 Tensão da Bateria do Automóvel

Tabela 17 – Medidas de avaliação obtidas para o conjunto de teste da série de tensão da bateria.

Modelo Inicial	Abordagem	RMSE	MAE	MAPE	POCID
-	ARIMA	0,07020	0,04833	8,90	42,82
-	MLP	0,06970	0,04739	8,83	41,28
-	SVM	0,07126	0,04799	8,90	41,56
-	LS-SVM	0,07144	0,04927	9,18	42,06
ARIMA	CL _{AM} (ZHANG, 2003)	0,07091	0,04948	9,10	45,32
	CL _{AL} (ZHU; WEI, 2013)	0,07046	0,04953	9,10	42,97
	CNL-M _{AM}	0,07003	0,04851	8,97	43,90
	CNL-M _{AL}	0,07034	0,04937	9,12	42,84
	CNL-L _{AM}	0,06986	0,04871	8,97	43,12
	CNL-L _{AL}	0,06995	0,04863	9,06	43,49
	CNL-S _{AM}	0,06996	0,04877	9,02	44,16
	CNL-S _{AL}	0,07087	0,04983	9,30	42,45
MLP	CL _{MA}	0,06881	0,04739	8,80	42,71
	CNL-M _{MA}	0,06897	0,04717	8,81	42,71
	CNL-L _{MA}	0,06925	0,04743	8,86	42,71
	CNL-S _{MA}	0,06871	0,04715	8,81	42,84
LS-SVM	CL _{LA}	0,07079	0,04949	9,13	41,02
	CNL-M _{LA}	0,07036	0,04934	9,10	41,28
	CNL-L _{LA}	0,06998	0,04904	9,11	41,28
	CNL-S _{LA}	0,07009	0,04905	9,10	41,02

A Tabela 17 apresenta as medidas de avaliação para o conjunto de teste da série de tensão da bateria do automóvel. O MLP é o melhor modelo monolítico para a maioria das medidas de avaliação. Os modelos híbridos CNL-S_{MA} e CNL-L_{LA} superam, respectivamente, o MLP e o LS-SVM nas métricas RMSE, MAE e POCID. Finalmente, quando o modelo ARIMA é considerado o modelo primário, o CNL-M_{AM} é mais benéfico que o ARIMA para as métricas RMSE e POCID.

As relações percentuais R_i para o conjunto de testes da série de tensão da bateria do automóvel são ilustradas na Tabela 18. Para esta série, reconhece-se que a eficiência de previsão dos modelos híbridos diminuiu, uma vez que agora apenas 62,5% das abordagens combinadas são superiores aos seus respectivos modelos únicos (valores positivos de R_m). É importante observar que, entre esses 62,5% das abordagens combinadas, a maioria dos sistemas híbridos utilizam uma modelagem não lineares para a série, e lineares para os resíduos.

Na Tabela 19, são apresentados os resultados das métricas de desempenho relativas MASE e ARV para os modelos com melhor desempenho selecionados na Tabela 17. Nem todos os modelos selecionados têm valores menores que 1 para a métrica MASE. Desta

Tabela 18 – Razões percentuais para todas as medidas de avaliação considerando o conjunto de testes da série de tensão da bateria.

Modelo Inicial	Abordagem	R_i (%)				
		RMSE	MAE	MAPE	POCID	m
ARIMA	CL _{AM} (ZHANG, 2003)	-1.01	-2.38	-2.15	5.85	0.08
	CL _{AL} (ZHU; WEI, 2013)	-0.38	-2.48	-2.17	0.35	-1.17
	CNL-M _{AM}	0.24	-0.39	-0.75	2.51	0.41
	CNL-M _{AL}	-0.21	-2.15	-2.39	0.04	-1.18
	CNL-L _{AM}	0.48	-0.80	-0.69	0.69	-0.08
	CNL-L _{AL}	0.36	-0.63	-1.73	1.56	-0.11
	CNL-S _{AM}	0.33	-0.91	-1.26	3.12	0.32
	CNL-S _{AL}	-0.95	-3.12	-4.42	-0.87	-2.34
MLP	CL _{MA}	1.27	-0.01	0.32	3.47	1.26
	CNL-M _{MA}	1.05	0.46	0.28	3.47	1.32
	CNL-L _{MA}	0.65	-0.10	-0.30	3.47	0.93
	CNL-S _{MA}	1.41	0.50	0.26	3.79	1.49
LS-SVM	CL _{LA}	0.91	-0.44	0.58	-2.48	-0.36
	CNL-M _{LA}	1.51	-0.14	0.88	-1.86	0.10
	CNL-L _{LA}	2.04	0.48	0.82	-1.86	0.37
	CNL-S _{LA}	1.89	0.46	0.91	-2.48	0.20

Tabela 19 – Métricas de desempenho relativas aplicadas nas abordagens com os melhores desempenhos de acordo com seus respectivos modelos iniciais para a tensão da bateria automotiva no conjunto de teste.

Modelo Inicial	Abordagem	MASE	ARV
ARIMA	CNL-M _{AM}	1.0104	0.2882
MLP	CNL-S _{MA}	0.9842	0.2782
LS-SVM	CNL-L _{LA}	1.0236	0.2886

forma, somente a abordagem CNL-S_{MA} apresenta um desempenho superior à previsão ingênua. Isto pode ter ocorrido devido o alta dependência temporal entre as observações desta série, conforme ilustrado no gráfico da função de autocorrelação da Figura 13. Nestes casos, o modelo de previsão passeio aleatório pode ser um candidato potencialmente bom. Na métrica ARV todos os valores são menores que 1 indicando a supremacia destes modelos híbridos com relação a média aritmética da série temporal.

O modelo CNL-S_{MA} está entre os modelos apontados com melhor desempenho na Tabela 17 e apresentou os menores erros com relação a todos os demais modelos em duas de quatro métricas de avaliação (RMSE e MAE). Os parâmetros selecionados na busca em grade para o modelo híbrido CNL-S_{MA} estão indicados na Tabela 20 nas três primeiras linhas. Na última linha é apresentado o resultado do teste de hipótese dos postos sinalizados de Wilcoxon. O *valor - p* = 0,1728 > 0,05 não rejeita a hipótese nula. Desta forma, com o nível de significância de 0,05, não pode-se afirmar que erros de previsão do modelo híbrido CNL-S_{MA} são menores que os erros de predição do modelo monolítico MLP.

Para a série temporal no conjunto de teste da tensão da bateria, a previsão do modelo

Tabela 20 – Parâmetros selecionados no busca em grade para o modelo híbrido CNL- S_{MA} e resultado do teste dos postos sinalizados de Wilcoxon no conjunto de teste da serie temporal tensão da bateria automotiva.

m_0	Nós na camada de entrada	Nós na camada oculta	Expoente de <i>weight-decay</i> α
MLP	5	17	5
m_1	p	d	q
ARIMA	17	1	17
m_2	C	γ	ϵ
SVM	4	0.0009765625	0.25
Teste dos postos sinalizados de Wilcoxon	<i>Valor – p</i> 0.1728 > 0.05		




Figura 16 – Resultados da previsão para série temporal da tensão da bateria do automóvel considerando 100 amostras contínuas do conjunto de teste.

híbrido CNL- S_{MA} e sua abordagem LC (LC_{MA}) são apresentados na Figura 16, juntamente com o seu respectivo modelo monolítico (MLP). Os três modelos comportam-se graficamente de forma similar possivelmente devido ao baixo ganho percentual médio R_m (1,22% e 1,08%) destes modelos híbridos com relação ao modelo monolítico MLP.

4.3 Resumo do Capítulo

Neste capítulo, foram expostos e discutidos os resultados obtidos a partir da aplicação dos modelos de séries temporais em dados automotivos. Ficou constatado que, os modelos híbridos que utilizam modelos não lineares para a série com lineares para os resíduos apresentaram os maiores ganhos percentuais com relação aos respectivos modelos monolíticos. E, comprovou-se com o teste de hipótese dos postos sinalizados de Wilcoxon, que em duas de três séries automotivas, foram encontrados modelos híbridos que possuem menores erros de previsão do que o respectivo modelo monolítico que modela a série. No capítulo a seguir, são apresentadas as conclusões do trabalho.

5 CONCLUSÕES

Este trabalho concentrou-se no estudo de modelos de previsão de séries temporais em dados automotivos. Três bases de dados foram construídas a partir de informações extraídas de alguns sensores veiculares, quais sejam, temperatura do líquido arrefecedor do motor, A/C na combustão interna do motor e tensão da bateria do automóvel. O objetivo do trabalho foi analisar a acurácia de previsão em dados automotivos de algumas modelagens híbridas conhecidas na literatura. Foi possível comparar empiricamente duas abordagens de combinação de modelos: Combinado Linearmente (CL) e Combinado Não Linearmente (CNL). A modelagem híbrida foi composta pela combinação de alguns modelos monolíticos clássicos: ARIMA, MLP, SVM e LS-SVM.

5.1 Contribuições

Em geral, os resultados mostraram que combinar os previsores da modelagem residual é uma abordagem que merece atenção no contexto dos dados automotivos, apesar do ganho percentual nas métricas de avaliação não ser tão significativo. Ao avaliar as estratégias de combinação com melhor desempenho de acordo com seus respectivos modelos iniciais (ver Tabelas 11, 15 e 19) as abordagens Combinadas Não Linearmente (CNL) são mais frequentes do que as Combinadas Linearmente (CL). Este resultado endossa alguns trabalhos da literatura (de MATTOS NETO; CAVALCANTI; MADEIRO, 2017; KHASHEI; BIJARI, 2011).

É importante destacar a precisão superior alcançada pela combinação alternativa de modelos não lineares para a série com lineares para os resíduos (ver Tabelas 12, 16 e 20). Os modelos híbridos com melhor desempenho em cada conjunto de dados possuem um modelo não linear como modelo inicial da configuração. Na literatura, modelos não lineares são amplamente utilizados em modelagem residual para melhorar a precisão de modelos lineares. No entanto, neste trabalho, o uso de modelos não lineares para a modelagem de séries temporais seguida de modelagem linear para resíduos leva ao desempenho superior na maioria das bases de dados analisadas. Isto evidencia que foi importante verificar o comportamento desta combinação alternativa, mesmo sendo pouco explorada na literatura. Este resultado sugere uma alternativa a ser investigada em outras aplicações. Porém, ainda que os modelos híbridos tenham obtido desempenhos superiores, os resultados dos modelos monolíticos não devem ser ignorados, visto que utilizam um processamento computacional menor e suas previsões não foram tão inferiores em relação às abordagens híbridas.

Apesar de 80s não ser um tempo de previsão adequado para alertar seres humanos

sobre um valor anormal no motor do veículo, este intervalo de tempo parece bem razoável para advertir sistemas autoadaptativos responsáveis pelo gerenciamento eletrônico do próprio motor. Por exemplo, alertar os atuadores do próprio motor com o objetivo de mudarem o estado de operação a fim de evitar chegar no valor anormal previsto, ou seja, em caso de predição de uma temperatura anormal (muito alta), o motor entraria em um estado de funcionamento específico para evitar chegar nesta temperatura atípica. Este mesmo princípio pode ser válido para os dados da A/C na combustão interna do motor, em caso de previsão de uma A/C anormal (mais combustível do que o comumente medido), o motor entraria em um estado de funcionamento específico para evitar chegar nesta A/C atípica. De qualquer forma, os resultados obtidos nesta pesquisa servirão de referência para trabalhos automotivos futuros que pretendam obter previsões em horizontes maiores.

5.2 Dificuldades Encontradas

Análise de séries temporais em dados automotivos é um tema pouco explorado na literatura acadêmica. Uma das grandes dificuldades encontradas neste trabalho foi a ausência de banco de dados automotivos públicos. Gravações de dados de motores dos fabricantes de automóveis são altamente confidenciais, e por esse motivo, não há um compartilhamento com a comunidade científica. Isto torna qualquer trabalho que envolva dados automotivos um grande desafio, visto que os autores do pesquisa devem construir os próprios bancos de dados, para, posteriormente, aplicar as simulações computacionais.

O intervalo de 80s entre as amostras foi escolhido para diminuir o tamanho da série evitando perdas significativas de informações, e as previsões nas simulações são de um passo à frete. Este mesmo intervalo de tempo foi escolhido em (ALMEIDA; CUNHA; de MATTOS NETO, 2016), que é outro trabalho do autor desta dissertação, e as simulações são em outro banco de dados automotivo. Porém, reconhece-se que o horizonte de previsão de 80s não é um tempo de antecipação satisfatório para alertar o motorista sobre um valor anormal em um sensor do veículo, visto que é impossível conduzir o automóvel a uma oficina dentro de 80s. Uma previsão em um intervalo de tempo maior seria mais adequada. Por outro lado, para obter previsões de um passo em um horizonte maior é necessário aumentar o intervalo de tempo entre as amostras a partir de médias, e assim perde-se informações da série. Isto é algo que deve ser investigado em trabalhos futuros.

5.3 Trabalhos Futuros

Pretende-se investigar argumentos teóricos que justificam a melhoria alcançada pelos modelos híbridos que utilizam a modelagem não linear da série com a modelagem linear dos resíduos. Além disso, é importante continuar a pesquisa nestes conjuntos de dados

automotivos com o objetivo de desenvolver modelos com melhor desempenho de previsão, pois o ganho percentual na acurácia dos modelos híbridos não foi tão significativo com relação aos modelos monolíticos. Ademais, as previsões evidenciam uma incompatibilidade de atraso de tempo da série prevista quando comparada com a série temporal real. Embora as simulações do trabalho de (THEISLER, 2013) indiquem que o algoritmo de aprendizagem de máquina tem melhor desempenho no conjunto de teste quando treinado com dados automotivos compostos de diferentes tipos de vias. Seria interessante verificar como os modelos de previsão se comportariam em banco de dados compostos somente de vias urbanas ou rodovias.

Métodos inteligentes de estimação de parâmetros também devem ser aplicados para verificar se há alguma alteração no erro de previsão dos modelos com relação a busca em grade. Previsões em horizontes maiores devem ser simuladas, ou em séries com granularidade maior, ou utilizando múltiplos passos à frente. Posteriormente, métodos de classificação devem ser investigados para utilização em um segundo estágio a fim de categorizar os valores de previsão como um comportamento típico ou atípico.

REFERÊNCIAS

- AHSAN, M.; STOYANOV, S.; BAILEY, C. Prognostics of automotive electronics with data driven approach: A review. *Proc. 39th Int. Spring Seminar on Elect. Technol. (ISSE 2016)*, p. 279–284, 2016.
- ALMEIDA, D. M.; CUNHA, D. C.; de MATTOS NETO, P. S. G. A proposal of an intelligent forecasting system for automotive diagnostics using time series analysis. *XIII Encontro Nacional de Inteligência Artificial e Computacional (ENIAC)*, p. 577–588, 2016.
- AUTOTAP. *Does My Car Have OBD-II?* 2011. Acessado em: 2018-07-14. Disponível em: <<http://www.obdii.com/connector.html>>.
- BARBALATA, C.; LEUSTEAN, L. *Average monthly liquid flow forecasting using neural networks*. Bucharest, Romania, 2004.
- BARROS, M. *Processos Estocásticos*. 1. ed. Rio de Janeiro: Papel Virtual, 2004.
- BERGMEIR, C.; BENÍTEZ, J. M. *Neural Networks using the Stuttgart Neural Network Simulator (SNNS)*. [S.l.], 2017. User Manual Package ‘RSNNS’ for R.
- BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C. *Time series analysis, forecasting and control*. 4. ed. San Francisco: John Wiley & Sons, 2008.
- BROCKWELL, P. J.; DAVIS, R. A. *Introduction to time series and forecasting*. New York: Springer, 2002. v. 2.
- BYTTNER, S.; ROGNVALDSSON, T.; SVENSSON, M. Consensus self-organized models for fault detection (cosmo). *Engineering Applications of Artificial Intelligence*, v. 24, p. 833–839, 2011.
- CAIRANO, S.; BERNARDINI, D.; BEMPORAD, A.; KOLMANOVSKY, I. V. Stochastic mpc with learning for driver-predictive vehicle control and its application to hev energy management. *IEEE Trans. Control Syst. Technol.*, v. 22, n. 3, p. 1018–1031, 2014.
- CARB. *On-Board Diagnostics (OBD) Program*. 2018. Acessado em: 2018-07-14. Disponível em: <<https://www.arb.ca.gov/msprog/obdprog/obdprog.htm>>.
- CLEVELAND, R. B.; CLEVELAND, W. S.; MCRAE, J. E.; TERPENNING, I. Stl: A seasonal-trend decomposition procedure based on loess. *Journal of Official Statistics*, v. 6, n. 1, p. 3–73, 1990.
- CONCEPCION, M. *OBD II Repair Strategies*. U.S.A: CreateSpace Independent Publishing Platform, 2011.
- COWPERTWAIT, P. S. P.; METCALFE, A. V. *Introductory Time Series with R*. 1. ed. New York: Springer, 2009.
- de MATTOS NETO, P. S. G.; CAVALCANTI, G. D. C.; MADEIRO, F. Nonlinear combination method of forecasters applied to pm time series. *Pattern Recognit. Lett.*, v. 95, p. 65–72, 2017.

- DHALL, R.; SOLANKI, V. An iot based predictive connected car maintenance approach. *Int. J. Interact. Multimed. Artif. Intell.*, v. 4, p. 16–22, 2017.
- EBRAHIMI, B.; R.TAFRESHI; MOHAMMADPOUR, J.; FRANCHEK, M.; GRIGORIADIS, K.; MASUDI, H. Second-order sliding mode strategy for air–fuel ratio control of lean-burn si engines. *IEEE Transactions on Control Systems Technology*, v. 22, n. 4, p. 1374–1384, 2014.
- ELM ELECTRONICS INC. *ELM327 OBD to RS242 Interpreter*. [S.l.], 2014. Manual do microcontrolador ELM327.
- GUO, S. H. Y.; SHEN, C.; LI, X. Y. Y.; BAI, Y. An adaptive svr for high-frequency stock price forecasting. *IEEE Access*, v. 6, p. 11397–11404, 2018.
- HSU, C.; CHANG, C.; LIN, C. *A practical guide to support vector classification*. Taiwan, 2016.
- HYNDMAN, R. J.; ATHANASOPOULOS, G. *Forecasting: principles and practice*. Melbourne, Australia: OTexts, 2013.
- HYNDMAN, R. J.; ATHANASOPOULOS, G. *Forecasting: principles and practice*. 2. ed. [S.l.]: OTexts, 2018.
- HYNDMAN, R. J.; KOEHLER, A. B. Another look at measures of forecast accuracy. *International Journal of Forecasting*, v. 22, n. 4, p. 679–688, 2006.
- HYNDMAN, R. J.; O'HARA-WILD, M.; BERGMEIR, C.; RAZBASH, S.; WANG, E. *Forecasting Functions for Time Series and Linear Models*. [S.l.], 2017. User Manual Package 'forecast' for R.
- JU, F.-Y.; HONG, W.-C. Application of seasonal svr with chaotic gravitational search algorithm in electricity forecasting. *Applied Mathematical Modelling*, Elsevier, v. 37, n. 23, p. 9643–9651, 2013.
- KERSHAW, J. F.; HALDERMAN, J. D. *Automotive Electrical and Electronic Systems*. 5. ed. New Jersey: Pearson Education, 2007.
- KHASHEI, M.; BIJARI, M. A novel hybridization of artificial neural networks and arima models for time series forecasting. *Applied Soft Computing*, v. 11, p. 2664–2675, 2011.
- KIM, Y.; RIZZONI, G.; UTKIN, V. Automotive engine diagnosis and control via nonlinear estimation. *IEEE Control Systems*, v. 18, n. 5, p. 84–99, 1998.
- LANGONE, R.; ALZATE, C.; KETELAERE, B.; VLASSELAER, J.; MEERT, W.; SUYKENS, J. A. K. Ls-svm based spectral clustering and regression for predicting maintenance of industrial machines. *Engineering Applications of Artificial Intelligence*, v. 37, p. 268–278, 2015.
- LI, B.; ZHANG, J.; HE, Y.; WANG, Y. Short-term load-forecasting method based on wavelet decomposition with second-order gray neural network model combined with adf test. *IEEE Access*, IEEE, v. 5, p. 16324–16331, 2017.
- LU, C.-J.; LEE, T.-S.; CHIU, C.-C. Financial time series forecasting using independent component analysis and support vector regression. *Decision Support Systems*, Elsevier, v. 47, n. 2, p. 115–125, 2009.

- MALIK, A.; MACIEJEWSKI, R.; TOWERS, S.; MCCULLOUGH, S.; EBERT, D. S. Proactive spatiotemporal resource allocation and predictive visual analytics for community policing and law enforcement. *IEEE Trans. Vis. Comput. Graphics*, v. 20, n. 12, p. 1863–1872, 2014.
- MCCORD, K. *Automotive Diagnostic Systems*. Minnesota: CarTech, 2011.
- MEYER, D.; DIMITRIADOU, E.; HORNIK, K.; WEINGESSEL, A.; LEISCH, F. *Misc Functions of the Department of Statistics, Probability Theory Group*. [S.l.], 2017. User Manual Package ‘e1071’ for R.
- PATTIPATI, B.; SANKAVARAM, C.; PATTIPATI, K. System identification and estimation framework for pivotal automotive battery management system characteristics. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, v. 41, n. 6, p. 869–884, 2011.
- PETRIS, G.; PETRONE, S.; CAMPAGNOLI, P. *Dynamic linear models with R*. New York: Springer Science & Business Media, 2009.
- PRECHELT, L. et al. Proben1: A set of neural network benchmark problems and benchmarking rules. Citeseer, 1994.
- RIEDMILLER, M.; BRAUN, H. *A Direct Adaptive Method for Faster Backpropagation Learning: The RPROP Algorithm*. Karlsruhe, Germany, 1993.
- SANTINI, A. *OBD-II: Functions, monitors and diagnostic*. New York: Delmar, 2011.
- SANZ, J. L.; MARTINEZ, C. O.; FLOREZ, J. A.; EGUILAZ, M. M.; MANSILLA, R. R.; KALMUS, J.; GRAEBER, M.; LUX, G. Thermal management in plug-in hybrid electric vehicles: A real-time nonlinear model predictive control implementation. *IEEE Transactions on Vehicular Technology*, v. 66, n. 9, p. 7751–7760, 2017.
- SHI, Y.; YU, D.; TIAN, Y.; SHI, Y. Air–fuel ratio prediction and nmpc for si engines with modified volterra model and rbf network. *Engineering Applications of Artificial Intelligence*, v. 45, n. 9, p. 313–324, 2015.
- SMOLA, A. J.; SCHÖLKOPF, B. A tutorial on support vector regression. *Statistics and computing*, Springer, v. 14, n. 3, p. 199–222, 2004.
- SOUALHI, A.; MEDJAHAR, K.; ZERHOUNI, N. Bearing health monitoring based on hilbert–huang transform, support vector machine, and regression. *IEEE Transactions on Instrumentation and Measurement*, v. 64, n. 1, p. 52–62, 2015.
- STEINWART, I.; THOMANN, P. *A Fast and Versatile SVM Package*. [S.l.], 2017. User Manual Package ‘liquidSVM’ for R.
- SUYKENNS, J. A. K.; VANDEWALLE, J. Least squares support vector machine classifiers. *Neural Processing Letters*, v. 9, n. 3, p. 293–300, 1999.
- THEISSLER, A. *Detecting anomalies in multivariate time series from automotive systems*. Tese (Doutorado) — Brunel University School of Engineering and Design PhD Theses, 2013.

- WAN, C.; XU, Z.; PINSON, P.; DONG, Z. Y.; WONG, K. P. Probabilistic forecasting of wind power generation using extreme learning machine. *IEEE Trans. Power Syst.*, v. 29, n. 3, p. 1033–1044, 2014.
- WANG, B.; LIU, Z.; LI, S. E.; MOURA, S. J.; PENG, H. State-of-charge estimation for lithium-ion batteries based on a nonlinear fractional model. *IEEE Transactions on Control Systems Technology*, v. 25, n. 1, p. 3–11, 2017.
- WANG, H.; HU, D. *Comparison of SVM and LS-SVM for Regression*. Shanghai, China, 2005.
- WANG, T.; JAGARWAL, A.; WAGNER, J. Optimization of an automotive radiator fan array operation to reduce power consumption. *IEEE/ASME Transactions on Mechatronics*, v. 20, n. 5, p. 2359–2369, 2015.
- WILCOXON, F. Individual comparisons by ranking methods. *Biometrics Bulletin*, v. 1, n. 6, p. 80–83, 1945.
- ZELL, A.; MACHE, N.; HUBNER, R.; MAMIER, G.; VOGT, M.; SCHMALZL, M.; HERRMANN, K. *Stuttgart Neural Network Simulator (SNNS)*. Germany, 2008. v. 4. User Manual SNNS.
- ZHANG, G. P. Time series forecasting using a hybrid arima and neural network model. *Neurocomputing*, v. 50, p. 159–175, 2003.
- ZHANG, G. P. *Neural Networks in Business Forecasting*. Hershey: IIRM Press, 2004.
- ZHANG, W. Y.; HONG, W.-C.; DONG, Y.; TSAI, G.; SUNG, J.-T.; FAN, G.-f. Application of svr with chaotic gasa algorithm in cyclic electric load forecasting. *Energy*, Elsevier, v. 45, n. 1, p. 850–858, 2012.
- ZHU, B.; WEI, Y. Carbon price forecasting with a novel hybrid arima and least squares support vector machines methodology. *Omega*, v. 41, p. 517–524, 2013.
- ZHU, T.; LUO, L.; ZHANG, X.; SHI, Y.; SHEN, W. Time-series approaches for forecasting the number of hospital daily discharged inpatients. *IEEE J. Biomed. Health Inform.*, v. 21, n. 2, p. 515–526, 2017.