



Camila Leão Pereira

**Identificação de modelo híbrido baseado em
Redes Neurais para dinâmica lateral de veículos
militares**

Dissertação de Mestrado

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo Programa de Pós-Graduação em Engenharia Mecânica, do Departamento de Engenharia Mecânica da PUC-Rio.

Orientador: Prof. Helon Vicente Hultmann Ayala

Rio de Janeiro
Abril de 2023



Camila Leão Pereira

**Identificação de modelo híbrido baseado em
Redes Neurais para dinâmica lateral de veículos
militares**

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo Programa de Pós-Graduação em Engenharia Mecânica da PUC-Rio. Aprovada pela Comissão Examinadora abaixo:

Prof. Helon Vicente Hultmann Ayala

Orientador

Departamento de Engenharia Mecânica – PUC-Rio

Prof. Marco Antonio Meggiolaro

Departamento de Engenharia Mecânica – PUC-Rio

Prof. Gustavo Simão Rodrigues

IME

Prof. Elias Dias Rossi Lopes

IME

Rio de Janeiro, 28 de Abril de 2023

Todos os direitos reservados. É proibida a reprodução total ou parcial do trabalho sem autorização do autor, do orientador e da universidade.

Camila Leão Pereira

Graduação em Engenharia Mecânica e de Automóveis pelo Instituto Militar de Engenharia (Rio de Janeiro - RJ) em 2014. Possui como áreas de interesse dinâmica veicular, controle de sistemas dinâmicos e identificação de sistemas. Atua em projetos de veículos militares.

Ficha Catalográfica

Pereira, Camila Leão

Identificação de modelo híbrido baseado em Redes Neurais para dinâmica lateral de veículos militares / Camila Leão Pereira; orientador: Helon Vicente Hultmann Ayala. – 2023.

64 f: il. color. ; 30 cm

Dissertação (mestrado) - Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Engenharia Mecânica, 2023.

Inclui bibliografia

1. Engenharia Mecânica – Teses. 2. Identificação de sistema. 3. Dinâmica veicular. 4. Veículos militares. 5. CONTSID. 6. Redes neurais. I. Ayala, Helon Vicente Hultmann. II. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Engenharia Mecânica. III. Título.

À minha amada família.

Agradecimentos

Após esse longo percurso, gostaria de registrar minha gratidão a todos que contribuíram para conclusão desse estudo.

À Deus, pela força e fé para persistir na missão.

Aos meus pais, Nazaré e Jorge, meus maiores exemplos de dedicação e amor, por sempre se fazerem presentes, mesmo que distantes fisicamente. Aos meus irmãos, Matheus e Murilo, que me motivam diariamente a ir além. À minha avó, Jacy, sinônimo de determinação, carinho e força para toda família. Ao meu noivo, Felipe, por me incentivar durante o desenvolvimento desse trabalho .

Ao meu orientador, Prof. Helon, por ter me apresentado e despertado meu interesse na área de identificação de sistemas. Agradeço por toda compreensão, auxílio, orientação e disponibilidade, sempre que necessário.

A todos os professores e funcionários do Departamento de Engenharia Mecânica da PUC-Rio e à PUC-Rio por toda colaboração e auxílios concedidos, sem os quais este trabalho não poderia ter sido realizado.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

Resumo

Pereira, Camila Leão; Ayala, Helon Vicente Hultmann. **Identificação de modelo híbrido baseado em Redes Neurais para dinâmica lateral de veículos militares**. Rio de Janeiro, 2023. 64p. Dissertação de Mestrado – Departamento de Engenharia Mecânica, Pontifícia Universidade Católica do Rio de Janeiro.

O estudo da dinâmica lateral é de grande importância para análise do comportamento de um veículo durante manobras e fundamental para a implementação de sistemas de controle de estabilidade e de trajetória em veículos autônomos. Nesse contexto, baseado em medições experimentais de um veículo militar de três eixos durante manobras de mudança dupla de faixa a diferentes velocidades, o presente trabalho apresenta métodos de identificação de sistemas para obtenção de modelos lineares por meio da ferramenta CONTSID (*CONTInuous-Time System IDentification*), disponível no MATLAB; de modelos não lineares baseados em Redes Neurais; e, por fim, a proposta de emprego de modelos híbridos com o intuito de minimizar o erro associado à primeira abordagem, somando-se ao modelo linear, o valor estimado do resíduo com a aplicação de redes neurais. Por se tratarem de modelos obtidos a partir de dados observados, como parâmetros de entrada e de saída do sistema, foram selecionados o ângulo do volante e a taxa de guinada do veículo, respectivamente. Com a utilização dos dados observados, foi realizada a identificação das funções de transferência para cada velocidade, o que possibilitou a análise da influência dessa variável no comportamento dinâmico do sistema. Em seguida, empregou-se uma abordagem via redes neurais ao mesmo conjunto de dados, com a construção de arquiteturas distintas por meio da modificação do número de neurônios, número de camadas e função de ativação. Por fim, um modelo híbrido foi combinado utilizando-se a modelagem linear e não linear para obtenção de melhorias na resposta do modelo final estimado. De acordo com os resultados, as técnicas empregadas apresentaram viabilidade de aplicação e resultados satisfatórios, destacando-se o aprimoramento do modelo linear por meio de sua substituição pelo modelo híbrido baseado em redes neurais. Do exposto, objetiva-se destacar o potencial dos métodos apresentados de forma que, posteriormente, esses estudos possam ser aprofundados para implementação de malhas de controle veicular, com o intuito de contribuir com o aumento da segurança, melhoria do conforto e no desenvolvimento de veículos autônomos.

Palavras-chave

Identificação de sistema; Dinâmica veicular; Veículos militares; CONTSID; Redes neurais.

Abstract

Pereira, Camila Leão; Ayala, Helon Vicente Hultmann (Advisor). **Hybrid model identification based on artificial neural networks for lateral dynamics of military vehicles**. Rio de Janeiro, 2023. 64p. Dissertação de Mestrado – Departamento de Engenharia Mecânica, Pontifícia Universidade Católica do Rio de Janeiro.

The study of lateral dynamics is of great importance for the vehicle behavior analysis during turning maneuvers, and it is fundamental to stability or path control systems used in autonomous vehicles. In this context, based on experimental measurements of a three-axle military wheeled vehicle during double lane changes maneuvers at different speed, this work presents methods for the identification of linear models using the CONTSID (CONTinuous-Time System IDentification) toolbox, available in MATLAB; nonlinear models based on artificial neural networks; and, the application of hybrid models to reduce the error associated with the first approach, combining the linear model to the estimated error using neural networks. Since those are data-driven methods, as input and output parameters of the system, the wheel steering angle and the yaw rate of the vehicle were respectively selected. Using the CONTSID toolbox, the identification of the transfer functions for each speed was performed, making it possible to evaluate the influence of this variable in the system's dynamics behavior. Thereafter, a neural network approach was applied to the same data set, changing architecture's parameters, such as number of neurons, layers and the activation function. At last, a hybrid model approach was presented through the combination of previous linear and nonlinear approaches to improve the estimated model response. The proposed methods showed satisfactory results, highlighting the improvement in the linear model through its replacement by the hybrid model based on neural networks. Therefore, this work aims to show the potential of the methods presented, and posteriorly contribute to studies on the implementation of vehicle control systems to increase safety, improve comfort and in the development of autonomous vehicles.

Keywords

System identification; Vehicle dynamics; Military vehicles; CONTSID; Artificial neural network.

Sumário

1	Introdução	11
1.1	Contextualização	11
1.2	Objetivos	13
1.3	Revisão bibliográfica	14
1.4	Contribuições	19
1.5	Organização da dissertação	19
2	Fundamentação teórica	21
2.1	Identificação de sistemas	21
2.2	Identificação de sistemas com a ferramenta CONTSID	25
2.3	Identificação de sistemas por meio de Redes Neurais Artificiais	27
3	Identificação da dinâmica lateral de um veículo militar utilizando dados de mudança dupla de faixa	31
3.1	Estudo de caso	31
3.1.1	Descrição do experimento	31
3.2	Modelo veicular	34
3.3	Identificação de sistema aplicado para modelagem da dinâmica lateral veicular	36
3.3.1	Algoritmo	37
3.3.2	Formulação do problema de identificação	37
3.4	Resultados e discussão	38
3.5	Conclusões parciais	42
4	Identificação da dinâmica lateral de um veículo militar por meio de modelos híbridos	44
4.1	Considerações iniciais	44
4.2	Metodologia	44
4.3	Resultados e discussão do modelo não linear	46
4.4	Identificação do modelo híbrido	52
5	Conclusões e trabalhos futuros	58
	Referências bibliográficas	60

Lista de figuras

Figura 1	Identificação de sistemas a partir de dados de entrada e saída de um processo	22
Figura 2	Etapas do procedimento de identificação (Coelho e Coelho, 2016)	23
Figura 3	Elementos presentes na aquisição das medidas de um sistema. Adaptado de (Tangirala,2018)	24
Figura 4	Esquemático para representação de um modelo de neurônio não linear k . Adaptado de (Haykin,2009)	29
Figura 5	Veículo instrumentado para obtenção das medidas experimentais	32
Figura 6	Medições do veículo durante uma manobra de mudança dupla de faixa realizada a, aproximadamente, 10 km/h	33
Figura 7	Espectro no domínio da frequência do ângulo do volante	34
Figura 8	Espectro no domínio da frequência da taxa de guinada	34
Figura 9	Coordenadas do veículo $Cxyz$ em um sistema de coordenadas inercial $OXYZ$ de acordo a ISO 8855 (Pereira, 2020)	35
Figura 10	Modelo "bicicleta"de um veículo de três eixos	35
Figura 11	Comparativo dos dados experimentais, dados filtrados e a resposta do modelo estimado da taxa de guinada	40
Figura 12	Diagrama de Bode da magnitude e da fase da taxa de guinada com relação à variação da velocidade do veículo	41
Figura 13	Comportamento dos polos e zeros dos modelos estimados com a variação da velocidade do veículo	42
Figura 14	Indicação das arquiteturas dos modelos híbridos A (50 épocas) e B (1000 épocas) que apresentaram melhorias em relação à resposta do modelo linear do CONTSID para cada velocidade	57
Figura 15	Comparativo entre os dados medidos, as medições filtradas (pós-processadas), a resposta do modelo CONTSID e do modelo híbrido B para 30 km/h (arquitetura 2)	57

Lista de tabelas

Tabela 1	Informações do veículo	32
Tabela 2	Parâmetros estimados do modelo para diferentes velocidades	39
Tabela 3	Principais parâmetros para identificação dos modelos não lineares	45
Tabela 4	Estimação de modelo não linear para 10 km/h	47
Tabela 5	Estimação de modelo não linear para 20 km/h	48
Tabela 6	Estimação de modelo não linear para 30 km/h	49
Tabela 7	Estimação de modelo não linear para 40 km/h	49
Tabela 8	Estimação de modelo não linear para 50 km/h	50
Tabela 9	Estimação de modelo não linear para 60 km/h	50
Tabela 10	Estimação de modelo não linear para 70 km/h	51
Tabela 11	Estimação de modelo não linear para 80 km/h	51
Tabela 12	Estimação de modelo híbrido para 10 km/h	53
Tabela 13	Estimação de modelo híbrido para 20 km/h	53
Tabela 14	Estimação de modelo híbrido para 30 km/h	54
Tabela 15	Estimação de modelo híbrido para 40 km/h	54
Tabela 16	Estimação de modelo híbrido para 50 km/h	55
Tabela 17	Estimação de modelo híbrido para 60 km/h	55
Tabela 18	Estimação de modelo híbrido para 70 km/h	56
Tabela 19	Estimação de modelo híbrido para 80 km/h	56

1 Introdução

1.1 Contextualização

Segundo (Tangirala,2018), a análise das características de um processo e as relações entre as variáveis são de extrema importância na predição, controle, monitoramento, projeto e inovação no sistema, sendo um ponto crucial a obtenção de uma descrição, usualmente, matemática do processo, chamada de modelo.

Os modelos matemáticos permitem a predição do comportamento dinâmico do veículo, além de parâmetros a serem ajustados para que o material atenda às especificações técnicas e operacionais solicitadas. Logo, auxiliam engenheiros e projetistas ao longo do desenvolvimento do produto, desde a fase do projeto até a implementação de melhorias, como a integração de sistemas de controle.

De acordo com (Jin et al., 2019), para melhoria da estabilidade e segurança ativa de veículos terrestres, vários sistemas avançados de controle da dinâmica veicular surgiram, como o sistema de controle do ângulo de guinada, o sistema ativo de esterçamento dianteiro e de assistência ao motorista. Contudo, o desempenho efetivo dessas implementações está diretamente ligado ao conhecimento dos parâmetros e estados do veículo, ou seja, diretamente relacionado ao quão representativo é o modelo empregado em relação ao sistema real.

Dessa forma, usualmente, há duas abordagens para construção de modelos: a utilização de formulações teóricas e hipóteses baseadas em leis da física; ou uma aproximação empírica baseada na análise dos dados observados (medidas experimentais). A última pode apresentar como vantagem a possibilidade de obtenção de modelos de um sistema dinâmico complexo em que algumas informações não seriam verificadas se apenas fossem levadas em consideração a abordagem física, devido a possíveis limitações práticas e hipóteses utilizadas na modelagem.

As simulações possibilitam um melhor entendimento dos processos e do comportamento do sistema dinâmico, além da facilidade para execução de

testes previamente à implementação de modificações no projeto e elaboração de novos conceitos. Adicionalmente, consistem em uma alternativa mais segura para a execução de experimentos, somando-se à economia de recursos e tempo associada. Cabe destacar, nesse sentido, que há uma dependência da precisão do modelo para permitir que os resultados da simulação sejam considerados válidos, o que implica na busca de modelos mais adequados, a depender da aplicação, para retratar o comportamento dinâmico real do sistema.

Nesse âmbito, o processo de identificação de sistemas refere-se à construção de um modelo dinâmico baseado, comumente, em dados observados/experimentais, por meio da análise e processamento das entradas e saídas de um processo realizado pelo sistema. De acordo com (Ljung,2010), a construção de modelos a partir de dados observados configura-se como um elemento fundamental na ciência. Dessa forma, diversas metodologias e nomenclaturas foram desenvolvidas para diferentes aplicações, dentre elas a predição do comportamento do sistema, atribuindo-se o termo identificação de sistemas comumente a técnicas ligadas a controle.

Há inúmeras abordagens na literatura para modelagem do comportamento dinâmico de um veículo, escolhidas geralmente com base na complexidade da formulação matemática, como os parâmetros necessários e o movimento em foco (longitudinal, lateral, vertical ou a combinação entre eles); além das informações disponíveis, como medidas experimentais da dinâmica do sistema, o que facilita a utilização de abordagens baseadas nos dados observados. A estimação de parâmetros, estados e até de possíveis modelos usando métodos de identificação de sistemas baseados em dados experimentais é uma alternativa relevante, especialmente devido à descrição incompleta da dinâmica do sistema, como hipóteses e limitações, e de incertezas nos valores dos parâmetros que podem afetar a formulação matemática (Ba et al., 2015) quando se é empregada a modelagem baseada em leis físicas.

A análise da dinâmica lateral é relevante para prever o comportamento do veículo em manobras que envolvem curvas. Esse conhecimento possibilita o projeto de sistemas de controle mais eficientes, essenciais não apenas para a melhoria dos aspectos de segurança, mas também para o desenvolvimento de veículos autônomos. No meio de Materiais de Emprego Militar (MEM), o emprego de controle de estabilização pode auxiliar consideravelmente o motorista durante uma manobra, tendo em vista o peso e o tamanho de veículos blindados, como Viaturas Blindadas de Transporte de Pessoal (VBTP) (Quintana, 2008, Anderson et al., 2015). Adicionalmente, a aplicação de veículos autônomos em operações, como reconhecimento e transporte, pode impactar diretamente na redução de fatalidades durante o seu emprego (Quintana, 2008, An-

derson et al., 2015).

No escopo deste trabalho, é apresentada a obtenção de modelos lineares da dinâmica lateral de um veículo militar de três eixos, por meio da estimação da taxa de guinada baseada no ângulo do volante para diversas velocidades durante uma manobra de mudança dupla de faixa, por meio da ferramenta CONTSID, disponível no MATLAB; propostas de modelos baseadas na abordagem não linear, utilizando-se redes neurais artificiais; e, por fim, modelos híbridos, construídos a partir da modelagem do CONTSID somada à estimação do erro do modelo linear com arquiteturas construídas via redes neurais, com o intuito de reduzir o resíduo obtido.

Os modelos não lineares obtidos por meio de redes neurais não se baseiam em modelo físico. Portanto, erros devido a simplificações físicas não são associados. Contudo, há uma grande dependência dos dados medidos fornecidos, bem como ajuste dos parâmetros da arquitetura utilizada na rede para convergência do modelo.

Do exposto, a intenção desse trabalho é apresentar potenciais da utilização de modelos lineares - que contam com um significado físico -, não lineares e híbridos - como uma junção das duas primeiras abordagens - para estimação de estados dinâmicos de um veículo, possibilitando, dentre outras, o entendimento do seu comportamento dinâmico e a aplicação de sistemas de controle. Portanto, fruto desse trabalho, pode-se aprofundar na implementação de malhas de controle na dinâmica veicular, com o intuito de contribuir com o aumento da segurança, melhorias de projeto e, posteriormente, inclusive no desenvolvimento e implementação de veículos autônomos.

1.2 Objetivos

Nesse sentido, a importância de aprofundamento no tema é justificada pelo fato de que modelos e, conseqüentemente, simulações são essenciais para o desenvolvimento, compreensão e aprimoramento de veículos, uma vez que possibilitam, por exemplo, predições relativas ao desempenho, análise da influência e ajustes de parâmetros do projeto e avanços na área de monitoramento e implementação de sistemas de controle integrados de forma mais segura, além da economia de recursos e tempo.

Portanto, esse trabalho tem por objetivo apresentar a aplicação da utilização de uma abordagem linear, não linear e híbrida - uma combinação das duas anteriores, com o objetivo de minimizar o erro associado à primeira - na obtenção da relação entre o ângulo do volante (dados de entrada) e a taxa de guinada (dados de saída) de um veículo militar de três eixos. Para cumprir

os objetivos deste trabalho, seguiu-se as seguintes etapas:

- revisão bibliográfica acerca do processo e metodologias de identificação de sistemas, utilizadas principalmente para estimação de estados e parâmetros de veículos;
- proposta e análise de modelagem linear por meio da estimação dos parâmetros das funções de transferência entre os dados experimentais de entrada e saída do veículo com a ferramenta (*toolbox*) CONTSID, disponível no MATLAB. A seleção da estrutura do modelo e a estimação dos parâmetros foi realizada com base em funções disponibilizadas no CONTSID, além de conhecimento prévio da formulação linear teórica do veículo, utilizando-se o modelo bicicleta;
- aplicação de abordagem não linear baseada em Redes Neurais Artificiais (RNA) para estimação dos modelos de acordo com os mesmos dados observados para construção dos modelos lineares, com a variação da arquitetura da rede de acordo com o número de neurônios, quantidade de camadas escondidas e função de ativação escolhida; e
- desenvolvimento de modelos híbridos, dados pela respostas obtidas com a abordagem linear somadas à estimação dos respectivos erros relativos aos dados observados via RNA.

1.3

Revisão bibliográfica

De acordo com (Ljung,2010), o termo "identificação de sistema"foi acu-nhado por Zadeh (1956) para o problema da estimação de modelo de sistemas dinâmicos na comunidade de controle. Nesse sentido, um dos primeiros objeti-vos da identificação de sistema foi sua aplicação em projetos dessa área, sendo um tema recorrente a importância da qualidade do modelo para o projeto de controladores.

Segundo (Sieberg, 2021), a melhoria na segurança dos veículos sempre foi um dos pontos mais importantes e relevantes na área automotiva, de tal forma que é um tema em desenvolvimento contínuo. Nesse sentido, várias metodologias baseadas em sistemas passivos e ativos estão em desenvolvimento ou já foram implementadas que apontam uma redução significativa do número de acidentes e aumento da segurança com a aplicação de sistemas de controle.

Dentre os sistemas ativos, pode-se citar a implementação de sistemas de controle da dinâmica veicular e sistemas de assistência avançada ao motorista. O primeiro, com foco em auxiliar a tarefa da direção, auxiliando na estabilidade, enquanto que o segundo foca na atividade do guiamento da direção.

Preliminarmente ao projeto de controladores, deve-se desenvolver a forma com que as informações do sistema dinâmico serão analisadas e processadas para que os sensores e atuadores possam trabalhar. Logo, recorre-se à obtenção de modelos representativos do processo real em estudo.

Por meio dos sensores, a depender da viabilidade e facilidade de obtenção da medida, pode-se obter os valores dos estados do veículo. De acordo com (Sieberg, 2021), sensores adicionais resultam em um aumento de custo, que deve ser evitado. Logo, uma prática comum é a utilização de estimadores de estado, que são capazes de estimar os estados relevantes com base nos dados adquiridos de outros sensores, com a redução de custos, além da estimação de parâmetros e estados de difícil medição. A estimação de estados usualmente é baseada em modelos teóricos, com o uso de simplificações e hipóteses atinentes ao modelo, o que implica em limitações e erros relativos às medidas reais. Logo, busca-se melhorar o desempenho dos modelos de estimação de estados, sendo um desafio.

De acordo com a revisão bibliográfica, duas abordagens diferentes são comumente utilizadas para obtenção de modelos da dinâmica veicular: a analítica, por meio da utilização de leis da física para o desenvolvimento da formulação matemática; ou por metodologias de identificação de sistemas, com o emprego dos dados observados/medidos para obtenção da representação do comportamento dinâmico.

Em (Chebly et al., 2017), um modelo veicular é analiticamente derivado a partir da convenção de Denavit-Hartenberg com a utilização das equações de Newton-Euler para desenvolvimento de um modelo multicorpos. A validação é realizada com o simulador SCANer-studio™ para diversas condições de direção. Ressalta-se que, apesar da modelagem multicorpos serem mais representativas dos sistemas dinâmicos, são mais complexas, envolvem um número de graus de liberdade e a necessidade de conhecimento maiores em relação à descrição da conexão existente entre os corpos.

Com relação à abordagem por identificação de sistemas, (Reina et al., 2019, Reina et al., 2017, Cheng et al., 2019, Chen et al., 2018) usam observadores baseados no modelo para identificar estados e parâmetros de um veículo de quatro rodas, sendo que (Reina et al., 2019, Reina et al., 2017) utilizam medições geradas a partir de simulações para validar a metodologia, enquanto que (Cheng et al., 2019, Chen et al., 2018) aplicam tanto medidas geradas quanto experimentais de um veículo para validação. Além disso, (Chindamo, 2018) aplica dados simulados, também de um veículo de quatro rodas, para treinar uma RNA para identificação do ângulo de deslizamento (*side-slip*).

(Narendra et al., 1990) demonstra que redes neurais podem ser utilizadas

de maneira eficiente para identificação e controle de sistemas dinâmicos não lineares. Por outro lado, (Ba et al., 2015) emprega três diferentes métodos para identificação de modelos usando os dados de entrada e saída de um veículo real de dois eixos.

Nesse contexto, uma das principais aplicações de modelos dinâmicos veiculares é no projeto de sistemas de controle. Uma revisão dos principais modelos e estratégias de controle para seguimento de trajetória é apresentada em (Amer et al., 2017), sendo a aproximação do modelo de dois graus de liberdade conhecido como modelo bicicleta um dos mais aplicados (Arifin et al., 2019).

Adicionalmente, conforme (Pascu et al., 2019), a relevância de métodos de identificação de modelos contínuos por meio de dados de entrada e saída de dados observados de um sistema dinâmico foi reconhecida, a partir do ponto de vista do controle baseado em modelo, dado que informações conhecidas anteriormente podem ser preservadas e utilizadas para aplicação em controle.

A análise da resposta transiente e permanente (*steady-state*) de um modelo bicicleta de um veículo de dois eixos é apresentada em (Kiefer, 1996). Apesar da simplicidade, a formulação empregada é útil para análise da interação entre os principais parâmetros, como pneus, propriedades do veículo e velocidade. Funções de transferência lineares entre os estados do veículo são utilizadas para análise da resposta em frequência de acordo com as entradas no sistema. Dessa forma, conclusões significativas acerca de controle e estabilidade lateral são obtidas por meio dessa representação. Contudo, a investigação realizada baseia-se apenas na formulação matemática desenvolvida, empregando-se as leis da física e com parâmetros constantes, que tendem a mudar durante a realização de manobras com o veículo, como os relacionados aos pneus.

Uma abordagem matemática análoga é endereçada em (Jang et al., 1997), que apresenta uma análise da sensibilidade da taxa de guinada de um carro de passeio no domínio da frequência. A função de transferência entre a entrada dada no ângulo do volante e a saída da taxa de guinada é obtida usando uma representação do modelo bicicleta. De acordo com esse estudo, essa modelagem apresenta os efeitos simples da dinâmica lateral, útil para o entendimento do comportamento dinâmico do veículo e que possibilitaria estudos futuros relativos a sistemas de controle. Adicionalmente, também é destacada a contribuição para ajuste de parâmetros na fase de projeto do veículo por meio da análise da influência da variação de valores das variáveis na resposta da taxa de guinada.

Utilizando-se estratégias de identificação de sistemas, diversas ferramen-

tas foram desenvolvidas para aplicação em *softwares* comerciais, como as de identificação de sistemas e a CONTinuous-Time System IDentification (CONT-SID) para MATLAB®. De acordo com (Garnier et al., 2018), o CONTSID disponibiliza no MATLAB® funções para estimação de modelos lineares, tais como funções de transferência e espaço de estados, baseados na estimação de parâmetros de um sistema dinâmico de acordo com as medidas de entrada e saída. Essa ferramenta já foi aplicada para obtenção de modelos de diversos sistemas, dentre eles para estimação de um modelo de segunda ordem para simulação e análise de modos de vibração relevantes em carros de passeio em (Figel et al., 2019).

No trabalho apresentado por (Ba et al., 2015), são aplicados três métodos diferentes de identificação baseada em dados de entrada e saída para modelagem da dinâmica lateral de um veículo: *Multivariable Output Error State Space* (MOESP), *Numerical Algorithms for Subspace State Space System Identification* (N4SID) e *Canonical Variate Analysis* (CVA). A estrutura do modelo é baseada no modelo bicicleta com três graus de liberdade, sendo empregados sinais de impulso, degrau e uma simulação de manobra de mudança dupla de faixa a velocidade constante para aquisição de dados. O ângulo da roda dianteira foi considerado como a variável de entrada, enquanto que o ângulo de deslizamento e a taxa de guinada, saídas. De acordo com os resultados, conclui-se que a abordagem proposta apresenta resultados satisfatórios em comparação aos dados observados, ressaltando-se que o experimento foi conduzido para um único valor de velocidade. Logo, a influência desse parâmetro no comportamento dinâmico não é analisada.

Em (James et al., 2018), é feita a identificação de um modelo linear obtido de acordo com os dados observados da dinâmica longitudinal de um veículo e comparado com o modelo físico não linear para análise da necessidade de um modelo mais complexo em relação a simplificações, especialmente para aplicações futuras, como projeto de controle. A metodologia usa o método de predição do erro (*prediction error method* - PEM) para identificação de um modelo linear contínuo no espaço de estados com as medições de um carro de passeio em condições normais. Os resultados indicam que a acurácia do modelo estimado para representar os dados observados apresentam melhores resultados quando comparados com a modelagem da resposta de um modelo bicicleta não linear. Contudo, as conclusões são feitas apenas para a dinâmica longitudinal e o estudo não aborda os aspectos relativos à dinâmica lateral.

Um estimador baseado em filtro de Kalman estendido (*Extended Kalman-Filter* - EKF) e o modelo bicicleta são utilizados em (Reina et al., 2019) para identificação dos estados de um veículo que não são diretamente observados e

acompanhamento da variação do parâmetro de *cornering stiffness* dos pneus. As simulações foram realizadas para análise do desempenho do veículo durante manobras comuns, como mudança dupla de faixa e aplicação de entrada degrau. Uma metodologia similar é empregada em (Reina et al., 2017) para identificar os estados e mudanças no comportamento de um veículo com base na alteração da massa. Apesar de os resultados da simulação apresentarem melhores resultados do que quando a massa constante é considerada, o observador EFK pode apresentar um desempenho não satisfatório sob condições de baixa excitação.

Para estimação dos ângulo de deslizamento e das forças laterais de um veículo, (Cheng et al., 2019) combinam uma metodologia baseada em observadores, o modelo bicicleta e outro com três graus de liberdade de um veículo, destacando que incertezas nos parâmetros do veículo e o ruído nas medições podem afetar o desempenho do estimador.

Um modelo de três graus de liberdade de um veículo de dois eixos é utilizado por (Chen et al., 2018) para estimar a força longitudinal, velocidade lateral e a taxa de guinada, combinando um observador da força longitudinal e um algoritmo de um filtro de acompanhamento, requerendo um desenvolvimento matemático complexo. Em (Chindamo, 2018), Redes Neurais Artificiais (RNA) são utilizadas para estimar o ângulo de deslizamento durante manobras a diferentes velocidades utilizando o *software* de simulação CarSim™. Contudo, o estudo foca na estimação de um único parâmetro do modelo e não é realizada a comparação com dados reais.

De acordo com (Jin et al., 2019), dentre as técnicas baseadas em medições experimentais, a mais popular para estimação de estados de um veículo são as RNA. Segundo (Cai et al., 2022), um veículo pode ser modelado de maneira precisa por meio da coleta de dados do seu movimento. Baseando-se no modelo físico e em métodos de aprendizado profundo, a arquitetura de um modelo híbrido é proposta, de forma que possibilite a introdução de mais informações da dinâmica do sistema ao modelo. De acordo com os resultados, é concluído que o modelo híbrido é satisfatório em relação às demais abordagens utilizadas e que é relevante para pesquisa e aplicações práticas.

Na pesquisa realizada por (Jianwei et al., 2023), para aprimorar a fidedignidade do modelo em relação aos dados medidos, um método baseado em redes neurais é proposto para análise do comportamento da dinâmica lateral de um veículo especial de cinco eixos. De acordo com os dados da simulação com o *software* TruckSim aplicando-se o modelo proposto, conclui-se que o método via redes neurais representa melhor o sistema do que a utilização de uma modelagem puramente baseada nas leis da física.

Do exposto, muitos dos trabalhos conduzidos são baseados em veículos de passeio de dois eixos, quatro rodas, o que indica que há poucos estudos na área de veículos com mais de dois eixos, caso de parte dos veículos blindados utilizados pelas Forças Armadas.

1.4

Contribuições

Do exposto, este trabalho pretende apresentar, em formato de estudos de caso, abordagens para identificação de modelos representativos da dinâmica lateral de veículo militar de três eixos por meio da obtenção de modelos lineares com o CONTSID, modelos não lineares utilizando RNA e, com o intuito de combinar as duas abordagens mencionadas para minimizar o erro do modelo, a proposta do modelo híbrido resultante da soma da resposta da saída do modelo linear com a estimação do erro via RNA.

Ainda, a obtenção do modelo contínuo linear do formato de função de transferência possibilita a análise da influência da velocidade na resposta em frequência e no comportamento dos polos e zeros do sistema, diretamente relacionados com a estabilidade.

Logo, a presente pesquisa configura-se como um passo inicial para aprofundamento na área de controle de estabilidade e de trajetória, destacando-se como contribuições a apresentação de técnicas de identificação de sistemas com a utilização de medições experimentais de um veículo de três eixos para estimação de modelos lineares, não lineares e híbridos. Os resultados parciais desse estudo foram divulgados em (Pereira et al., 2021).

Por fim, cabe ressaltar que não há muitos estudos disponíveis na área de modelagem e dinâmica de veículos militares, sujeitos inclusive a condições mais severas de operação do que carros de passeio, que também requerem simulações e análises do seu comportamento dinâmico em diversas fases ao longo do ciclo de vida do material, desde o seu projeto até o emprego real e implementação de melhorias.

1.5

Organização da dissertação

A organização dos capítulos deste trabalho foi realizada da seguinte maneira:

- o Capítulo 1 consiste na apresentação da contextualização e justificativa para estudo do tema, com a apresentação dos principais objetivos da dissertação. É feita uma revisão bibliográfica acerca dos métodos utilizados para estimação de estados e parâmetros da dinâmica veicular,

- verificando-se a tendência para aplicação dos resultados obtidos na implementação de sistemas de controle;
- o Capítulo 2 aborda a fundamentação teórica para desenvolvimento dos modelos lineares e não lineares apresentados, destacando-se a utilização da ferramenta CONTSID para geração de modelos lineares e de redes neurais para geração de modelos não lineares;
 - o Capítulo 3 apresenta o desenvolvimento de modelos lineares utilizando a ferramenta CONTSID aplicadas a um estudo de caso baseado em dados experimentais de um veículo militar de três eixos;
 - o Capítulo 4 aborda a utilização de redes neurais para estimação de modelos caixa preta e a geração de modelos híbridos, combinando-se os resultados obtidos por meio do CONTSID com a estimação do erro do modelo linear com redes neurais; e
 - Por fim, o Capítulo 5 apresenta as principais conclusões advindas do estudo apresentado, bem como sugestões de trabalhos futuros.

2

Fundamentação teórica

2.1

Identificação de sistemas

Como apresentado no Capítulo 1, a obtenção de modelos para representação de sistemas dinâmicos são essenciais para a compreensão e introdução de ajustes, monitoramento e controle ao processo. Segundo (Tangirala,2018), dentre as principais aplicações de modelos estão:

- Projetos: realização de simulações, emprego de métodos de otimização e ajustes de parâmetros, planejamento;
- Estimação: predições, acompanhamento do processo e controle, utilização de sensores, filtragem dos dados;
- Controle: análise da estabilidade do sistema, projeto de controladores, avaliação do desempenho dinâmico;
- Monitoramento: emprego de controle estatístico da qualidade, análise, detecção e diagnóstico de falhas.

Dentre os possíveis métodos para obtenção de modelos matemáticos para representação da dinâmica do sistema, de acordo com (Coelho e Coelho, 2016), pode-se citar a análise físico-matemática, com o emprego das leis da física que caracterizam o sistema, tratando-se de uma modelagem fenomenológica; ou uma análise experimental, obtida por meio de medidas ou observações do sistema (modelagem experimental). Dessa forma, modelos amparados apenas nos conhecimentos das leis da física são comumente chamados de caixa branca; aqueles que utilizam apenas as medições observadas são denominados de caixa preta; e os que utilizam as informações advindas das duas abordagens são caixa cinza.

Visto que a intenção do modelo é representar o comportamento do sistema quando submetido a determinadas condições ou entradas, sem a realização de experimentos, seu uso em simulações do sistema é considerado um procedimento de baixo custo e seguro. Nesse quesito, ressalta-se que a validade (adequação) dos resultados da simulação dependem da qualidade do modelo matemático.

Nesse contexto, um sistema é uma entidade que possui variáveis que interagem de acordo com os sinais de entrada e demais aspectos associados ao ambiente para execução de processos que geram sinais de saída. Logo, de acordo com (Coelho e Coelho, 2016, Ljung, 2010), a identificação de sistemas trata-se de procedimentos para derivação do modelo matemático de um sistema dinâmico em estudo a partir de dados de entrada e saída observados, representando suas características de forma adequada para um emprego específico.

Atualmente, há diversas técnicas empregadas que dependem do sistema e do modelo a ser estimado (linear, não linear, híbrido, não paramétrico, etc) e que variam de complexidade. Dessa forma, apesar das diferentes abordagens, para seleção do modelo e ajuste dos parâmetros da estrutura final, deve-se considerar o conhecimento *a priori* do sistema (linearidade, grau de não linearidade, entre outros); propriedades do modelo do sistema identificado (complexidade); seleção da medida do erro a ser minimizada; presença de ruídos; critérios de desempenho e validação.

A figura 1 representa o conceito de identificação de sistemas, destacando-se a obtenção do modelo a partir de sinais de entrada e saída de um determinado sistema executando um processo. De acordo com (Tangirala, 2018), o modelo identificado consiste de dois componentes (i) uma descrição matemática das relações de causa e efeito, geralmente chamado de modelo determinístico; e (ii) uma descrição estatística e matemática das incertezas, conhecida como modelo estocástico, proveniente de erros na observação, incertezas no processos e a presença de erros no modelo devido a fatores dinâmicos não considerados.

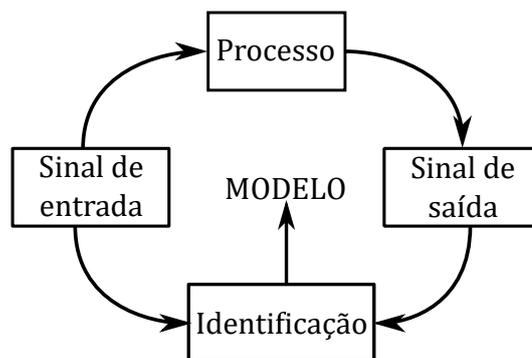


Figura 1: Identificação de sistemas a partir de dados de entrada e saída de um processo

Logo, o principal objetivo é usar o componente determinístico (entrada-saída) do modelo, pois caracteriza a dinâmica do processo físico. Um fato importante é que a acurácia e precisão do modelo determinístico estimado depende das hipóteses do modelo estocástico.

O processo de identificação consiste, geralmente, nas seguintes etapas, representadas na figura 2: medidas do processo, determinação da estrutura, estimação dos parâmetros e validação do modelo.

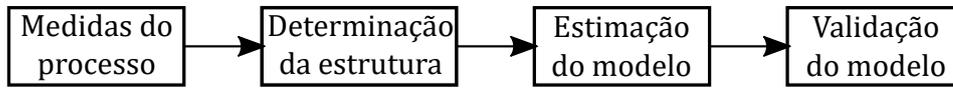


Figura 2: Etapas do procedimento de identificação (Coelho e Coelho, 2016)

Preliminarmente, trabalha-se com a aquisição e tratamento das medidas do processo (dados experimentais). Destaca-se que a qualidade dos dados é de extrema importância para uma identificação satisfatória do sistema. Na fase seguinte, a determinação da estrutura do modelo, adequada ao sistema observado, é realizada a partir de um conjunto de modelos candidatos, baseados em algum conhecimento *a priori* acerca do sistema a ser identificado e nas informações necessárias para aplicação da técnica de identificação escolhida.

Em seguida, a estimação do modelo é baseada na seleção de técnicas de estimação para a classe da estrutura definida, fase comumente chamada de treinamento ou aprendizado; enquanto que a validação do modelo é efetuada pela sua comparação com as medidas observadas do sistema real. Nesse aspecto, pode-se considerar que o modelo é satisfatório se o erro reflete corretamente a resposta do sistema dentro dos limites e erros aceitáveis (tolerância) para uma determinada aplicação.

Além do sistema em análise propriamente dito, conforme figura 3, em um processo de identificação, há outros elementos que influenciam na acurácia e precisão do modelo, tal que existem informações úteis e outras não relevantes para análise do comportamento do sistema, respectivamente, sinal e ruído (Ljung,2010). Após a aplicação das entradas no sistema, os atuadores e as perturbações, que podem ou não ser mensuráveis, interagem com o processo a ser identificado. Logo, o real sistema medido considera o processo e os elementos adicionais associados ao sistema e à medição, como as perturbações e ruídos, inserido-se nesse aspecto o próprio ruído dos sensores utilizados na aquisição das medidas (Tangirala,2018).

Logo, (Ljung,2010) recomenda que um modelo seja obtido levando-se em consideração que ele deve apresentar boa aderência aos dados de estimação e não deve ser muito complexo.

Basicamente, uma característica de sistemas dinâmicos é a causalidade, de tal forma que o comportamento do sistema no futuro é dependente do passado. Portanto, a predição dos valores de saída $y(t)$ no instante t , depende de todas ou algumas das medidas de entrada $u(t)$ e saída anteriores do sistema. Dessa forma, denotando-se as medidas de estimação por Z_e^N , sendo N o

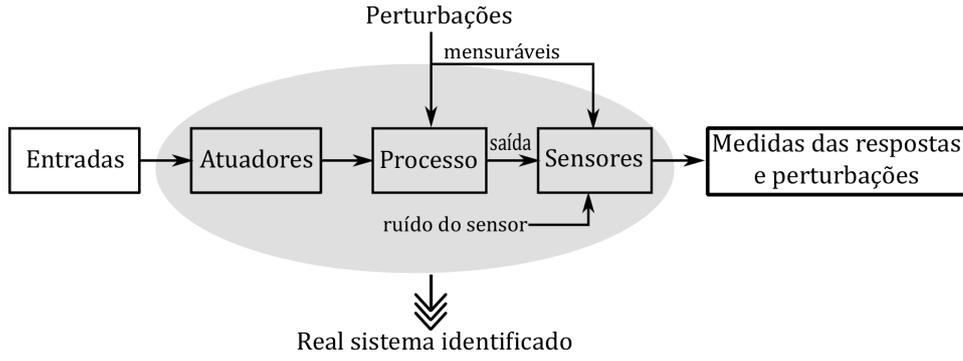


Figura 3: Elementos presentes na aquisição das medidas de um sistema. Adaptado de (Tangirala,2018)

tamanho da amostra, tem-se:

$$Z^{t-1} = [y(t-1), u(t-1), y(t-2), u(t-2), \dots], \quad (1)$$

tal que as predições de $\hat{y}(t|t-1) = g(Z^{t-1})$.

A partir do conceito descrito pela eq. (1) que diversas técnicas de identificação de sistemas foram elaboradas. Seja um sistema dinâmico descrito por equações diferenciais, tal que:

$$a_0 y^{(n)} + a_1 y^{(n-1)} + \dots + a_{n-1} \dot{y} + a_n y = b_0 u^{(m)} + b_1 u^{(m-1)} + \dots + b_{m-1} \dot{u} + b_m u, \quad (2)$$

onde y é a saída e u é a entrada do sistema, com $n \geq m$. A função de transferência é dada pela transformada de Laplace da relação entre o sinal de saída e o sinal de entrada de um sistema, considerando-se condições iniciais nulas (obtenção de modelo contínuo):

$$G(s) = \frac{\mathcal{L}[saída]}{\mathcal{L}[entrada]} = \frac{Y(s)}{U(s)} = \frac{b_0 s^{(m)} + b_1 s^{(m-1)} + \dots + b_{m-1} s + b_m}{a_0 s^{(n)} + a_1 s^{(n-1)} + \dots + a_{n-1} s + a_n}, \quad (3)$$

sendo n a ordem do sistema (polos), m o número de zeros e $a_0 = 1$. Contudo, como a identificação de sistemas utiliza dados observados, usualmente emprega-se a discretização do modelo, analogamente à representação da transformada de Laplace, na transformada Z, tal que:

$$G(z) = \frac{Y(z)}{U(z)} = \frac{\sum_{j=0}^m b_j z^{-j}}{\sum_{i=0}^n a_i z^{-i}}, \quad (4)$$

cuja equação diferencial é dada por:

$$y(k) = -a_1 y(k-1) - \dots - a_n y(k-n) + b_1 u(k-1) + \dots + b_m u(k-m) \quad (5)$$

2.2

Identificação de sistemas com a ferramenta CONTSID

Segundo (Garnier et al.,1999), há diversas ferramentas disponíveis para identificação de sistemas lineares a partir de dados amostrais utilizando MATLAB, destacando-se o próprio *toolbox* disponível para identificação de sistemas: *System IDentification*(SID), com foco na obtenção de modelos discretos operando em malha aberta. Contudo, apesar de os modelos discretos serem atrativos para o emprego de sistema de controle, os modelos contínuos ainda são relevantes para os sistemas físicos.

Dessa forma, em 1999, (Garnier et al.,1999) apresentou a ferramenta *CONtinuous-Time System IDentification* (CONTSID), *toolbox* disponível para MATLAB, baseada na maioria das abordagens encontradas na literatura à época para estimação de modelos contínuos paramétricos para sistemas lineares invariantes no tempo a partir de dados amostrais, além de ferramentas para análise das propriedades dos modelos estimados. Logo, dado o sistema linear de ordem n com uma entrada u e uma saída y , sem a presença de ruído, descrito pela eq. (6), o objetivo da identificação de um sistema contínuo é achar os parâmetros a_i e b_i a partir dos dados de entrada e saída do sistema dinâmico analisado.

$$\sum_{i=0}^n a_{n-i}y^{(i)}(t) = \sum_{i=0}^m b_{m-i}u^{(i)}(t), \quad m \leq n, a_0 = 1, \quad (6)$$

De acordo com (Garnier et al.,2006, Garnier et al.,2009, Garnier,2011), as principais características do CONTSID são:

- possibilita a utilização de vários métodos desenvolvidos no domínio do tempo para identificação de modelos paramétricos de sistemas dinâmicos contínuos a partir de dados amostrais de entrada e saída;
- proporciona métodos tradicionais e atuais de identificação de modelos no formato de funções de transferência e espaço de estados para tanto para sistemas de única entrada e única saída, quanto para múltiplas entradas e saídas;
- permite a utilização de dados amostrados de forma irregular (suave) de maneira direta;
- pode ser considerado uma extensão do *toolbox* de SID do MATLAB, possuindo configuração similar para facilitar sua utilização;
- apresenta uma interface gráfica que possibilita com que o usuário analise os dados experimentais e avalie os modelos de maneira facilitada; e
- está disponível gratuitamente em <http://www.contsid.cran.univ-lorraine.fr/>.

Dentre as motivações para a obtenção de um modelo contínuo por meio de identificação de sistemas estão: possibilidade de entendimento físico das propriedades do sistema, utilização da experiência/conhecimento prévio da ordem do modelo, possibilita a filtragem dos dados e a transformação dos modelos contínuos em discretos.

O procedimento para determinação de um modelo contínuo no espaço de tempo de um sistema dinâmico diretamente a partir dos dados de entrada e saída no espaço de tempo é similar ao processo executado na identificação de modelos discretos. Portanto, o processo de identificação consiste em, repetidamente selecionar a estrutura do modelo, calcular o modelo mais adequado dentro da estrutura definida e avaliar o modelo identificado. O processo iterativo é composto das seguintes etapas (Garnier,2011):

1. projeto do experimento e a aquisição dos dados de entrada e saída do processo a ser identificado;
2. análise e tratamento das medições, com o intuito de selecionar uma parcela útil dos dados originais;
3. seleção e definição da estrutura do modelo (um conjunto de candidatos para descrição do sistema) dentro do qual o modelo será estimado;
4. cálculo do modelo mais adequado dentro da estrutura escolhida de acordo com os dados de entrada e saída e o critério de ajuste; e
5. análise das propriedades dos modelos obtidos.

Após execução dos passos apresentados anteriormente, se o modelo for considerado satisfatório, pode-se parar a iteração. Caso contrário, deve-se voltar ao passo 3 para análise de um outro conjunto de modelos; ou ao passo 4 para tentativas utilizando outros métodos de estimação; ou, inclusive, voltar as passos 1 e 2 e trabalhar na obtenção e tratamento dos dados de entrada e saída utilizados.

Os passos 1 e 2 não precisam ser realizados no ambiente do CONT-SID. Contudo, a partir do passo 3, pode-se empregar as funções de seleção da ordem do modelo "SRIVCSTRUC" e "SELCSTRUC", implementadas nessa ferramenta, para auxílio na definição da estrutura do modelo. A combinação das funções "SRIVCSTRUC" com o algoritmo de estimação da Variável Instrumental Refinada Simplificado (*Simplified Refined Instrumental Variable for Continuous-time model Identification - SRIVC*), disponível na função "SRIVC", permite a construção dos modelos em faixa de diferentes ordens de estruturas e cálculo do coeficiente de determinação R^2 e do critério de informação de

Young (*Young Information Criterion - YIC*), medidas estatísticas que permitem a avaliação da aderência do modelo aos dados experimentais.

Para tanto, define-se os valores mínimos e máximos do numerador e denominador da função de transferência a ser estimada, tal que o modelo contínuo é ajustado para os dados das medições fornecidas ao algoritmo para cada estrutura dentro da faixa selecionada. Combinando-se o conjunto de estruturas candidatas à função "SELCSTRUC", a saída apresenta a tabela com os valores estatísticos computados para verificação da aderência da estrutura aos dados reais para análise. Da análise dos resultados, é possível verificar qual o melhor modelo por meio dos critérios apresentados, sendo indicado que seja escolhido o que apresenta o valor mais negativo de YIC associado ao R^2 próximo a 1.

Com a estrutura definida, pode-se utilizar a função "TFRIVC" para estimação da função de transferência do modelo contínuo, fornecendo como entrada o número de polos e o número de zeros (obtidos com o auxílio do procedimento descrito para seleção da estrutura), além dos dados observados após tratamento. Para estimação, o algoritmo implementado no CONTSID também faz uso da Variável Instrumental Refinada Simplificado.

Para avaliação da qualidade do modelo, pode-se simular o modelo em simulação livre (*free run - FR*) e realizar os cálculos do resíduo ξ (erro do modelo), do R^2 e da raiz do erro médio quadrático $RMSE$ dos valores estimados em relação à medida fornecida, conforme as Equações (7), (8) e (9), respectivamente, tal que $y(t)$ representa a medida real e \hat{y} o respectivo valor estimado no instante t .

$$\xi(t) = y(t) - \hat{y}(t) \quad (7)$$

$$R^2 = 1 - \frac{\sum[\xi(t)]^2}{\sum_{t=1}^N [y(t) - \hat{y}(t)]} \quad (8)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N [\xi(t)]^2} \quad (9)$$

Portanto, quanto mais próximo de 1 o valor de R^2 , implica que o modelo é mais aderente aos dados experimentais fornecidos como amostra para o processo de identificação do sistema.

2.3

Identificação de sistemas por meio de Redes Neurais Artificiais

De acordo com (Haykin,2009), uma rede neural é como se fosse um processador paralelo e distribuído, composto por unidades simples de processa-

mento que armazenam conhecimento experimental para disponibilizá-los para uso. Dessa forma, a analogia feita ao cérebro humano é decorrente do fato de as redes neurais adquirirem conhecimento a partir do ambiente, por meio de um processo de aprendizagem, tal que esse conhecimento é armazenado no que é chamado de peso sináptico, associado à força de conexão entre os neurônios da rede.

Segundo (Ljung,2010), as Redes Neurais Artificiais (RNA) apresentaram um desenvolvimento significativo nas últimas décadas, principalmente pela eficiência demonstrada na resolução de um grande número de problemas de identificação não lineares. Para estruturação das RNA, definem-se, inicialmente, as unidades básicas denominadas de neurônios (processadores ou nós), conectados com outros por meios de sinapses para formação de uma rede de nós.

Segundo (Sanchez,2009), as redes são classificadas em dois grupos, de acordo com a arquitetura, em redes Perceptron e redes Perceptron Multicamadas (PMC)(*Multilayer Perceptron* - MLP), ressaltando-se que essa última é considerada como uma das mais importantes na área de RNA. Nesse caso, a rede é composta por uma camada de entrada, uma ou mais camadas escondidas e uma camada de saída, estruturadas de tal forma que permitam com que a rede seja treinada progressivamente para o aprendizado de tarefas complexas.

Combinando-se os neurônios em camadas, conectadas entre si, estrutura-se a arquitetura da rede, tal que a entrada de uma camada intermediária é saída da camada anterior (camada de entrada), e a saída dessa mesma camada é a entrada da camada seguinte (camada de saída). Dessa forma, os neurônios passam pelo processo de treinamento e processamento das informações.

Os neurônios são composto por três elementos básicos, representados na figura 4 (Haykin,2009):

- um conjunto de sinapses: atribuem pesos às entradas dos neurônios;
- um somatório: função (Net) dada pela eq. (11), que combina linearmente os valores das entradas ponderados pelos pesos das sinapses correspondentes de cada neurônio; e
- função de ativação: limita a saída dos neurônios e, conseqüentemente, do valor da saída da rede, de acordo com alguma função não linear, geralmente escrita na faixa de amplitude normalizada da saída de um neurônio como um intervalo de $[0,1]$ ou $[-1,1]$.

As entradas do sistema são ponderadas pelos pesos sinápticos, conforme eq. (10), e associadas da função somatório (Net) para ativação do valor da saída (Sanchez,2009), calculado pela eq (12), com base na função de ativação φ utilizada.

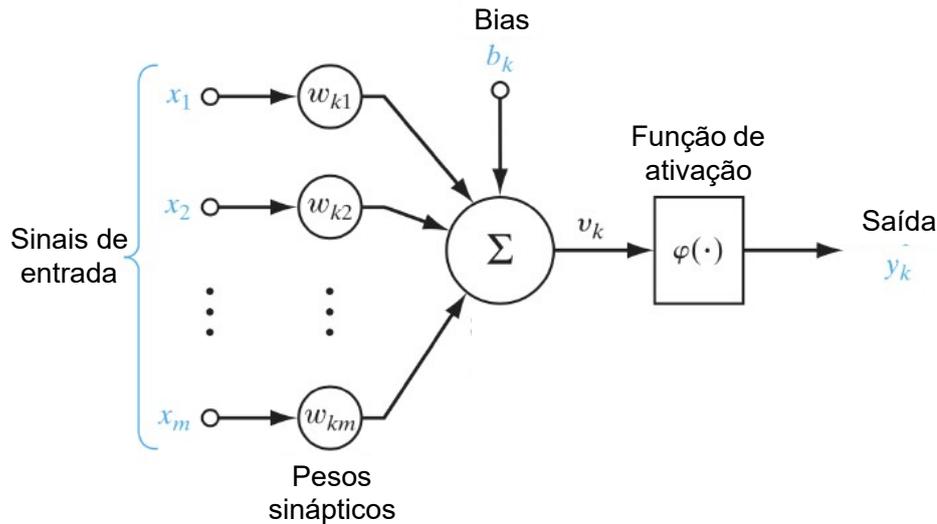


Figura 4: Esquemático para representação de um modelo de neurônio não linear k . Adaptado de (Haykin,2009)

$$u_k = \sum_{j=1}^m w_{kj}x_j, \quad (10)$$

$$Net_k = \sum_{j=1}^p w_{kj}x_j + b_k, \quad (11)$$

$$y_k = \varphi(u_k + b_k), \quad (12)$$

tal que b_k é conhecido como o termo polarizador (bias), valor constante associado ao modelo do neurônio, e w_{kj} corresponde ao peso sináptico da sinapse j do sinal de entrada x_j conectado ao neurônio k .

Conforme (Sung et al., 2021), a rede neural é treinada para modelar a relação entre a entrada e a saída desejada ajustando-se os pesos da rede, tal que a qualidade do peso é usualmente medida como uma função de perda (*loss function*), sendo a mais utilizada a do erro médio quadrático. Como o próprio nome indica, o objetivo dessa função é minimizar o erro médio quadrático entre a saída de rede neural com um peso \mathbf{W} e os dados realmente observados no sistema. Logo, utilizando-se o processo iterativo de gradiente descendente, o valor de \mathbf{W} é atualizado de acordo com a taxa de aprendizagem e com base em quantidades menores de dados do conjunto completo das medições (*batch set*) para viabilizar o processo.

Logo, como alguns aspectos a serem considerados, (Sanchez,2009) cita que o número de camadas escondidas influi na relação entrada-saída da rede, indicando que um maior número de camadas teria melhor capacidade de extração das características de um processo desconhecido. Contudo, o aumento do número de camadas também possibilita com que os neurônios não respondam de maneira satisfatória a padrões nunca visto. Dessa forma,

um número reduzido de camadas escondidas e neurônios produz uma rede pequena que talvez não seja capaz de armazenar e representar todos os padrões necessários do sistema para validação do modelo; assim como uma rede muito grande, além de demandar maior esforço computacional, pode tentar modelar pontos além do processo de interesse.

Nesse quesito, ressalta-se a relevância da função de ativação no processo, bem como o algoritmo de aprendizado selecionado para obtenção dos pesos das conexão desejados para resolução da tarefa. Dentre as diversas funções de ativação disponíveis, pode-se citar: a linear; a *rectified linear unit* (ReLU) (Sharma et al., 2017, Sung et al., 2021); a Sigmoid (Sharma et al., 2017); a *Scaled Exponential Linear Units* (SELU); a Tanh; e a *Leaky* ReLU.

Apesar de não haver um critério para escolha da função de ativação a ser utilizada no processo de identificação de sistemas via redes neurais, (Sharma et al., 2017) aponta que a função ReLU é a mais utilizada e apresenta melhores resultados em relação a outras funções na maioria dos casos. Além disso, também indica que estudos mostram que tanto a Sigmoid quanto a Tanh não são adequadas para camadas escondidas, sendo a ReLU a escolha usual para aplicação nesses casos por apresentar derivada igual a 1.

Para implementação do algoritmo de identificação utilizando-se redes neurais, analogamente à ferramenta CONTSID, disponível para MATLAB, a combinação da plataforma Tensorflow, utilizada em aprendizado de máquinas, com a Interface de Programação de Aplicação (*Application Programming Interface* - API) Keras, escrita em Python, auxilia na criação dos modelos com base na utilização de algoritmos já implementados e flexibilidade para modificações na arquitetura da rede. Dessa forma, pode-se definir a arquitetura das RNA com escolha do número de neurônios, a quantidade de camadas escondidas, função de ativação e diversos outros parâmetros associados ao algoritmo de treinamento, como o método de otimização utilizado.

Para verificação da resposta do modelo, de acordo com (Narendra et al., 1990), pode-se trabalhar com a identificação de sistemas não lineares no formato de série-paralelo, com a simulação do tipo um passo à frente (*one-step-ahead* - OSA), ou no modelo paralelo, tratando-se de uma simulação livre. No geral, a simulação OSA não é unicamente utilizada para validar o modelo, visto que o erro é zerado a cada passo. Na simulação livre, o erro é acumulado, obtendo-se mais qualidade de informação com valores do erro médio quadrático e do R^2 .

3

Identificação da dinâmica lateral de um veículo militar utilizando dados de mudança dupla de faixa

3.1

Estudo de caso

O problema de identificação formulado consiste em um estudo de caso utilizando dados experimentais de um veículo militar de três eixos do tipo 6x6 realizando manobras de mudança dupla de faixa a diferentes velocidades para seleção da estrutura de modelo; estimação dos parâmetros das funções de transferência entre o ângulo de guinada (*yaw rate*) (saída) e o ângulo de esterçamento do volante (entrada) em diferentes velocidades; e comparação do modelo obtido com os dados experimentais para validação.

3.1.1

Descrição do experimento

As medidas experimentais foram obtidas de uma Viatura Blindada de Transporte de Pessoal (VBTP), utilizada pelo Exército Brasileiro (EB), com três eixos, sendo o eixo frontal e intermediário esterçantes. Os dados foram coletados durante a realização de manobras de mudança dupla de faixa, executadas de acordo com a norma *Allied Vehicle Testing Publications* (AVTP) 03-160W da Organização do Tratado do Atlântico Norte (NATO, do inglês *North Atlantic Treaty Organization*). Esse teste é utilizado para avaliar a estabilidade lateral de um veículo e é um dos mais empregados para identificação de parâmetros e estados relacionados à dinâmica lateral. A manobra consiste na transição da faixa da direita para a esquerda, seguido pelo retorno à faixa da direita à velocidade constante. A pista de teste foi montada de acordo com o dispositivo disponível em (NATO, 1991), considerando as dimensões do veículo apresentadas na Tabela 1. O veículo utilizado no experimento é mostrado na figura 5.

Para aquisição dos dados experimentais, foram utilizados os seguintes equipamentos: um *data logger* VBOX 3i da Racelogic®; uma unidade de medida inercial (IMU, do inglês *Inertial Measurement Unit*) modelo RLVBIMU04 da Racelogic®, fixada no chão no compartimento da tropa para medições das

Tabela 1: Informações do veículo

Parâmetro	Símbolo	Valor
Massa	m	15,770 kg
Comprimento	L	7,10 m
Altura	H	2,60 m
Largura	w_v	3,30 m
Distância do CG ao eixo dianteiro	a_1	1,77 m
Distância do CG ao eixo intermediário	a_2	0,07 m
Distância do CG ao eixo traseiro	a_3	1,93 m



Figura 5: Veículo instrumentado para obtenção das medidas experimentais

taxas de arfagem, rolagem e guinada, além das acelerações nos eixos x , y e z ; uma antena GPS posicionada no teto do veículo para permitir as medições de velocidade e distância de deslocamento da viatura; e um transdutor linear da MICRO-EPSILON® montado no cilindro auxiliar de esterçamento da roda dianteira esquerda de forma a possibilitar a obtenção da medida do ângulo de esterçamento da roda dianteira esquerda por meio de uma relação linear, obtida experimentalmente, entre a tensão registrada pelo transdutor e o ângulo do volante. A mesma instrumentação e alguns dos dados levantados também embasaram os estudos apresentados em (Pereira, 2020).

Com o veículo descarregado, realizou-se a manobra de mudança dupla de faixa, segundo a norma (NATO, 1991), a velocidades de 10 km/h, 20 km/h, 30 km/h, 40 km/h, 50 km/h, 60 km/h, 70 km/h e 80 km/h. Os dados foram capturados à taxa de 100 Hz e salvos para análise posterior. Um exemplo das medições adquiridas está apresentado na figura 6. A taxa de guinada e o ângulo do volante são as variáveis de interesse nesse estudo dado que as medições da taxa de guinada são mais confiáveis do que as da aceleração lateral, enquanto que o ângulo do volante foi escolhido como entrada da função de transferência do modelo.

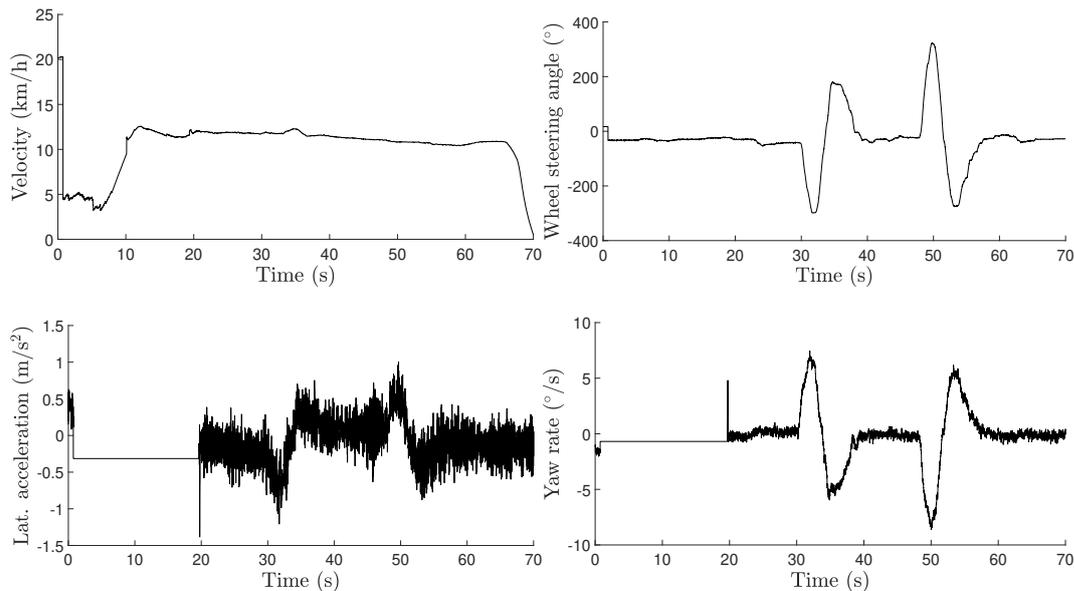


Figura 6: Medições do veículo durante uma manobra de mudança dupla de faixa realizada a, aproximadamente, 10 km/h

O pré-processamento das medidas experimentais é crucial para compensar distorções causadas principalmente pela vibração devido ao funcionamento do motor e o *offset* dos sensores. Por exemplo, erros na resposta da IMU podem ser decorrentes de desalinhamento do sensor e uma divergência de um fator de escala, que pode ser calibrado de acordo com (Nirmal et al.,2016). Baseado no espectrograma dos sinais capturados da taxa de guinada e do ângulo do volante, foi aplicado um filtro Butterworth de décima-segunda ordem com frequência de corte normalizada de 2,5 Hz a 3,5 Hz. O filtro possibilitou a remoção de componentes de alta-frequência oriundos de outras fontes, como ruído e a vibração do veículo. Também foi aplicado um filtro digital de fase zero para remover o atraso de fase do sinal filtrado e, devido ao *offset* significativo nas medidas dos sensores do ângulo do volante e na aceleração lateral, também foi realizada a compensação, como pode ser visto na figura 6. É importante salientar que o motorista foi o responsável por manter a velocidade do veículo constante durante cada manobra. Consequentemente, além da filtragem dos dados, tendências e valores discrepantes foram removidos para selecionar amostras relevantes dos dados originais.

Outro aspecto que pode ser avaliado é o espectro no domínio da frequência do ângulo do volante e da taxa de guinada, pois permite avaliar as medições em uma faixa de frequências. De acordo com a figura 7 e figura 8, é possível concluir que a energia de ambos os sinais está concentrada em baixas frequências, o que é significativo para a aplicação dos modelos de estimação.

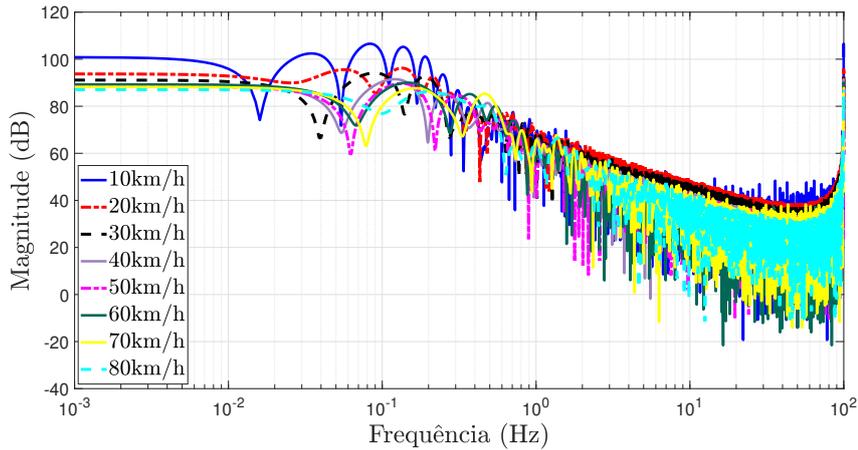


Figura 7: Espectro no domínio da frequência do ângulo do volante

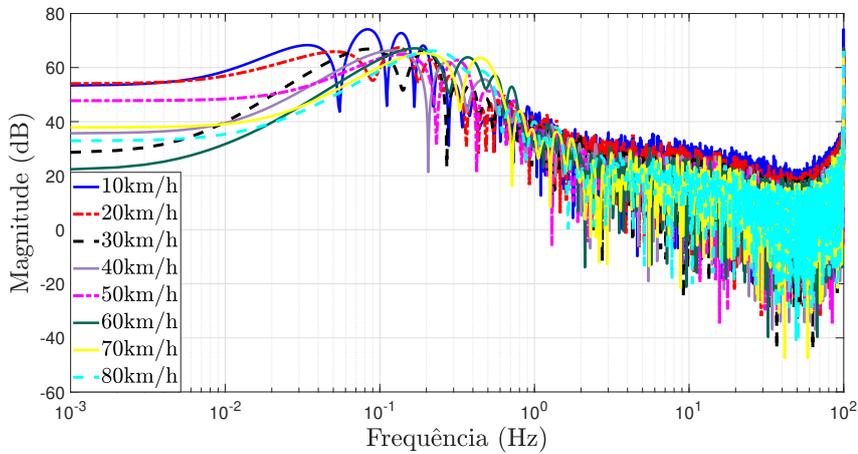


Figura 8: Espectro no domínio da frequência da taxa de guinada

3.2 Modelo veicular

A formulação matemática baseada em um modelo físico é uma das principais abordagens para representar um sistema dinâmico. Dessa forma, as equações de Newton-Euler são frequentemente aplicadas para modelagem de sistemas dinâmicos com base em um referencial conveniente, geralmente do corpo, e um referencial global (inercial).

Adotando-se um sistema de coordenadas do corpo $Cxyz$, tal que C é o centro de massa do veículo, com relação a um sistema de coordenadas inercial $OXYZ$ apresentado na figura 9, tem-se que a orientação do veículo é dada em função dos ângulos de rolagem φ (*roll*) com relação ao eixo x , arfagem θ (*pitch*) com relação ao eixo y e guinada (*yaw*) ψ , relativo ao eixo z (Jazar, 2008). As respectivas taxas de variação dos ângulos são denotadas por taxa de rolagem (*roll rate*) $\dot{\varphi} = p$, taxa de arfagem (*pitch rate*) $\dot{\theta} = q$ e taxa de guinada *yaw rate* $\dot{\psi} = r$.

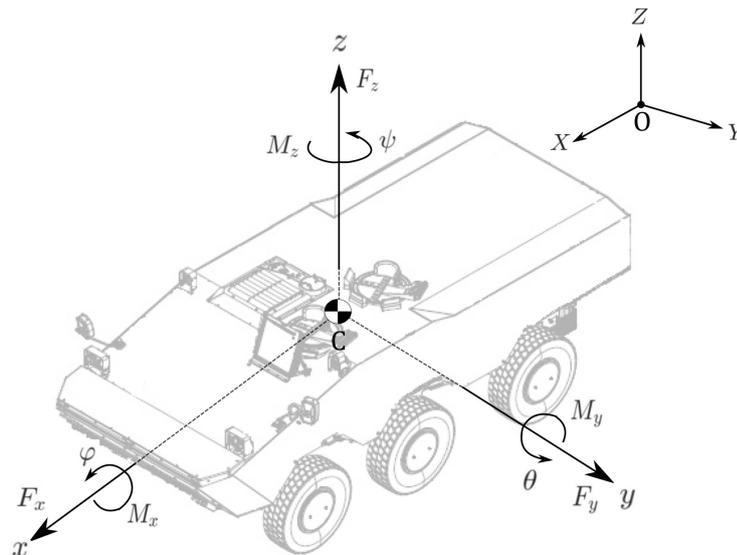


Figura 9: Coordenadas do veículo $Cxyz$ em um sistema de coordenadas inercial $OXYZ$ de acordo a ISO 8855 (Pereira, 2020)

Para definir uma estrutura linear, considerou-se o modelo bicicleta para representar a dinâmica lateral, utilizando-se as equações de movimento linearizadas de Newton-Euler no plano xy das forças atuantes em cada eixo, assumindo que as duas rodas de cada eixo podem ser representadas por uma única roda equivalente. A figura 10 mostra uma representação esquemática do modelo, onde \mathbf{v} é o vetor velocidade do veículo, r é a taxa de guinada, enquanto δ_f e δ_m são os ângulos de esterçamento das rodas dianteira e intermediária.

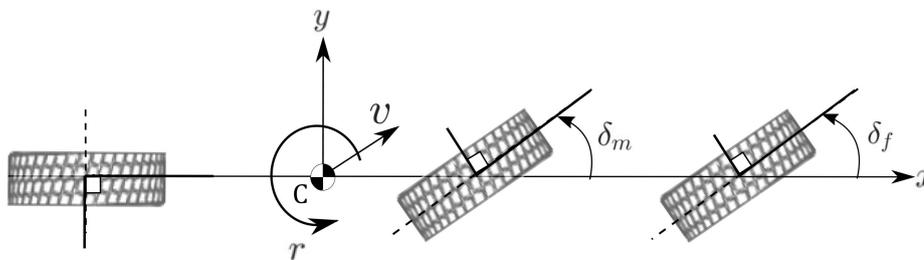


Figura 10: Modelo "bicicleta" de um veículo de três eixos

Para pequenos ângulos de esterçamento e sob o regime linear de operação dos dos pneus, as forças laterais F_y atuando nos pneus podem ser consideradas como uma função linear do ângulo de deslizamento (*slip-angle* α , tal que $F_y = -C_\alpha \alpha$, onde C_α é o coeficiente de rigidez (*cornering stiffness*) do pneu (Jazar, 2008). Com base no modelo bicicleta linearizado para um veículo de dois eixos apresentado em (Jazar, 2008), assumindo uma velocidade constante e desconsiderando a rolagem, um modelo análogo de dois graus de liberdade para um veículo de três eixos foi obtido em função da velocidade lateral, v_y , da taxa de guinada r , da massa do veículo m , do coeficiente de rigidez dos pneus,

da distância dos eixos ao centro de massa do veículo, do momento de inércia I_z e do ângulo de esterçamento equivalente da roda dianteira δ_f .

$$\begin{bmatrix} \dot{v}_y \\ \dot{r} \end{bmatrix} = A \begin{bmatrix} v_y \\ r \end{bmatrix} + B\delta_f, \quad (13)$$

onde:

$$A = \begin{bmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{bmatrix} = \begin{bmatrix} -\frac{C_{\alpha_f} + C_{\alpha_m} + C_{\alpha_r}}{mv_x} & \frac{-a_1 C_{\alpha_f} - a_2 C_{\alpha_m} + a_3 C_{\alpha_r}}{mv_x} - v_x \\ -\frac{a_1 C_{\alpha_f} + a_2 C_{\alpha_m} - a_3 C_{\alpha_r}}{I_z v_x} & -\frac{a_1^2 C_{\alpha_f} + a_2^2 C_{\alpha_m} + a_3^2 C_{\alpha_r}}{I_z v_x} \end{bmatrix}, \quad (14)$$

$$B = \begin{bmatrix} B_1 \\ B_2 \end{bmatrix} = \begin{bmatrix} \frac{C_{\alpha_f}}{m} + \left(\frac{a_2 + a_3}{a_1 + a_3}\right) \frac{C_{\alpha_m}}{m} \\ \frac{a_1 C_{\alpha_f}}{I_z} + \left(\frac{a_2 + a_3}{a_1 + a_3}\right) \frac{a_2 C_{\alpha_m}}{I_z} \end{bmatrix}, \quad (15)$$

Considerando uma relação linear entre os ângulos de esterçamento da roda dianteira e intermediária, segundo a geometria de Ackermann, obtém-se:

$$\delta_m = \tan^{-1} \left(\frac{a_3 + a_2}{a_3 + a_1} \tan(\delta_f) \right) \approx \frac{a_2 + a_3}{a_1 + a_3} \delta_f. \quad (16)$$

Portanto, a partir das equações de movimento com o emprego da transformada de Laplace expressas pela eq. (13), a estrutura da função de transferência $G_{\delta}^r(s)$ para a taxa de guinada, considerando o ângulo de esterçamento da roda dianteira como entrada, apresenta dois polos e um zero, os quais variam com os elementos da matriz A e do vetor B , tal que :

$$\begin{aligned} G_{\delta}^r(s) &= \frac{r(s)}{\delta_f(s)} \\ &= \frac{(A_{21}B_1B_2)s - (A_{11}A_{21}B_1B_2)}{s^2 - (A_{11} + A_{22})s + (A_{22}A_{11} - A_{12}A_{21})}. \end{aligned} \quad (17)$$

Supondo que existe uma relação linear entre o ângulo de esterçamento da roda dianteira e o ângulo do volante, a estrutura apresentada anteriormente ainda é válida para uma função de transferência considerando o ângulo do volante como sinal de entrada.

3.3 Identificação de sistema aplicado para modelagem da dinâmica lateral veicular

Nessa seção, são dados detalhes do procedimento de identificação adotado para estimar modelos lineares da dinâmica lateral para diferentes velocidades usando os dados experimentais do veículo obtidos de acordo com o apresentado na Seção 3.1.

3.3.1

Algoritmo

Para estimar um modelo de função de transferência entre os dados amostrados da taxa de guinada e do ângulo do volante, foi aplicado um procedimento de identificação de sistemas com o uso da ferramenta (*toolbox*) CONTSID, disponível para instalação no MATLAB. O processo consistiu nas seguintes etapas baseadas na sequência recomendada para identificação de sistemas apresentada em (Garnier et al., 2018):

1. aquisição dos dados de entrada/saída no domínio do tempo das manobras de mudança dupla de faixa;
2. seleção e pré-processamento de amostras relevantes dos dados para cada velocidade. Esta etapa inclui a análise do espectrograma dos sinais de entrada/saída, redução de ruído através de filtragem e remoção de *offset*;
3. definição e seleção da estrutura do modelo (um conjunto de candidatos para descrever o sistema);
4. estimação dos parâmetros da função de transferência da estrutura do modelo usando os dados de entrada/saída pós-processados, a estrutura do modelo selecionada e as técnicas de identificação implementadas no CONTSID; e
5. análise da adequação do modelo obtido em relação aos dados experimentais com base no coeficiente de correlação múltipla R^2 (*multiple correlation coefficient*) entre a resposta estimada do modelo \hat{y} e as medidas $y(t)$. Como parâmetro, $R^2 > 0.9$ é considerado satisfatório para muitas aplicações (Schaible, 1997).

3.3.2

Formulação do problema de identificação

Uma descrição dos passos 1 e 2 do procedimento do algoritmo anterior já foi apresentada na Seção 3.1.1. Em relação à definição da estrutura do modelo (etapa 3), foram utilizadas duas abordagens. A primeira foi a função de transferência linear entre a taxa de guinada e o ângulo do volante obtida através do modelo bicicleta, explicado na Seção 3.2. A segunda foi uma função de seleção da ordem do modelo baseada no método de Variável Instrumental Refinado (do inglês, *Refined Instrumental Variable for Continuous-time - RIVC*), disponível no CONTSID, para pesquisar automaticamente toda uma gama de modelos de diferentes ordens, fornecendo um conjunto de melhores

estruturas de acordo com o critério de informação de Young (do inglês, *Young Information Criterion* - YIC) e o critério de coeficiente de determinação associado R_T^2 . A seleção da estrutura do modelo final foi baseada no conjunto comum de valores para diferentes velocidades.

Para a abordagem utilizando o CONTSID, considerou-se a faixa na ordem de um a dois parâmetros para o numerador e de dois a cinco parâmetros para o denominador como entradas para a função de seleção do modelo. Em seguida, o método retornou as estruturas de modelo selecionadas para cada conjunto de dados medidos de entrada/saída para cada velocidade. As estruturas comuns para todas as velocidades avaliadas foram dois polos e um zero, de acordo com a primeira abordagem na Seção 3.2; e três polos e um zero. Conseqüentemente, ambas as estruturas candidatas foram analisadas para verificar a influência da velocidade do veículo na resposta em frequência da taxa de guinada e no comportamento dos polos e zeros do sistema. Dadas as medidas de entrada/saída pós-processadas e a estrutura selecionada da função de transferência (número de polos e zeros), o CONTSID foi utilizado para estimar os parâmetros dos modelos contínuos de erro de saída usando o método de Variável Instrumental Refinada Simples (do inglês, *Simple Refined Instrumental Variable for Continuous-time models* - SRIVC).

3.4

Resultados e discussão

Seguindo a metodologia apresentada na Seção 3.3 e usando os dados do teste de mudança dupla de faixa para diferentes velocidades, foram estimadas as funções de transferência considerando a taxa de guinada como saída e o ângulo de esterçamento do volante como entrada. Assim, pode-se verificar a influência da velocidade nos modelos identificados, como sua resposta em frequência e o comportamento dos polos e zeros.

Os polos e zeros estimados das funções de transferência e os respectivos coeficientes R^2 são apresentados na Tabela 2, enquanto a figura 11 exibe a comparação entre dados medidos (sem filtro), medições pós-processadas (filtradas) e a resposta do modelo para cada velocidade. Pode-se notar que os modelos resultantes correspondem satisfatoriamente aos dados medidos, com $R^2 > 0,94$. Como as medições do ângulo do volante e da taxa de guinada possuem energia concentrada em baixas frequências, os modelos estimados são válidos para essa faixa.

Além disso, a análise da resposta em frequência pode fornecer informações sobre o desempenho do veículo durante uma manobra. A influência da velocidade na resposta em frequência da estrutura do modelo de segunda or-

Tabela 2: Parâmetros estimados do modelo para diferentes velocidades

Velocidade	Polos	Zeros	R^2
10 km/h	$-2.3265 + 7.4728i$ $-2.3265 - 7.4728i$	11.3127	0.9917
20 km/h	$-5.0054 + 6.8656i$ $-5.0054 - 6.8656i$	11.0120	0.9857
30 km/h	-2,5182 -0.9126	-0.7003	0.9818
40 km/h	$-7.8329 + 4.7040i$ $-7.8329 - 4.7040i$	11.1251	0.9844
50 km/h	$-6.8170 + 3.7474i$ $-6.8170 - 3.7474i$	15.7334	0.9914
60 km/h	-2.9090 -0.0060	0.0258	0.9720
70 km/h	$-4.2729 + 3.6978i$ $-4.2729 - 3.6978i$	24.5142	0.9825
80 km/h	-11.2494 -3.8269	16.9710	0.9820

dem pode ser examinada no diagrama de Bode na figura 12. Verifica-se que um aumento na velocidade implica um aumento positivo na magnitude do estado estacionário e no atraso de fase após 1 Hz, de acordo com as conclusões dos estudos teóricos apresentados em (Jang et al., 1997) e (Abe, 2015). Uma característica importante a ser avaliada é o ganho na resposta da taxa de guinada em relação ao seu valor estático, dado que incrementos mínimos são desejáveis para melhor dirigibilidade e estabilidade (Yuen et al., 2014). A partir do gráfico de magnitude na figura 12, percebe-se também que os picos mais altos correspondem às menores velocidades.

De acordo com a análise apresentada em (Abe, 2015), é possível observar que o veículo muda sua característica de subesterçante, a baixas velocidades, para um comportamento neutro em velocidades mais altas, o que pode afetar a estabilidade lateral do veículo. Uma tendência subesterçante implica que os ângulos de esterçamento do volante são maiores com o aumento da velocidade para manter o mesmo raio de curvatura durante uma manobra, enquanto o oposto é verdadeiro para condições sobre-esterçantes. Para um veículo com uma característica de direção neutra, o mesmo ângulo de esterçamento pode ser mantido para manutenção do raio da curva. É importante destacar que o comportamento subesterçante é considerado estável, enquanto o sobre-esterçante é instável, uma vez que é mais difícil para o motorista recuperar o controle do veículo.

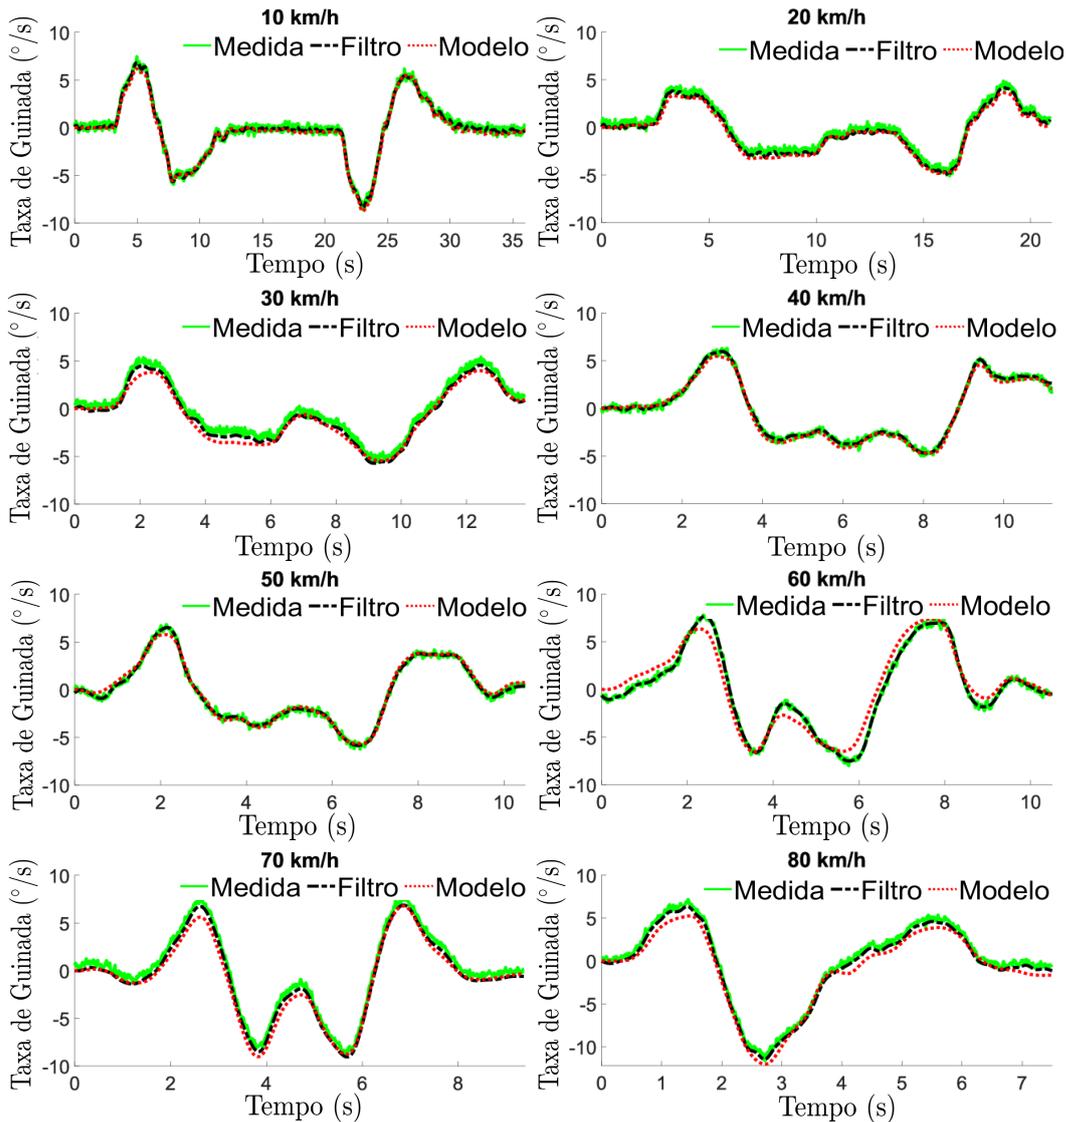


Figura 11: Comparativo dos dados experimentais, dados filtrados e a resposta do modelo estimado da taxa de guinada

Da figura 12, também é possível notar que em baixas frequências (menores que 0,1 Hz), o gráfico de fase tem um atraso de fase inicial de, aproximadamente, 180° (entrada-saída fora de fase), que diverge do valor de 0° previsto na análise feita em (Abe, 2015). Essa divergência foi causada pelo atraso de fase nos dados de medição do ângulo do volante e da taxa de guinada. Em frequências intermediárias, entre 0,1 Hz e 1 Hz, há um atraso de fase negativo crescente, enquanto que para frequências mais altas, a fase para a maioria dos valores de velocidade tende a convergir para -80° . As exceções são os modelos para 30 km/h e 60 km/h, que foram os únicos com zero negativo, cujas fases tendem a 100° .

A influência da variação da velocidade no comportamento dos polos e zeros pode ser visualizada na figura 13. Os polos estão localizados no semiplano

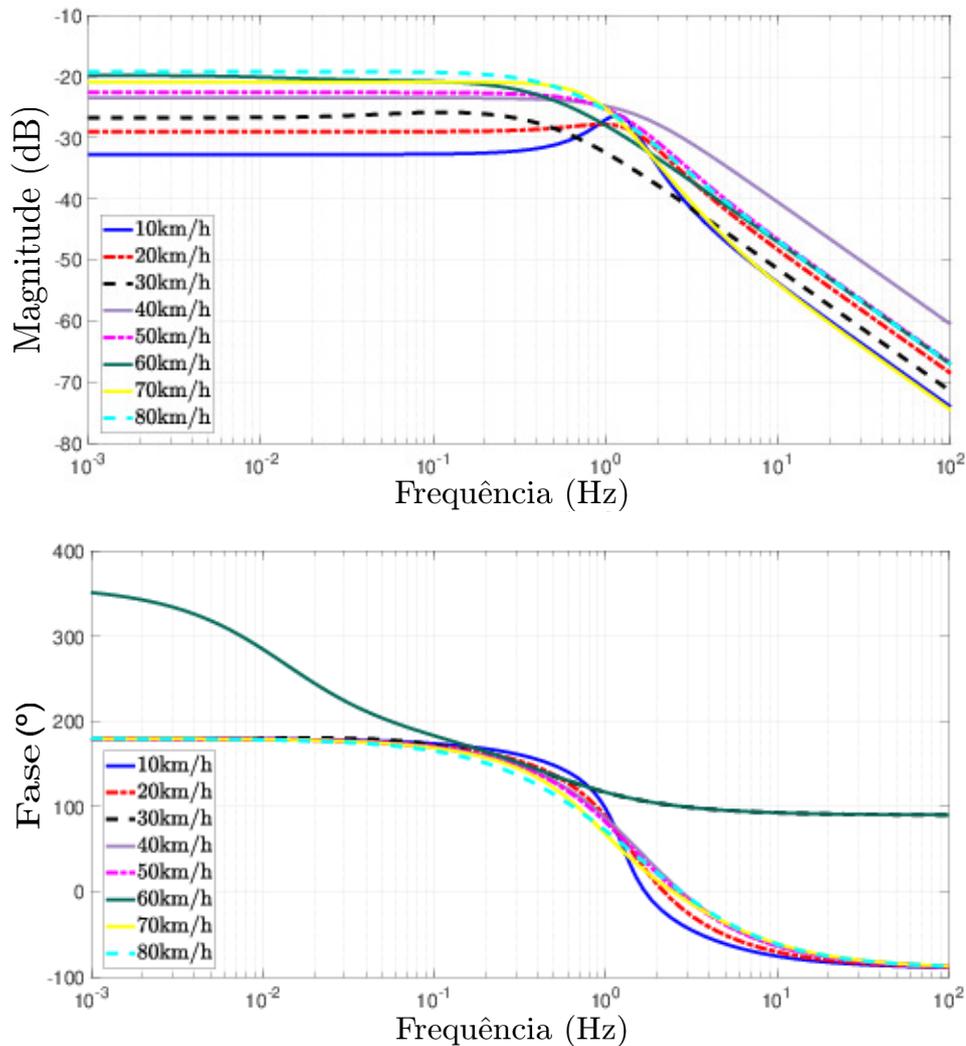


Figura 12: Diagrama de Bode da magnitude e da fase da taxa de guinada com relação à variação da velocidade do veículo

esquerdo do plano s (componentes reais negativos), o que é uma indicação da estabilidade do sistema. Adicionalmente, eles tendem a se mover de um sistema subamortecido (polos imaginários) em velocidades mais baixas para um sistema superamortecido (polos reais) em velocidades mais altas. De acordo com os modelos obtidos, a maioria dos zeros está localizada na metade direita do plano s , ou seja, zeros de fase não mínima, o que implica que o sistema possui características de fase não mínima. De acordo com (Kiefer, 1996), isso pode fazer com que a resposta comece inicialmente na direção oposta.

O mesmo procedimento aplicado à estrutura do modelo de terceira ordem resultou em polos cancelando zeros para a maioria das velocidades, o que pode significar que alguns dos parâmetros adicionados não são relevantes, ou seja, com o aumento da complexidade da estrutura do modelo, o algoritmo de identificação cancela a influência de polos adicionais com zeros para obter o melhor ajuste da resposta. Nesse aspecto, destaca-se a afirmação contida

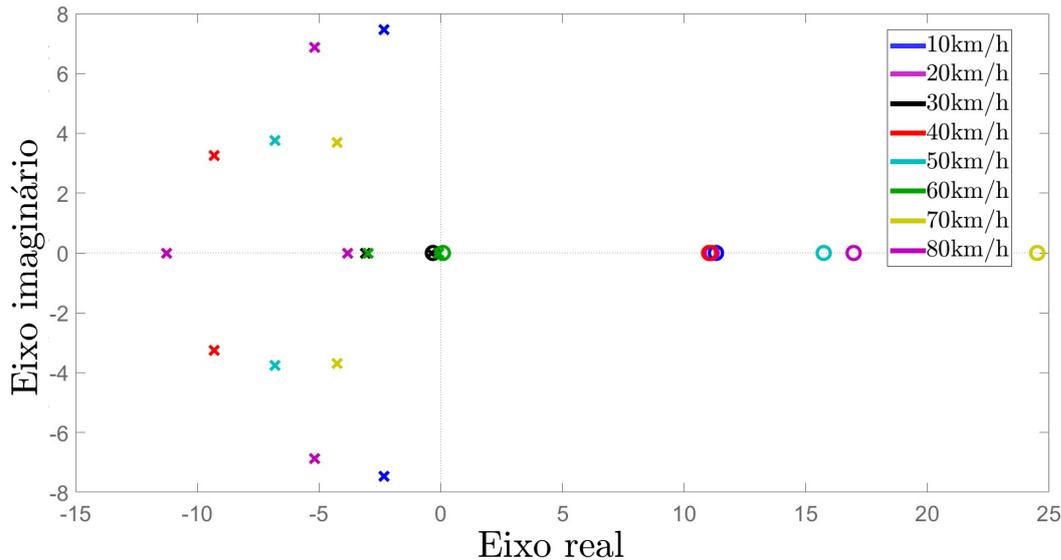


Figura 13: Comportamento dos polos e zeros dos modelos estimados com a variação da velocidade do veículo

em (Garnier et al., 2018) de que modelos de ordem superior nem sempre são mais precisos e podem contribuir o aumento das incertezas dos parâmetros. Ressalta-se, porém, que foram verificadas variações significativas nos modelos estimados do CONTSID com modificações nos processos de pré-processamento dos dados, principalmente quanto à remoção do *offset* e da seleção de janela da amostra dos dados originais.

Outra questão é que, como mencionado anteriormente, os dados de entrada-saída estão concentrados em baixas frequências. Portanto, os modelos identificados são considerados representações do sistema naquele intervalo. Para obter um modelo que descreva completamente o sistema, entende-se que são necessárias mais informações. Por exemplo, (Chindamo, 2018) aplicou um sinal do tipo *swept sine* em simulações para gerar dados suficientes de um sistema para treinar uma Rede Neural Artificial. Para o estudo de caso em foco, os dados foram adquiridos durante manobras de mudança dupla de faixa seguindo o padrão NATO AVTP 03-160W (NATO, 1991) e, devido às dimensões do veículo e medidas de segurança, não foi possível gerar sinais de entrada-saída de frequências mais altas, tendo em mente que a entrada é o ângulo do volante e a saída é a taxa de guinada.

3.5

Conclusões parciais

A primeira abordagem proposta neste Capítulo para identificação da dinâmica lateral de um veículo militar de três eixos apresentou a obtenção de modelos contínuos lineares no formato de funções de transferência com a

utilização da ferramenta CONTSID, disponível no MATLAB.

Esta abordagem baseia-se nos dados medidos de entrada-saída e não requer conhecimento dos parâmetros do veículo, que podem ser desconhecidos e difíceis de medir. Com base em medidas experimentais do veículo realizando manobras de mudança dupla de faixa a diversas velocidades, os parâmetros das funções de transferência entre o ângulo do volante (entrada) e a taxa de guinada (saída) foram estimados com o emprego do método da Variável Instrumental Refinada Simples, disponível no CONTSID.

O estudo de caso apresentado destacou a fase da instrumentação do veículo, tratamento dos dados experimentais obtidos e a realização da identificação dos modelos. A seleção da estrutura e a estimação dos parâmetros foram realizadas por meio de métodos implementados e disponibilizados no CONTSID, além da utilização de formulações físicas para auxiliar na escolha da ordem da estrutura.

De acordo com os resultados, os modelos lineares estimados apresentaram boa concordância com os dados experimentais, identificando-se que há uma correlação linear significativa entre o ângulo do volante e a taxa de guinada. Adicionalmente, dada a resposta em frequência dos modelos identificados, concluiu-se que o aumento da velocidade do veículo implica um maior ganho de magnitude, sendo que os polos do sistema apresentam a tendência de passar de um sistema subamortecido (polos imaginários) em velocidades mais baixas para um sistema superamortecido sistema (polos reais) em velocidades mais altas. Além disso, com base nos sinais de entrada/saída, aponta-se que a energia deles está concentrada em baixas frequências, onde os modelos obtidos são válidos.

Por fim, destaca-se que os modelos obtidos fornecem um entendimento acerca da resposta dinâmica do veículo em tela para o caso em análise e que, apesar dos resultados satisfatórios, há possibilidade de melhorias da resposta do modelo com a análise e inclusão de não lineares do sistema que não foram consideradas na formulação linear, aspecto alvo de estudo no Capítulo 4.

4

Identificação da dinâmica lateral de um veículo militar por meio de modelos híbridos

4.1

Considerações iniciais

De acordo com o apresentado nos Capítulos 1 e 2, os modelos não lineares auxiliam na obtenção de respostas de sistemas dinâmicos e facilitam a obtenção de informações não captadas por modelos simplesmente lineares. Dentre um dos métodos bastante empregados nesse escopo, está a utilização de Redes Neurais Artificiais (RNA). Dessa forma, modelos satisfatórios podem ser obtidos por meio da construção da arquitetura da rede e desenvolvimento do processo de treinamento.

Contudo, a depender da arquitetura e nível de complexidade da rede neural estruturada, tem-se um incremento no tempo de processamento do cálculo para obtenção do modelo. Isso, somado à possibilidade de representação do comportamento dinâmico de um sistema por modelos mais simplificados, como os lineares, resulta na proposta de obtenção de modelos híbridos desse trabalho. Logo, além da análise do modelo não linear via RNA, este Capítulo também apresenta os resultados da implementação de modelos híbridos, obtidos da combinação dos modelos lineares do CONTSID, somados à estimação do erro realizada por redes neurais, com o intuito de captar eventuais não linearidades presentes no sistema e melhorar a resposta do modelo com base nos dados de entrada e saída utilizados.

4.2

Metodologia

Para o desenvolvimento das propostas de modelo utilizando RNA, utilizou-se os mesmos dados experimentais pós-processados apresentados no Capítulo 3 das medidas de entrada do ângulo do volante e da saída do ângulo de guinada de um veículo militar de três eixos.

Tendo em vista que há diversas possibilidades para estruturação da rede neural e que a intenção é trabalhar com estruturas mais simples, foram fixados os valores da ordem do modelo, a taxa de aprendizado, o *batch size* e o

número de épocas, variando-se a quantidade de camadas, de 1 a 4, o número de neurônios por camada (16, 32, 64 ou 128) e as funções de ativação para identificação dos modelos. Consequentemente, para cada função de ativação, obtiveram-se 16 arquiteturas e modelos diferentes. A Tabela 3 apresenta os principais parâmetros utilizados na criação dos modelos não lineares e o Algoritmo 1 apresenta as etapas para identificação do sistema por meio de redes neurais, implementado em Python com o auxílio da API Keras.

Tabela 3: Principais parâmetros para identificação dos modelos não lineares

Parâmetro	Valor
Ordem do modelo	$n_y = 2$ $n_u = 2$
Otimizador	Adam - taxa de aprendizagem: 10^{-3}
Função de perda (<i>loss function</i>)	erro quadrático médio
<i>Batch size</i>	8
Número de épocas	50
Número de camadas escondidas	1, 2, 3 ou 4
Número de neurônios por camada	16, 32, 64 ou 128

Algoritmo 1: Identificação via RNA

Entradas Ângulo do volante $u(t)$, taxa de guinada $y(t)$, ordem do modelo na saída n_y , ordem do modelo na entrada n_u , número de épocas, de neurônios por camada e quantidade de camadas

Início

Passo 1: Normalização dos valores de $u(t)$ e $y(t)$

Passo 2: Cálculo da matriz de regressão com base nas variáveis y e u e da ordem do modelo, dada pelos parâmetros n_y e n_u

Passo 3: Definição da arquitetura da rede baseada na saída da matriz de regressão, na quantidade de neurônios por camada, número de camadas e função de ativação ('relu' e 'selu' utilizadas nesse trabalho).

Passo 4: Criação do modelo usando o Keras, considerando-se a entrada e a saída da rede criada no Passo 3.

Passo 5: Compilação do modelo para treinamento com a função 'model.compile', definindo-se o otimizador e a função de perda.

Passo 6: Treinamento da rede com a função 'model.fit', baseado na matriz de regressão, número de épocas e *batch size*

Passo 7: Cálculo da saída do modelo em simulação livre y_e de acordo com a entrada $u(t)$.

Fim

Cabe ressaltar que a etapa de normalização das medidas experimentais de entrada e saída anteriormente ao início do processo de identificação é crucial para obtenção de bons resultados, além de reduzir significativamente o tempo de simulação, segundo (Sola, 1997). De acordo com (Theodoridis e Koutroumbas, 2006), caso os valores das medições estejam em faixas diferentes, os maiores terão maior influência na função custo, sem que isso necessariamente reflita a significância desse dado do processo. Logo, o processo de normalização auxilia na resolução dessa questão, de tal forma que as medidas estejam dentro de uma mesma faixa de valores.

Ainda com relação a esse aspecto, (Nayak et al., 2014) afirma que a normalização é uma transformação realizada nos dados para distribuí-los igualmente e dimensioná-los dentro de uma faixa aceitável para a rede. Dessa forma, busca-se garantir a qualidade das informações a serem utilizadas no processo de identificação, minimizar o aparecimento de bias dentro da rede, agilizar o treinamento e melhorar o desempenho da rede (número de iterações de treinamento e o erro final obtido), à medida em que a faixa de valores das variáveis de entrada são equalizadas por meio da normalização.

A normalização das medidas afeta no desempenho do erro dos parâmetros estimadores treinados para prever o valor das diversas variáveis e trata-se de uma transformação linear das medidas originais, sendo utilizada neste trabalho a fórmula apresentada na eq. (18), trabalhando-se no intervalo de $[0,1]$:

$$\hat{a} = [a - \min(a)] / [\max(a) - \min(a)], \quad (18)$$

tal que a é a medida a ser normalizada; $\min(a)$ e $\max(a)$ são os valores mínimos e máximos de a , respectivamente; e \hat{a} representa o dado normalizado.

4.3

Resultados e discussão do modelo não linear

Empregando-se a metodologia apresentada na Seção 4.2, os resultados dos modelos não lineares obtidos para cada velocidade estão apresentados nas Tabelas 4 a 11 a seguir, para diversas arquiteturas.

Da análise das Tabelas 4 a 11, percebe-se que a função de ativação ReLU apresentou resultados melhores em praticamente todas as arquiteturas construídas em relação aos modelos não lineares com a função de ativação SELU. Inclusive, para a maioria das arquiteturas, a utilização da função SELU não obteve valores de $R^2 > 0,9$ e, em algumas, apresentou dificuldades de convergência, como na arquitetura 1 da estimação do modelo de 60 km/h. Verificando-se na formulação das funções de ativação ReLU, dada pela eq. (19), e SELU, eq. (20), tem-se que:

Tabela 4: Estimação de modelo não linear para 10 km/h

Arquit.	Nº Camadas	Neurônios/ Camada	R^2 selu	R^2 relu	R^2 CONTSID
1	1	16	-	0,9195	0,9917
2		32	-48,8397	0,9741	
3		64	-76,9905	0,7931	
4		128	0,9534	0,9887	
5	2	16	-65,6527	0,9637	0,9917
6		32	-99,6641	0,9718	
7		64	-42,3901	0,9124	
8		128	-1,2813	0,9836	
9	3	16	0,9079	-0,2054	0,9917
10		32	-22,8082	0,8616	
11		64	-624,5796	0,6932	
12		128	-23,1211	0,9863	
13	4	16	-17,4868	0,9874	0,9917
14		32	0,9297	0,9712	
15		64	0,0785	0,9750	
16		128	0,9824	0,9847	

$$f(x)_{ReLU} = \max(0, x), \quad (19)$$

$$f(x)_{SELU} = \begin{cases} \lambda x, & \text{se } x > 0, \\ \lambda \alpha (e^x - 1), & \text{se } x \leq 0, \end{cases} \quad (20)$$

tal que α e b são constante pré-definidas ($\alpha = 1.67326324$ e $\lambda = 1.05070098$).

Do exposto, a saída da função ReLU é linear se a entrada for positiva, ou igual a zero, caso contrário. Pela simplicidade, essa função é calculada rapidamente em relação às outras, inclusive à SELU. Em contrapartida, a SELU apresenta valores maiores que a entrada, para x maior do que zero e valores negativos para x menores do que zero. Possivelmente, pelo fato das medições terem uma tendência linear, conforme resultados obtidos com o CONTSID, não apresentarem variações bruscas e terem um comportamento bem definido, a função de ativação ReLU é satisfatória para abordagem da identificação, enquanto que os valores ativados de saída da SELU impactam na convergência do método dentro das arquiteturas pré-estabelecidas.

Além disso, cabe ressaltar que apesar dos resultados satisfatórios obtidos com os modelos não lineares com a função de ativação ReLU, ainda assim o modelo linear do CONTSID apresentou melhores resultados em comparação às diversas arquiteturas das redes neurais, destacando-se que apenas algumas das estruturas para estimação do modelo de 30 km/h (arquiteturas 1 e 14), 40 km/h (arquitetura 3), 50 km/h (arquitetura 15), 60 km/h (arquiteturas 1,

Tabela 5: Estimação de modelo não linear para 20 km/h

Arquit.	Nº Camadas	Neurônios/ Camada	R^2 selu	R^2 relu	R^2 CONTSID
1	1	16	-	0,8751	0,9857
2		32	-18,4829	0,9445	
3		64	-31,1345	0,9653	
4		128	-7,5939	0,9010	
5	2	16	-31,2078	0,9322	0,9857
6		32	-44,1014	0,9524	
7		64	-12,3883	0,9678	
8		128	-7,2827	0,8050	
9	3	16	0,9195	-3,1494	0,9857
10		32	-6,7063	0,9544	
11		64	-8,0896	0,8850	
12		128	-13,1432	0,8453	
13	4	16	-20,5810	0,9715	0,9857
14		32	0,7375	0,9715	
15		64	-16,8732	0,9767	
16		128	0,9339	0,9782	

4 e 10) e 70 km/h (arquitetura 3), mostraram resultados melhores do que o modelo linear estimado. Dentre os motivos, pode-se apontar:

1. o fato de realmente haver uma relação linear entre o ângulo do volante e a taxa de guinada, pelo menos a baixas velocidades, conforme formulação analítica apresentada no Capítulo 2;
2. como percebido na construção dos modelos lineares, as medidas experimentais influenciam diretamente no processo de estimação. Logo, há possibilidade de os modelos não lineares terem seu desempenho afetado devido à soma do erro acumulado na simulação livre e alterações nas medidas estimadas dos atrasos utilizados no cálculo da matriz de regressão; e
3. outra possibilidade é que as redes neurais trabalham em porções fracionadas dos dados completos, estabelecidas de acordo com a arquitetura selecionada e com o número de iterações. Logo, os valores pré-estabelecidos dos parâmetros empregados no algoritmo podem ter degradado o desempenho do modelo e sua convergência.

Percebe-se também que o aumento do número de camadas ou de neurônios não necessariamente implica que o modelo apresenta melhor desempenho. Logo, conclui-se que, quando comparado a todas as arquiteturas geradas, o

Tabela 6: Estimação de modelo não linear para 30 km/h

Arquit.	Nº Camadas	Neurônios/ Camada	R^2 selu	R^2 relu	R^2 CONTSID
1	1	16	0,9785	0,9808	0,9788
2		32	0,4523	0,8652	
3		64	0,6219	0,7175	
4		128	0,6971	0,8573	
5	2	16	0,7927	0,9563	0,9788
6		32	-43,8460	0,9278	
7		64	-14,7396	0,3742	
8		128	0,5653	0,9656	
9	3	16	0,5789	0,1965	0,9788
10		32	0,5087	0,9044	
11		64	-15,7165	0,9318	
12		128	-9,1966	0,9729	
13	4	16	0,9729	0,9061	0,9788
14		32	-2,2356	0,9839	
15		64	-15,2016	0,9739	
16		128	0,6198	0,9585	

Tabela 7: Estimação de modelo não linear para 40 km/h

Arquit.	Nº Camadas	Neurônios/ Camada	R^2 selu	R^2 relu	R^2 CONTSID
1	1	16	-	0,9794	0,9844
2		32	-8,9351 ⁵⁶	0,5988	
3		64	-26,6711	0,9909	
4		128	0,9727	0,9742	
5	2	16	-13,6821	0,9355	0,9844
6		32	-16,4475	0,9852	
7		64	-10,5549	0,9267	
8		128	-3,7074	0,8617	
9	3	16	-12,6611	0,5550	0,9844
10		32	-0,4488	0,9791	
11		64	0,6542	0,9470	
12		128	-10,9113	0,7313	
13	4	16	-36,7218	0,8979	0,9844
14		32	-9,4158	0,9058	
15		64	-15,7445	0,9796	
16		128	0,9316	0,9439	

modelo linear com a ferramenta CONTSID mostrou-se mais adequado para descrição do comportamento dinâmico no veículo no estudo de caso em aná-

Tabela 8: Estimação de modelo não linear para 50 km/h

Arquit.	Nº Camadas	Neurônios/ Camada	R^2 selu	R^2 relu	R^2 CONTSID
1	1	16	0,8008	0,9877	0,9914
2		32	-3,2458 ⁶⁴	0,7689	
3		64	-63,2936	0,9489	
4		128	0,9457	0,9891	
5	2	16	-19,6058	0,9553	0,9914
6		32	-16,4831	0,8232	
7		64	-7,3125	0,9483	
8		128	-7,6582	0,9242	
9	3	16	-20,9744	-2,5944	0,9914
10		32	0,6361	0,9413	
11		64	0,9856	0,9811	
12		128	-13,6279	0,9113	
13	4	16	0,9715	0,9702	0,9914
14		32	0,8850	0,9625	
15		64	-16,1069	0,9934	
16		128	-15,0277	0,7289	

Tabela 9: Estimação de modelo não linear para 60 km/h

Arquit.	Nº Camadas	Neurônios/ Camada	R^2 selu	R^2 relu	R^2 CONTSID
1	1	16	-	0,9744	0,9720
2		32	0,7508	0,7503	
3		64	-64,8809	0,8851	
4		128	-16,2193	0,9886	
5	2	16	-16,8240	0,8809	0,9720
6		32	0,7598	0,9368	
7		64	-11,5677	0,7940	
8		128	-20,2369	0,9706	
9	3	16	-20,4037	-15,0773	0,9720
10		32	-0,3744	0,9737	
11		64	-18,9928	0,9133	
12		128	-8,0791	0,8857	
13	4	16	-24,3183	0,9054	0,9720
14		32	0,8005	0,8858	
15		64	-32,4547	0,9569	
16		128	-2,1456	0,9588	

lise. Contudo, destaca-se que foi possível a identificação de pelo menos uma arquitetura empregando redes neurais com desempenho superior ao modelo

Tabela 10: Estimação de modelo não linear para 70 km/h

Arquit.	Nº Camadas	Neurônios/ Camada	R^2 selu	R^2 relu	R^2 CONTSID
1	1	16	-	0,9143	0,9825
2		32	-8,5737	0,8793	
3		64	-41,7117	0,9834	
4		128	-	0,9597	
5	2	16	-10,4887	0,9610	0,9825
6		32	-16,4049	0,9566	
7		64	-14,7691	0,7597	
8		128	-5,6749	-8,7150	
9	3	16	-17,9431	-3,2411	0,9825
10		32	0,3978	0,9455	
11		64	-3,1780	0,8394	
12		128	0,9734	0,9152	
13	4	16	0,9904	0,9587	0,9825
14		32	-12,6579	0,7179	
15		64	0,9670	0,9600	
16		128	-15,6810	0,9747	

Tabela 11: Estimação de modelo não linear para 80 km/h

Arquit.	Nº Camadas	Neurônios/ Camada	R^2 selu	R^2 relu	R^2 CONTSID
1	1	16	-	0,9536	0,9820
2		32	-8,7714	0,4796	
3		64	0,6366	0,8260	
4		128	-	0,9439	
5	2	16	-31,0167	0,9586	0,9820
6		32	-34,1147	0,9418	
7		64	-0,5853	0,9598	
8		128	-1640,1618	-2,6530	
9	3	16	-24,1373	0,3401	0,9820
10		32	-0,5918	0,7775	
11		64	-0,2804	0,9283	
12		128	-2,6522	0,8672	
13	4	16	-5,8628	0,7589	0,9820
14		32	-4,6712	0,9194	
15		64	-1,0438	0,9517	
16		128	0,9745	0,8926	

linear para a maioria das velocidades, com exceção de 10 km/h, 20 km/h e 80 km/h, que podem ter sido influenciadas pelas medidas devido à pequena

diferença entre os maiores R^2 calculados para cada uma das duas abordagens.

4.4

Identificação do modelo híbrido

De acordo com os resultados apresentados no Capítulo 3 e na Seção anterior, identificou-se que os modelos lineares obtidos com o CONTSID apresentam resultados satisfatórios com relação às medidas experimentais. Contudo, há características dinâmicas que eles não conseguiram representar e algumas das arquiteturas das redes neurais construídas consideraram apresentar desempenho superior.

Portanto, com o intuito de aprimorar os resultados do modelo linear, este trabalho propõe também a análise de modelos híbridos baseados na combinação dos modelos lineares com a abordagem não linear, por meio da soma dos resultados estimados do CONTSID com a estimação do erro desse modelo empregando o algoritmo de redes neurais. Dessa forma, pretende-se corrigir os fenômenos dinâmicos não captados pelo modelo linear com a adição de possíveis não linearidades.

Para tanto, a mesma metodologia apresentada na Seção 4.2 foi utilizada, todavia, apenas com o emprego da função *ReLU*, por ter demonstrado os melhores resultados, e a inclusão da análise da influência da quantidade de épocas (número de iterações) no processo de identificação. Dessa forma, foram criados dois grupos de estruturas híbridas: o modelo híbrido A, que utiliza 50 épocas (mesmo valor empregado anteriormente); e o modelo híbrido B, com 1000 épocas. Os resultados estão apresentados nas Tabelas 12 a 19.

Avaliando-se os resultados obtidos pelos modelos híbridos das Tabelas 12 a 19, a figura 14 identifica as arquiteturas que possibilitaram a redução do erro do modelo linear (CONTSID) com o emprego da modelagem híbrida proposta.

Logo, verifica-se que o acréscimo de componentes não lineares possibilitou a melhoria na descrição da dinâmica do sistema para, pelo menos, uma arquitetura/modelo híbrido em tela, apesar dos valores elevados de R^2 dos resultados dos modelos lineares estimados. Outrossim, o aumento do número de épocas, de maneira geral, influenciou na precisão do modelo, quando compara-se os modelos híbridos A e B. Nesse sentido, destaca-se que para a velocidade de 20 km/h, para praticamente todas as arquiteturas, com exceção da 16, as respostas obtidas dos modelos estimados foram mais representativas das medições adquiridas do que a abordagem linear com o CONTSID.

A título de referência, a figura 15 representa um comparativo visual entre os modelos identificados com a abordagem linear (CONTSID) e a implementação do modelo híbrido B, empregando-se a arquitetura 2, em relação à saída

Tabela 12: Estimação de modelo híbrido para 10 km/h

Arquit.	Nº Camadas	Neurônios/ Camada	R^2 relu	R^2 CONTSID	R^2 híbrido A	R^2 híbrido B
1	1	16	0,9195	0,9917	0,9671	0,9463
2		32	0,9741		0,8628	0,9674
3		64	0,7931		0,9883	0,9733
4		128	0,9887		0,5520	0,9769
5	2	16	0,9637	0,9917	0,9209	0,9725
6		32	0,9718		0,9760	0,9715
7		64	0,9124		0,9395	0,9773
8		128	0,9836		0,9786	0,9848
9	3	16	-0,2054	0,9917	0,9573	0,9728
10		32	0,8616		0,9429	0,9639
11		64	0,6932		0,9663	0,9835
12		128	0,9863		0,9875	0,9584
13	4	16	0,9874	0,9917	0,9832	0,9866
14		32	0,9712		0,9939	0,9809
15		64	0,9750		0,9862	0,9733
16		128	0,9847		0,9870	0,9720

Tabela 13: Estimação de modelo híbrido para 20 km/h

Arquit.	Nº Camadas	Neurônios/ Camada	R^2 relu	R^2 CONTSID	R^2 híbrido A	R^2 híbrido B
1	1	16	0,8751	0,9857	0,9038	0,9937
2		32	0,9445		0,9565	0,9923
3		64	0,9653		0,9831	0,9931
4		128	0,9010		0,9169	0,9930
5	2	16	0,9322	0,9857	0,9900	0,9921
6		32	0,9524		0,8649	0,9916
7		64	0,9678		0,9829	0,9917
8		128	0,8050		0,9714	0,9915
9	3	16	-3,1494	0,9857	0,7344	0,9935
10		32	0,9544		0,9724	0,9925
11		64	0,8850		0,9736	0,9932
12		128	0,8453		0,9684	0,9911
13	4	16	0,9715	0,9857	0,9710	0,9898
14		32	0,9715		0,9905	0,9919
15		64	0,9767		0,9655	0,9912
16		128	0,9782		0,9804	0,9856

medida do sistema (dados originais e filtrados) para 30 km/h. Nesse exemplo, percebe-se que o modelo híbrido apresenta maior flexibilidade para acompa-

Tabela 14: Estimação de modelo híbrido para 30 km/h

Arquit.	Nº Camadas	Neurônios/ Camada	R^2 relu	R^2 CONTSID	R^2 híbrido A	R^2 híbrido B
1	1	16	0,9808	0,9788	0,9664	0,9826
2		32	0,8652		-2,2238	0,9936
3		64	0,7175		-2,9886 ³²	0,9816
4		128	0,8573		-	0,9878
5	2	16	0,9563	0,9788	0,9528	0,9758
6		32	0,9278		0,8532	0,1175
7		64	0,3742		-1,0863	-1,4182 ⁷⁰
8		128	0,9656		0,9772	-
9	3	16	0,1965	0,9788	0,9197	0,9838
10		32	0,9044		0,8319	0,9747
11		64	0,9318		0,9590	-2,2604
12		128	0,9729		-2,8495 ⁷²	-1,6062 ⁶⁸
13	4	16	0,9061	0,9788	0,9513	0,9632
14		32	0,9839		0,9570	0,9568
15		64	0,9739		-0,6197	0,9733
16		128	0,9585		-9,3085 ²⁸	-1,3729 ⁷¹

Tabela 15: Estimação de modelo híbrido para 40 km/h

Arquit.	Nº Camadas	Neurônios/ Camada	R^2 relu	R^2 CONTSID	R^2 híbrido A	R^2 híbrido B
1	1	16	0,9794	0,9844	0,9904	0,9822
2		32	0,5988		0,9917	0,9936
3		64	0,9909		0,9833	0,9310
4		128	0,9742		0,6733	0,9788
5	2	16	0,9355	0,9844	0,9852	0,9799
6		32	0,9852		0,8695	0,9735
7		64	0,9267		0,9236	0,9857
8		128	0,8617		0,9781	0,9891
9	3	16	0,5550	0,9844	0,9794	0,9898
10		32	0,9791		0,9742	-1,9721 ²⁸
11		64	0,9470		0,9796	0,9845
12		128	0,7313		0,9772	0,9874
13	4	16	0,8979	0,9844	0,9859	0,9775
14		32	0,9058		0,9839	0,9860
15		64	0,9796		0,9753	0,9866
16		128	0,9439		0,9151	0,9746

nhamento de variações que ocorrem nos dados observados, enquanto que o modelo linear possui um comportamento composto por curvas e retas mais pa-

Tabela 16: Estimação de modelo híbrido para 50 km/h

Arquit.	Nº Camadas	Neurônios/ Camada	R^2 relu	R^2 CONTSID	R^2 híbrido A	R^2 híbrido B
1	1	16	0,9877	0,9914	0,9887	0,9847
2		32	0,7689		0,9776	0,9929
3		64	0,9489		0,9900	0,9742
4		128	0,9891		0,9654	0,9640
5	2	16	0,9553	0,9914	0,9492	0,9567
6		32	0,8232		0,9814	0,9703
7		64	0,9483		0,9731	0,9546
8		128	0,9242		0,9509	0,9531
9	3	16	-2,5944	0,9914	0,9578	0,9717
10		32	0,9413		0,9769	0,7507
11		64	0,9811		0,9764	0,9918
12		128	0,9113		0,9576	0,9825
13	4	16	0,9702	0,9914	0,9940	0,9814
14		32	0,9625		-3,5936 ²⁴	0,9860
15		64	0,9934		0,9654	0,9833
16		128	0,7289		0,9573	0,9910

Tabela 17: Estimação de modelo híbrido para 60 km/h

Arquit.	Nº Camadas	Neurônios/ Camada	R^2 relu	R^2 CONTSID	R^2 híbrido A	R^2 híbrido B
1	1	16	0,9744	0,9720	-1,8062	0,9535
2		32	0,7503		-78,1526	0,9175
3		64	0,8851		-3,2705 ¹⁵	0,9322
4		128	0,9886		0,9450	-2,2049 ⁵³
5	2	16	0,8809	0,9720	0,7352	0,6583
6		32	0,9368		0,9159	0,9232
7		64	0,7940		0,8607	0,9402
8		128	0,9706		-1,2379 ⁴⁴	0,9751
9	3	16	-15,0773	0,9720	0,9291	0,9446
10		32	0,9737		0,9281	0,9240
11		64	0,9133		0,9313	0,9796
12		128	0,8857		-	0,9730
13	4	16	0,9054	0,9720	-1,4656	0,7849
14		32	0,8858		0,9510	0,9735
15		64	0,9569		0,9010	0,9433
16		128	0,9588		0,9719	0,9741

dronizadas e suaves, sem a presença de ondulações significativas, mesmo que ocorram no sistema real.

Tabela 18: Estimação de modelo híbrido para 70 km/h

Arquit.	Nº Camadas	Neurônios/ Camada	R^2 relu	R^2 CONTSID	R^2 híbrido A	R^2 híbrido B
1	1	16	0,9143	0,9825	-1,1029	-0,3376
2		32	0,8793		-40,8606	-3,6963 ²⁵
3		64	0,9834		0,9747	-319,9055
4		128	0,9597		0,9880	0,9912
5	2	16	0,9610	0,9825	0,9451	0,8075
6		32	0,9566		0,8901	0,9717
7		64	0,7597		0,9751	0,9369
8		128	-8,7150		0,9891	0,9571
9	3	16	-3,2411	0,9825	0,9746	0,9091
10		32	0,9455		0,9895	-5,2780 ²¹
11		64	0,8394		0,9763	0,9346
12		128	0,9152		0,9758	0,9672
13	4	16	0,9587	0,9825	0,9519	0,8030
14		32	0,7179		-50,9882	-9,4582 ²⁶
15		64	0,9600		0,9916	0,9809
16		128	0,9747		0,9865	0,9805

Tabela 19: Estimação de modelo híbrido para 80 km/h

Arquit.	Nº Camadas	Neurônios/ Camada	R^2 relu	R^2 CONTSID	R^2 híbrido A	R^2 híbrido B
1	1	16	0,9536	0,9820	0,9619	0,9657
2		32	0,4796		0,9585	0,9814
3		64	0,8260		0,9513	0,9711
4		128	0,9439		0,9708	0,9843
5	2	16	0,9586	0,9820	0,9777	0,9751
6		32	0,9418		0,9528	0,9598
7		64	0,9598		0,9674	0,9704
8		128	-2,6530		0,9341	0,9877
9	3	16	0,3401	0,9820	0,9605	0,9704
10		32	0,7775		0,9600	0,9901
11		64	0,9283		0,9679	0,9891
12		128	0,8672		0,9537	0,9780
13	4	16	0,7589	0,9820	0,9520	0,9679
14		32	0,9194		0,9673	0,9881
15		64	0,9517		0,9560	0,9891
16		128	0,8926		0,9401	0,9825

Arquitetura	10 km/h		20 km/h		30 km/h		40 km/h		50 km/h		60 km/h		70 km/h		80 km/h	
	A	B	A	B	A	B	A	B	A	B	A	B	A	B	A	B
1				✓		✓	✓	✓								
2				✓		✓	✓	✓		✓						
3				✓		✓										
4				✓		✓						✓	✓			✓
5			✓	✓			✓									
6				✓												
7				✓				✓								
8				✓				✓				✓	✓			✓
9				✓			✓	✓								
10				✓								✓	✓			✓
11				✓			✓	✓		✓		✓				✓
12				✓				✓				✓	✓			✓
13				✓			✓		✓							
14	✓		✓	✓			✓	✓				✓				✓
15				✓				✓					✓	✓		✓
16				✓								✓	✓			✓

Figura 14: Indicação das arquiteturas dos modelos híbridos A (50 épocas) e B (1000 épocas) que apresentaram melhorias em relação à resposta do modelo linear do CONTSID para cada velocidade

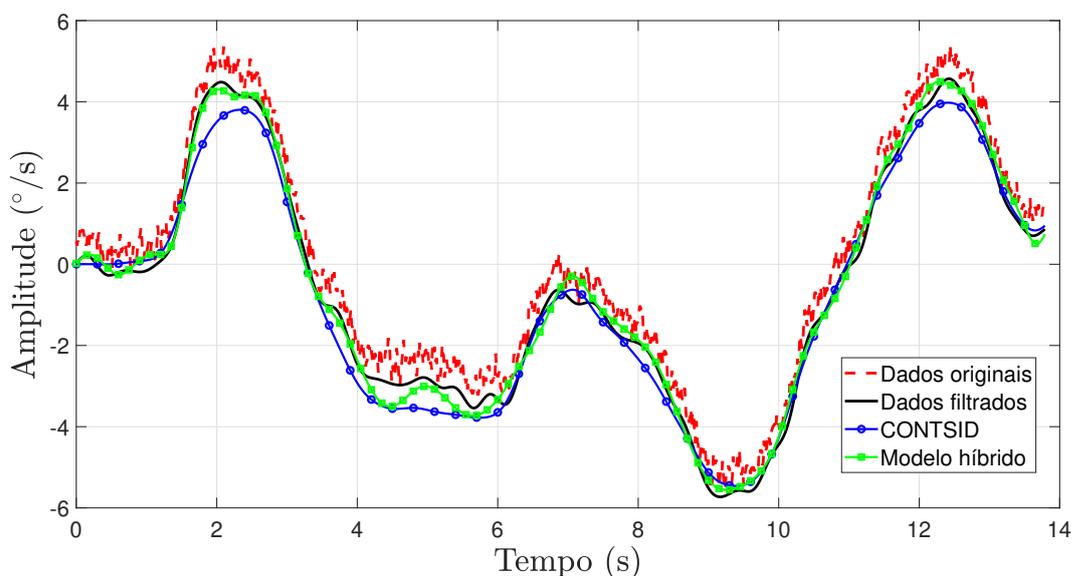


Figura 15: Comparativo entre os dados medidos, as medições filtradas (pós-processadas), a resposta do modelo CONTSID e do modelo híbrido B para 30 km/h (arquitetura 2)

5

Conclusões e trabalhos futuros

Com foco no estudo de caso baseado em dados experimentais de uma viatura militar de três eixos durante uma manobra de mudança dupla de faixa a diversas velocidades, o presente trabalho apresenta, preliminarmente, a obtenção de modelos contínuos lineares para representação da dinâmica lateral do veículo.

A partir dos sinais de entrada e de saída dos ângulos do volante e da taxa de guinada, respectivamente, com o auxílio da ferramenta CONTSID, disponível no MATLAB, o processo para seleção da estrutura e estimação dos parâmetros das funções de transferência é implementado. Os resultados obtidos com a abordagem linear apresentam resultados aderentes aos dados observados e possibilitam a análise da influência da velocidade no comportamento dinâmico do sistema. De acordo com a análise da resposta em frequência da variação da velocidade, verifica-se que o aumento da velocidade implica em maiores ganhos e que os polos tendem a se mover de um sistema subamortecido para superamortecido.

Em seguida, com a utilização das mesmas medições experimentais do veículo, a identificação é realizada com a obtenção de modelos não lineares via Redes Neurais Artificiais. A partir das diversas arquiteturas simuladas, verificou-se a influência de modificações na estrutura (como número de neurônios, número de camadas e função de ativação) na resposta do modelo estimado, bem como a análise comparativa entre os modelos lineares e não lineares obtidos.

Nesse aspecto, ressalta-se que a alteração da função de ativação resultou em melhorias significativas da resposta do modelo, inclusive em comparação aos modelos lineares para algumas arquiteturas, dentro dos parâmetros pré-definidos da estrutura da rede.

Por fim, com o intuito de minimizar o erro do modelo linear, este estudo apresentou uma abordagem para representação do sistema por meio de modelos híbridos, desenvolvidos como uma combinação da resposta dos modelos lineares do CONTSID, somados aos erros correlacionados estimados com o algoritmo apresentado de identificação de sistema com a utilização de Redes Neurais Artificiais (não linear). Dessa forma, verificou-se o aprimoramento da resposta

dos modelos finais estimados para diversas arquiteturas analisadas.

Do exposto, o presente trabalho apresentou três técnicas distintas para identificação, baseada em dados observados, da dinâmica lateral de um veículo de três eixos, obtendo-se resultados satisfatórios.

Logo, os modelos obtidos possibilitam uma predição inicial do comportamento da dinâmica lateral do veículo e configuram uma das etapas para estudos futuros relativos ao projeto e emprego de sistemas de controle, tais como controle de trajetória e de estabilidade.

Com base na metodologia utilizada e nos resultados obtidos, dentre sugestões de trabalhos futuros, pode-se mencionar:

- geração de um banco de modelos para identificação do sistema para as demais velocidades, não abordadas no estudo de caso apresentado;
- identificação do sistema em malha fechada para melhorar os espectros dos sinais de entrada-saída e os modelos estimados, utilizando projeto de experimentos;
- identificação de parâmetros físicos do modelo linear no domínio da frequência;
- identificação adaptativa das propriedades de atrito e dos coeficientes de rigidez dos pneus; e
- projeto de controle preditivo de modelo (MPC, do inglês *model predictive control*) e identificação adaptativa para seguimento de trajetória, relevantes para ambientes complexos.

Referências bibliográficas

ABE, M.. **Vehicle handling dynamics: theory and application.** Butterworth-Heinemann, 2015.

AMER, N. H.; ZAMZURI, H.; HUDHA, K. ; KADIR, Z. A.. **Modelling and control strategies in path tracking control for autonomous ground vehicles: a review of state of the art and challenges.** Journal of intelligent & robotic systems, 86(2):225–254, 2017.

ANDERSON, J. M.; ARBOUR, B.; ARNOLD, R.; KADIOFSKY, T.; KEELEY, T.; MACLEOD, M. R.; BOURDON, S.; CROOTOF, R.; MATSUMURA, J. ; MAYER, C.. **Autonomous systems: Issues for defence policymakers.** Technical report, NATO Allied Command Transformation, 2015.

ARIFIN, B.; SUPRAPTO, B. Y.; PRASETYOWATI, S. A. D. ; NAWAWI, Z.. **The lateral control of autonomous vehicles: A review.** Em: 2019 INTERNATIONAL CONFERENCE ON ELECTRICAL ENGINEERING AND COMPUTER SCIENCE (ICECOS), p. 277–282. IEEE, 2019.

BA, T.; GUAN, X. ; ZHANG, J.. **Vehicle lateral dynamics modelling by subspace identification methods and tyre cornering stiffness estimation.** International Journal of Vehicle Systems Modelling and Testing, 10(4):340–355, 2015.

CAI, Y.; YU, X.; WANG, H.; SUN, X.; CHEN, L. ; TENG, C.. **Hybrid physics and neural network model for lateral vehicle dynamic state prediction.** Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering, 2022.

CHEBLY, A.; TALJ, R. ; CHARARA, A.. **Coupled longitudinal and lateral control for an autonomous vehicle dynamics modeled using a robotics formalism.** IFAC-PapersOnLine, 50(1):12526–12532, 2017.

CHEN, T.; XU, X.; CHEN, L.; JIANG, H.; CAI, Y. ; LI, Y.. **Estimation of longitudinal force, lateral vehicle speed and yaw rate for four-wheel independent driven electric vehicles.** Mechanical Systems and Signal Processing, 101:377–388, 2018.

CHENG, S.; LI, L.; YAN, B.; LIU, C.; WANG, X. ; FANG, J.. **Simultaneous estimation of tire side-slip angle and lateral tire force for vehicle lateral stability control**. *Mechanical Systems and Signal Processing*, 132:168–182, 2019.

CHINDAMO, D.; GADOLA, M.. **Estimation of vehicle side-slip angle using an artificial neural network**. Em: *MATEC WEB OF CONFERENCES*, volumen 166, p. 02001. EDP Sciences, 2018.

COELHO, A. A. R.; DOS SANTOS COELHO, L.. **Identificação de sistemas dinâmicos lineares**. 2016.

FIGEL, K. J.; SCHULTALBERS, M. ; SVARICEK, F.. **Experimental analysis of driveline shuffle with focus on the interaction between traction and torsional vibrations**. *IFAC-PapersOnLine*, 52(5):322–328, 2019.

GARNIER, H.; GILSON, M.. **CONTSID: a Matlab toolbox for standard and advanced identification of black-box continuous-time models**. *IFAC-PapersOnLine*, 51(15):688–693, 2018.

GAMIER, H.; MENSLER, M.. **CONTSID—a continuous-time system identification toolbox for Matlab**. Em: *1999 EUROPEAN CONTROL CONFERENCE (ECC)*, p. 3322–3327. IEEE, 1999.

GARNIER, H.; GILSON, M. ; CERVELLIN, O.. **Latest developments for the Matlab CONTSID toolbox**. *IFAC Proceedings Volumes*, 39(1):714–719, 2006.

GARNIER, H.; GILSON, M. ; LAURAIN, V.. **The CONTSID toolbox for Matlab: extensions and latest developments**. *IFAC Proceedings Volumes*, 42(10):735–740, 2009.

GARNIER, H.. **Teaching data-based continuous-time model identification with the CONTSID toolbox for Matlab**. *IFAC Proceedings Volumes*, 44(1):6373–6378, 2011.

HAYKIN, S.. **Neural networks and learning machines**. Pearson Education India, 2009.

JAMES, S.; ANDERSON, S. R.. **Linear system identification of longitudinal vehicle dynamics versus nonlinear physical modelling**. Em: *UKACC 12TH INTERNATIONAL CONFERENCE ON CONTROL (CONTROL)*, p. 146–151. IEEE, 2018.

JANG, J.-H.; HAN, C.-S.. **The sensitivity analysis of yaw rate for a front wheel steering vehicle: In the frequency domain.** KSME International Journal, 11(1):56–66, 1997.

JAZAR, N.. **Vehicle Dynamics, Theory and Application.** Springer, Riverdale, NY, 2008.

JIANWEI, C.; CHUANQIANG, Y.; ZHIHAO, L.; SHENGJIN, T.; ZHIHAO, Z. ; HONGBIN, S.. **Data modeling of multi-axle special vehicles and lateral dynamics applications.** Acta Armamentarii, 44(1):165, 2023.

JIN, X.; YIN, G. ; CHEN, N.. **Advanced estimation techniques for vehicle system dynamic state: A survey.** Sensors, 19(19):4289, 2019.

KIEFER, J.. **Modeling of road vehicle lateral dynamics.** Dissertação de mestrado, Rochester Institute of Technology, 1996.

LJUNG, L.. **Perspectives on system identification.** Annual Reviews in Control, 34(1):1–12, 2010.

NORTH ATLANTIC TREATY ORGANIZATION (NATO). **NATO Dynamic Stability, Allied Vehicle Testing Publications (AVTP) 03-160 W,** 1991.

KUMPATI, S. N.; KANNAN, P. ; OTHERS. **Identification and control of dynamical systems using neural networks.** IEEE Transactions on neural networks, 1(1):4–27, 1990.

NAYAK, S.; MISRA, B. B. ; BEHERA, H. S.. **Impact of data normalization on stock index forecasting.** International Journal of Computer Information Systems and Industrial Management Applications, 6(2014):257–269, 2014.

NIRMAL, K.; SREEJITH, A.; MATHEW, J.; SARPOTDAR, M.; SURESH, A.; PRAKASH, A.; SAFONOVA, M. ; MURTHY, J.. **Noise modeling and analysis of an IMU-based attitude sensor: improvement of performance by filtering and sensor fusion.** Em: ADVANCES IN OPTICAL AND MECHANICAL TECHNOLOGIES FOR TELESCOPES AND INSTRUMENTATION II, volumen 9912, p. 99126W. International Society for Optics and Photonics, 2016.

PASCU, V.; GARNIER, H.; LJUNG, L. ; JANOT, A.. **Benchmark problems for continuous-time model identification: design aspects, results and perspectives.** Automatica, 107:511–517, 2019.

LEÃO PEREIRA, C.. **Implementação computacional e análise do emprego de um sistema de controle de assistência ao motorista em um modelo de veículo 6x6**. Dissertação de mestrado, Instituto Militar de Engenharia, 2020.

PEREIRA, C. L.; DE SOUSA, D. H. ; AYALA, H. V.. **Three-axle vehicle lateral dynamics identification using double lane change maneuvers data**. Em: 2021 29TH MEDITERRANEAN CONFERENCE ON CONTROL AND AUTOMATION (MED), p. 910–915. IEEE, 2021.

QUINTANA, E.. **The ethics and legal implications of military unmanned vehicles**. RUSI, Occasional Paper, 2008.

REINA, G.; PAIANO, M. ; BLANCO-CLARACO, J.-L.. **Vehicle parameter estimation using a model-based estimator**. *Mechanical Systems and Signal Processing*, 87:227–241, 2017.

REINA, G.; MESSINA, A.. **Vehicle dynamics estimation via augmented Extended Kalman Filtering**. *Measurement*, 133:383–395, 2019.

SANCHEZ, E. C. M.. **Controle por aprendizado acelerado e neuro-fuzzy de sistemas servo-hidráulicos de alta frequência**. Rio de Janeiro: PUC-Rio, 2009.

SCHAIBLE, B.; XIE, H. ; LEE, Y.-C.. **Fuzzy logic models for ranking process effects**. *IEEE Transactions on Fuzzy Systems*, 5(4):545–556, 1997.

SHARMA, S.; SHARMA, S. ; ATHAIYA, A.. **Activation functions in neural networks**. *Towards Data Sci*, 6(12):310–316, 2017.

SIEBERG, P. M.. **Hybrid Methods in Vehicle Dynamics State Estimation and Control—Exploiting Potentials and Ensuring Reliability of Artificial Intelligence**. Tese de PhD, Universität Duisburg-Essen, 2021, 2021.

SOLA, J.; SEVILLA, J.. **Importance of input data normalization for the application of neural networks to complex industrial problems**. *IEEE Transactions on nuclear science*, 44(3):1464–1468, 1997.

SUNG, I.; CHOI, B. ; NIELSEN, P.. **On the training of a neural network for online path planning with offline path planning algorithms**. *International Journal of Information Management*, 57:102142, 2021.

TANGIRALA, A. K.. **Principles of system identification: theory and practice**. CRC Press, 2018.

THEODORIDIS, S.; KOUTROUMBAS, K.. **Pattern recognition**. Elsevier, 2009.

YUEN, T. J.; FOONG, S. M. ; RAMLI, R.. **Optimized suspension kinematic profiles for handling performance using 10-degree-of-freedom vehicle model**. Proceedings of the Institution of Mechanical Engineers, Part K: Journal of Multi-body Dynamics, 228(1):82–99, 2014.