

ESCOLA POLITÉCNICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA
MESTRADO EM ENGENHARIA ELÉTRICA

RAFAEL DE VASCONCELOS

IDENTIFICAÇÃO DE REDES DINÂMICAS: APLICADA A PELOTÃO DE VEÍCULOS
AUTÔNOMOS

Porto Alegre

2020

PÓS-GRADUAÇÃO - *STRICTO SENSU*



Pontifícia Universidade Católica
do Rio Grande do Sul

Rafael de Vasconcelos

Identificação de Redes Dinâmicas: Aplicada a Pelotão de Veículos Autônomos

Porto Alegre - RS, Brasil

2020

Rafael de Vasconcelos

Identificação de Redes Dinâmicas: Aplicada a Pelotão de Veículos Autônomos

Dissertação de Mestrado apresentada para Programa de Pós Graduação em Engenharia Elétrica da Pontifícia Universidade Católica do Rio Grande do Sul, como requisito para obter o título de Mestre em Engenharia Elétrica.

Área de Pesquisa: Sinais, Sistemas e Tecnologia da Informação.

Linha de Pesquisa: Automação e Sistema.

Pontifícia Universidade Católica do Rio Grande do Sul – PUCRS

Escola Politécnica

Programa de Pós-Graduação em Engenharia Elétrica - PPGEE

Orientador: Prof. Dr. Guilherme Araujo Pimentel

Porto Alegre - RS, Brasil

2020

Ficha Catalográfica

V33 li Vasconcelos, Rafael de

Identificação de Redes Dinâmicas : Aplicada a Pelotão de Veículos Autônomos / Rafael de Vasconcelos. – 2020.

73 f.

Dissertação (Mestrado) – Programa de Pós-Graduação em Engenharia Elétrica, PUCRS.

Orientador: Prof. Dr. Guilherme Araujo Pimentel.

1. formação de pelotões. 2. veículos autônomos. 3. identificação de parâmetros. 4. redes dinâmicas. 5. variáveis instrumentais. I. Pimentel, Guilherme Araujo. II. Título.

Elaborada pelo Sistema de Geração Automática de Ficha Catalográfica da PUCRS
com os dados fornecidos pelo(a) autor(a).

Bibliotecária responsável: Clarissa Jesinska Selbach CRB-10/2051

Agradecimentos

Gostaria de agradecer a todos que participaram deste processo juntamente comigo. Aos professor Guilherme Pimentel, Aurélio T. Salton e Alexandre Bazanella pelo auxílio essencial que ofereceram ao longo da pesquisa realizada e no caminho em busca do conhecimento. Aos meus familiares que formam a base da pessoa que sou e, em especial, minha esposa Joice e meu filho Eduardo. Um agradecimento especial ao professor Guilherme Pimentel que não mediu esforços para auxiliar no processo de aprendizado, sempre muito atencioso no processo de orientação deste trabalho, demonstrando ser muito humano compreendendo situações pessoais e eventos anormais como a pandemia que atravessamos ao longo desta pesquisa. Agradeço também a Deus. Agradeço a CAPES e a HP pelo apoio financeiro.

“Quanto mais aumenta nosso conhecimento, mais evidente fica nossa ignorância.”
(John F. Kennedy)

Resumo

Redes dinâmicas estão presentes em problemas de engenharia, biologia, economia, e modelam as interconexões dinâmicas que ocorrem dentro dos sistemas. A identificação do modelo da rede é uma ferramenta para aprimorar o controle e manuseio de sistemas complexos. Neste trabalho, será aplicado o conceito de identificação de redes dinâmicas em um pelotão de veículos autônomos. O objetivo da formação de um pelotão com os veículos é de minimizar o arrasto aerodinâmico e, assim, gerar economia de combustível e diminuição da emissão de poluentes. Para alcançar resultados significativos de economia, é necessário manter pequenos espaços entre os veículos e, para manter o menor espaçamento com segurança, o uso de veículos autônomos é aplicado. Nesta dissertação, duas topologias de rede serão apresentadas para descrever o pelotão de veículos, e o resultado da identificação por modelagem numérica das funções de transferência será apresentado para cada uma das topologias. A modelagem dos veículos é feita de forma que o coeficiente de arrasto aerodinâmico dos veículos também seja identificada. A topologia de rede influencia na variância dos parâmetros identificados, sendo a rede com maior profundidade a com melhor resultado.

Palavras-chaves: formação de pelotões, veículos autônomos, identificação de parâmetros, redes dinâmicas, variáveis instrumentais, coeficiente de arrasto aerodinâmico.

Abstract

Dynamic networks are present in systems from different areas, such as engineering, biology, economics, and model the dynamic connections that occur within the systems. The network model identification is a tool to improve the control and handling of complex systems. In this work, the concept of network identification will be applied in a platoon of autonomous vehicles. The objective of forming a platoon with vehicles is to minimize aerodynamic drag and thus generate fuel savings and decrease pollutant emissions. To achieve significant savings results it is necessary to maintain small spaces between vehicles, and to maintain the smallest spacing safely the use of autonomous vehicles is applied. In this work, two network topologies are presented to describe the vehicle platoon, and the result of the identification by numerical modeling of the transfer functions is presented for each of the topologies. The modeling of vehicles is done in such a way that the aerodynamic drag coefficient of the vehicles is also identified. We conclude that the network topology influences the variance of the identified signals, and the network with greater depth presents better results.

Key-words: platoon formation, autonomous vehicles parameter identification, Dynamic networks, instrumental variables, aerodynamic height coefficient .

Lista de ilustrações

| | |
|---|----|
| Figura 1 – Sistema Mecânico Massa Mola. | 18 |
| Figura 2 – Exemplo de dois sistemas (G_{21} e G_{12}) em rede, que formam uma rede dinâmica. W1 e W2 são sinais também considerados nós da rede, r1 é o sinal de excitação aplicado ao sinal W1 e v2 é ruído do sinal W2. . . | 20 |
| Figura 3 – Demonstração gráfica dos métodos de discretização. | 29 |
| Figura 4 – Representação gráfica de um sistema SISO. | 29 |
| Figura 5 – Representação gráfica de um sistema MIMO. | 30 |
| Figura 6 – Representação gráfica de um sistema MISO. | 30 |
| Figura 7 – Representação gráfica de um sistema SIMO. | 31 |
| Figura 8 – Sistema Linear. | 31 |
| Figura 9 – Representação gráfica de uma rede. | 38 |
| Figura 10 – Representação simples dos veículos de carga, HDV. | 47 |
| Figura 11 – Arquitetura de um sistema de pelotão para N veículos em pelotão. . . | 49 |
| Figura 12 – Diagrama de bloco da dinâmica da rede baseada no veículo. | 51 |
| Figura 13 – Diagrama de Blocos da rede dinâmica baseada nos sensores, representada pela equação (4.21). | 52 |
| Figura 14 – Dados da simulação para identificar a função de transferência dos veículos. | 54 |
| Figura 15 – Diagrama Bode da diferença entre a função de transferência identificada e verdadeira. Veículo nº2 identificação da rede "baseada em veículo" $G_2^v(q^{-1}, \hat{\theta}_2^v)/G_2^v(q^{-1})$ | 56 |
| Figura 16 – Diagrama Bode da diferença entre a função de transferência identificada e verdadeira. Veículo nº3 identificação da rede "baseada em veículo" $G_3^v(q^{-1}, \hat{\theta}_3^v)/G_3^v(q^{-1})$ | 57 |
| Figura 17 – Diagrama Bode da diferença entre a função de transferência identificada e verdadeira. Veículo nº2 identificação da rede "baseada em sensor" $G_{31}^s(q^{-1}, \hat{\theta}_{31}^v)/G_{31}^s(q^{-1})$ | 57 |
| Figura 18 – Diagrama Bode da diferença entre a função de transferência identificada e verdadeira. Veículo nº2 identificação da rede "baseada em sensor" $G_{32}^s(q^{-1}, \hat{\theta}_{32}^v)/G_{32}^s(q^{-1})$ | 58 |
| Figura 19 – Diagrama Bode da diferença entre a função de transferência identificada e verdadeira. Veículo nº3 identificação da rede "baseada em sensor" $G_{53}^s(q^{-1}, \hat{\theta}_{53}^v)/G_{53}^s(q^{-1})$ | 58 |
| Figura 20 – Diagrama Bode da diferença entre a função de transferência identificada e verdadeira. Veículo nº3 identificação da rede "baseada em sensor" $G_{54}^s(q^{-1}, \hat{\theta}_{54}^v)/G_{54}^s(q^{-1})$ | 59 |
| Figura 21 – Trecho de pista, vista superior. | 66 |

| | |
|---|----|
| Figura 22 – Pista, corte transversal. | 67 |
| Figura 23 – Materiais empregados na fabricação da pista. | 67 |
| Figura 24 – Pista construída para testes. | 68 |
| Figura 25 – Veículo do protótipo utilizado nos testes. | 68 |
| Figura 26 – Placa, esquemático. | 69 |
| Figura 27 – Placa, vista superior. | 70 |
| Figura 28 – Placa, vista inferior. | 70 |
| Figura 29 – Procedimento de teste 1, realizado em cada veículo em malha aberta. | 72 |
| Figura 30 – Velocidade lida em cada um dos veículos nas 3 interações realizadas, ao se aplicar o procedimento de teste. A primeira linha apresenta os dados do veículo 1, a segunda linha do veículo 2 e na terceira linha os dados do veículo 3. | 73 |
| Figura 31 – Gráfico com resultados simulados a partir da função de transferência identificada. | 74 |

Lista de tabelas

| | |
|---|----|
| Tabela 1 – Dados para simulação numérica veículo 1. | 54 |
| Tabela 2 – Dados para simulação numérica veículo 2. | 54 |
| Tabela 3 – Dados para simulação numérica veículo 3. | 55 |
| Tabela 4 – Resultados da identificação do coeficiente de resistência do Ar $n = 1000$ | 56 |
| Tabela 5 – Materiais empregados na fabricação da pista. | 67 |

Lista de abreviaturas e siglas

| | |
|-------|---|
| MIMO | Multiple Input Multiple Output |
| MISO | Multiple Input Single Output |
| SISO | Single Input Single Output |
| SIMO | Single Input Single Output |
| CC | Cruise Control |
| ACC | Advanced Cruise Control |
| ARX | Auto Regressive with Exogeneous Inputs |
| ARMAX | Auto Regressive Moving Average with Exogeneous Inputs |
| PI | Ação Proporcional Integral |
| HDV | Heavy Duty Vehicle |
| FT | Função de Transferência |
| LS | Função de Transferência |
| MQ | Mínimos Quadrados |
| VI | Variáveis Instrumentais |

Lista de símbolos

| | |
|----------------|---------------------------------|
| A^T | Transposta da matriz A |
| A^{-1} | Inversa da matriz A |
| $\dot{x}(t)$ | derivada de $x(t)$ |
| $\ddot{x}(t)$ | derivada segunda de $x(t)$ |
| ξ | erro de estimação |
| \mathcal{L} | transformada de Laplace |
| ψ | vetor de variáveis regressores |
| $E(\cdot)$ | esperança |
| $cor(x, y)$ | correlação entre x e y |
| θ | parâmetros do sistema |
| $\hat{\theta}$ | parâmetros estimados do sistema |

Sumário

| | | |
|----------|---|-----------|
| 1 | INTRODUÇÃO | 15 |
| 1.1 | Modelagem de Sistemas e Tipos de Modelagem | 16 |
| 1.2 | Estado da Arte | 19 |
| 1.3 | Análise do Problema | 22 |
| 1.4 | Objetivo | 23 |
| 1.4.1 | Objetivos Específicos | 23 |
| 2 | FUNDAMENTAÇÃO TEÓRICA | 25 |
| 2.1 | Causalidade | 25 |
| 2.2 | Invariância no Tempo | 25 |
| 2.3 | Linearidade | 26 |
| 2.4 | Sistemas de Tempo Contínuo e de Tempo Discreto | 27 |
| 2.5 | Modelos Monovariáveis e Multivariáveis | 29 |
| 2.6 | Representação do Modelo na Forma de Função de Transferência | 31 |
| 2.7 | Representação do Modelo na Forma de Espaço de Estados | 32 |
| 2.8 | Modelos ARX e ARMAX | 34 |
| 2.9 | Redes Dinâmicas | 35 |
| 3 | IDENTIFICAÇÃO DE SISTEMAS | 40 |
| 3.1 | Métodos de Identificação de Sistemas | 40 |
| 3.1.1 | Mínimos Quadrados | 40 |
| 3.1.2 | Variáveis Instrumentais | 44 |
| 4 | IDENTIFICAÇÃO DE PARÂMETROS DO SISTEMA EM REDE DINÂMICA - APLICADO A PELOTÃO DE VEÍCULOS | 45 |
| 4.1 | Modelagem Matemática da Dinâmica de um Veículo HDV | 46 |
| 4.2 | Modelo do Controle dos Veículos HDV's em Pelotão | 48 |
| 4.3 | Modelo de Representação de Redes Dinâmicas do Pelotão | 49 |
| 4.3.1 | Representação em Redes Dinâmicas Baseada no Veículo | 50 |
| 4.3.2 | Representação em Redes Dinâmicas Baseada nos Sensores | 51 |
| 4.4 | Implementação e Simulação Numérica | 53 |
| 4.4.1 | Simulação Numérica - Rede Baseada no Veículo | 55 |
| 4.4.2 | Simulação Numérica - Rede Baseada nos Sensores | 55 |
| 5 | CONCLUSÃO | 60 |
| 5.1 | Trabalhos Futuros | 60 |

| | | |
|------------|---|-----------|
| | REFERÊNCIAS | 62 |
| A | IMPLEMENTAÇÃO PROTÓTIPO | 66 |
| A.1 | Protótipo | 66 |
| A.1.1 | Pista | 66 |
| A.1.2 | Veículos | 68 |
| A.2 | Implementação e Identificação usando o Protótipo | 70 |
| A.2.1 | Controle Proporcional Integral - PI | 71 |
| A.2.2 | Implementação da Identificação em Protótipo | 72 |
| A.2.2.1 | Validação do modelo dos veículos | 73 |

1 Introdução

Com os avanços da área da engenharia, os sistemas tem se tornado cada vez mais complexos e interconectados, caracterizando um sistema que possui características de redes dinâmicas (Dankers et al., 2016). Contudo, as abordagens mais utilizadas para identificação dos parâmetros e modelos matemáticos dos sistemas são abordagens clássicas em malha aberta ou em malha fechada (Van den Hof; DANKERS; WEERTS, 2018).

Normalmente, esses dispositivos/sistemas possuem estruturas de controle em malha fechada para fazer com que o sistema siga uma referência. Dentro de um sistema complexo de controle, existem vários pequenos sistemas que controlam partes específicas do sistema. Esta topologia forma um sistema de controle distribuído, que tem por objetivo ser mais eficiente, aumentar a confiabilidade do controle e a qualidade do processo. Como exemplo de sistemas em rede, pode-se citar, os sistemas de telecomunicação, rede de distribuição de energia (THORP; PHADKE, 1991) e sistemas de controle distribuído (TANG; DAOUIDIS, 2019).

Dankers et al. (2016) argumenta que a complexidade dos sistemas aumenta conforme o aumento de seu tamanho, afirmando que esses sistemas não podem ser operados, projetados e mantidos sem a ajuda de modelos. Sendo assim, faz-se necessário métodos para identificação de sistemas dinâmicos complexos, ou também chamados de sistemas em redes dinâmicas. Em Ljung (1999) é apresentado o que realmente devemos esperar dos métodos de identificação.

“um sistema no mundo real é um objeto de um tipo diferente dos nossos modelos matemáticos. Em certo sentido, há uma tela impenetrável entre nosso mundo de descrições matemáticas e o mundo real. Nós podemos olhar através desta janela e comparar certos aspectos dos sistemas físicos com sua descrição matemática, mas nunca podemos estabelecer nenhuma conexão exata entre eles. A questão da identificação do sistema de usabilidade da natureza para a descrição matemática tem alguns aspectos filosóficos profundos e, em termos práticos, temos que ter uma visão mais pragmática dos modelos "(LJUNG, 1999)

Aguirre (2007) ainda analisa que, ao se obter um sistema a partir de identificação, ele pode ser feito com menor conhecimento do processo, e, mesmo assim, pode representar o sistema de forma satisfatória para os objetivos desejados. Segundo o mesmo autor,

"geralmente, um modelo fenomenológico bem implementado representa de forma mais detalhada um determinado sistema, porém, requer maior esforço e conhecimento do processo. Por outro lado, a modelagem por identificação é mais simples e rápida, sendo em muitas situações, os modelos por ela obtidos, fidedignos o suficiente para o estudo que se deseja realizar "(AGUIRRE, 2007).

Com os avanços nas áreas de instrumentação e de tecnologia, existe cada vez mais a possibilidade de se incluir inúmeros tipos de sensores em um sistema em rede podendo-se coletar informações dos mais diversos tipos, como temperatura, pressão, peso, velocidade, distância, umidade. Para auxiliarem na construção do modelo da rede e no entendimento da dinâmica desse modelo, essas informações são chamadas de variáveis de entrada. O modelo matemático descreve a forma como as variáveis de entrada interagem com as variáveis internas do sistema, gerando as variáveis de saída, que são os atuadores, pistões motores, solenoides, telas, entre outros.

Especificamente, nesse trabalho trabalhar-se-á com pelotões de veículos, que são grupos de carros, ônibus, caminhões ou qualquer veículo que possa se juntar a outros e formar um conjunto. A ideia principal desse sistema é formar com esses veículos filas ordenadas com pequenos espaços entre si, propiciando, assim, uma menor resistência do ar ao deslocamento dos veículos do pelotão, gerando economia de combustível, aumento do tráfego nas autoestradas, diminuição dos gases nocivos ao efeito estufa e diminuição do custo do transporte, conforme Liang (2016). Quando os veículos estão em pelotão, a interação que ocorre entre eles pode ser estudada como uma rede dinâmica.

Ao longo deste trabalho serão apresentados conceitos a respeito dos sistemas, da identificação de sistemas e de sistemas em redes. Será realizada a comparação entre duas propostas de modelagem de um mesmo sistema em rede dinâmica, e os resultados serão analisados. O estudo de identificação será aplicado a uma rede de pelotões de veículos, não foi localizado trabalhos de identificação de sistemas em rede aplicados a rede de pelotão de veículos. Esse capítulo faz uma introdução ao tema de modelagem matemática de um sistema. Na Seção 1.1, explica-se diferentes tipos de modelagem matemática, seguido de uma apresentação do estado da arte deste assunto na Seção 1.2. O problema a ser estudado é exposto nas Seção 1.3. Por fim, o capítulo com os objetivos da dissertação apresentados na Seção 1.4.

1.1 Modelagem de Sistemas e Tipos de Modelagem

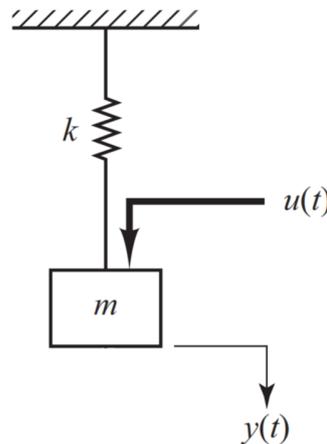
Um modelo matemático de um sistema real é um sistema análogo matemático que representa algumas das características observadas no sistema real (AGUIRRE, 2007).

Aguirre (2007) apresenta um exemplo sobre a construção de um modelo mental que é feito de forma quase inconsciente. Ao seguir o pensamento que ele apresentou, pode-se expor dois exemplos: (i) ao digitar no teclado de um computador pessoal, cria-se o modelo do teclado que se usa mentalmente e a digitação se torna mais rápida e automática. Se o teclado for substituído por um modelo diferente, é provável que pequenos erros de digitação sejam cometidos até que o modelo mental seja adaptado para o novo tipo de teclado; (ii) outro bom exemplo é o modelo que se constrói para dirigir frequentemente o mesmo carro. Ao trocar de carro, é preciso atualizar pequenos parâmetros no modelo mental, como a altura do pedal da embreagem, pressão de acionamento dos pedais, curso do volante e as dimensões do carro.

A modelagem de um sistema procura descrever matematicamente a relação entre as variáveis de entrada e de saída do sistema estudado. Um modelo matemático não descreve necessariamente todas as características do sistema observado, mas procura os aspectos que se deseja observar. Então, deve estar muito claro quais são os objetivos que se quer atingir com o modelo, quais parâmetros ou comportamentos é preciso que ele represente de forma fidedigna para chegar no objetivo esperado.

A identificação do modelo matemático dos sistemas reais pode ser feita a partir do conhecimento profundo de seu funcionamento e de todas as leis da física que o descrevem. A interação que há entre as leis físicas que agem sobre o sistema gera um modelo matemático que descreve seu funcionamento. Essa técnica se chama modelagem caixa branca, ou natureza física do processo. Nem sempre é viável fazer este tipo de modelagem, devido à complexidade dos sistemas. Em muitos casos reais, não se tem conhecimento de todas as dinâmicas envolvidas no processo, como exemplo o ruído na leitura dos sinais, o atrito mecânico, a frequência de amostragem, as perdas térmicas, a interferência eletromagnética, entre outras. Como exemplo de modelagem caixa branca, é possível citar um sistema mecânico massa-mola, apresentado na Figura 1.

Figura 1 – Sistema Mecânico Massa Mola.



Fonte: Adaptado de Ogata (2014).

Esse sistema pode ser modelado através da descrição das leis físicas que atuam na massa através da segunda Lei de Newton. A dinâmica desse sistema pode ser descrita com a soma das forças presentes no sistema. A equação (1.2) descreve a força que a massa exerce, e a equação (1.1), descreve a força que a mola exerce. A interação desses dois comportamentos físicos determina o modelo do sistema massa mola (1.3). Uma força externa $u(t)$ é a entrada do sistema e o deslocamento $y(t)$ é a saída.

A equação física que descreve a dinâmica da mola é dada pela equação a seguir, onde K é uma característica construtiva da mola, chamado de coeficiente elástico.

$$f(t) = Ky(t). \quad (1.1)$$

A equação física que descreve a dinâmica da massa, onde m é o valor da massa e a a aceleração que atua nela.

$$f(t) = ma(t) \longrightarrow f(t) = m\ddot{y}(t). \quad (1.2)$$

A equação do modelo matemático do sistema massa mola pode então ser descrito como:

$$u(t) = m\ddot{y}(t) + ky(t). \quad (1.3)$$

No sistema apresentado, a modelagem matemática foi possível devido ao conhecimento das leis físicas envolvidas. Note-se que o conhecimento da constante elástica k e a massa m é necessário para que o modelo gerado esteja correto. A constante elástica é de fácil estimação, mas, se o sistema proposto possuir características construtivas desconhecidas, elas devem ser identificadas para gerar o modelo. Em sistemas complexos, essa técnica se torna inviável, e outras técnicas de identificação são mais adequadas.

Outras técnicas para identificação dos modelos dos sistemas exigem pouco ou nenhum conhecimento prévio da física nele envolvida, e ajudam na modelagem de sistemas complexos ou com características físicas desconhecidas. Esses métodos se baseiam em causa e efeito entre as variáveis de entrada e as variáveis de saída, são chamados de modelos caixa preta. Esses modelos se baseiam unicamente na análise dos dados de entrada do sistema e seus efeitos nas variáveis de saída, determinando um modelo matemático que descreva a relação entre os dados observados.

Existe ainda modelagem do tipo caixa cinza, que é uma mistura dos dois métodos. Parte do conhecimento prévio da modelagem física do sistema e seu comportamento, para determinar o tipo de equação ou dinâmica que ele representa, similar ao modelo caixa branca. Mas parte do modelo, como exemplo, os parâmetros das equações dinâmicas, são estipulados através da análise das variáveis de entrada e saída assim como no modelo caixa preta. Dai obtêm-se o nome caixa cinza.

1.2 Estado da Arte

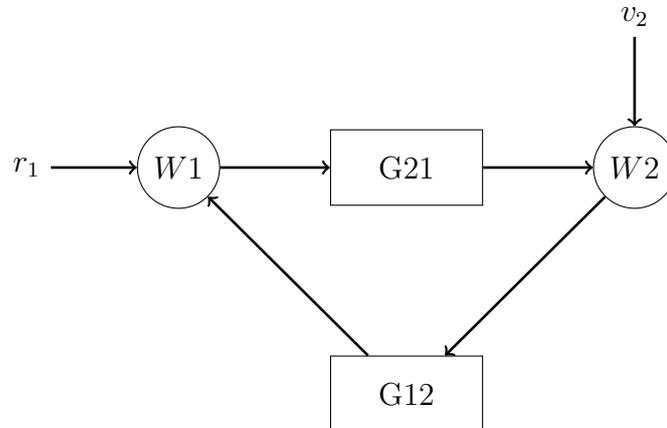
A literatura a respeito da identificação de sistemas em rede está dividida em duas categorias, com base no conhecimento da estrutura de interconexão da rede: se ela é conhecida ou não (Dankers et al., 2016).

Quando a estrutura de interconexão da rede é considerada desconhecida, o seu estudo é referido como detecção de topologia e visa identificar a estrutura da rede estudada. Uma breve apresentação de métodos de identificação das topologias e alguns trabalhos na área serão apresentados nesta seção.

Segundo Dankers et al. (2016), os métodos de identificação de topologia de rede primeiramente se basearam no método de *Granger* e *Causalidade de Granger* (Vidyasagar, 1980; GRANGER, 1969), e sua aplicação pode ser vista em Wu, Wang e Zheng (2012). Outros métodos são propostos, como o filtro de Wiener, que foi utilizado em Materassi e Salapaka (2012) para reconstruir a topologia da rede. O método de identificação da topologia de uma rede de larga escala é apresentado em Sanandaji, Vincent e Wakin (2011) onde um algoritmo de regressão linear é proposto para identificação. Já Chiuso e Pillonetto (2012) desenvolveram um ponto de vista baseado em técnicas de aproximação Bayesianas para a identificação.

Caso a estrutura da rede seja conhecida, o que se propõe é identificar a dinâmica da rede ou de um módulo específico da rede. Nesta dissertação será abordado a identificação dos módulos da rede, existem diferentes técnicas que são abordadas no intuito de identificar a função de transferência ou o comportamento dinâmico dos módulos da rede, os quais serão apresentados na continuação desta seção. O alvo do estudo desta dissertação é a identificação dos módulos da rede; então, essas técnicas serão discutidas com mais

Figura 2 – Exemplo de dois sistemas (G_{21} e G_{12}) em rede, que formam uma rede dinâmica. W1 e W2 são sinais também considerados nós da rede, r_1 é o sinal de excitação aplicado ao sinal W1 e v_2 é ruído do sinal W2.



Fonte: O autor, 2020.

detalhes aqui para futuras referências.

O estudo de identificação de redes dinâmicas é geralmente um problema de identificação de sistemas em malha fechada. Esse comportamento é observado dentro de um sistema em rede. Os sinais de saída de um nó, muitas vezes, geram estímulos nos demais nós e, conseqüentemente, na entrada do próprio nó estudado. Dá-se a essa característica o nome de laço (*loop*), e são comumente encontrados nas redes dinâmicas, como vemos na figura 2.

A diferença fundamental entre os métodos de identificação de malha aberta e malha fechada é a presença de correlação do ruído do sistema com a entrada do sistema. Num sistema em malha aberta, essa correlação não existe, mas num sistema de malha fechada há um caminho de realimentação do sinal de saída na entrada (WEERTS; Van den Hof; DANKERS, 2017).

Nos últimos anos, muitos métodos foram desenvolvidos para contornar este problema. Van den Hof, Dankers e Weerts (2018) cita que tais técnicas podem ser descritas como métodos para descorrelacionar o sinal de entrada com o ruído do sistema. O que muitos métodos fazem é estender a estrutura de identificação em malha fechada para o conceito de identificação em rede.

Na sequência, serão apresentados os principais métodos para identificação de um módulo da rede e uma pequena explicação de cada um é apresentada, a compilação do estado atual da pesquisa foi construída com base no estudo apresentado em Hof e Ramaswamy (2020) e em DANKERS (2014).

O *método direto* de identificação (LJUNG, 1999; Van Den Hof DOUWE K. DE VRIES, 1992), utiliza um conjunto de dados de entrada e um conjunto de dados de saída do sis-

tema, estimando os parâmetros da matriz de transferência $\bar{G}(q, \theta)$ com o menor valor de variância possível.

Esse método utiliza os sinais de excitação externa e o sinal de ruído para criar um conjunto de dados suficientemente informativos para o sistema ser identificado, além de produzir estimativas consistentes. Em contra partida, caso haja erro dos sensores, nos sinais de entrada, esse método apresenta viés de estimação. Em Van den Hof et al. (2013), o método é apresentado para determinar tanto módulos da rede SISO, quanto MIMO. O método indireto pode, mas não necessita utilizar todas as variáveis de entrada para identificar um módulo. Pode-se escolher um conjunto de variáveis que atenda a especificação, de que, ao retirar as demais variáveis, o módulo alvo permaneça invariante. Essa técnica tem o nome de imersão. Uma abordagem para identificar este critério é citada em Dankers et al. (2016), que propõem a observação das conexões em paralelos e de loop do módulo a ser identificado. Variáveis de confusão podem aparecer no processo de remoção das variáveis não observadas, determinadas por Hof e Ramaswamy (2020) como variáveis não mensuradas, elas aparecem na entrada e na saída do sistema. Esse problema pode ser contornado adicionando variáveis na entrada, conforme propõe Dankers et al. (2017). Variáveis de confusão podem surgir no processo de imersão, são chamadas de variáveis de confusão indiretas. Quando houver a correlação de ruídos de processo e estrutura de correlação de perturbação surgirão variáveis de confusão, denominadas de variáveis de confusão diretas. Em Ramaswamy e Hof (2019), a solução para as variáveis de confusão é abordada. Weerts et al. (2019) apresentou uma técnica alternativa à imersão que flexibiliza a escolha dos sinais.

O *método indireto* consiste em selecionar um conjunto dos dados de entrada e um conjunto dos dados de saída para a estimação dos nós internos do sistema, através de um matriz $T := (I - G)^{-1}$ que mapeia os sinais externos com os nós internos de interesse. Um passo posterior é necessário para identificar a dinâmica de um módulo específico da rede a partir da matriz estimada \hat{T} . Existem variações do método indireto como método de dois estágios (Van Den Hof; SCHRAMA, 1993; Van den Hof et al., 2013) e método de projeção (Forssell; Ljung, 2000) e de variáveis instrumentais (SÖDERSTRÖM; STOICA, 2002; SÖDERSTRÖM; STOICA, 1983; Van Den Hof; SCHRAMA, 1993). O método indireto conta apenas com os sinais de excitação externos para gerar dados em um conjunto, diferente do método direto que possui o sinal de ruído. Então, esse sinal deve ser suficientemente informativo para o sistema ser identificado, mas esse método, diferentemente do método direto, apresenta estimativas consistentes, mesmo quando houver erro dos sensores nos sinais de entrada, que ocorre devido à realimentação da malha fechada. Com base em $\hat{T}(q)$, uma estimativa consistente de G pode ser obtida resolvendo-se $(I - \hat{G})\hat{T}(q) = R$. Identificando apenas uma submatriz de T e resolvendo apenas um subconjunto da equação, um módulo de destino incorporado na dinâmica rede pode ser identificado (GEVERS; BAZANELLA; da Silva, 2018; Hendrickx; Gevers; Bazanella, 2019). Bazanella, Gevers e

Hendrickx (2019) analisa quais nós devem ser medidos se todos estiverem disponíveis na rede, para se ter uma estimativa consistente.

DANKERS (2014) explica o *método de dois estágios* como uma projeção das variáveis externas de excitação e, em seguida, a função de transferência entre os sinais projetados é identificada. Estes métodos descorrelacionam o sinal de entrada do ruído do processo no primeiro estágio e depois estima o sistema com as variáveis descorrelacionadas no segundo estágio.

Abordagens não paramétricas, em que as relações entre densidades espectrais particularmente estimadas dos sinais internos, são usadas como base para a estimativa do módulo. Uma abordagem semi-paramétrica foi introduzida em Galrinho, Everitt e Hjalmarsson (2017). Método de subespaço, desenvolvido por Yu e Verhaegen (2018), que consegue lidar com sinais de interação não medidos entre os módulos. A generalização do método direto e indireto, apresentado por Ramaswamy, J. Van den Hof e Dankers (2019) permite maior flexibilização na seleção do sinal dos nós a serem identificados.

1.3 Análise do Problema

Na medida em que a economia mundial cresce, o tráfego de cargas aumenta, especialmente nas rodovias, instigando, assim, o interesse por estudar pelotões de veículos autônomos (LIANG; MARTENSSON; JOHANSSON, 2016a). O transporte rodoviário de carga é responsável por 49.0% na União Europeia (2018) (COMMISSION, 2108), 45.9 % nos Estados Unidos (2014) (WILMSMEIER; SPENGLER, 2015) e 61.1 % no Brasil (2019) (CNT, 2019), dentre todos os transportes realizados.

Para alcançar economia, de até 20 %, do consumo de combustível, conforme exposto por Liang, Martensson e Johansson (2016b) e também estudado em Michaelian e Browand (2000), é necessário que os veículos mantenham um pequeno espaçamento entre eles, o que gera um menor arrasto aerodinâmico, mas aumenta o risco de acidentes. Uma solução para essas questões é a formação de pelotões de veículos autônomos, que podem manter uma distância predefinida do veículo da frente com segurança.

Em Michaelian e Browand (2000) foram realizados testes de consumo em uma rodovia com pelotões de carros formados por 2,3 e 4 veículos, com distâncias entre 3 e 6m. Os resultados obtidos variam conforme a posição do veículo no pelotão e o número de veículos do pelotão. Entretanto, mesmo com veículos de passeio que tem um menor arrasto aerodinâmico, a economia de combustível pode chegar a 10 %.

Análises aprofundadas sobre a economia de combustível dos veículos em um pelotão podem ser encontradas em (LIANG, 2016) e dados sobre as forças de arrasto aerodinâmico no pelotão, em (NORRBY, 2014).

Muitas pesquisas podem ser encontradas na literatura em que os controladores são projetados para manter o espaçamento desejado entre os veículos, por exemplo Dai et al. (2018), Liang (2016) e Sedran (2016). A maioria dos estudos considera que o comportamento dinâmico de todos os veículos no pelotão é o mesmo, ou que os modelos matemáticos são conhecidos e não se alteram.

Entretanto, à medida que as massas dos veículos ou o desempenho dos freios variam ao longo do tempo, devido à carga e à descarga de mercadorias ou à depreciação dos sistemas de freio, o modelo desse sistema muda. Se essas mudanças não forem consideradas, podem ocorrer acidentes com os veículos autônomos, principalmente, quando o pelotão entrar em uma estrada com subida e descida. Este estudo foca em como pode-se identificar o modelo dinâmico de veículo autônomo, considerando que o sistema pode ser representado como um sistema dinâmico em rede.

Considera-se que a dinâmica dos veículos e a topologia da rede são conhecidas, sendo representada por equações de transferência de segunda ordem. O foco do estudo é identificar os parâmetros dessas funções que vão ditar a dinâmica dos veículos e da rede.

É sabido que a conexão do pelotão pode ser representada como o modelo de uma rede dinâmica, onde cada veículo influencia na dinâmica dos demais, como num sistema distribuído.

1.4 Objetivo

Este trabalho tem como objetivo central implementar uma técnica de identificação de modelo dinâmico em redes aplicado à pelotões de veículos autônomos. Além de apresentar duas topologias de representação da rede formada pelo pelotão de veículos, e comparar o resultado da identificação do sistema entre as topologias propostas. Outro objetivo é aplicar a técnica de identificação, considerando que os veículos possuem características distintas de peso dinâmica e controle. Por fim, através da representação em rede, obter os coeficientes de arrasto aerodinâmico dos veículos.

Mais especificamente, com este trabalho busca-se atingir os seguintes objetivos específicos:

1.4.1 Objetivos Específicos

- Aplicar técnicas de identificação de sistemas em uma rede de três veículos com parâmetros distintos, que estejam em formação de pelotão;
- Identificar a função de transferência dos módulos da rede;
- Identificar o coeficiente de arrasto aerodinâmico dos veículos;

- Comparar a identificação em duas topologias de representação da rede estudada.

2 Fundamentação Teórica

A modelagem matemática é usada frequentemente para descrever o comportamento dinâmico de sistemas ou de determinadas características de um sistema. A identificação busca descrever o comportamento do sistema por um modelo matemático. Abaixo, serão expostos alguns conceitos ligados a este assunto, que serão utilizados no decorrer deste trabalho.

2.1 Causalidade

A definição de causalidade determina que o sistema se baseia em amostras do intervalo de tempo passado. Ao assumir que o tempo atual do sistema é $t = 0$, o sistema se baseia nas amostras $t < 0$, e não depende de amostras em $t > 0$, ou amostras futuras. Isso determina que o sistema é causal. Diz-se, então, que um sistema é causal se o valor atual do sinal de saída depender somente dos valores presentes e/ou passados do sinal de entrada (OGATA, 2014).

A identificação em redes dinâmicas é fundamentalmente baseada na noção de que somos capazes de determinar quais variáveis causam quais (DANKERS, 2014). Causalidade é uma definição ainda discutida, pois agrega fatores filosóficos (RUSSELL, 1912), e, assim, a real relação de causa e efeito pode ser interpretada de formas diferentes. Para limitar as possibilidades de interpretação deste conceito num sistema, deve-se determinar suas condições de operação. Ao delimitar as especificações de operação de uma situação problema, determinando as variáveis do sistema que são entrada e as variáveis que são saída, e ao gerar dados nesse sistema, tem-se um ciclo de causa e efeito.

Do ponto de vista de identificação, pode-se ver que, mesmo que a causalidade possa ser discutida nas equações de diferenças usadas nos modelos, uma estrutura causal certamente está presente nos dados coletados no sistema (DANKERS, 2014).

2.2 Invariância no Tempo

A teoria de redes dinâmicas abordadas nesse trabalho considera que seus módulos são invariantes no tempo (GEVERS; BAZANELLA; PIMENTEL, 2018). Se o sistema identificado variar a lei que o rege, a identificação deixa de ser válida e uma nova identificação do sistema deve ser feita. Assume-se que a identificação da dinâmica do sistema é feita através da observação dos dados gerados por esse sistema em vários instantes de tempo. Os dados devem ter sido gerados pela mesma relação matemática, para que faça sentido

observá-los e analisá-los em conjunto. Então, nesse trabalho, as técnicas de identificação em rede abordadas consideram os sistemas invariantes no tempo.

Um sistema é invariante no tempo quando não se altera dentro do intervalo de tempo que está sendo observado, isso não quer dizer que suas variáveis de entrada e saída não se alterem, elas evoluem ao longo do tempo conforme a lei que as rege; a lei matemática que é invariável ao longo do tempo (AGUIRRE, 2007).

2.3 Linearidade

O desenvolvimento dos métodos de identificação abordados serão aplicados a sistemas Lineares. Este conceito será apresentado nesta seção.

Um sistema linear é aquele que mantém sua dinâmica inalterada ao longo dos pontos de operação observados. Formalmente, um sistema é considerado linear quando respeita o princípio da superposição. Que pode ser dividido em duas propriedades: a da aditividade e a da homogeneidade (LATHI, 2007).

A propriedade da aditividade pode ser descrita por um sistema linear que tem uma entrada x_1 que gera sozinha uma saída y_1 , e uma entrada x_2 que atuando sozinha gera uma saída y_2 . Quando as duas entradas atuarem junto, devem gerar a saída $y_1 + y_2$.

$$x_1 \longrightarrow y_1 \text{ e } x_2 \longrightarrow y_2, \quad (2.1)$$

então para todo x_1 e x_2

$$x_1 + x_2 \longrightarrow y_1 + y_2. \quad (2.2)$$

A segunda propriedade que forma esse teorema é a da homogeneidade ou escalonamento, sendo um número k real ou imaginário. Se uma entrada for aumentada k vezes, seu efeito aumentará k vezes; então, para um entrada x e uma saída y tem-se:

$$kx \longrightarrow ky. \quad (2.3)$$

Por fim, pode-se definir o teorema da superposição unindo as duas propriedades. Se o sistema obtiver a resposta a duas entradas simultâneas, considerando as entradas individualmente e somando os resultados, o sistema cumpriu o princípio da superposição e é linear.

O teorema da superposição, considera então a entrada $u(t)$ e sua respectiva saída $y(t)$. Para dois casos:

$$u_1(t) \longrightarrow y_1(t), \quad (2.4)$$

$$u_2(t) \longrightarrow y_2(t). \quad (2.5)$$

Para satisfazer o teorema da superposição, as saídas do sistema devem satisfazer a seguinte expressão:

$$au_1(t) + bu_2(t) \longrightarrow ay_1(t) + by_2(t), \quad (2.6)$$

sendo a e b constantes.

Considerações frequentemente feitas em modelagem matemáticas são de que o sistema é linear e invariante no tempo. Esses conceitos são adotados a fim de simplificar os modelos matemáticos dos sistemas reais, resumindo o sistema real a condições estritas de operação.

2.4 Sistemas de Tempo Contínuo e de Tempo Discreto

Sistemas reais, em sua grande maioria, são de tempo contínuo, e representam a evolução do sistema de forma contínua ao longo do tempo. Sistemas de tempo contínuo possuem uma entrada $u(t)$ e uma saída $y(t)$, onde t é o instante no tempo.

Já sistemas de tempo discreto são, geralmente, sistemas que trabalham com sinais de tempo contínuo amostrados em intervalos de tempo determinados, chamado período de amostragem. Este processo de amostragem do sinal é chamado de discretização. Sistemas de tempo discreto possuem uma entrada $u[n]$ e uma saída $y[n]$, onde n é o número da amostra no tempo e representa o n -ésimo número na sequência.

Os sistemas de controle digitais possuem o processamento de forma discreta e operam com sinais discretos. Mesmo que a natureza do sinal de entrada do sistema a ser medido seja contínuo, o sistema irá amostrá-lo na entrada, sendo convertido em um sinal de tempo discreto, o qual então é processado pelo sistema em tempo discreto resultando em uma saída discreta (LATHI, 2007).

Na abordagem de identificação de sistemas desta dissertação iremos trabalhar com sistemas discretos. Para proceder com a identificação do sistema, precisamos discretizar a função de transferência.

A equação de aproximação de Euler backwards é apresentada a seguir para discretização da equação diferencial do sistema. Utilizando o instante atual e o anterior ao atual para o cálculo da área.

A equação da derivada de aproximação utilizada pelo método de *Euler backwards* é dada por:

$$\dot{y}(kT) = \frac{y(k) - y(k-1)}{T}. \quad (2.7)$$

Considerando um sistema de primeira ordem,

$$\dot{y}(t) + ay(t) = au(t), \quad (2.8)$$

que apresenta a função de transferência

$$G(s) = \frac{a}{s + a}, \quad (2.9)$$

obtém-se a aproximação por Euler backwards utilizando (2.7) em (2.8)

$$\frac{y(k) - y(k-1)}{T} + ay(k) = au(k), \quad (2.10)$$

onde se tem:

$$zY(z) - Y(z) + aTY(z) = aTU(z) \quad (2.11)$$

e, portanto:

$$G(z) = \frac{Y(z)}{U(z)} = \frac{aT}{1 - z^{-1} - aT}, \quad (2.12)$$

logo

$$G(z) = \frac{a}{\frac{z-1}{Tz} + a}. \quad (2.13)$$

Ao observar a (2.9) com a (2.13), pode-se ver que, para obter a função de transferência discretizada a partir da função de transferência, podemos usar a relação abaixo:

$$s = \frac{z-1}{Tz} \quad (2.14)$$

São usuais, ainda, a equação de discretização por aproximação de Forward e Tustin. A derivada da discretização pelo método de Forward, discretiza a equação de diferença observando o tempo atual e o instante futuro. E tem a seguinte notação:

$$\dot{y}(kT) = \frac{y(k+1) - y(k)}{T}, \quad (2.15)$$

levando à seguinte relação de transformação direta de s para z , como

$$s = \frac{z-1}{T}. \quad (2.16)$$

A equação de Tustin ou bilinear, discretiza a equação observada com uma relação trapezoidal, efetuando uma linha reta entre as amostras, tentando fazer uma aproximação mais exata da área da equação que está sendo amostrada (FRANKLIN; POWELL; EMAMI-NAEINI, 2013). A equação diferencial da aproximação por Tustin é:

$$\frac{\dot{y}(k) + \dot{y}(k-1)}{2} = \frac{y(k) - y(k-1)}{T} \quad (2.17)$$

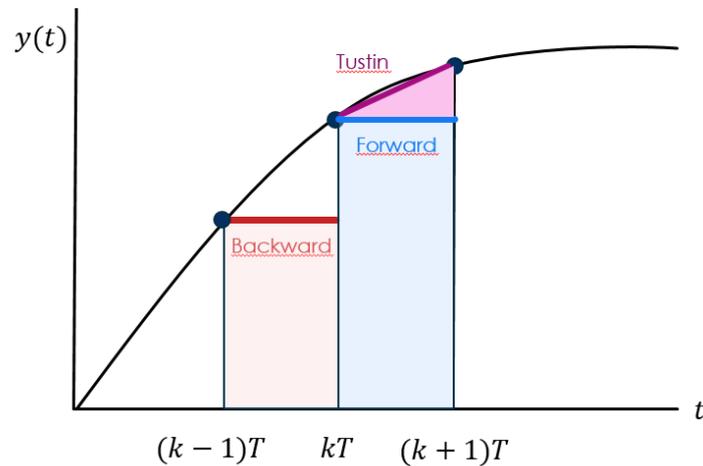
O que leva à seguinte relação de transformação direta.

$$s = \frac{2(z-1)}{T(z+1)} \quad (2.18)$$

Uma comparação gráfica dos 3 métodos de discretização pode ser vista na figura

3.

Figura 3 – Demonstração gráfica dos métodos de discretização.



Fonte: O autor, 2020.

2.5 Modelos Monovariáveis e Multivariáveis

Os modelos das redes dinâmicas podem ser encontrados com várias topologias, muitas delas são combinações dos módulos que compõem a rede. Os módulos podem assumir configurações do tipo SISO e MISO (Van den Hof et al., 2013). Enquanto as redes também podem combinar os módulos e representar sistemas do tipo MIMO (WEERTS et al., 2018). As redes ainda podem assumir topologias que são transpostas de espaço de estados com múltiplas variáveis de entrada e saída (KIVITS; J. Van den Hof, 2018).

As classificações de um sistema pela quantidade de sinais que possui na entrada e na saída, são definidas da seguinte forma:

Modelo SISO (Single Input-Single Output), sendo uma única variável de entrada e uma única variável de saída. Muitos dos sistemas de controle são deste tipo, e estão empregados em situações simples do cotidiano. Como exemplo de sistemas SISO pode-se citar o controle de temperatura de um aquecedor de água e o controle do nível de uma caixa d'água. Sendo representado graficamente como na Figura 4.

Figura 4 – Representação gráfica de um sistema SISO.



Fonte: O autor, 2020.

Modelo MIMO (Multiple Input-Multiple Output) de múltiplas entradas e múltiplas saídas, refere-se a modelos com mais de uma variável de entrada e mais de uma variável de saída. São sistemas complexos onde diversos fatores observados na entrada do sistema determinam a atuação do sistema em mais de uma forma de saída. Como exemplos de sistemas MIMO pode-se descrever a atuação do controle de ignição eletrônica de um carro, que observa diversos sensores do carro como rotação do motor, temperatura, sensor de oxigênio que monitora a queima do combustível. Todos esses sensores são entradas no sistema que, através de seu modelo, geram os sinais de saída na ignição das velas e nos bicos injetores de combustível do veículo e no fluxo de ar (ASHOK; ASHOK; KUMAR, 2016). Sendo representado graficamente como na Figura 5.

Figura 5 – Representação gráfica de um sistema MIMO.



Fonte: O autor, 2020.

Modelo MISO (Multiple Input Single Output) de múltiplas variáveis de entrada e uma única variável de saída. Sistemas desse tipo são encontrados em tarefas em que diversos itens devem ser ponderados para tomar uma ação. Redes dinâmicas estudadas nesse trabalho tem como estrutura sistemas do tipo MISO. Um sistema de controle MISO simples de exemplificar é o sensor de presença integrado com fotocélula para acender uma lâmpada. Nele, a lâmpada só acende se o sensor de presença indicar movimento e se o sensor de luminosidade indicar que está escuro. Sendo representado graficamente como na Figura 6.

Figura 6 – Representação gráfica de um sistema MISO.



Fonte: O autor, 2020.

Modelo do tipo SIMO (Single Input Single Output) possui uma única variável de entrada e múltiplas variáveis de saída. Um demultiplexador com uma única entrada pode ser considerado um sistema SIMO. Esse modelo também é aplicado em sistemas em

que, a partir da informação obtida de um atuador, se controla diversos sensores. Sendo representado graficamente como na Figura 7.

Figura 7 – Representação gráfica de um sistema SIMO.



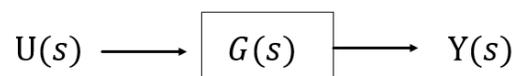
Fonte: O autor, 2020.

2.6 Representação do Modelo na Forma de Função de Transferência

Função de transferência é por definição a relação entre a transformada de Laplace do sinal de saída pela transformada de Laplace do sinal de entrada, que usualmente é a transformada da função impulso (OGATA, 2014). Assim, a função de transferência é geralmente representada como a razão de dois polinômios no domínio s e é chamada de $G(s)$, conforme equação (2.19). Essa relação é representada na Figura 8.

$$G(s) = \frac{\mathcal{L}[\text{saída}]}{\mathcal{L}[\text{entrada}]}\Bigg|_{C.I.=0} \quad (2.19)$$

Figura 8 – Sistema Linear.



Fonte: O autor, 2020.

Um problema típico da modelagem de sistemas lineares é o de obter a função de transferência do sistema em estudo. A maior potência de s no denominador determina a ordem do sistema. A equação diferencial, por sua vez, é obtida considerando-se as leis que descrevem os fenômenos físicos envolvidos no processo. O conceito da função de transferência é aplicado apenas a sistemas lineares e invariantes no tempo, com condições iniciais nulas (OGATA, 2014).

Pode-se caracterizar uma função de transferência da seguinte forma genérica: Considere o sistema linear invariante no tempo descrito pela seguinte equação diferencial de enésima ordem,

$$a_n \frac{d^n y(t)}{dt^n} + a_{n-1} \frac{d^{n-1} y(t)}{dt^{n-1}} + \dots + a_0 y(t) = b_m \frac{d^m u(t)}{dt^m} + b_{m-1} \frac{d^{m-1} u(t)}{dt^{m-1}} + \dots + b_0 u(t). \quad (2.20)$$

Aplicando a transformada de Laplace a ambos os lados da equação genérica apresentada em (2.20) e admitindo as condições iniciais nulas, obtém-se as equações de entrada e saída no domínio de Laplace.

Aplicando a relação nas equações no domínio de Laplace de saída $Y(s)$ pela equação de entrada $U(s)$ obtém-se a função de transferência

$$G(s) = \frac{Y(s)}{U(s)} = \frac{b_m s^m + b_{m-1} s^{m-1} + \dots + b_0}{a_n s^n + a_{n-1} s^{n-1} + \dots + a_0}, \quad (2.21)$$

onde n representa o grau do polinômio do denominador. As raízes deste polinômio chamamos de polos. E m é o grau do polinômio do numerador. As raízes deste polinômio chamamos de zeros.

Todos os sistemas que têm a mesma função de transferência, apresentarão a mesma saída em resposta ao mesmo impulso. Quanto à classificação, as funções de transferência denominam-se:

- Estritamente própria: Quando o grau do polinômio denominador é maior que o grau do polinômio numerador.
- Biprópria: Quando o grau dos polinômios denominador e numerador são iguais ($n = m$)
- Imprópria: Quando o grau do polinômio denominador é menor que o grau do polinômio numerador ($n < m$).

2.7 Representação do Modelo na Forma de Espaço de Estados

O conceito de estado define que o estado de um sistema dinâmico é o menor conjunto de variáveis, desde que, conhecidas as variáveis no instante $t=0$ juntamente com os sinais de entrada, possa se descrever qualquer comportamento do sistema para qualquer $t > 0$ (OGATA, 2014).

As variáveis de estado são as que fazem parte do conjunto de variáveis necessárias para descrever completamente o comportamento do sistema. Uma variável de estado não necessariamente deve ter um significado físico, ser mensurada ou observada. As variáveis de estado compõem o vetor de estados x . O espaço n -dimensional cujos eixos coordenados

são formados pelos eixos x_1, x_2, x_n , que são as variáveis de estado, é denominado espaço de estados. E qualquer estado pode ser representado por um ponto neste espaço de estados.

Suponha-se que um sistema com múltiplas entradas e múltiplas saídas envolva n integradores. Considere também que existam r entradas $u_1(t), u_2(t), \dots, u_r(t)$ e m saídas $y_1(t), y_2(t), \dots, y_m(t)$. Defina as n saídas dos integradores como variáveis de estado: $x_1(t), x_2(t), \dots, x_n(t)$. Então, o sistema pode ser descrito como:

$$\begin{aligned}\dot{x}_1(t) &= f_1(x_1, x_2, \dots, x_n; u_1, u_2, \dots, u_r; t) \\ \dot{x}_2(t) &= f_2(x_1, x_2, \dots, x_n; u_1, u_2, \dots, u_r; t) \\ &\vdots \\ \dot{x}_n(t) &= f_n(x_1, x_2, \dots, x_n; u_1, u_2, \dots, u_r; t)\end{aligned}\tag{2.22}$$

$$\begin{aligned}y_1(t) &= g_1(x_1, x_2, \dots, x_n; u_1, u_2, \dots, u_r; t) \\ y_2(t) &= g_2(x_1, x_2, \dots, x_n; u_1, u_2, \dots, u_r; t) \\ &\vdots \\ y_m(t) &= g_m(x_1, x_2, \dots, x_n; u_1, u_2, \dots, u_r; t)\end{aligned}\tag{2.23}$$

As equação (2.22) é a equação de estados e pode ser reescrita de forma simplificada como:

$$\dot{x}(t) = f(x, u, t).\tag{2.24}$$

As equações (2.23) são equações de saída e podem ser reescritas como:

$$y(t) = g(x, u, t).\tag{2.25}$$

Se as equações (2.24) e a (2.25) forem lineares ou linearizadas em torno de um ponto de operação e as funções vetoriais f e g não envolverem o tempo t explicitamente, então o sistema será denominado de sistema invariante no tempo. E obtém-se a equação de estado e de saída linearizadas.

$$\begin{cases} \dot{x}(t) = Ax(t) + Bu(t) \\ y(t) = Cx(t) + Du(t) \end{cases},\tag{2.26}$$

sendo $x(t)$ o vetor das variáveis de estado, tamanho n ; $y(t)$ o vetor das variáveis de saída, tamanho m ; $\dot{x}(t)$ o vetor da derivada das variáveis de estado, tamanho n ; $u(t)$ o vetor das

variáveis de entrada, tamanho r ; A a matriz de estados, tamanho $n \times n$; B a matriz de entrada, tamanho $n \times r$; C a matriz de saída, tamanho $m \times n$ e D a matriz de transmissão direta entre entrada e saída, tamanho $m \times r$.

2.8 Modelos ARX e ARMAX

Nesta seção serão apresentados os modelos ARX e ARMAX, utilizados para representação de sistemas em tempo discreto, que são adequados para as técnicas de identificação. Essa representação é baseada na equação geral (2.27) apresentada na sequência,

$$A(q)y(k) = \frac{B(q)}{F(q)}u(k) + \frac{C(q)}{D(q)}v(k). \quad (2.27)$$

Os polinômios $A(q)$, $B(q)$, $C(q)$, $D(q)$ e $F(q)$ possuem a seguinte estrutura:

$$\begin{aligned} A(q) &= 1 - a_1q^{-1} - \dots - a_{n_y}q^{-n_y} \\ B(q) &= b_1q^{-1} + \dots - b_{n_u}q^{-n_u} \\ C(q) &= 1 + c_1q^{-1} + \dots - c_{n_v}q^{-n_v} \\ D(q) &= 1 + d_1q^{-1} + \dots - d_{n_d}q^{-n_d} \\ F(q) &= 1 + f_1q^{-1} + \dots - b_{n_f}q^{-n_f} \end{aligned} \quad (2.28)$$

onde $v(k)$ representa um ruído branco, e q^{-1} é um operador de atraso de forma que $y(k)q^{-1} = y(k-1)$.

Sendo a equação que representa um sistema descrito pela equação (2.29) com $u(t)$ a entrada do sistema, $e(t)$ perturbação e $y(t)$ a saída.

$$y(k) = G(q)u(k) + H(q)v(k) \quad (2.29)$$

O modelo auto-regressivo com entradas externas (ARX do inglês autoregressive with exoneous inputs) pode ser obtido a partir da equação geral (2.27). Tornando $C(q) = D(q) = F(q) = 1$, sendo $A(q)$ e $B(q)$ polinômios arbitrários, resultando em:

$$A(q)y(k) = B(q)u(k) + v(k) \quad (2.30)$$

O modelo (2.30) pode ser reescrito colocando a saída $y(k)$ em evidência da seguinte forma:

$$y(k) = \frac{B(q)}{A(q)}u(k) + \frac{1}{A(q)}v(k) \quad (2.31)$$

Podemos definir para o modelo ARX a equação de transferência do sistema $G(q)$ como

$$G(q) = \frac{B(q)}{A(q)} \quad (2.32)$$

E a equação do ruído $H(q)$ como

$$H(q) = \frac{1}{A(q)}. \quad (2.33)$$

O modelo ARX pode ser expandido com a utilização de uma média móvel aplicada à perturbação, dando origem ao modelo ARMAX. A média móvel inserida no modelo é representada por $C(q)$, dando origem ao modelo auto-regressivo com média móvel e entrada exôgenas (ARMAX do inglês autoregressive moving average with exogenous inputs). Ele pode ser obtido a partir do modelo geral (2.27), tornando além de $A(q)$ e $B(q)$, o polinômio $C(q)$ como um polinômio arbitrário. Com isso, obtém-se a equação:

$$A(q)y(k) = B(q)u(k) + C(q)v(k) \quad (2.34)$$

que se torna

$$y(k) = \frac{B(q)}{A(q)}u(k) + \frac{C(q)}{A(q)}v(k) \quad (2.35)$$

Possuindo as seguintes funções de transferência:

$$G(q) = \frac{B(q)}{A(q)} \text{ e } H(q) = \frac{C(q)}{A(q)} \quad (2.36)$$

O ruído adicionado à saída, $e(k)$ é modelado como ruído branco filtrado pelo filtro, $C(q)/A(q)$. Também chamado de filtro ARMA, que é um filtro de média móvel.

2.9 Redes Dinâmicas

Nos últimos anos, as interconexões de vários dispositivos autônomos aumentaram a complexidade dos sistemas (Dankers et al., 2016). Normalmente, cada um desses dispositivos têm uma estrutura de sistema em malha fechada com um controlador. Essa topologia forma um sistema de controle distribuído que tem como objetivo produzir maneiras eficientes de melhorar a confiabilidade do controle, a qualidade e a eficiência do processo (TANG; DAOUTIDIS, 2019).

Uma rede consiste em um conjunto de variáveis (DANKERS, 2014). Elas podem ser variáveis externas, que podem ser manipuladas por um agente externo e inserir sinais e estímulos na rede, ou variáveis internas, que se relacionam umas com as outras através de um comportamento dinâmico. As variáveis internas podem ser mensuradas, quando

se referem a sinais e características da rede. As variáveis internas estão relacionadas às características da rede e, no presente caso da implementação em pelotão de veículos, é possível encontrar variáveis que representam a velocidade de um determinado veículo, distância entre ele e o veículo à frente.

Em uma rede, podem existir distúrbios não mensuráveis que afetam o valor de variáveis internas, como ruídos térmicos, vento em uma estrutura mecânica em deslocamento, distúrbios eletromagnéticos. Este conjunto de eventos não mensuráveis podem ser representado por uma variável de ruído.

O modelo de uma rede dinâmica é uma ferramenta que ajuda a entender e manipular um sistema. O modelo dinâmico de uma rede pode ser expresso como uma extensão do método clássico de modelo de malha fechada multivariáveis (Van den Hof et al., 2013).

Considerar-se-á a rede como sendo composta por sistemas lineares e invariantes no tempo. Os nós dessa rede são mensuráveis e conectados por funções de transferência. Os sinais externos de manipulação são sinais de excitação conhecidos, e o sinal de ruído é estacionário e desconhecido.

A estrutura da rede será representada por L nós, relacionados a L variáveis internas, w_j , $j = 1, \dots, L$ (GEVERS; BAZANELLA; PIMENTEL, 2018). Cada variável w_j pode ser expressada como:

$$\omega(t) = \sum_{k \in N_j} G_k(q)\omega_k(t) + r_j(t) + e(t), \quad (2.37)$$

onde:

- N_j é o índice das variáveis internas w_k , que possui uma conexão causal direta, $k \neq j$, $G_{jk}^0 \neq 0$;
- e_j é um distúrbio relacionado ao ruído do processo;
- r_j é uma variável externa que pode ser manipulada.

Esses nós (de sinais) são relacionados entre si e com os sinais externos r_j e com sinal de ruído e_j pela seguinte equação de rede, que é definida como o modelo de rede (*network model*) e em que a matriz G^0 pode ser chamada de matriz da rede (*network matrix*):

$$\begin{bmatrix} \omega_1 \\ \omega_2 \\ \vdots \\ \omega_L \end{bmatrix} = \begin{bmatrix} 0 & G_{12} & \cdots & G_{1L} \\ G_{21} & 0 & \ddots & G_{2L} \\ \vdots & \ddots & \ddots & \vdots \\ G_{L1} & G_{L2} & \cdots & 0 \end{bmatrix} \begin{bmatrix} \omega_1 \\ \omega_2 \\ \vdots \\ \omega_L \end{bmatrix} + K^0(q) \begin{bmatrix} r_1 \\ r_2 \\ \vdots \\ r_L \end{bmatrix} + H^0(q) \begin{bmatrix} e_1 \\ e_2 \\ \vdots \\ e_L \end{bmatrix},$$

ou

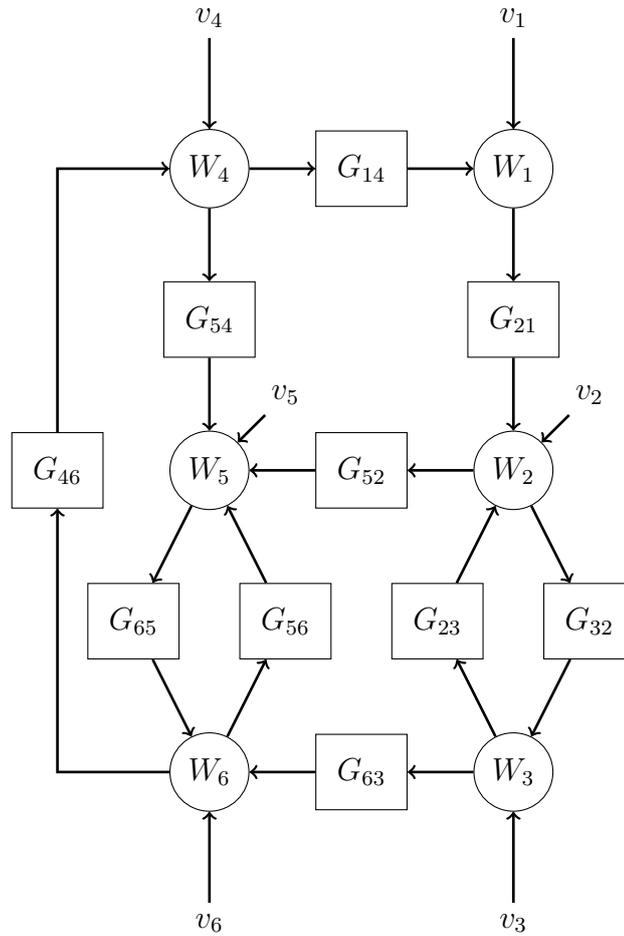
$$\omega(t) = G^0(q)\omega(t) + K^0(q)r(t) + H^0(q)e(t), \quad (2.38)$$

Com as seguintes propriedades (GEVERS; BAZANELLA; PIMENTEL, 2018):

- G_{jp} são funções de transferência próprias mas não necessariamente funções de transferência estritamente próprias. Algumas delas podem ser zero, indicando que não há conexão de $\omega_p(t)$ para $\omega_j(t)$;
- Há um atraso em todo laço indo de $\omega_p(t)$ para ele mesmo;
- A rede está bem posta quando $(I - G^0)^{-1}$ é própria e estável;
- Todos os nós de sinal $\omega_p(t)$, $p = 1, \dots, L$ são mensuráveis;
- K^0 reflete como os sinais de excitação externos afetam os nós de sinais;
- $e \in \mathcal{R}^L$ é um distúrbio não mensurável, referido como um ruído do processo com uma matriz de covariância definida positiva Σ . $H(q)$ é uma $L \times L$ estável racional;
- Os sinais de excitação externa r_j são assumidos para serem não correlacionado com os sinais de ruído $e_j, j = 1, \dots, L$.

Como exemplo será apresentada a representação exposta em (Dankers et al., 2016) de uma rede com seis nós, conforme Figura 9. Perceba que a representação é feita com círculos representando os nós, e os retângulos representando as funções de transferência que expressam a relação dinâmica que ocorre entre os nós da rede.

Figura 9 – Representação gráfica de uma rede.



Fonte: Dankers et al. (2016).

A rede utilizada na Figura 9 pode ser representada através da seguinte matriz de rede:

$$\begin{bmatrix} \omega_1 \\ \omega_2 \\ \omega_3 \\ \omega_4 \\ \omega_5 \\ \omega_6 \end{bmatrix} = \begin{bmatrix} 0 & 0 & 0 & G_{14} & 0 & 0 \\ G_{21} & 0 & G_{23} & 0 & 0 & 0 \\ 0 & G_{32} & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & G_{46} \\ 0 & G_{52} & 0 & G_{54} & 0 & G_{56} \\ 0 & 0 & G_{63} & 0 & G_{65} & 0 \end{bmatrix} \begin{bmatrix} \omega_1 \\ \omega_2 \\ \omega_3 \\ \omega_4 \\ \omega_5 \\ \omega_6 \end{bmatrix} + \begin{bmatrix} v_1 \\ v_2 \\ v_3 \\ v_4 \\ v_5 \\ v_6 \end{bmatrix}.$$

A variável de ruído de processo \$v_j\$ representa as variáveis desconhecidas ou não modeladas que afetam o nó \$w_j\$. É comum utilizar o modelo de um filtro de ruído branco \$e_j\$ para modelar estas variáveis.

$$v_j = H_j(q)e_j(t). \tag{2.39}$$

Exemplos de ruído de processo são: ruído térmico em circuitos elétricos, radiação eletromagnética induzindo corrente nos fios de redes elétricas, vibrações em estruturas mecânicas e vento turbulento atingindo uma estrutura mecânica.

Essa estrutura de rede apresentada será implementada a pelotões de veículos, considerando os veículos como sistemas de controle distribuído, que, ao entrar em formato de pelotão, possuem uma dinâmica em rede.

3 Identificação de Sistemas

A identificação de sistema é uma metodologia desenvolvida para estimar, através de testes e excitações das plantas, os seus modelos matemáticos dinâmicos. A identificação dos sistemas é uma alternativa ao método de modelagem matemática do sistema caixa branca, onde é necessário um conhecimento profundo do sistema e das leis da física que estão envolvidas no processo. A identificação de sistemas se baseia no conhecimento dos sinais de entrada $u(k)$, e de saída $y(k)$. Ela ocorre através da relação causa e efeito, obtendo um modelo que expresse a relação existente entre os sinais obtidos. Segundo Aguirre (2007), existem importantes escolhas envolvidas em problemas reais de identificação, e estão descritas a seguir:

- O teste dinâmico e coleta de dados, que envolve a escolha do tipo de sinal de excitação, tempo de amostragem e a execução do teste.
- Escolha da representação matemática a ser usada, dentre elas, funções de transferência, mais utilizadas em problemas determinísticos, modelos ARMAX para identificação estocástica.
- Determinação da estrutura do modelo, no caso de modelos lineares, a escolha ocorre no número de polos e zeros e do atraso no tempo.
- Escolha do método de identificação a ser utilizado.
- Validação do modelo. Após identificar o modelo do sistema, é necessário validar que ele representa as características de interesse do sistema original.

3.1 Métodos de Identificação de Sistemas

3.1.1 Mínimos Quadrados

O método dos mínimos quadrados é composto por uma ferramenta matemática utilizada para identificar parâmetros de um modelo matemático. Sua representação é feita por um vetor x , que representa as variáveis independentes (ou regressores) do sistema, um vetor y que representa as variáveis de saída do sistema, um vetor θ que representa os parâmetros da função de transferência do sistema e é relacionado à dinâmica do sistema. Este é o vetor de parâmetros que deve ser determinado pelo método.

Na representação matemática, ainda temos o vetor de erro $e(k)$ que representa ruído presente nos sistema e nas leituras. A ferramenta de mínimos quadrados garante

matematicamente através de uma função de minimização que encontra os parâmetros que representam a dinâmica do sistema observado, com o menor valor de erro possível de estimação, para o conjunto de dados utilizados para a estimação. O método se baseia na observação do comportamento de um sistema em diversos instantes de tempo, e pondera todas estas leituras encontrando os parâmetros que melhor descrevem seu comportamento.

Considere

$$y = f(x, \theta), \quad (3.1)$$

a representação para as m observações que podem ser interpretada como está descrito na sequência

$$\begin{aligned} y_1 &= f(x_1, \theta) \\ y_2 &= f(x_2, \theta) \\ &\vdots \\ y_m &= f(x_m, \theta). \end{aligned} \quad (3.2)$$

Existem algumas considerações importantes que devem ser feitas ao utilizar o método de mínimos quadrados.

A primeira é que a função e seus parâmetros são invariantes ao longo do tempo, garantindo que as amostras obtidas nos diversos instantes estão sobre a influência da mesma lei matemática. A outra consideração é de que a equação observada pode ser escrita como na equação (3.3), garantindo que a equação é linear nos parâmetros.

$$y = x^T \theta. \quad (3.3)$$

Tendo correspondido as restrições impostas, podemos reescrever a equação (3.3) da seguinte forma:

$$\begin{aligned} \begin{bmatrix} y(1) \\ y(2) \\ \vdots \\ y(m) \end{bmatrix} &= \begin{bmatrix} x_1(1) & x_2(1) & \dots & x_n(1) \\ x_1(2) & x_2(2) & \dots & x_n(2) \\ \vdots & \vdots & \vdots & \vdots \\ x_1(m) & x_2(m) & \dots & x_n(m) \end{bmatrix} \begin{bmatrix} \theta_1 \\ \theta_2 \\ \vdots \\ \theta_n \end{bmatrix}, \\ y &= X\theta. \end{aligned}$$

Na equação (3.3) se $m=n$, pode-se inverter a matriz X , através das determinações feitas, e desta forma, encontrar o valor do vetor de parâmetros.

$$\theta = X^{-1}y. \quad (3.4)$$

Na equação acima, X deve ser quadrada para poder ser invertida, mas, na maioria dos casos, deseja-se usar uma quantidade de amostras maior que o número de variáveis

de restrições. Dessa forma, tem-se que a matriz X não é inversível. Para solucionar este problema de forma algébrica, multiplica-se os dois lados da equação (3.4) por X^T e obtém-se o seguinte desenvolvimento:

$$X^T y = X^T X \theta. \quad (3.5)$$

Chegando à seguinte equação:

$$\theta = [X^T X]^{-1} X^T y, \quad (3.6)$$

onde matriz encontrada $[X^T X]^{-1} X^T$ é conhecida como a matriz pseudo inversa.

O problema da matriz x não ser inversível também pode ser resolvido como sendo um problema de otimização, minimizando o erro entre o modelo e os dados experimentais a partir do ajuste de θ .

Para desenvolver este método é preciso assumir agora que se conhece o valor estimado do vetor de parâmetros e será usado para representá-lo $\hat{\theta}$. Desta forma, soma-se a ele o erro ξ de estimação proveniente de ruído que existe nas leituras obtidas pelos sensores e no sistema. A função fica representada da seguinte forma:

$$y = X \hat{\theta} + \xi. \quad (3.7)$$

Assim, busca-se o valor de $\hat{\theta}$ que minimize o valor de ξ . Uma forma de quantificar o erro obtido pelo vetor de parâmetros estimado é somar o quadrado dos valores do erro. Desse jeito, erros de estimação positivos e negativos possuem o mesmo peso, quantificando a qualidade do vetor de parâmetros estimado. Com isso, busca-se minimizar o valor do somatório do quadrado dos erros ajustando $\hat{\theta}$ através de uma função custo

$$J_{MQ} = \sum_{i=1}^m \xi(i)^2 = \xi^T \xi = \|\xi\|^2. \quad (3.8)$$

Isolando ξ em (3.7) e substituindo ξ em (3.8) obtém-se:

$$J_{MQ} = (y - X \hat{\theta})^T (y - X \hat{\theta}). \quad (3.9)$$

Tem-se após manipular e derivar a equação a seguinte expressão que minimiza o somatório do quadrado dos erros de estimação

$$\hat{\theta}_{MQ} = [X^T X]^{-1} X^T y. \quad (3.10)$$

Pode-se representar o estimador de mínimos quadrados aplicando a modelos do tipo ARX, considerando o modelo do sistema como:

$$y(k) = \psi^T(k-1) \hat{\theta} + \xi(k) \quad (3.11)$$

Sendo que k indica o instante da coleta de amostras e $\psi(k-1)$ é o vetor de $n_\theta = \dim[\hat{\theta}]$ variáveis regressoras.

$$\psi(k-1) = [\psi_1 \quad \psi_2 \quad \dots \quad \psi_{n_\theta}]^T \quad (3.12)$$

Tomadas até o instante $k-1$. As variáveis regressoras neste caso do modelo ARX são apresentadas em (3.13) e podem ser representadas por uma matriz de regressores denominada Ψ .

$$\psi(k-1) = [y(k-1) \quad \dots \quad y(k-n_y) \quad u(k-1) \quad \dots \quad u(k-n_u)]^T. \quad (3.13)$$

na forma vetorial

$$y = \Psi\hat{\theta} + \xi. \quad (3.14)$$

Aplicando o método de mínimos quadrados (3.10) aplicado a representação dos regressores do modelo ARX (3.14).

$$\hat{\theta}_{MQ} = [\Psi^T\Psi]^{-1}\Psi^T y \quad (3.15)$$

É possível reescrever a equação acima utilizando o somatório dos regressores.

$$\hat{\theta}_{MQ} = \left[\frac{1}{N} \sum_{k=1}^N \psi(k-1)\psi^T(k-1) \right]^{-1} \left[\frac{1}{N} \sum_{k=1}^N \psi(k-1)y(k) \right] \quad (3.16)$$

Existem ainda derivações do método de mínimos quadrados. Um deles é o algoritmo de mínimos quadrados ponderados, onde um novo vetor é inserido na solução dos mínimos quadrados que dá pesos diferentes para as amostras observadas, supondo que uma amostra é mais relevante que outra.

O método de mínimos quadrados é robusto em situações que respeitem as seguintes restrições:

$$E[\psi(t)\psi^T(t)] \quad \text{é não singular,} \quad (3.17)$$

$$E[\psi(t)v(t)] = 0. \quad (3.18)$$

onde $E[\cdot]$ denota o operador de esperança matemática. Para casos de identificação em que exista correlação entre o ruído v e as variáveis do sistema, o método convencional de mínimos quadrados não é indicado, pois apresenta viés/polarização de estimação. Pode ser visto em exemplos em Aguirre (2007), Söderström e Stoica (2002).

O método mínimos quadrados é um método simples para identificação do sistema que possui algumas propriedades atraentes. A estimativa é fácil de calcular e suas propriedades numéricas são bem estudadas. As propriedades de consistência restritiva são a principal desvantagem e podem ser vistas como o principal motivo para considerar métodos mais avançados. (SÖDERSTRÖM; STOICA, 2002)

3.1.2 Variáveis Instrumentais

A fim de contornar o problema de viés na estimação apresentado no método de mínimos quadrados nos casos apresentados na Seção 3.1.1, o método de variáveis instrumentais é revisitado nesta seção.

Pode-se definir o estimador de variáveis instrumentais como uma generalização do estimador de mínimos quadrados. O objetivo é modificar o estimador de mínimos quadrados tornando ele consistente para qualquer distúrbio arbitrário (SÖDERSTRÖM; STOICA, 2002).

A equação que descreve o estimador de variáveis instrumentais é apresentada abaixo e é uma modificação da equação (3.10).

$$\hat{\theta}_{VI} = [z(t)\psi^T(t)]^{-1}z(t)y(t) \quad (3.19)$$

onde $z(t)$ é o vetor de variáveis instrumentais. Note que quando as variáveis instrumentais são selecionadas como $z(t) = \psi(t)$, teremos o regressor de mínimos quadrados.

As variáveis arbitrárias contidas no vetor $z(t)$, não podem ter correlação com o ruído, e , mas devem ser altamente correlacionadas com o processo, φ . (3.20). A escolha destas variáveis não é uma escolha trivial. Elas devem respeitar as seguintes condições:

$$\begin{aligned} \text{cor}(z, e) &= 0 \\ \text{cor}(z, \varphi) &\neq 0 \end{aligned} \quad (3.20)$$

Se $z(t)$ satisfizer as condições da (3.20) diz-se que $z(t)$ é um instrumento válido para o método. Uma das formas mais simples para a seleção das variáveis instrumentais é a seleção do sinal de referência, ou sinal de excitação, aplicada ao sistemas.

Pode-se aplicar o método de variáveis instrumentais através de um modelo ARX, conforme foi feito na seção (3.1.1), considerando o modelo da equação (3.11) que representa o modelo ARX, representado na forma vetorial na equação (3.14), aplica-se o estimador de variáveis instrumentais (3.19). Ainda pode-se reescrever a equação das variáveis instrumentais utilizando o somatório dos regressores como

$$\hat{\theta}_{VI} = \left[\frac{1}{N} \sum_{t=1}^N z(t)\psi^T(t) \right]^{-1} \left[\frac{1}{N} \sum_{t=1}^N z(t)y(t) \right]. \quad (3.21)$$

4 Identificação de Parâmetros do Sistema em Rede Dinâmica - Aplicado a Pelotão de Veículos

Nesse capítulo, será apresentada a modelagem matemática de um veículo de transporte pesado, do inglês *heavy duty vehicle*. Utilizar-se-á também a sigla HDV a partir de agora para se referir aos veículos estudados. Será apresentada a dinâmica do controle estabelecido para os veículos, a modelagem da rede dinâmica que os veículos formam quando estão em um pelotão e, por fim, a identificação dos parâmetros desta rede de forma simulada.

A seguir, serão apresentados alguns parâmetros qualitativos a serem observados na técnica de identificação de sistemas.

Para identificação do sistema, é necessário efetuar a coleta de dados. Uma vez que a identificação irá ocorrer a partir de dados amostrados em simulação, é necessário gerar tais dados. Para a identificação, os dados são obtidos a partir de situações de testes, elaborados para extrair informações da dinâmicas do sistema, problemas importantes nesta etapa são a escolha dos sinais de excitação do sistema e as características de execução do teste, assim como a escolha do tempo de amostragem dos dados.

A escolha dos sinais de excitação utilizados para amostragem deve garantir que as variáveis excitadas gerem amostras em todas as faixas de operações do sistema. Na prática, nem sempre é possível excursionar o sistema numa ampla faixa de operação e pode-se determinar a utilização de um sinal de excitação apenas dentro da faixa de operação desejada do sistema, e obter os dados dentro destas condições.

A frequência de amostragem deve obedecer ao teorema de Nyquist e ser duas vezes mais rápida que a frequência de interesse dos dados.

As características em que os testes ocorrem devem ser determinadas na tentativa de diminuir as variações entre os modelos matemáticos e as situações reais. No caso de pelotões de veículos, é possível considerar características do terreno, terreno plano, aclives ou declives. Outras características como peso diferente entre os veículos também serão exploradas para validação da técnica de identificação.

A escolha da representação matemática a ser usada para representar o modelo é um fator importante e podem ser utilizadas funções de transferência em tempo contínuo em problemas de identificação determinística. Outras linhas de pesquisa podem optar pela representação estocástica. Neste estudo, será utilizada a representação por funções

de transferência, pois sua utilização é mais usual em estudos de controle.

Determinação da estrutura do modelo: No caso de modelos lineares, a escolha da sua estrutura limita-se, basicamente, à escolha do número de polos e de zeros da função de transferência, bem como a determinação de atraso no tempo. Como muitos modelos não lineares são linearizados para a manipulação matemática, muitos sistemas reais podem ser representados desta forma.

Escolha do algoritmo a ser utilizado na estimação dos parâmetros: Neste estudo propõe-se a utilização do método de variáveis instrumentais apresentado em 3.1.2, as características de outros métodos pode ser vista na Seção 1.2.

A determinação do número de polos e zeros pode ser obtida através de técnicas matemáticas ou através do conhecimento do comportamento dinâmico do sistema. Como o sistema a ser identificado é conhecido, a quantidade de polos e zeros é determinada pelo modelo utilizado, o modelo que descreve o veículo HDV pode ser visto na Seção 4.1.

A validação do modelo matemático encontrado é feita verificando se o modelo obtido a partir dos dados amostrados possui as características do modelo real. Uma vez que o sistema é identificado, deve ter sua dinâmica comparada com a do sistema real, e apresentar um erro aceitável para que seja satisfatório.

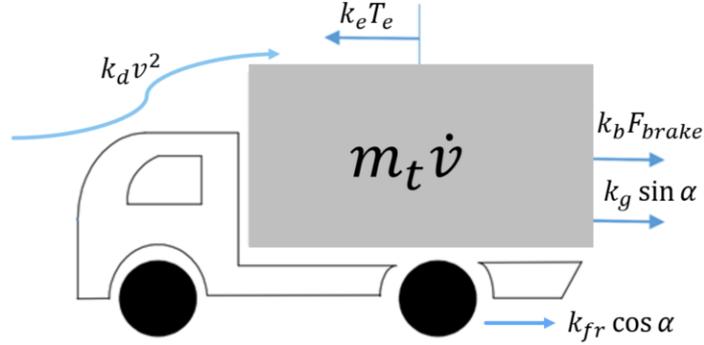
Desta forma, podem ser determinados os seguintes critérios qualitativos.

- Tipo de sinal de excitação.
- Características do teste.
- Algoritmo de identificação utilizado.
- Percentual de erro entre os valores dos parâmetros identificados e dos reais.

4.1 Modelagem Matemática da Dinâmica de um Veículo HDV

Neste estudo de caso, será formado um pelotão com três veículos. Para modelar a dinâmica deste pelotão, primeiro se obtém um modelo individual de cada veículo, conforme a Figura 10.

Figura 10 – Representação simples dos veículos de carga, HDV.



Fonte: O autor, 2020.

A equação que representa a dinâmica do centro e massa do HDV pode ser descrita por:

$$m_t \dot{v} = k_e T_e - k_b F_{brake} - k_d v^2 - k_{fr} \cos \alpha - k_g \sin \alpha, \quad (4.1)$$

onde v é a velocidade do veículo, \dot{v} é a sua derivada (aceleração), m_t demonstra a “massa acelerada”, $T_e \in R$ representa o torque líquido do motor. k_e , k_b , k_d , k_{fr} , e k_g denota a característica do veículo e meio ambiente e do freio, resistência do ar, atrito da estrada, e força de gravidade, respectivamente. α é o declive do terreno F_{brake} é a ação dos freios (ALAM; MARTENSSON; JOHANSSON, 2015).

O modelo não linear (4.1) pode ser linearizado entorno da velocidade de cruzeiro v_o , e do torque do motor $T_{e,o}$ que mantém a velocidade, um espaçamento fixo entre os veículos $\tau_{s,o}$, e a constante de inclinação α_o considerada zero para linearização.

A equação linearizada do HDV pode ser representada por

$$\begin{cases} \dot{v}_1 = -\frac{2k_{d,1}v_o}{m_{t,1}}v_1 + k_{e,1}T_{e,1} \text{ (líder)} \\ \dot{v}_i = -\frac{2\tilde{k}_{d,i}v_o}{m_{t,i}}v_i + \frac{k_{d,i}v_o^2}{m_{t,i}}d_{(i-1)i} + k_{e,i}T_{e,i} \text{ (seguidores)}, \end{cases}$$

onde $\tilde{k}_{d,i} > 0$ é o coeficiente relacionado à resistência do ar e à velocidade do veículo e $k_{d,i} > 0$ é o coeficiente ou a resistência do ar relativa a distância entre os dois veículos. Valores típicos do intervalo de valores de k_d são 0,5 a 1,1 (SANDBERG, 2001), e $\tilde{k}_{d,i} = k_d(1 - \Phi(d)/100)$, onde $\Phi = 41,29 - 0,414d$, $d = \tau_s v$ e $v = v_o$ (ALAM; MARTENSSON; JOHANSSON, 2015).

Suposição 4.1. A massa $m_{t,i}$ e a velocidade de cruzeiro v_o são conhecidos ou podem ser medidas.

Suposição 4.2. O coeficiente $k_{e,i}$ que transforma o torque do motor ($T_{e,i}$) em força linear é conhecido.

O pelotão de veículos pode ser representada em uma forma compacta para N veículos

$$\begin{cases} \dot{v}_1 = \Theta_1 v_1 + k_{e,1} T_{e,1} \text{ (líder)} \\ \dot{v}_i = \Theta_i v_i + \delta_i d_{(i-1)i} + k_{e,i} T_{e,i} \text{ (seguidores)} \end{cases}$$

onde $i = 2, \dots, N$ é o número de HDVs em formação.

$$\Theta_1 = -\frac{2k_{d,1}v_o}{m_{t,1}}, \quad \Theta_i = -\frac{2\tilde{k}_{d,i}v_o}{m_{t,i}} \text{ and } \delta_i = -\frac{k_{d,i}v_o^2}{m_{t,i}}. \quad (4.2)$$

Considerando a velocidade dos HDVs (v_1, v_2, \dots, v_N) e a distância relativa entre os HDVs ($d_{12}, d_{23}, \dots, d_{(N-1)N}$).

4.2 Modelo do Controle dos Veículos HDV's em Pelotão

Neste estudo, considera-se que cada veículo possui um controle embarcado que mantém o controle de sua velocidade e a distância entre o veículo à sua frente, com o objetivo de manter a formação do pelotão.

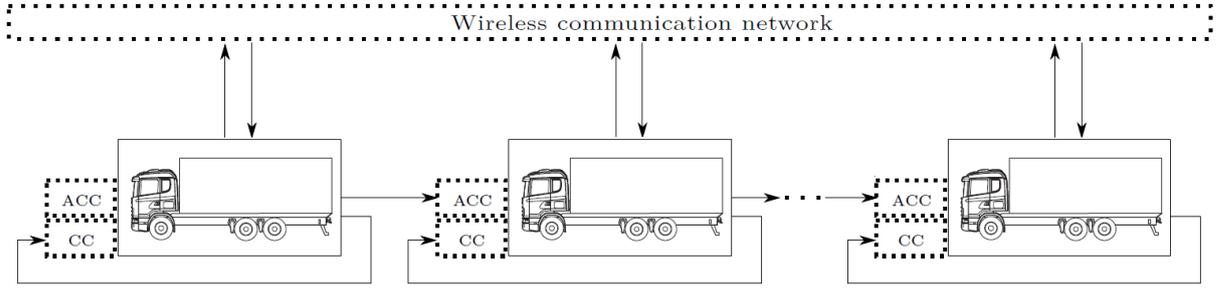
Um veículo autônomo em um pelotão sempre toma decisões baseado em estímulos do ambiente que o cerca, como aclives e declives do terreno, distância para os demais veículos, ou outros estímulos que venham a ser considerados no seu sistema de controle. Pode-se dizer, com isso, que a equação de movimento dos veículos é causal, pois sempre dependem de um estímulo no instante atual para ter uma resposta do veículo.

Cada HDV inserido em um pelotão tem duas camadas de controle e a conexão da rede sem fio para enviar informações relevantes entre os veículos. A camada mais inferior é a camada de Controle de Cruzeiro - CC (*Cruise control*), onde o controle atua na velocidade do veículo mantendo a velocidade selecionada pelo motorista. A camada acima é chamada de controle de cruzeiro avançado - ACC (*Advance Cruise Control*) usa um sensor de radar para controlar o espaçamento desejado ao veículo que precede (LIANG; MARTENSSON; JOHANSSON, 2016b).

Será considerado um pelotão formado por 3 veículos pesados (HDVs). A Figura 11 ilustra a arquitetura do sistema de pelotão para um pelotão de N veículos. O veículo líder com índice $i = 1$, é o da esquerda e o último veículo é o da direita. A arquitetura de controle de velocidade do veículo é mostrada a frente de cada veículo. O fluxo de informações no sistema é dado pelas setas (ALAM; MARTENSSON; JOHANSSON, 2015).

Para manter-se a formação do pelotão, um controle de realimentação de estados também pode ser projetado conforme a lei proposta por Alam, Gattami e Johansson (2011).

Figura 11 – Arquitetura de um sistema de pelotão para N veículos em pelotão.



Fonte: O autor adaptado de Liang, Martensson e Johansson (2016b).

$$T_{e,1} = -K_1^3 v_1 + r_{v1} \quad (4.3)$$

$$T_{e,i} = -K_i^1 v_{(i-1)} - K_i^2 d_{(i-1)i} - K_i^3 v_i + r_{vi}, \quad (4.4)$$

onde $T_{e,i}$ é o torque de entrada para o i^{th} veículo, o $K_i^{1,2,3}$ é o ganho de realimentação e o r_{vi} é a referência de velocidade atual.

A implementação desta lei de controle dá a seguinte representação em malha fechada:

$$\dot{v}_1 = (\Theta_1 - k_{e,1} K_1^3) v_1 + r_{v,1}, \text{ (líder)} \quad (4.5)$$

$$\dot{v}_i = (\Theta_i + k_{e,i} K_i^3) v_i + (\delta_i + k_{e,i} K_i^2) d_{(i-1)i} - k_{e,i} K_i^1 v_{(i-1)} + r_{v,i}. \text{ (seguidores)}. \quad (4.6)$$

O objetivo deste trabalho é a identificação do sistema em rede, o controle adotado é exposto com detalhes, quanto sua estabilidade e desenvolvimento no artigo de Alam2011.

4.3 Modelo de Representação de Redes Dinâmicas do Pelotão

Para apresentar o problema estudado na estrutura de identificação de redes dinâmicas (Dankers et al., 2016; GEVERS; BAZANELLA; PIMENTEL, 2018), são consideradas duas estruturas de rede:

- Baseada nos veículos, onde cada nó L corresponde a um HDV e N é considerado apenas a velocidade dos veículo.
- Baseada nos sensores, onde cada nó L corresponde a um tipo de sensor utilizada em cada um HDV. Assim, além da velocidade, a distância para o veículo à frente também é considerada.

Sendo os nós do sinal são representados como $\omega_1(t), \dots, \omega_L(t)$. Esses nós (de sinais), são relacionados entre si e com os sinais externos r_j e com sinal de ruído branco e_j pela equação de rede (2.38) apresentada na subseção 2.9.

A identificabilidade da rede pode ser avaliada, considerando um modelo com determinado valor de parâmetro θ_1 . O modelo é *localmente identificável em θ_1* se existe um $\delta > 0$ e um conjunto de dados $\mathbf{z}(\cdot) \triangleq \{u(\cdot), x_0\}$ de tal forma que, para todos $\theta \in \|\theta - \theta_1\| \leq \delta$, as saídas do modelo com esses dois valores de parâmetros diferentes θ e θ_1 , ambos conduzidos pelo mesmo conjunto de dados são idênticos (i.e. $\omega(t, \theta) = \omega(t, \theta_1) \forall t > 0$) somente se $\theta = \theta_1$. O modelo é *globalmente identificável em θ_1* se o mesmo vale para todos $\delta > 0$. O modelo é *estruturalmente identificável* se este for identificável para todos θ . O desenvolvimento do conceito de identificabilidade da rede pode ser visto com profundidade em Gevers, Bazanella e Pimentel (2018), Ljung (1999) e em Gevers et al. (2013).

O objetivo desse estudo é identificar o modelo da função de transferência de cada HDV e também os parâmetros k_d e \tilde{k}_d , que são ligados ao coeficiente de resistência do ar. Para isso, medidas da velocidade do veículo (v_i) e distância relativa ($d_{(i-1)i}$) são coletadas com um tempo de amostragem t_s . Para proceder com o processo de identificação, primeiro é necessário obter a função de transferência usando a aproximação de Euler Backward para as equações da velocidade (4.5) obtidas no controle por realimentação de estados apresentado na Seção 4.2.

$$V_i(q^{-1}) = -\frac{-K_i^1 k_{e,i} t_s}{(K_i^3 k_{e,i} t_s - \Theta_i t_s + 1 - q^{-1})} V_{(i-1)}(q^{-1}) + \frac{(\delta_i t_s - K_i^2 k_{e,i} t_s)}{K_i^3 k_{e,i} t_s - \Theta_i t_s + 1 - q^{-1}} D_{(i-1)i}(q^{-1}), \quad (4.7)$$

e para distância relativa

$$D_{(i-1)i}(q^{-1}) = (V_i(q^{-1}) - V_{(i-1)}(q^{-1})t_s)/(q^{-1} - 1), \quad (4.8)$$

onde q^{-1} é o operador de atraso, i.e. $q^{-1}u(t) = u(t - 1)$. Baseado em uma função de transferência discreta, o problema é fundido na representação do modelo de rede dinâmica.

4.3.1 Representação em Redes Dinâmicas Baseada no Veículo

Assumindo que o i -ésimo veículo controla a distância relativa usando apenas informações do veículo imediatamente anterior, a função de transferência discreta da velocidade do veículo líder $V_1(q^{-1})$ é a velocidade do último veículo $V_N(q^{-1})$ pode ser expressa por

$$V_N(q^{-1}) = G_1^v(q^{-1})G_2^v(q^{-1}) \cdots G_{N-1}^v(q^{-1})V_1(q^{-1}), \quad (4.9)$$

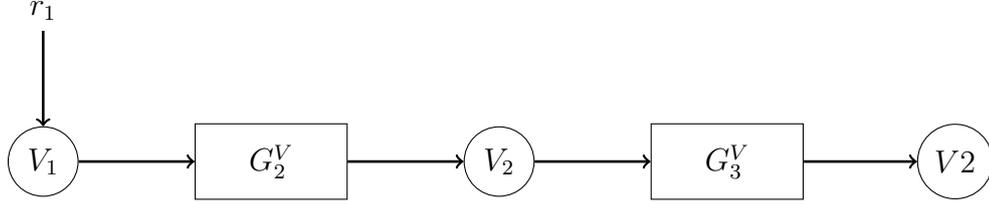
onde

$$V_i(q^{-1}) = G_i^v(q^{-1})V_{i-1}(q^{-1}), \quad i = 2, \dots, N. \quad (4.10)$$

Sendo que o sobrescrito $(\cdot)^v$ significa a estrutura de rede dinâmica baseada em veículo. Figura 12 representa o diagrama de bloco da equação (4.9), que é representada

como um ramo da rede. Onde o sinal r_1 representa o sinal de referência de velocidade para o veículo.

Figura 12 – Diagrama de bloco da dinâmica da rede baseada no veículo.



Fonte: O autor, 2020.

Substituindo (4.8) em (4.7) obtemos a função de transferência

$$G_i^v(q^{-1}, \hat{\theta}) = \frac{b_{0,i}^v + b_{1,i}^v q^{-1}}{a_{0,i}^v + a_{1,i}^v q^{-1} + a_{2,i}^v q^{-2}} \quad (4.11)$$

com

$$b_{0,i}^v = (\delta_i - k_{e,i} K_i^2) t_s^2 + (-k_{e,i} K_i^1) t_s, \quad (4.12)$$

$$b_{1,i}^v = (k_{e,i} K_i^1) t_s, \quad (4.13)$$

$$a_{0,i}^v = (1 - (\Theta_i + k_{e,i} K_i^3) t_s + (\delta_i - k_{e,i} K_i^2) t_s^2), \quad (4.14)$$

$$a_{1,i}^v = ((\Theta_i + k_{e,i} K_i^3) t_s - 2), \quad (4.15)$$

$$a_{2,i}^v = 1. \quad (4.16)$$

Considerando o método variáveis instrumentais IV (3.19) e (4.11) é definido o vetor de parâmetros e de regressores como:

$$\hat{\theta}_i^v = [a_{0,i}^v \ a_{1,i}^v \ a_{2,i}^v \ b_{0,i}^v \ b_{1,i}^v] \quad (4.17)$$

$$\phi_2^v = [-v_2[k] \ -v_2[k-1] \ -v_2[k-2] \ v_1[k] \ v_1[k-1]] \quad (4.18)$$

$$\phi_3^v = [-v_2[k] \ -v_3[k-1] \ -v_3[k-2] \ v_2[k] \ v_2[k-1]] \quad (4.19)$$

onde $i = \{2, 3\}$ e as variáveis instrumentais como (4.20).

Neste trabalho a escolha das variáveis instrumentais é um sinal de entrada da rede, a variável r_1 (a velocidade setada para o líder do pelotão) onde

$$z(t) = [r_1(t) \ r_1(t-1) \ r_1(t-2) \ \dots \ r_1(t-M)]. \quad (4.20)$$

Onde M é o numero de interações realizadas.

4.3.2 Representação em Redes Dinâmicas Baseada nos Sensores

A matriz de rede G^0 a partir da equação (2.38) representa a interconexão dos veículos HDVs. Tomando as equações discretas em malha fechada da formação do pelotão,

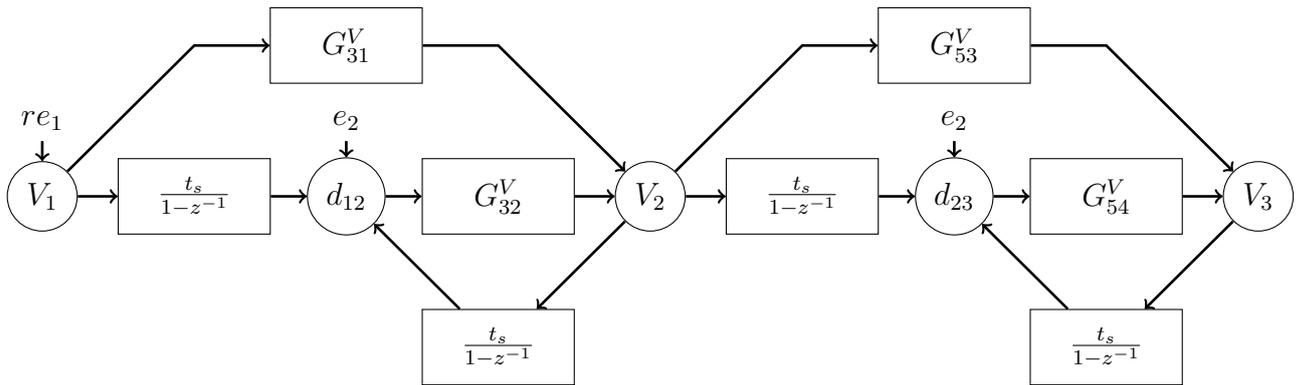
equações (4.7) e (4.8), e as medições do sensor de velocidade e sensor de distância relativa, a matriz de rede pode ser expressa como

$$\begin{bmatrix} v_1(t) \\ d_{12}(t) \\ v_2(t) \\ d_{23}(t) \\ v_3(t) \end{bmatrix} = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 \\ \frac{t_s}{1-z^{-1}} & 0 & -\frac{t_s}{1-z^{-1}} & 0 & 0 \\ -\frac{k_{e,2}K_2^1 t_s}{(-\Theta_2+k_{e,2}L_2^2)t_s+1-z^{-1}} & \frac{(\delta_2-k_{e,2}K_2^2)t_s}{(-\Theta_2+k_{e,2}K_2^2)t_s+1-z^{-1}} & 0 & 0 & 0 \\ 0 & 0 & \frac{t_s}{1-z^{-1}} & 0 & -\frac{t_s}{1-z^{-1}} \\ 0 & 0 & -\frac{k_{e,3}K_3^1 t_s}{(-\Theta_3+k_{e,3}K_3^1)t_s+1-z^{-1}} & \frac{(\delta_3-k_{e,3}K_3^2)t_s}{(-\Theta_3+k_{e,3}K_3^2)t_s+1-z^{-1}} & 0 \end{bmatrix} \begin{bmatrix} v_1(t) \\ d_{12}(t) \\ v_2(t) \\ d_{23}(t) \\ v_3(t) \end{bmatrix} + \begin{bmatrix} re_1(t) \\ re_2(t) \\ re_3(t) \\ re_4(t) \\ re_5(t) \end{bmatrix}. \quad (4.21)$$

A identificabilidade da rede dinâmica deve ser analisada para obter a identificação correta dos parâmetros da rede. Considerando que o único sinal de excitação é dado pelo líder do pelotão ($re_1(t) \neq 0$) e os parâmetros do HDV n° 2 são desejados, devemos garantir que os sinais $v_1(t)$, $v_2(t)$ e $d_{12}(t)$ são sinais não correlacionados, caso contrário, o subconjunto de parâmetros não é identificável.

Na Figura 13 podemos ver que o sinal $v_1(t)$ é correlacionado com $v_2(t)$ e $d_{12}(t)$ quando não houver ruído nas medições. Isso significa que a rede não é identificável, a menos que haja ruído não correlacionado nas medições de velocidade e distância relativa, i.e. $re_2(t) \neq re_3(t) \neq 0$. Para o HDV n° 3 nós temos um resultado similar, onde devemos garantir os sinais $v_2(t)$, $v_3(t)$ e $d_{23}(t)$ não são correlacionados, para garantir a identificabilidade da rede. Normalmente, na prática, todas as medições possuem ruído e isso é uma vantagem para a identificação dinâmica da rede.

Figura 13 – Diagrama de Blocos da rede dinâmica baseada nos sensores, representada pela equação (4.21).



Fonte: O autor, 2020.

Baseado na (4.21) os módulos ou as funções discretas de transferência a serem identificadas são apresentadas por

$$G_{(j(j-2))}^s(q^{-1}, \hat{\theta}) = \frac{b_{0,i}^s}{a_{0,i}^s + a_{1,i}^s q^{-1}} \quad (4.22)$$

$$G_{(j(j-1))}^s(q^{-1}, \hat{\theta}) = \frac{d_{0,i}^s}{c_{0,i}^s + c_{1,i}^s q^{-1}} \quad (4.23)$$

sendo $j = \{3, 5\}$ e $i = \{2, 3\}$, onde sobrescrito $(\cdot)^s$ significa a rede dinâmica baseada em sensor com

$$b_{0,i}^s = k_{e,i} K_i^1 t_s \quad (4.24)$$

$$d_{0,i}^s = (\delta_i - k_{e,i} K_i^2) t_s \quad (4.25)$$

$$a_{0,i}^s = c_{0,i}^s = (\Theta_i - k_{e,i} K_i^3) t_s + 1 \quad (4.26)$$

$$a_{1,i}^s = c_{1,i}^s = 1 \quad (4.27)$$

Os parâmetros são identificados usando o método IV (3.19), (4.22) e (4.23). Baseado nisso, define-se os vetores de parâmetros e os regressores

$$\hat{\theta}_{(j(j-2))}^s = [a_{0,i}^s \quad a_{1,i}^s \quad b_{0,i}^s] \quad (4.28)$$

$$\phi_{(j(j-2))}^s = [-v_i[k] \quad -v_i[k-1] \quad v_{(i-1)}[k]] \quad (4.29)$$

$$\hat{\theta}_{(j(j-1))}^s = [c_{0,i}^s \quad c_{1,i}^s \quad d_{0,i}^s] \quad (4.30)$$

$$\phi_{(j(j-1))}^s = [-v_i[k] \quad -v_i[k-1] \quad d_{(i-1)i}[k]] \quad (4.31)$$

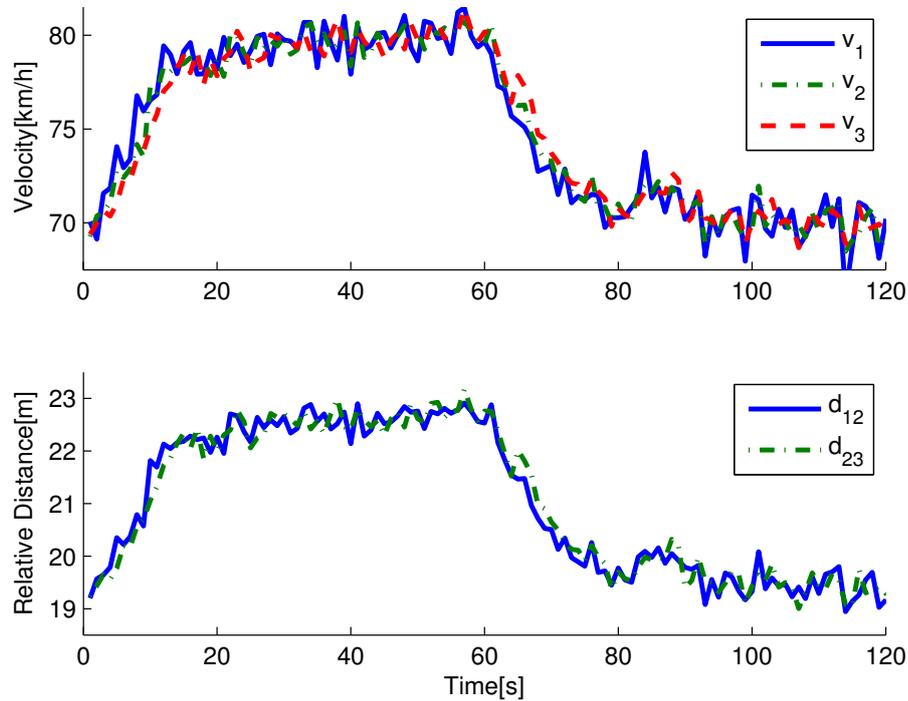
e consideramos as variáveis instrumentais como (4.20).

4.4 Implementação e Simulação Numérica

Simulações são geradas considerando $n = 1000$ diferentes realizações do ruído do sensor de distância relativa, que é um ruído branco com variação 0, 1. Três veículos autônomos serão utilizados para implementação, no ambiente de simulação numérica, com tempo de amostragem de 1ms. Os veículos possuem um modelo matemático conhecido e descritos pela Seção 4.1.

No procedimento simulado, semelhante ao proposto por (ALAM; MARTENSSON; JOHANSSON, 2015), primeiro é considerado que o pelotão de HDV está se movendo em velocidade constante de 70 km/h ($v_o=70$ km/h), significa que a distância entre o veículo é constante como definido anteriormente ($\tau_{s,o}=1s$). O distúrbio na rede é adicionado pelo líder que é forçado a acelerar através de uma alteração de velocidade de 70km/h para 80km/h e depois de 60 segundos retoma a velocidade de cruzeiro de 70km/h. Isso resulta em um degrau de excitação no pelotão de veículos, como é mostrado na Figura 14. O sensor de radar, que mede a distância relativa entre dois HDVs, são considerados como tendo ruído branco com variação de 0, 1. É importante destacar que diferentemente do trabalho apresentado por Dai et al. (2018), Liang, Martensson e Johansson (2016b), Sedran (2016), cada veículo tem um comportamento diferente, o que significa que $m_{t,1} \neq m_{t,2} \neq m_{t,3}$, $\tilde{k}_{d,1} \neq \tilde{k}_{d,2} \neq \tilde{k}_{d,3}$ e $k_{d,1} \neq k_{d,2} \neq k_{d,3}$.

Figura 14 – Dados da simulação para identificar a função de transferência dos veículos.



Fonte: O autor, 2020.

Os parâmetros da simulação de cada veículo são apresentados na tabela a seguir:

Tabela 1 – Dados para simulação numérica veículo 1.

| Parâmetros | Veículo 1 |
|------------|------------------------|
| $m_{t,1}$ | 40000kg |
| $k_{e,1}$ | $0,148 \times 10^{-3}$ |
| $k_{d,1}$ | 0.6 |
| v_0 | 19,44m/s(70km/h) |
| k_1^3 | $0,98 \times 10^3$ |

Tabela 2 – Dados para simulação numérica veículo 2.

| Parâmetros | Veículo 2 |
|------------|------------------------|
| $m_{t,1}$ | 30000kg |
| $k_{e,1}$ | $0,148 \times 10^{-3}$ |
| v_0 | 19,44m/s(70km/h) |
| k_2^1 | -6.56×10^3 |
| k_2^2 | 500.35×10^3 |
| k_2^3 | 590.03×10^3 |

Tabela 3 – Dados para simulação numérica veículo 3.

| Parâmetros | Veículo 3 |
|------------|------------------------|
| $m_{t,1}$ | $50000kg$ |
| $k_{e,1}$ | $0,148 \times 10^{-3}$ |
| v_0 | $19,44m/s(70km/h)$ |
| k_3^1 | -6.8×10^3 |
| k_3^2 | 590.35×10^3 |
| k_3^3 | 700.03×10^3 |

4.4.1 Simulação Numérica - Rede Baseada no Veículo

A rede é identificável, pois ela possui a estrutura de um ramo. Para isso, o método das variáveis instrumentais, apresentado na seção 3.1.2, usa os dados para estimar a função de transferência dos veículos e também o coeficiente de atrito do ar.

Para obter os parâmetros desejados ($k_{d,i}$ e $\tilde{k}_{d,i}$) primeiro é preciso computar Θ_i e δ_i usando equações (4.15) e (4.12), respectivamente, e depois equações apresentadas em (4.2).

A Figura 15 e 16, mostra a representação de Bode da diferença entre o modelo real do veículo e o modelo identificado. Também a Tabela 4 apresenta os valores reais, os valores médios estimados e suas variações para a identificação dos coeficientes de resistência do ar. A seguir, apresentar-se-ão os resultados para a identificação da rede baseada em sensor e, posteriormente, a comparação entre os dois resultados.

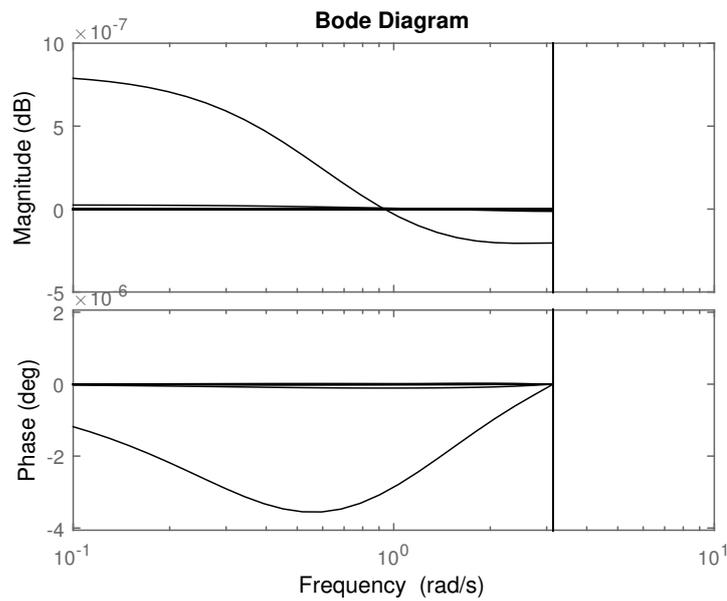
4.4.2 Simulação Numérica - Rede Baseada nos Sensores

O procedimento de identificação usa o mesmo conjunto de dados apresentado na seção anterior. Como o sistema é representado como uma rede dinâmica baseada nos sensores, que considera as medidas de $v_1(t)$, $v_2(t)$ e $d_{12}(t)$, onde $d_{12}(t)$ (o sensor de radar do HDV nº 2) possui medições ruidosas para a identificação do HDV nº 2. Um regressor semelhante é considerado para o terceiro veículo, mas neste caso ele usa as medidas de $v_2(t)$, $v_3(t)$ e $d_{23}(t)$, onde $d_{23}(t)$ (o sensor de radar do HDV nº 3) possui medições ruidosas para a identificação do HDV nº 3. Para obter os parâmetros desejados ($k_{d,i}$ e $\tilde{k}_{d,i}$) primeiro computamos Θ_i e δ_i usando equações (4.26) e (4.25), respectivamente, e depois as equações apresentadas em (4.2). Os valores reais, os valores médios estimados e sua variância são apresentados na Tabela 4.

Tabela 4 – Resultados da identificação do coeficiente de resistência do Ar $n = 1000$.

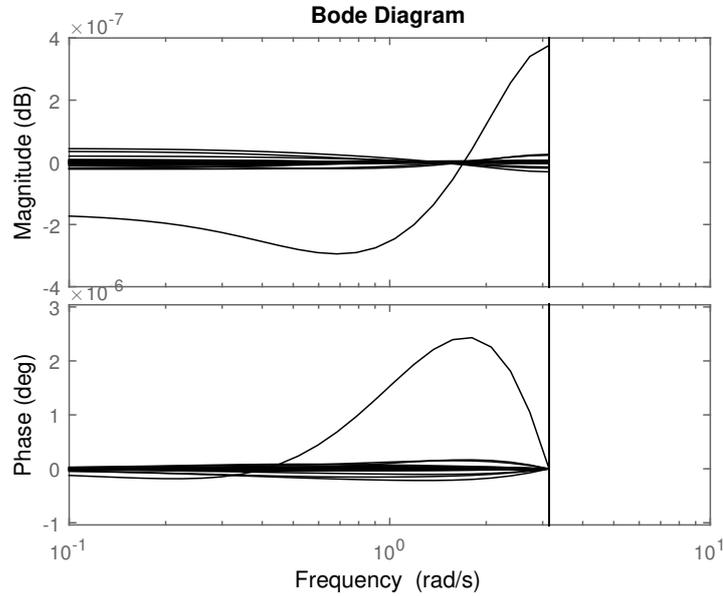
| 2*Parâmetros | 2*Valor Real | Valores Estimados (Estrutura Baseada no Veículo) | | Valores Estimados (Estrutura Baseada nos Sensores) | |
|-----------------|------------------------|--|------------------------|--|-------------------------|
| | | Media | Variância | Media | Variância |
| $k_{d,2}$ | 1.100×10^0 | 1.097×10^0 | 1.230×10^{-2} | 1.099×10^0 | 2.979×10^{-6} |
| $\hat{k}_{d,2}$ | 8.228×10^{-1} | 8.240×10^{-1} | 2.729×10^{-3} | 8.228×10^{-1} | 6.567×10^{-7} |
| $k_{d,3}$ | 8.000×10^{-1} | 8.009×10^{-1} | 2.983×10^{-2} | 8.000×10^{-1} | 3.673×10^{-9} |
| $\hat{k}_{d,3}$ | 5.340×10^{-1} | 5.336×10^{-1} | 6.704×10^{-3} | 5.340×10^{-1} | 8.209×10^{-10} |

Figura 15 – Diagrama Bode da diferença entre a função de transferência identificada e verdadeira. Veículo n°2 identificação da rede "baseada em veículo" $G_2^v(q^{-1}, \hat{\theta}_2^v)/G_2^v(q^{-1})$



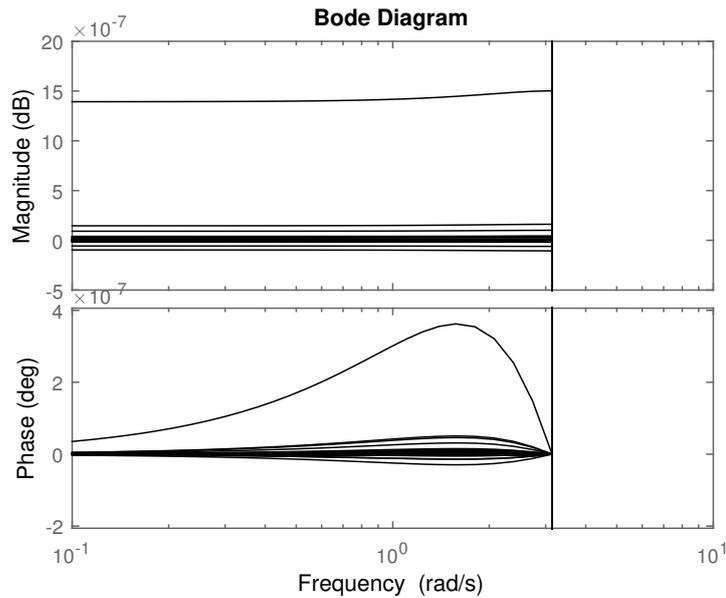
Fonte: O autor, 2020.

Figura 16 – Diagrama Bode da diferença entre a função de transferência identificada e verdadeira. Veículo nº3 identificação da rede "baseada em veículo" $G_3^v(q^{-1}, \hat{\theta}_3^v)/G_3^v(q^{-1})$



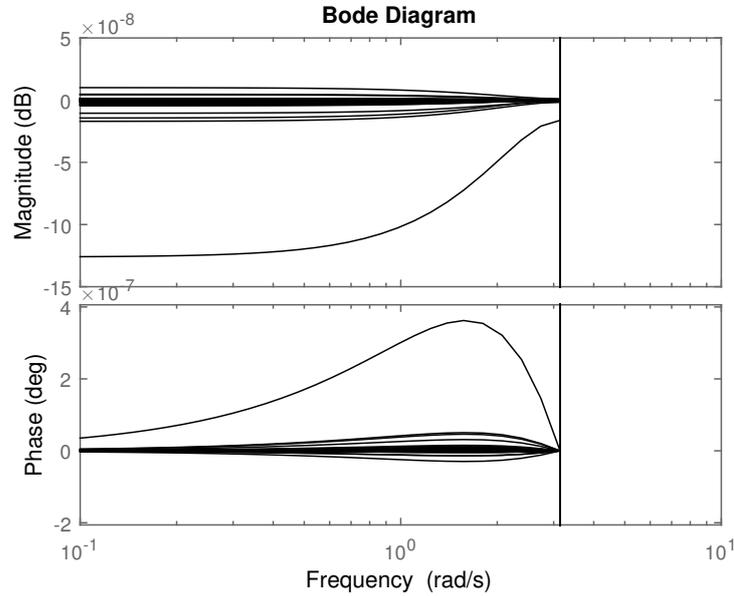
Fonte: O autor, 2020.

Figura 17 – Diagrama Bode da diferença entre a função de transferência identificada e verdadeira. Veículo nº2 identificação da rede "baseada em sensor" $G_{31}^s(q^{-1}, \hat{\theta}_{31}^s)/G_{31}^s(q^{-1})$



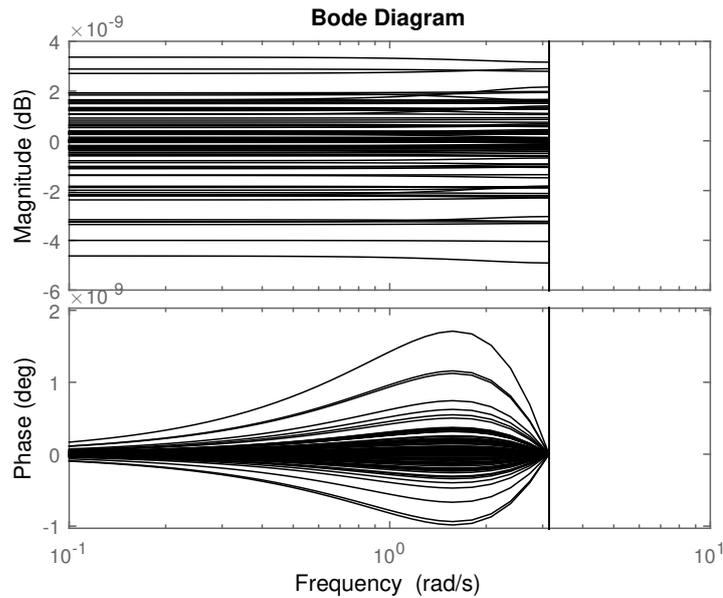
Fonte: O autor, 2020.

Figura 18 – Diagrama Bode da diferença entre a função de transferência identificada e verdadeira. Veículo nº2 identificação da rede "baseada em sensor" $G_{32}^s(q^{-1}, \hat{\theta}_{32})/G_{32}^s(q^{-1})$



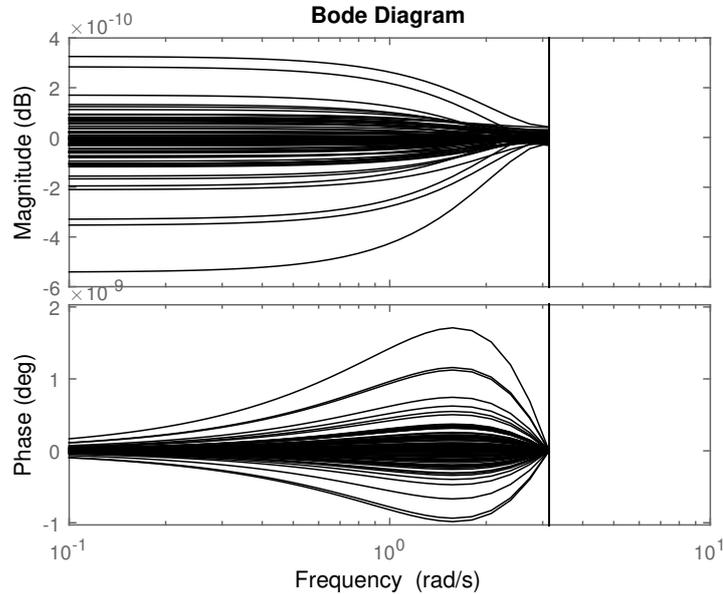
Fonte: O autor, 2020.

Figura 19 – Diagrama Bode da diferença entre a função de transferência identificada e verdadeira. Veículo nº3 identificação da rede "baseada em sensor" $G_{53}^s(q^{-1}, \hat{\theta}_{53})/G_{53}^s(q^{-1})$



Fonte: O autor, 2020.

Figura 20 – Diagrama Bode da diferença entre a função de transferência identificada e verdadeira. Veículo nº3 identificação da rede "baseada em sensor" $G_{54}^s(q^{-1}, \hat{\theta}_{54})/G_{54}^s(q^{-1})$



Fonte: O autor, 2020.

As figuras 15,16,17,18,19,20, apresentam os diagramas de bode da diferença entre as funções de transferência identificadas e as verdadeiras. Observe que as funções de transferência da identificação baseada em sensor são mais precisas que a identificação da base do veículo, com magnitudes ao redor de 10^{-9} . Comparando os resultados da Tabela 4 é evidente que a variação dos parâmetros estimados para a representação de rede dinâmica baseada em sensor é quase cinco vezes menor que a estrutura baseada em veículo, como apresentado na Figura 20. É importante destacar que o conjunto de dados das velocidades usadas para os dois procedimentos de identificação são os mesmos. Isso mostra o impacto da estrutura dinâmica da rede na variação da estimação. Dependendo da estrutura de rede do sistema, é possível obter o mesmo modelo com ordem reduzida, o que afeta a variância das estimativas. Além disso, os resultados mostram que quanto mais profunda é a função de transferência desejada na rede, se a identificabilidade for garantida, menor a variância nos modelos identificados, resultando em um modelo mais confiável para fins de controle.

5 Conclusão

A identificação do modelo dinâmico de rede é útil para muitas aplicações com sistemas de controle distribuído. Ao longo da dissertação, foi desenvolvida a fundamentação teórica da identificação de redes dinâmicas. No estado da arte, foram apresentados os métodos usuais de identificação e, no capítulo 3, abordado com mais profundidade o método de variáveis instrumentais utilizado na análise desenvolvida. Nessa dissertação, foi apresentado um método para identificar a função de transferência de cada veículo em um pelotão, formatado como uma rede. Através da identificação da função de transferência dos veículos, também foi identificado o coeficiente de resistência do ar para cada veículo do pelotão. O modelo de cada veículo foi proposto no capítulo 4.

Duas representações dinâmicas de rede diferentes foram apresentadas para o mesmo sistema: representação baseada no veículo, levando em consideração apenas o conhecimento da velocidade de cada HDV, e representação de redes dinâmicas baseada em sensor, em que foi acrescentado o sensor de distância na topologia da rede.

Uma simulação numérica foi realizada nas topologias de rede propostas e a função de transferência dos veículos foi identificada. As diferenças entre as funções de transferência identificadas e as verdadeiras, e a variação dos coeficientes de resistência do ar se tornam menores na topologia baseada em sensor, mostrando que a topologia escolhida influencia as estimativas.

Como resultado desta pesquisa foi desenvolvido e apresentado o artigo Guilherme A. Pimentel et al. (2020), no 21st IFAC World Congress, 2020.

5.1 Trabalhos Futuros

Os métodos estudados podem ser aplicados a um protótipo de pelotão de veículos a fim de obter dados reais de simulação, para a identificação do sistema com dados reais, para que se possa comparando os resultados simulados numericamente e os obtidos no protótipo. O projeto e a implementação do protótipo para 3 veículos autônomos de escala laboratorial está apresentado no Apêndice A desta dissertação.

A continuação do estudo na área de identificação do modelo do pelotão de veículos pode ser usada para, a partir do modelo identificado, aprimorar as técnicas de controle do pelotão, procurando diminuir ainda mais o espaço entre os veículos do pelotão durante o deslocamento, gerando assim, maior economia de combustível e benefícios ambientais.

A partir da identificação dos parâmetros relacionados ao arrasto aerodinâmico dos veículos, pode ser desenvolvida pesquisa para aplicação de métodos de controle com o objetivo de encontrar a distância ótima entre os veículos em relação ao arrasto aerodinâmico.

Referências

- AGUIRRE, L. A. *Introdução À Identificação de Sistemas*. [S.l.]: Editora UFMG, 2007. Citado 6 vezes nas páginas 15, 16, 17, 26, 40 e 43.
- ALAM, A.; MARTENSSON, J.; JOHANSSON, K. H. Experimental evaluation of decentralized cooperative cruise control for heavy-duty vehicle platooning. *Control Engineering Practice*, v. 38, p. 11 – 25, 2015. ISSN 0967-0661. Citado 3 vezes nas páginas 47, 48 e 53.
- Alam, A. A.; Gattami, A.; Johansson, K. H. Suboptimal decentralized controller design for chain structures: Applications to vehicle formations. In: *2011 50th IEEE Conference on Decision and Control and European Control Conference*. [S.l.: s.n.], 2011. p. 6894–6900. Citado na página 48.
- ASHOK, B.; ASHOK, S. D.; KUMAR, C. R. A review on control system architecture of a si engine management system. *Annu. Rev. Control.*, v. 41, p. 94–118, 2016. Citado na página 30.
- Bazanella, A. S.; Gevers, M.; Hendrickx, J. M. Network identification with partial excitation and measurement. In: *2019 IEEE 58th Conference on Decision and Control (CDC)*. [S.l.: s.n.], 2019. p. 5500–5506. Citado na página 22.
- CHIUSO, A.; PILLONETTO, G. A bayesian approach to sparse dynamic network identification. *Automatica*, v. 48, n. 8, p. 1553 – 1565, 2012. ISSN 0005-1098. Citado na página 19.
- CNT. *Boletim Estatístico - Confederação Nacional de Transporte - February 2019*. [S.l.], 2019. Citado na página 22.
- COMMISSION, E. *EU TRANSPORT - STATISTICAL POCKETBOOK 2018*. [S.l.], 2108. Citado na página 22.
- DAI, S.-L. et al. Platoon formation control with prescribed performance guarantees for usvs. *IEEE Transactions on Industrial Electronics*, v. 65, 2018. Citado 2 vezes nas páginas 23 e 53.
- DANKERS, A. et al. Conditions for handling confounding variables in dynamic networks. *IFAC-PapersOnLine*, v. 50, n. 1, p. 3983 – 3988, 2017. 20th IFAC World Congress. Citado na página 21.
- Dankers, A. et al. Identification of dynamic models in complex networks with prediction error methods: Predictor input selection. *IEEE Transactions on Automatic Control*, v. 61, n. 4, p. 937–952, April 2016. ISSN 0018-9286. Citado 7 vezes nas páginas 15, 19, 21, 35, 37, 38 e 49.
- DANKERS, A. G. *System Identification in Dynamic Networks*. Tese (Doutorado) — Delft University of Technology, 2014. Citado 4 vezes nas páginas 20, 22, 25 e 35.

- Forsell, U.; Ljung, L. Identification of unstable systems using output error and box-jenkins model structures. *IEEE Transactions on Automatic Control*, v. 45, n. 1, p. 137–141, 2000. Citado na página 21.
- FRANKLIN, G. F.; POWELL, J. D.; EMAMI-NAEINI, A. *Sistemas de controle para engenharia*. 6. ed. [S.l.]: Bookman, Porto Alegre, 2013. Citado na página 28.
- GALRINHO, M.; EVERITT, N.; HJALMARSSON, H. Incorporating noise modeling in dynamic networks using non-parametric models **this work was supported by the swedish research council under contracts 2015-05285 and 2016-06079. *IFAC-PapersOnLine*, v. 50, n. 1, p. 10568 – 10573, 2017. ISSN 2405-8963. 20th IFAC World Congress. Citado na página 22.
- GEVERS, M. et al. Identifiability and excitation of linearly parametrized polynomial systems. In: *Proceedings of 52nd IEEE Conference on Decision and Control (CDC2013)*. [S.l.: s.n.], 2013. v. 1. Citado na página 50.
- GEVERS, M.; BAZANELLA, A. S.; da Silva, G. V. A practical method for the consistent identification of a module in a dynamical network. *IFAC-PapersOnLine*, v. 51, n. 15, p. 862 – 867, 2018. ISSN 2405-8963. 18th IFAC Symposium on System Identification SYSID 2018. Citado na página 21.
- GEVERS, M.; BAZANELLA, A. S.; PIMENTEL, G. A. Emerging applications of control and systems. In: _____. [S.l.]: Springer International Publishing AG, 2018. cap. Identification of Dynamical Networks, p. 151 – 163. Citado 5 vezes nas páginas 25, 36, 37, 49 e 50.
- GRANGER, C. W. J. Investigating causal relations by econometric models and cross-spectral methods. *Econometrica*, [Wiley, Econometric Society], v. 37, n. 3, p. 424–438, 1969. Citado na página 19.
- Guilherme A. Pimentel et al. Network topology impact on the identification of dynamic network models with application to autonomous vehicle platooning. In: *21st IFAC World Congress*. [S.l.: s.n.], 2020. Citado na página 60.
- Hendrickx, J. M.; Gevers, M.; Bazanella, A. S. Identifiability of dynamical networks with partial node measurements. *IEEE Transactions on Automatic Control*, v. 64, n. 6, p. 2240–2253, 2019. Citado na página 21.
- HOF, P. M. V. den; RAMASWAMY, K. R. Single module identification in dynamic networks - the current status. *IFAC*, 2020. 21th IFAC World Congress. Citado 2 vezes nas páginas 20 e 21.
- KIVITS, E.; J. Van den Hof, P. M. On representations of linear dynamic networks. In: *18th IFAC Symposium on System Identification*. [S.l.: s.n.], 2018. Citado na página 29.
- LATHI, B. *Sinais e Sistemas Lineares*. 2. ed. [S.l.]: Bookman, São Paulo, 2007. Citado 2 vezes nas páginas 26 e 27.
- LIANG, K.-Y. *Fuel-Efficient Heavy-Duty Vehicle Platoon Formation*. Tese (Doutorado) — KTH Royal Institute of Technology - School of Electrical Engineering, 2016. Citado 3 vezes nas páginas 16, 22 e 23.

- LIANG, K.-Y.; MARTENSSON, J.; JOHANSSON, K. H. Experiments on platoon formation of heavy trucks in traffic. In: *2016 IEEE 19th International Conference on Intelligent Transportation Systems (ITSC)*. [S.l.: s.n.], 2016. Citado na página 22.
- LIANG, K.-Y.; MARTENSSON, J.; JOHANSSON, K. H. Heavy-duty vehicle platoon formation for fuel efficiency. *IEEE Transactions on Intelligent Transportation Systems*, v. 17, n. 4, 2016. Citado 4 vezes nas páginas 22, 48, 49 e 53.
- LJUNG, L. *System Identification*. [S.l.]: Prince-Hall, Inc, 1999. Citado 3 vezes nas páginas 15, 20 e 50.
- Materassi, D.; Salapaka, M. V. On the problem of reconstructing an unknown topology via locality properties of the wiener filter. *IEEE Transactions on Automatic Control*, v. 57, n. 7, p. 1765–1777, 2012. Citado na página 19.
- MICHAELIAN, M.; BROWAND, F. Field experiments demonstrate fuel savings for close-following. 01 2000. Citado na página 22.
- NORRBY, D. *A CFD Study Of The Aerodynamic Eects OfPlatooning Trucks*. 135 p. Dissertação (Mestrado) — KTH, Mechanics, 2014. Citado na página 22.
- OGATA, K. *Engenharia de Controle Moderno 5ª edição*. [S.l.]: Pearson Education do Brasil Ltda, São Paulo, Brasil, 2014. Citado 4 vezes nas páginas 18, 25, 31 e 32.
- RAMASWAMY, K. R.; HOF, P. M. J. V. den. A local direct method for module identification in dynamic networks with correlated noise. *ArXiv*, abs/1908.00976, 2019. Citado na página 21.
- Ramaswamy, K. R.; J. Van den Hof, P. M.; Dankers, A. G. Generalized sensing and actuation schemes for local module identification in dynamic networks. In: *2019 IEEE 58th Conference on Decision and Control (CDC)*. [S.l.: s.n.], 2019. p. 5519–5524. Citado na página 22.
- RUSSELL, B. On the notion of cause. *Proceedings of the Aristotelian Society*, [Aristotelian Society, Wiley], v. 13, p. 1–26, 1912. ISSN 00667374, 14679264. Citado na página 25.
- Sanandaji, B. M.; Vincent, T. L.; Wakin, M. B. Exact topology identification of large-scale interconnected dynamical systems from compressive observations. In: *Proceedings of the 2011 American Control Conference*. [S.l.: s.n.], 2011. p. 649–656. Citado na página 19.
- SANDBERG, T. *Heavy Truck Modeling for Fuel Consumption Simulations and Measurements*. Tese (Doutorado) — Linköping Studies in Science and Technology, 2001. Citado na página 47.
- SEDRAN, S. *A truck dynamics model for driving simulators*. Tese (Doutorado) — Automotive Engineering Department of Applied Mechanics Gothenburg, 2016. Citado 2 vezes nas páginas 23 e 53.
- SÖDERSTRÖM, T.; STOICA, P. *Instrumental Variable Methods for System Identification*. [S.l.]: Springer, Berlin, Heidelberg, 1983. Citado na página 21.

- SÖDERSTRÖM, T.; STOICA, P. Instrumental variable methods for system identification. *Circuits, Systems and Signal Processing*, 2002. ISSN 1531-5878. Citado 3 vezes nas páginas 21, 43 e 44.
- TANG, W.; DAOUTIDIS, P. Distributed control and optimization of process system networks: A review and perspective. *Chinese Journal of Chemical Engineering*, v. 27, n. 7, p. 1461 – 1473, 2019. ISSN 1004-9541. Citado 2 vezes nas páginas 15 e 35.
- THORP, J. S.; PHADKE, A. G. Computer relaying in power systems. In: LEONDES, C. (Ed.). *Analysis and Control System Techniques for Electric Power Systems, Part 4 of 4*. [S.l.]: Academic Press, 1991, (Control and Dynamic Systems, v. 44). p. 1 – 57. Citado na página 15.
- Van Den Hof DOUWE K. DE VRIES, P. S. P. M. J. Delay structure conditions for identifiability of close loop systems. *Automatica*, v. 28, n. 5, p. 1047–1050, 1992. Citado na página 20.
- Van den Hof, P. M. et al. Identification of dynamic models in complex network with prediction error methods - basic methods for consistent module estimates. *Automatica*, v. 49, p. 2994 – 3006, 2013. Citado 3 vezes nas páginas 21, 29 e 36.
- Van den Hof, P. M.; DANKERS, A. G.; WEERTS, H. H. From closed-loop identification to dynamic networks. *2017 IEEE 56th Annual Conference on Decision and Control*, 2018. Citado 2 vezes nas páginas 15 e 20.
- Van Den Hof, P. M.; SCHRAMA, R. J. An indirect method for transfer function estimation from closed loop data. *Automatica*, v. 29, n. 6, p. 1523 – 1527, 1993. Citado na página 21.
- Vidyasagar, M. On the well-posedness of large-scale interconnected systems. *IEEE Transactions on Automatic Control*, v. 25, n. 3, p. 413–421, 1980. Citado na página 19.
- WEERTS, H. H. et al. A sequential least squares algorithm for armax dynamic network identification. *IFAC-PapersOnLine*, v. 51, n. 15, p. 844 – 849, 2018. ISSN 2405-8963. 18th IFAC Symposium on System Identification SYSID 2018. Citado na página 29.
- WEERTS, H. H.; Van den Hof, P. M.; DANKERS, A. G. Identification in dynamic networks. *elsevier*, 2017. Citado na página 20.
- WEERTS, H. H. M. et al. Abstractions of linear dynamic networks for input selection in local module identification. *CoRR*, abs/1901.00348, 2019. Citado na página 21.
- WILMSMEIER, G.; SPENGLER, T. The evolution of modal split in freight transport in south america, 2000-2013. *Cepal - Bulletin FAL*, v. 343, n. 7, 2015. Citado na página 22.
- Wu, X.; Wang, W.; Zheng, W. X. Topology detection of complex networks with hidden variables and stochastic perturbations. In: *2012 IEEE International Symposium on Circuits and Systems (ISCAS)*. [S.l.: s.n.], 2012. p. 898–901. Citado na página 19.
- Yu, C.; Verhaegen, M. Subspace identification of individual systems operating in a network (si²on). *IEEE Transactions on Automatic Control*, v. 63, n. 4, p. 1120–1125, 2018. Citado na página 22.

A Implementação Protótipo

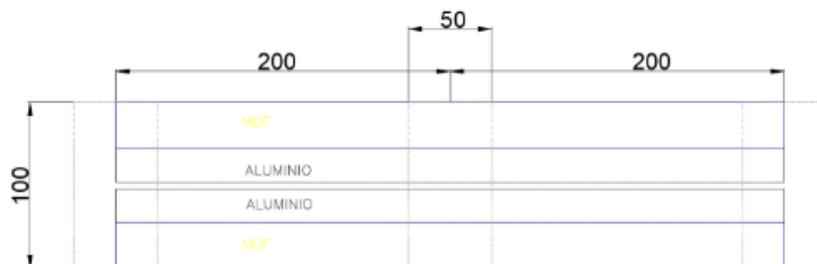
A.1 Protótipo

O protótipo é dividido em 2 sistemas, pista e veículos. A pista é a plataforma onde os veículos andam. Os veículos possuem um microcontrolador, sensores, rádio, e o software que implementa o sistema de controle e coleta de dados. Esta seção segue essa mesma divisão. O conceito do desenvolvimento deste protótipo teve como primícia eliminar os movimentos dos veículos em apenas uma direção, eliminando as variáveis relacionadas à direção do sistema, utilizar um sistema que não utiliza baterias, para praticidade e continuidade dos testes, e utilizar comunicação via rádio para troca de informações e coleta de dados.

A.1.1 Pista

A pista desenvolvida se baseia na estrutura de uma pista de autorama. Com essa escolha, muitos componentes utilizados no protótipo são análogos de autoramas e podem ser utilizados em nosso protótipo. A pista foi fabricada nos laboratórios da PUC/RS (pelos alunos de iniciação científica). A pista possui sua base em MDF, com guias condutoras de energia, que são feitas com duas barras de alumínio paralelas com um vão guia entre elas, dispostas sobre travessas de MDF que ajustam a largura da pista, complementares às barras de alumínio para finalizar a pista e o trecho de rodagem dos pneus dos veículos, foram cortados trechos de MDF. As dimensões dessas peças estão nas figuras 21 e 22.

Figura 21 – Trecho de pista, vista superior.



Fonte: O autor, 2020.

Figura 22 – Pista, corte transversal.

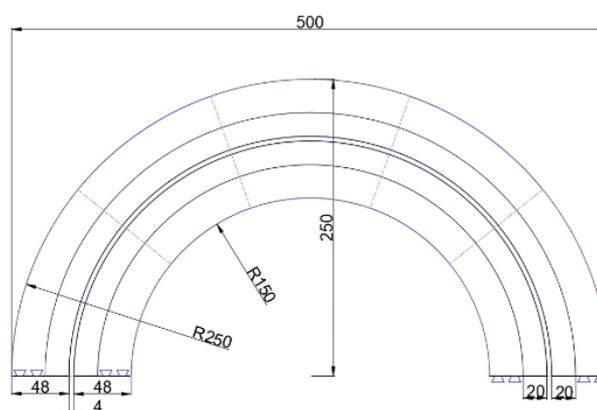


Fonte: O autor, 2020.

A construção das curvas seguiu o croqui da figura 23.

Na tabela 5, está descrita a especificação dos materiais empregados na fabricação da pista de testes.

Figura 23 – Materiais empregados na fabricação da pista.



Fonte: O autor, 2020.

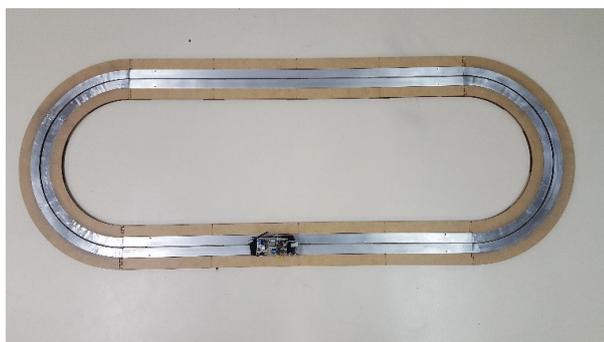
Tabela 5 – Materiais empregados na fabricação da pista.

| Material | Especificação |
|--------------------------------|----------------|
| Fibra de Média Densidade (MDF) | Espessura: 3mm |
| Barras chatas de alumínio | Espessura: 3mm |
| Fio condutor elétrico | Diâmetro: 1mm |
| Cianoacrilato (Super Bonder) | |
| Cola PVA (cola para madeira) | |

A pista possui alimentação 15V contínua, fornecida por uma fonte externa. Essa energia é fornecida aos veículos através das barras de alumínio ao longo da pista, sendo uma barra de polaridade positiva e outra negativa.

Na figura 24 pode ser vista a pista concluída.

Figura 24 – Pista construída para testes.



Fonte: O autor, 2020.

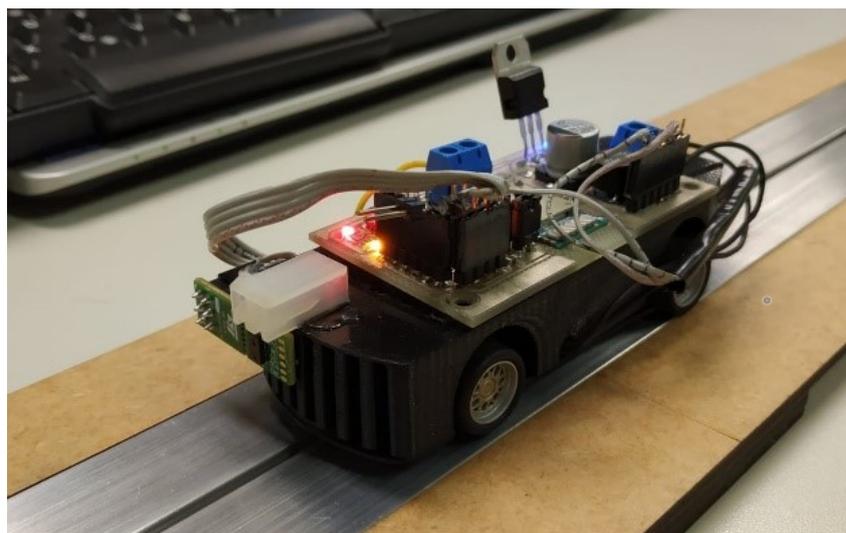
A.1.2 Veículos

Os veículos foram montados sobre o chassi de um veículo de autorama. Dessa forma, a conexão elétrica do veículo com a pista, as escovas, já está incorporada no chassi e de fácil substituição. Já estão incorporados no chassis do veículo o motor transmissão e as rodas. Foi desenvolvida na impressora 3d uma carenagem para acomodar a parte eletrônica e os sensores, com encaixe sobre o chassi do veículo de autorama.

Os veículos são baseados na escala 1:43, os chassis utilizados são da marca SCX. A alimentação elétrica dos motores é modelada por pulsos PWM.

Na figura 25 uma imagem de um dos veículos desenvolvidos é apresentada.

Figura 25 – Veículo do protótipo utilizado nos testes.



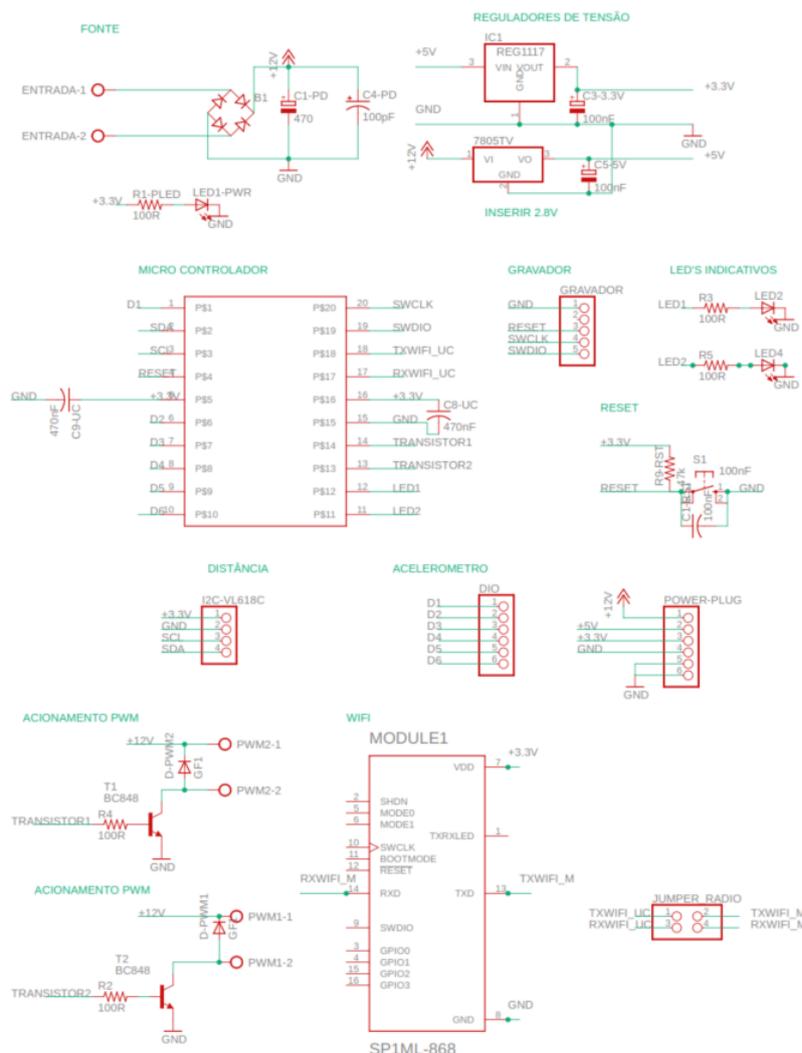
Fonte: O autor, 2020.

A parte eletrônica do veículo é dividida em duas categorias: a placa de controle e os sensores. A placa pode ser dividida em quatro partes, quais sejam: circuito de alimentação,

circuito de potência, circuito de controle e circuito de comunicação. O circuito de alimentação é responsável pela alimentação interna do sistema. Nesta divisão, há reguladores de tensão 3.3V e 5V, ponte de retificação para ajuste da polaridade, capacitores de filtro, pois a alimentação da pista é obtida através de escovas que geram ruído elétrico. O circuito de potência é formado por transistors responsáveis por acionar via PWM os motores e um diodo rápido inversamente polarizado a fim de eliminar correntes geradas pelo efeito de chaveamento do PWM sobre uma carga indutiva. O circuito de controle é formado pelo microcontrolador. Esse componente é responsável pela manipulação de todos os periféricos do veículo. O microcontrolador utilizado foi o st32xxxx. O circuito de comunicação é composto pelo rádio SPIRIT1 868, que é responsável pelo tráfego de informação através de uma comunicação “RX TX” entre os dados do protótipo e o computador.

O esquemático da placa é apresentado abaixo (figura 26).

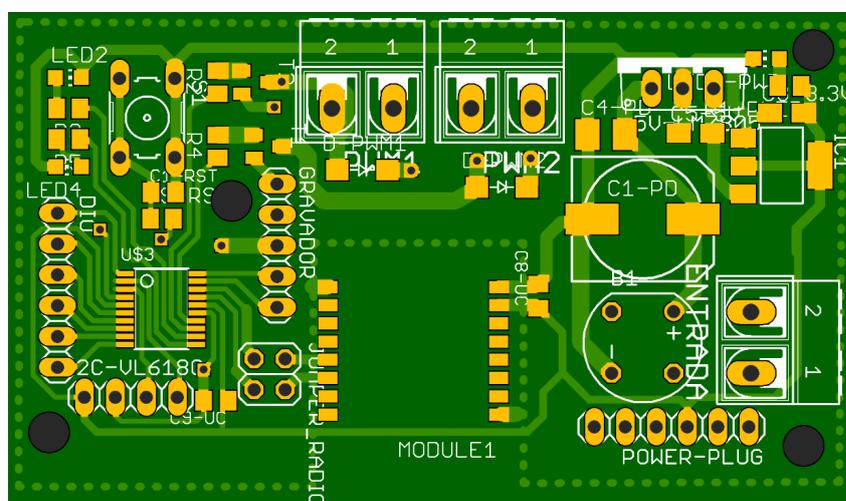
Figura 26 – Placa, esquemático.



Fonte: O autor, 2020.

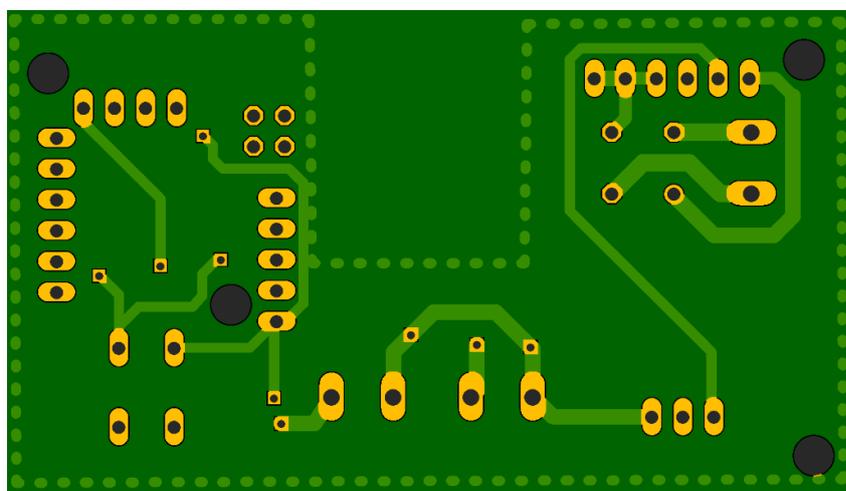
Na figura 27 e 28 é possível ver o layout da placa.

Figura 27 – Placa, vista superior.



Fonte: O autor, 2020.

Figura 28 – Placa, vista inferior.



Fonte: O autor, 2020.

A.2 Implementação e Identificação usando o Protótipo

Para realização das simulações, os veículos foram dispostos na pista de teste e postos em movimento até atingirem a distância entre si determinada pela lei de controle. Nesse momento, o veículo que vai à frente insere um sinal do tipo degrau no pelotão, que é representado pelo aumento de sua velocidade, e, posteriormente, retorna à velocidade inicial. Todos os outros veículos apresentam uma resposta a esse estímulo. Nesse momento, os dados de distância e velocidade dos três veículos é amostrada.

Após o experimento, os dados são coletados, o algoritmo de identificação é executado, e os parâmetros das funções de transferência que descrevem o modelo são encontrados. Primeiramente, são identificados os parâmetros de cada veículo individualmente e os resultados são validados.

Posteriormente, são identificados os valores através da identificação em rede, e os resultados comparados e validados.

A.2.1 Controle Proporcional Integral - PI

O controle de cruzeiro (CC) e o controle de cruzeiro avançado (ACC) do veículo, estipulam respectivamente a velocidade do veículo e a distância do veículo à frente. O controle CC e o controle ACC podem ser implementados com um controlador PI. Sua dinâmica é apresentada a seguir. O controle Proporcional:

$$u(t) = K_p e(t) \quad (\text{A.1})$$

E equação descreve a dinâmica entre o sinal de saída do controlador $u(t)$ e o sinal de erro $e(t)$, K_p é o ganho proporcional.

Já o controle Integral é proporcional ao sinal de erro integrado ao longo do tempo.

$$u(t) = K_i \int_0^t e(t) dt \quad (\text{A.2})$$

Em ambos os casos, o $e(t)$ é o valor da diferença entre a velocidade ou a distância determinada e o valor no instante que o veículo se encontra.

A ação do controle Proporcional Integral - PI é dada pela equação

$$u(t) = K_p e(t) + \frac{K_p}{T_i} \int_0^t e(t) dt \quad (\text{A.3})$$

A função de transferência do controlador PI é:

$$\frac{U(s)}{E(s)} = K_p \left(1 + \frac{1}{T_i s} \right) \quad (\text{A.4})$$

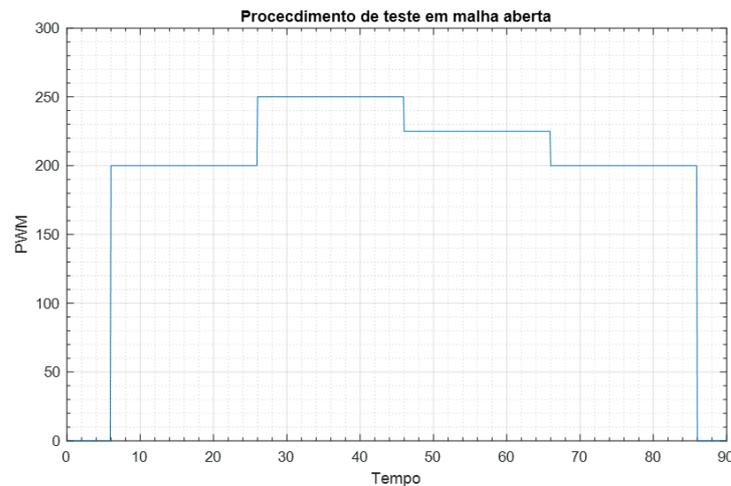
Onde T_i é chamado tempo integrativo.

O veículo anda sempre utilizando o controle CC baseado em sua velocidade. Ao chegar perto de um veículo, o controle de ACC é ativado e sua lei de controle é regida pelo sensor de distância a fim de manter uma distância segura do veículo da frente que propicie economia de combustível. Este controle é de fácil implementação e foi escolhido para ser utilizado nos protótipos.

A.2.2 Implementação da Identificação em Protótipo

Os veículos são modelados como apresentados na seção 4.1. Sua dinâmica pode ser representada por uma equação de segunda ordem, como é mostrado na equação 4.2. Nesta seção, são identificados, através de mínimos quadrados, que foi explanado na seção 3.1.1, os parâmetros da função de segunda ordem de cada um dos veículos do protótipo; eles serão chamados de veículo-1, veículo-2 e veículo-3. Essa identificação será utilizada para comparar os resultados obtidos na identificação em rede. Cada um dos três veículos foi submetido a um procedimento de teste igual em malha aberta. Eles recebem um comando para alterar a velocidade, através de uma variável de entrada chamada PWM. O fluxograma do procedimento adotado é apresentado na figura 29, chamaremos este teste de teste1. Como se pode observar, no instante de tempo 6s o PWM, é alterado para 200; no instante de tempo 26s, o PWM é alterado para 250; no instante de tempo 46s, o PWM é alterado para 225; no instante de tempo 66s, o PWM é alterado novamente para 200 e, por fim, no instante 86s, para 0.

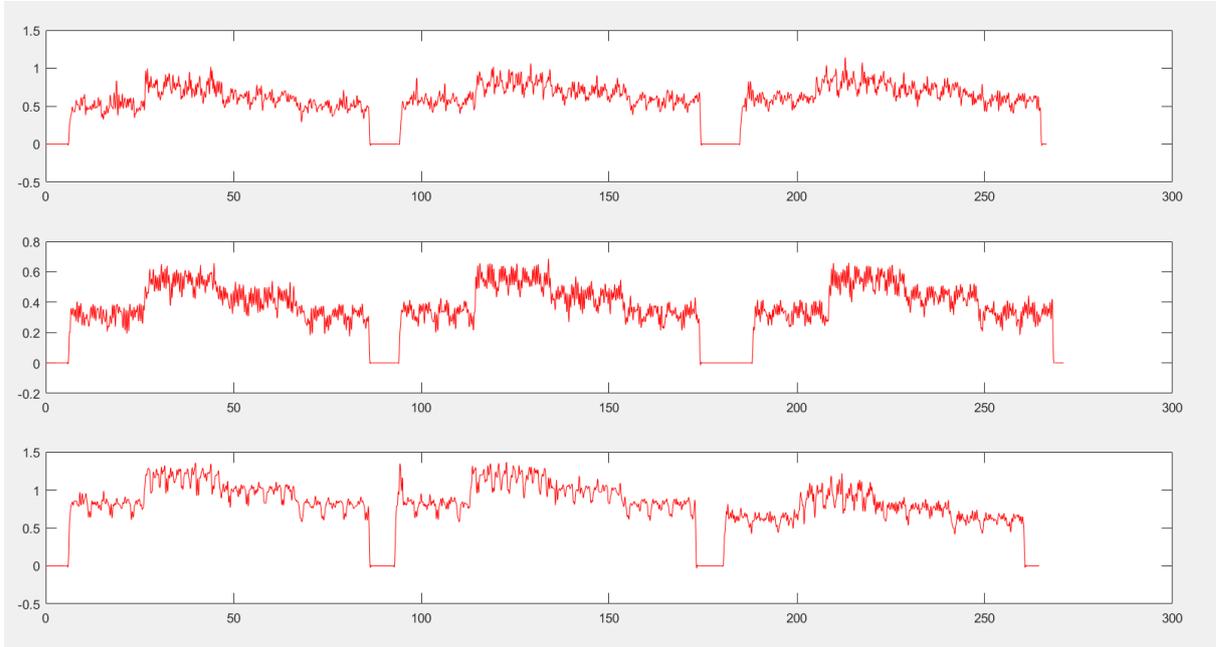
Figura 29 – Procedimento de teste 1, realizado em cada veículo em malha aberta.



Fonte: O autor, 2020.

Os valores de velocidade lidos durante este teste pelo sensor são armazenados, a variável velocidade é a variável de saída, ela é amostrada em um período de amostragem (t_s) de 1ms. A identificação de parâmetros por mínimos quadrados é calculada utilizando esse conjunto de dados para identificar os parâmetros das respectivas funções de transferência. São utilizadas 3 interações do teste para estimar os parâmetros do modelo de cada um dos veículos. A figura 30 apresenta os dados lidos nas 3 interações para cada um dos veículos.

Figura 30 – Velocidade lida em cada um dos veículos nas 3 interações realizadas, ao se aplicar o procedimento de teste. A primeira linha apresenta os dados do veículo 1, a segunda linha do veículo 2 e na terceira linha os dados do veículo 3.



Fonte: O autor, 2020.

A equação A.5 representa a função de transferência obtida para o veículo 1.

$$Gz = \frac{0.0001755 + 0.001397^{-1}}{1 - 0.04618^{-1} - 0.422^{-2}} \quad (\text{A.5})$$

A equação A.6 representa a função de transferência obtida para veículo 2.

$$Gz = \frac{0.0001755 + 0.001397^{-1}}{1 - 0.04618^{-1} - 0.422^{-2}} \quad (\text{A.6})$$

A equação A.7 representa a função de transferência obtida para veículo 3.

$$Gz = \frac{0.0001755 + 0.001397^{-1}}{1 - 0.04618^{-1} - 0.422^{-2}} \quad (\text{A.7})$$

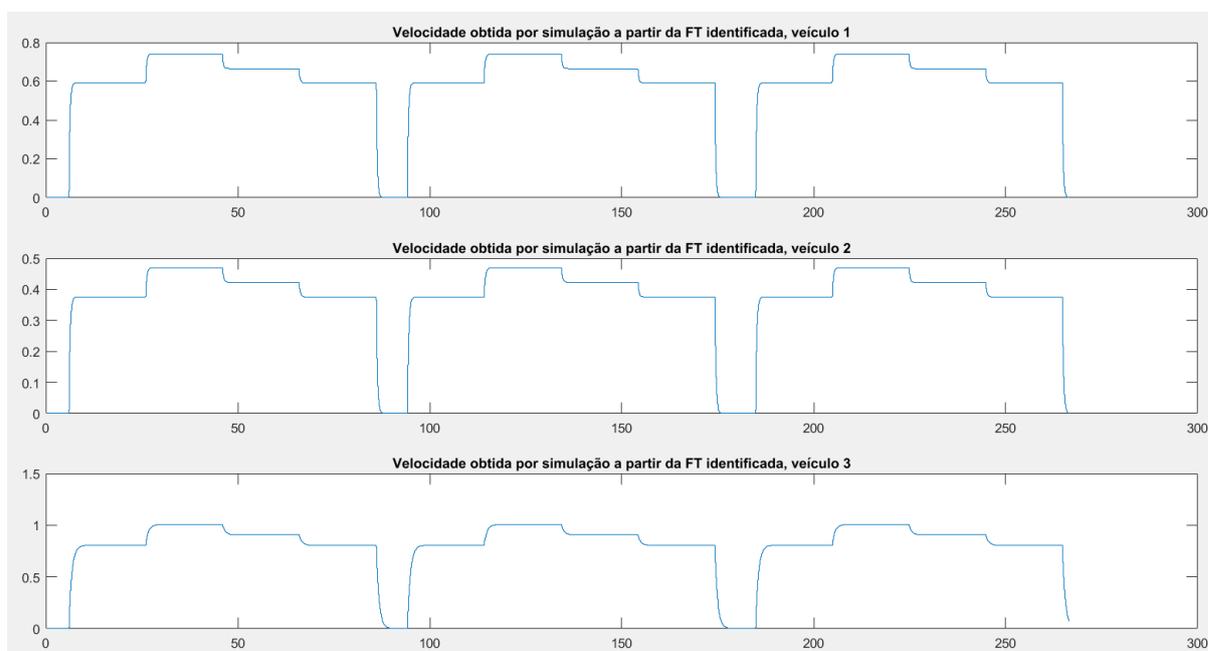
A.2.2.1 Validação do modelo dos veículos

As funções de transferência obtidas pelo método de mínimos quadrados devem ser validadas, para comprovar que realmente descrevem as dinâmicas de atuação dos veículos. Para efetuar essa validação, não se deve utilizar os mesmos dados que geraram o modelo. Desta forma, um novo teste é proposto, chamamos este teste de teste2, que é aplicado aos veículos reais e ao modelo matemático identificado pelo teste1 de forma simulada.

O desejado é que o modelo obtido consiga descrever o comportamento dos veículos para qualquer outro sinal de entrada, validando a capacidade de generalização do modelo para qualquer entrada. Ao realizar dois testes, um para gerar o modelo matemático e outro para validar sua resposta, é importante que os testes sejam feitos em condições de operação iguais já que consideramos que o sistema é linear.

Durante a implementação da etapa de protótipo não foi realizado o teste2 a tempo nos veículos reais para comparar com a as funções de transferências identificadas. A simulação então foi aplicada nos mesmos dados que geraram o modelo para demonstrar que as funções de transferência identificadas consegue descrever o comportamento dos veículos como é visto na figura 31.

Figura 31 – Gráfico com resultados simulados a partir da função de transferência identificada.



Fonte: O autor, 2020.

Verificou-se que o modelo matemático obtido por mínimos quadrados descreve o comportamento dos veículos ao menos no mesmo conjunto de dados que o gerou.



Pontifícia Universidade Católica do Rio Grande do Sul

ESCOLA POLITÉCNICA

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA - PPGE

IDENTIFICAÇÃO DE REDES DINÂMICAS: APLICADA A PELOTÃO DE VEÍCULOS AUTÔNOMOS

CANDIDATO: RAFAEL DE VASCONCELOS

Esta Dissertação de Mestrado foi julgada para obtenção do título de MESTRE EM ENGENHARIA ELÉTRICA e aprovada em sua forma final pelo Programa de Pós-Graduação em Engenharia Elétrica da Pontifícia Universidade Católica do Rio Grande do Sul.

DR. GUILHERME ARAUJO PIMENTEL - ORIENTADOR

BANCA EXAMINADORA

DR. RICARDO RODRIGO PEREZ IBACACHE - PNPD - PUCRS

DR. RAFAEL DA SILVEIRA CASTRO - PPGE - PUCRS

PUCRS



Pontifícia Universidade Católica do Rio Grande do Sul
Pró-Reitoria de Graduação
Av. Ipiranga, 6681 - Prédio 1 - 3º. andar
Porto Alegre - RS - Brasil
Fone: (51) 3320-3500 - Fax: (51) 3339-1564
E-mail: prograd@pucrs.br
Site: www.pucrs.br