

DESENVOLVIMENTO DE UM SENSOR VIRTUAL PARA A VELOCIDADE LONGITUDINAL DE UM AUTOMÓVEL

PEDRO HENRIQUE DE A. BRAZ*, BRUNO HENRIQUE G. BARBOSA*, DANILO ALVES DE LIMA*,
GERALDO LUCIANO DE C. NETO*

**Departamento de Engenharia
Universidade Federal de Lavras
Lavras, Minas Gerais, Brasil*

Emails: pedrobraz12@hotmail.com, brunohb@gmail.com, daniloalvesdelima@yahoo.com.br,
geraldolcneto123@gmail.com

Abstract— The development of intelligent vehicles has increased over the years, but to have access to the magnitudes of the environment and its dynamics, the vehicle needs reliable sensors to carry out these measurements. However, physical sensors are susceptible to problems, such as measurement errors, availability, and high-cost. An alternative, without high economic costs, to overcome these problems is the use of virtual sensors. This work describes the process of identifying a virtual sensor, capable of estimating the longitudinal speed of an intelligent vehicle by means of low-cost physical sensors, such as the accelerometer of a smartphone. For this, NARX (Non-linear AutoRegressive with eXogenous inputs) polynomial models were identified, with parameters obtained by the least squares estimator and regressors chosen by the error reduction rate. Finally, robust models to mass variations of the vehicle were implemented and analyzed. The results obtained were satisfactory in terms of robustness to vehicle mass variations. One way to increase the applicability of these virtual sensors would be to obtain robustness in relation to variations in track sloping, which is desired for future work.

Keywords— Intelligent vehicles. Virtual sensors. NARX models.

Resumo— O desenvolvimento de veículos inteligentes vem crescendo com o passar dos anos, mas para o veículo ter acesso as grandezas do ambiente e de sua dinâmica, ele precisa de sensores confiáveis para realizar essas medições. Porém, os sensores físicos são suscetíveis a problemas, tais como: erros de medição, disponibilidade e custo elevado. Uma alternativa, sem altos custos econômicos, para contornar esses problemas é o uso de sensores virtuais. Este trabalho descreve o processo de identificação de um sensor virtual, capaz de estimar a velocidade longitudinal de um veículo inteligente por meio de sensores físicos de baixo custo, como por exemplo, o acelerômetro de um *smartphone*. Para isso, modelos polinomiais NARX (do inglês *Non-linear AutoRegressive with eXogenous inputs*) foram identificados, com parâmetros obtidos pelo estimador de mínimos quadrados e regressores escolhidos por meio da taxa de redução de erro. Por fim, a obtenção de modelos robustos às variações massa do veículo foram implementados e analisados. Avalia-se que os resultados obtidos foram satisfatórios quanto a robustez às variações de massa do veículo. Uma maneira de aumentar a aplicabilidade destes sensores virtuais seria obtendo a robustez em relação às variações de inclinação da via, o qual fica indicado para trabalhos futuros.

Palavras-chave— Veículos inteligentes. Sensores virtuais. Modelos NARX.

1 Introdução

Desde a invenção do automóvel, o seu uso foi se tornando cada vez mais frequente. Hoje os automóveis são utilizados nas mais variadas atividades: como ir ao trabalho, ir à escola, para passear e realizar o transporte de cargas e pessoas. Impulsionada pela enorme popularização de seu uso ao redor do globo, a produção de automóveis sofreu um espantoso aumento, trazendo consigo problemas com tráfego, poluição ambiental e com a segurança de passageiros. Estes problemas serviram como motivação para as montadoras desenvolverem veículos melhores para o seu usuário e para o meio o qual trafega, de forma a otimizar o uso das rodovias e combustível, fornecer transporte seguro e confortável e causar o menor impacto ambiental possível. Uma das maneiras encontradas para possibilitar essa otimização foi a utilização sistemas de controle eletromecânicos, tais como sistemas avançados de assistência ao condutor (ADAS - do inglês *Advanced Driver Assistance Systems*) e sistemas de controle ativo de estabilidade (ASC - do

inglês *Active Stability Control*) (Rajamani, 2011).

Esses sistemas auxiliaram o desenvolvimento de veículos inteligentes, os quais possuem sua definição padronizada pela sociedade dos engenheiros automobilísticos (SAE - do inglês *Society of Automotive Engineers*). Nela, entende-se por veículos inteligentes todos aqueles que se enquadram como sistema automatizado de condução (ADS - do inglês *Automated Driving System*) entre os níveis 1 e 5 da tabela definida pela SAE International (Orad, 2016).

Os sensores físicos são essenciais para os sistemas de controle e para os veículos inteligentes, ambos precisam de sensores confiáveis que possam medir as variáveis que atuam no veículo ao decorrer de sua trajetória. São exemplos de variáveis mensuráveis ou estimáveis a aceleração, velocidade, o ângulo de inclinação e as forças laterais e longitudinais do veículo. No entanto, os sensores físicos são suscetíveis a problemas, tais como erros de medição, disponibilidade, confiabilidade e custo elevado. Uma alternativa, sem altos custos econômicos, para contornar esses problemas é

o uso de *soft sensors* ou sensores virtuais (Lotufo and Garcia, 2008). Os quais podem ser definidos como *softwares* capazes de estimar variáveis não medidas do processo, por meio de variáveis medidas (Ferreira et al., 2010). Como exemplo de sua utilização, pode-se citar a pesquisa desenvolvida por Boada et al. (2015), onde foram utilizados os valores de aceleração lateral, velocidade longitudinal, ângulo de esterçamento das rodas e a taxa de desvio da trajetória do veículo como entradas de um sistema de inferência *neuro-fuzzy* adaptativo para a estimação do ângulo de deriva do veículo. Este ângulo pode ser usado em um sistema de estabilidade eletrônico.

Outra função importante desempenhada pelos sensores virtuais é a de validação do valor medido por um sensor físico, detectando alguma falha na medição deste. Em Oosterom and Babuska (2000) foi desenvolvido um sensor virtual por meio de técnicas *fuzzy* com a finalidade de estimar a aceleração de uma aeronave. Essa estimativa foi empregada em um sistema de monitoramento para detecção e identificação de falhas em sensores físicos presentes na aeronave.

Visto isso, percebe-se que o uso de *soft sensors* em veículos inteligentes possui grande potencial de aplicabilidade para a estimativa de diversas variáveis integrantes dos sistemas ADAS modernos. O desenvolvimento de um sensor virtual para a velocidade longitudinal de um veículo é de suma importância para o funcionamento de sistemas ADAS como: o sistema de antibloqueio de frenagem (ABS - do inglês *Anti-lock Breaking System*) e o controle de cruzeiro adaptativo (ACC - do inglês *Adaptive Cruise Control*), de forma a proporcionar um parâmetro para validação do valor de velocidade já medido pelo veículo e para a detecção de falhas no mesmo.

O propósito deste trabalho é contribuir para o desenvolvimento de sensores virtuais, propondo uma técnica para se projetar um sensor virtual que estime a velocidade longitudinal do veículo por meio de sensores de baixo custo. Visando, assim, contribuir para a validação do valor de velocidade já medido pelo veículo e para a detecção de uma possível falha no mesmo.

Para tal, as seguintes etapas foram cumpridas: coleta de dados, filtragem dos dados, sincronização, melhora da resolução dos dados de velocidade, análise do tempo morto do sistema, identificação dos modelos e análise de seus desempenhos em simulação livre.

2 Modelos NARMAX

Os modelos NARMAX (do inglês *Non-linear AutoRegressive Moving Average with eXogenous inputs*) mapeiam um sistema não-linear composto por entradas, saídas e ruídos passados até a saída atual, dada por (Leontaritis and Billings, 1985;

Chen and Billings, 1989; Aguirre, 2007):

$$y(k) = F^l[y(k-1), \dots, y(k-n_y), u(k-d), \dots, u(k-d-n_u), e(k-1), \dots, e(k-n_e)] + e(k), \quad (1)$$

onde y é a saída, u é a entrada e e é o ruído do sistema. n_y, n_u, n_e são os atrasos máximos da saída, entrada e ruído, respectivamente, e d é o tempo morto do sistema.

Como a função $F^l[\cdot]$ normalmente não é conhecida “a priori”, utiliza-se aproximações, polinomiais e racionais, para representá-la. Em uma representação polinomial do modelo NARMAX, o grau de não-linearidade (l) representa o número máximo de termos $y(k), u(k)$ e $e(k)$ multiplicados entre si na função $F^l[\cdot]$.

Os modelos NARX (do inglês *Non-linear AutoRegressive with eXogenous inputs*) representam um subconjunto dos modelos NARMAX, onde é apresentada apenas a sua parte determinística. Os modelos NARX são representados por:

$$y(k) = F^l[y(k-1), \dots, y(k-n_y), u(k-d), \dots, u(k-d-n_u)] + e(k), \quad (2)$$

onde F é uma função polinomial de grau l .

Ao se aumentar o grau de não-linearidade (l) do modelo NARX, ocorre uma explosão combinatória do número de parâmetros do modelo. O ERR é um método utilizado para contornar este problema, uma vez que seleciona os parâmetros de maior importância para o modelo (Quachio and Garcia, 2011).


3 Metodologia de Desenvolvimento

A coleta dos dados desta pesquisa se deu por meio de ensaios realizados em um Nissan Kicks SL 1.6 2017 com trocas de marchas automáticas, com o auxílio do scanner OBD-II (*On-Board Diagnostic*) ELM 327 mini. Este dispositivo é conectado ao barramento CAN (*Controller Area Network*) do veículo e se comunica por meio de *bluetooth* a um aparelho *smartphone* Asus Zenfone 5 T00J com sistema operacional Android, como ilustra a Figura 1. O *smartphone* utilizado possui um aplicativo para a coleta dos dados do barramento CAN do veículo e dele próprio (Neto et al., 2016).

Durante a coleta de dados, o *smartphone* foi posicionado dentro do veículo com sua tela direcionada para o teto, em frente ao câmbio do mesmo. O sentido positivo do seu eixo y ficou direcionado para a frente do veículo, o do eixo x para o banco do passageiro e do eixo z para o teto. A Figura 2 ilustra como estão posicionados os eixos do *smartphone*.

Para o desenvolvimento da pesquisa foram coletados os dados de velocidade longitudinal nas rodas dianteiras, posição do acelerador e RPM do

Figura 1: Interação e dados coletados entre carro, OBD-II e *smartphone*.



Fonte: Do autor.

Figura 2: Sistema de eixos do *smartphone*.



motor, fornecidos pelo barramento CAN do veículo e os dados do acelerômetro e orientação nos eixos x, y e z, GPS e a sua precisão, todos fornecidos pelo *smartphone*. Os dados de orientação fornecem por meio de um sensor virtual, os graus de rotação que do dispositivo em torno dos seus eixos (x, y, z). Os dados do barramento CAN foram coletados a uma taxa de amostragem de aproximadamente 5 Hz, taxa limite do dispositivo OBD-II utilizado. Já os dados do *smartphone* foram coletados a uma taxa de aproximadamente 50 Hz, que corresponde a taxa máxima do aparelho. Estes dados foram salvos em dois arquivos .txt no próprio *smartphone*, um com os dados do barramento CAN e outro como os dados fornecidos pelo *smartphone*.

O banco de dados utilizado na pesquisa foi coletado por meio de ensaios específicos, variando-se a inclinação da via e o número de pessoas no veículo, de maneira a coletar os dados de possíveis inclinações e pesos impostos ao veículo. Nos ensaios foram usadas inclinações de vias positiva ($03^{\circ}02'54''$), negativa ($-03^{\circ}02'54''$) e aproximadamente nula ($0^{\circ}42'42''$), e os pesos de uma, três e cinco pessoas estimados em 80 kg, 240 Kg e 400 kg, respectivamente. Além disso, eles também foram divididos de acordo com o tipo de movimento que o condutor do veículo transmitia ao acelerador, simulando um sinal degrau ou um sinal aleatório com múltiplos níveis (MRS - do inglês *Multi-level*

Random Signal).

Cada ensaio, com um tipo de movimento aplicado ao acelerador (Degrau ou MRS), um certo número de pessoas (um, três ou cinco) e uma inclinação (positiva, nula e negativa), foram repetidos três vezes, de forma a se ter ensaios diferentes para as mesmas especificações de tipo de movimento, peso e inclinação (Tabela 1). Com estas especificações, o banco de dados coletado é composto por 54 ensaios com tipos de movimento no acelerador (Degrau ou MRS), número de pessoas no veículo (um, três ou cinco) e inclinação da via (positiva, nula ou negativa).

Tabela 1: Ensaios da coleta do banco de dados.

Características	Opções
Tipo entrada no pedal	Degrau ou MRS
N. pessoas	1, 3 ou 5
Via	Positiva, Negativa, ou Nula
Repetições	3
N. médio amostras treino	2100
N. médio amostras validação	1050


Fonte: Do autor.

Os dados coletados possuem algumas limitações, como: ruído nos dados do acelerômetro e de orientação, os dados fornecidos pelo OBD-II estão dessincronizados em relação aos coletados do *smartphone* e baixa resolução dos dados de velocidade. Nos ensaios MRS com uma pessoa no veículo ocorreu o congelamento dos dados de acelerômetro e orientação nos eixos x, y e z, provavelmente devido a um superaquecimento do *smartphone*. Os ensaios em que ocorreram esse problema tiveram seus dados desconsiderados no desenvolvimento desta pesquisa.

A correlação cruzada entre a velocidade e os dados de RPM e acelerômetro no eixo y foi analisada, constatando que não há tempo morto na sua resposta em relação a estes dados.

Como etapa do pré-processamento de dados, tratou-se o ruído de medição nos dados do acelerômetro e orientação fornecidos pelo *smartphone*, aplicando um filtro passa-baixa de segunda ordem projetado no software Matlab®. Este filtro possui as especificações de 10 dB (decibéis) de ondulação permitida na banda passante, 20 dB de atenuação na banda, 0.08π rad/amostra de frequência no início da banda passante e 0.3π rad/amostra de frequência no final da banda. O resultado da aplicação do filtro passa-baixa pode ser visto na Figura 3, onde foram comparados os dados antes e após a filtragem e nota-se que o filtro atenuou o ruído presente nestes dados.

Figura 3: Dados do acelerômetro em y antes e após o filtro passa-baixa.



Fonte: Do autor.

Outra etapa do pré-processamento foi a sincronização dos dados do barramento CAN com os do *smartphone*, que foram coletados com taxas de amostragem diferentes, 5 Hz e 50 Hz respectivamente, e melhora da resolução dos dados de velocidade fornecida pelo OBD-II que era de 1 km/h. Para isto, foi aplicado um filtro de Kalman (KF - do inglês *Kalman Filter*) em todo o banco de dados, onde este usou a relação expressa na equação 3 para estimar a velocidade e a relação dos demais dados foi expressa pela equação 4:

$$Vel(k) = Vel(k-1) + a(k-1) * Te, \quad (3)$$


$$X(k) = X(k-1), \quad (4)$$

sendo Vel a velocidade longitudinal nas rodas dianteiras, a a aceleração medida pelo acelerômetro do *smartphone* no eixo y, Te o período de amostragem e X os outros dados coletados (posição do acelerador, RPM, acelerômetro e orientação em seus eixos). O Te assumiu o valor de 0,03, que é aproximadamente o período de amostragem fornecido pelo *smartphone*, o ruído de medição recebeu o valor de 0,25 km/h e o ruído do processo foi considerado nulo. Estes valores foram escolhidos com o objetivo de conseguir uma boa estimativa da velocidade e, ao mesmo tempo, suavizar a sua representação gráfica.

Os dados de velocidade de um ensaio após filtragem do KF em comparação com os dados originais podem ser observados na Figura 4. Estes novos dados de velocidade possuem uma resolução média, um EQM (erro quadrático médio) e um R^2 (coeficiente de determinação) aproximados de 0,07 km/h, 2,9379 km²/h² e 0,9942, respectivamente, demonstrando que o KF aumentou a resolução dos dados de velocidade e também suavizou a sua representação gráfica.

Modelos NARX (*Non-linear AutoRegressive with eXogenous inputs*) polinomiais foram identificados para estimar a velocidade longitudinal do veículo. Estes modelos são de segundo grau e não foi utilizado modelo de ruído (o número máximo

Figura 4: Velocidade longitudinal estimada pelo filtro de Kalman.



Fonte: Do autor.

de atrasos do ruído é zero) por não apresentar resultados que justificassem seu uso, ou seja, o algoritmo implementado Mínimos Quadrados Estendidos (ELS - do inglês *Extended Least Squares*) se reduziu ao algoritmo de Mínimos Quadrados (LS - do inglês *Least Squares*). O número de termos de processo, número máximo de atrasos na entrada e na saída variaram entre os modelos, de forma a obter melhor desempenho em simulação livre em dados de validação. Os modelos foram desenvolvidos no software Matlab®, com parâmetros obtidos pelo estimador de mínimos quadrados e seus regressores foram escolhidos por meio da taxa de redução de erro (ERR - do inglês *Erro Reduction Ratio*) proveniente da sua inclusão.


Uma análise conceitual e gráfica dos dados foi realizada para determinar quais representavam melhor o comportamento dinâmico da velocidade do veículo e seriam melhores entradas para os modelos de estimativa da velocidade longitudinal do veículo. Após observar o comportamento da velocidade durante os ensaios e compará-lo com o dos demais dados, percebeu-se que os dados RPM e os dados do acelerômetro no eixo y (Figura 5) eram os que melhor representavam a velocidade. Com isso, a união dos dados de RPM e de aceleração (acelerômetro em y) foram escolhidas como entradas para os modelos.

Após a escolha das entradas dos modelos, estes foram projetados para todas as variações do conjunto massa do veículo e inclinação da via (Tabela 2). Depois foram projetados modelos para serem robustos às variações de massa do veículo, onde os modelos foram treinados com os dados do ensaio com três pessoas, simulando um valor intermediário da massa total que o veículo pode atingir. Em suas validações foram usados os dados dos ensaios com três e cinco pessoas (Tabela 3), todos sem variações de inclinação da via.

Por fim, como forma de testar a robustez dos modelos a possíveis falhas no sensor de velocidade foi simulado valores nulos dos dados de velocidade durante sua execução.

Todos os modelos projetados foram treinados exclusivamente com dados MRS, respeitando as

Figura 5: Exemplo de dados MRS de entrada dos modelos.



Fonte: Do autor.

Tabela 2: Modelos NARX com entrada RPM e aceleração.

Modelos (N. pes- soas/Incli)	Ensaios Utilizados (Tipo/N. pessoas/Incli)	
	Treinamento	Validação
3/Pos	MRS-3-Pos	Deg e MRS-3-Pos
3/Neg	MRS-3-Neg	Deg e MRS-3-Neg
3/Nul	MRS-3-Nul	Deg e MRS-3-Nul
5/Pos	MRS-5-Pos	Deg e MRS-5-Pos
5/Neg	MRS-5-Neg	Deg e MRS-5-Neg
5/Nul	MRS-5-Nul	Deg e MRS-5-Nul

Fonte: Do autor.

restrições de massa e inclinação de cada modelo, e validados com dados MRS e Degrau. Os dados disponíveis foram divididos em 2/3 para treinamento e 1/3 para validação, de forma que os dados de treinamento e validação dos modelos fossem sempre diferentes.

Tabela 3: Modelos NARX robustos à massa do veículo com entrada RPM e aceleração.

Modelos (Inclinação)	Ensaios Utilizados (Tipo/N. pessoas/Incli)	
	Treinamento	Validação
Pos	MRS-3-Pos	Deg e MRS-3 e 5-Pos
Neg	MRS-3-Neg	Deg e MRS-3 e 5-Neg
Nul	MRS-3-Nul	Deg e MRS-3 e 5-Nul

Fonte: Do autor.

4 Resultados e Discussões

Com o objetivo de utilizar informações provenientes de sensores diferentes, possivelmente trazendo mais informação para construção dos modelos, projetou-se modelos NARX polinomiais tendo como entradas os dados de RPM e de aceleração (medida pelo acelerômetro do *smartphone* no eixo y) e os dados de velocidade longitudinal do veículo como saída.

Esses modelos foram treinados previamente e validados com ensaios de mesma massa e inclinação, como apresentado na Tabela 2. A Figura 6 mostra as saídas do modelo para o ensaio com cinco pessoas na via plana, onde as curvas azuis tracejadas representam os dados de velocidade advindos da filtragem de Kalman e as curvas vermelhas contínuas os dados das saídas do modelo.

Os regressores do modelo NARX polinomial para o ensaio com cinco pessoas na via plana são expostos na seguinte equação:

5 pessoas/Plano:

$$y(k) = 1,8866y(k-1) - 1,3747y(k-2) + 3,7198e^{-4}u(k-1) + 0,9131y(k-3) - 7,5772e^{-8}u(k-1)u(k-1)^2 + 1,5219e^{-4}y(k-15)y(k-15)^2 + 1,0412e^{-4}u(k-3) - 0,7428y(k-4) + 0,3008y(k-5)$$

Os valores de EQM e R^2 dos modelos NARX polinomial com entrada RPM e aceleração, são mostrados nas Tabelas 4 e 5.

Os resultados exibidos pelos modelos NARX polinomiais com entrada RPM e aceleração quando validados para dados de mesma massa e inclinação da via foram satisfatórios, apresentando o maior valor de EQM igual a 16,8637 km^2/h^2 . Os seus resultados acompanharam bem o comportamento da velocidade, em Degrau e MRS. Nas suas equações não aparecem termos cruzados ($u(k-a)y(k-b)$), comprovando que este não é aparentemente o tipo de não-linearidade deste sistema.

Gráfico de velocidade longitudinal (km/h) versus tempo (s) para o veículo 1. A curva original (azul tracejada) e a curva estimada (vermelha sólida) são quase idênticas, mostrando uma aceleração progressiva de 0 a 60 km/h em 18 segundos.

Fonte: Do autor.

Nº de pes- soas/Inclinação	EQM(km ² /h ²)	R ²
3/D	1,3538	0,99696
3/I	10,6806	0,98766
3/P	8,5432	0,99188
5/D	2,9209	0,99961
5/I	16,8637	0,98439
5/P	3,362	0,99555
Média	7,2874	0,9927


Fonte: Do autor.

Para obter modelos NARX polinomiais com entrada RPM e aceleração robustos às variações de massa do veículo, os modelos foram treinados com ensaios de três pessoas no veículo, simulando um valor intermediário da massa total que o veículo pode atingir e validados conforme a Tabela 3. As saídas do modelo para o ensaio na via plana são ilustrados nas Figuras 7 e 8, onde as curvas azuis


Nº de pes- soas/Inclinação	EQM(km ² /h ²)	R ²
3/D	9,9725	0,97393
3/I	3,2028	0,99146
3/P	7,6132	0,997
5/D	4,9118	0,9925
5/I	2,8434	0,96208
5/P	7,6982	0,99375
Média	6,0403	0,9851

Fonte: Do autor.

Figura 7: Saídas do modelo NARX polinomial com entrada RPM e aceleração robusto às variações de massa para o ensaio na via plana (entrada Degrau).



(a) 3 pessoas




(b) 5 pessoas

Fonte: Do autor.


Inclinado:

$$y(k) = 1,5506y(k-1) - 0,7306y(k-2)$$

Figura 8: Saídas do modelo NARX polinomial com entrada RPM e aceleração robusto às variações de massa para o ensaio na via plana (entrada MRS).



(a) 3 pessoas



(b) 5 pessoas

Fonte: Do autor.

$$2) + 2,7561e^{-4}u(k-5) + 0,1712y(k-3) - 3,5022e^{-8}u(k-9)u(k-15)^2 + 3,7284e^{-8}u(k-1)u(k-11)^2 - 5,486e^{-8}u(k-3)u(k-7)^2 + 0,0044y(k-12)y(k-12)^2 - 0,0191y(k-7)y(k-13)^2 + 0,0115y(k-6)y(k-13)^2 + 2,3591e^{-8}u(k-4)u(k-15)^2 - 0,0017y(k-4)y(k-12)^2 + 0,0081y(k-8)y(k-13)^2 - 0,0031y(k-10)y(k-13)^2 + 2,6602e^{-8}u(k-2)u(k-5)^2$$

Tabela 6: Desempenho dos modelos NARX polinomiais com entrada RPM e aceleração robustos às variações de massa (entrada Degrau).

Nº de pes-soas/Inclinação	EQM(km ² /h ²)	R ²
3/D	13,8398	0,96373
5/D	8,6426	0,99537
3/I	1,1846	0,99252
5/I	3,0436	0,99445
3/P	7,6848	0,99637
5/P	2,0695	0,99708
Média	6,0775	0,9899

Fonte: Do autor.

Os modelos NARX polinomiais com entrada RPM e aceleração robustos às variações de massa apresentaram bons resultados. Eles também não

Tabela 7: Desempenho dos modelos NARX polinomiais com entrada RPM e aceleração robustos às variações de massa (entrada MRS).

Nº de pes-soas/Inclinação	EQM(km ² /h ²)	R ²
3/D	3,4623	0,99351
5/D	4,1527	0,99003
3/I	18,4247	0,97754
5/I	11,3927	0,97813
3/P	5,6456	0,98637
5/P	6,32	0,98754
Média	8,2330	0,9855

Fonte: Do autor.

apresentaram termos cruzados ($u(k-a)y(k-b)$) e na equação do modelo para ensaio na via inclinada ocorreu um número semelhante de termos não-lineares na saída e na entrada, indicando que ambas não-linearidades são importantes para este modelo em específico. Com estas considerações, os seus resultados acompanharam bem a dinâmica da velocidade, em todos os ensaios, e apresentaram um máximo valor de EQM igual a 18,4247 km²/h² na validação do ensaio com três pessoas na via inclinada (entrada MRS), chegando em alguns momentos a um desvio superior a 10% do valor atual da velocidade, o que poderia gerar uma infração de trânsito em vias com restrições de velocidade. Com algumas ressalvas, os resultados obtidos foram bons para uma abordagem validada em simulação livre.

4.2 Falha no sensor de velocidade


De maneira a demonstrar que os modelos NARX polinomiais foram validados em simulação livre, foi simulada uma falha na medição do sensor de velocidade do veículo. Essa falha foi caracterizada com o zeramento do valor da velocidade medido pelo sensor, como observado na Figura 9. Note que o modelo não sofreu influência da falha no sensor de velocidade do veículo, mostrando-se robusto a esse tipo de problema, comprovando sua característica de *soft sensor*. Esse resultado também comprova que o modelo está validado em simulação livre.

5 Conclusão

Neste trabalho, uma abordagem para projetar sensores virtuais que estimem a velocidade longitudinal do veículo foi desenvolvida. A técnica sugerida, utiliza dados obtidos de sensores de baixo custo em conjunto com técnicas de identificação de sistemas para realizar essa estimativa.

Com os resultados obtidos nesta pesquisa,

Figura 9: Saída do modelo NARX polinomial com entrada RPM e aceleração para a falha no sensor de velocidade.



Fonte: Do autor.

percebe-se que os modelos NARX polinomiais obtiveram resultados satisfatórios para a estimativa, validada em simulação livre, da velocidade longitudinal do veículo. Os modelos com entrada RPM e aceleração apresentaram bons resultados, demonstrando que essas entradas informaram bem os modelos sobre o comportamento dinâmico da velocidade do veículo. Os modelos NARX também apresentaram resultados consideráveis para a robustez às variações de massa do veículo.

Na grande maioria dos modelos, não ocorreram regressores com termos cruzados ($u(k-a)y(k-b)$) em suas equações, demonstrando que a constante de tempo do sistema não varia com o ponto de operação, e ocorreu uma dominância dos regressores relacionados com não-linearidades da entrada, mostrando que o sistema possui uma curva estática não-linear.

Pode-se observar que os dados de aceleração fornecido pelo acelerômetro do *smartphone* representam a aceleração imposta pelo veículo com satisfatória precisão. Em um contexto de pesquisa científica, isto facilitaria a coleta desta informação, visto que na grande parte das pesquisas sobre este assunto, ela é coletada por meio de um acelerômetro instalado no eixo traseiro do veículo. A coleta por meio do acelerômetro do *smartphone* se torna mais prática e simples de se realizar.

Como trabalhos futuros, espera-se identificar modelos robustos às variações de inclinação da via sofridas pelo veículo. Também anseia-se coletar mais informações sobre a inclinação da via, seja por meio de um *smartphone* com giroscópio ou por outro sensor semelhante.

6 Agradecimentos

Especialmente ao professor Dimitri Campos Viana por sua valiosa contribuição, à Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) pela concessão da bolsa de estudos para o desenvolvimento desta pesquisa e ao Laboratório de Mobilidade Terrestre da Universidade

Federal de Lavras (LMT - UFLA) por disponibilizar o módulo OBD-II.

Referências

- Aguirre, L. A. (2007). *Introdução à identificação de sistemas—Técnicas lineares e não-lineares aplicadas a sistemas reais*, Editora UFMG.
- Boada, B. L., Boada, M. J. L., Gauchía, A., Olmeda, E. and Díaz, V. (2015). Sideslip angle estimator based on anfis for vehicle handling and stability, *Journal of Mechanical Science and Technology* **29**(4): 1473–1481.
- Chen, S. and Billings, S. A. (1989). Representations of non-linear systems: the nar-max model, *International Journal of Control* **49**(3): 1013–1032.
- Ferreira, T. P., Braga, C. M. P. and Seixas Filho, C. (2010). Sensores virtuais—soft sensors, *Universidade Federal de Minas Gerais*.
- Leontaritis, I. J. and Billings, S. A. (1985). Input-output parametric models for non-linear systems part i: deterministic non-linear systems; input-output parametric models for non-linear systems - part ii: sthochastic non-linear systems, *International Journal of Control* **41**(2): 303–344.
- Lotufo, F. A. and Garcia, C. (2008). Sensores virtuais ou soft sensors: Uma introdução, *7th Brazilian Conference on Dynamics, Control and Applications, São Paulo*.
- Neto, G. L. D. C., Lima, D. A. D. and Neto, A. D. M. (2016). The use of smartphones as a smart sensor for intelligent vehicles, *2016 XIII Latin American Robotics Symposium and IV Brazilian Robotics Symposium (LARS/SBR)*, pp. 37–42.
- Oosterom, M. and Babuska, R. (2000). Virtual sensor for fault detection and isolation in flight control systems-fuzzy modeling approach, *Decision and Control, 2000. Proceedings of the 39th IEEE Conference on*, Vol. 3, IEEE, pp. 2645–2650.
- Orad, O. A. D. C. (2016). Taxonomy and definitions for terms related to driving automation systems for on-road motor vehicles.
- Quachio, R. and Garcia, C. (2011). Aplicação do método pls-ph para identificação de modelos narx polinomiais, *10ª Conferência Brasileira de Dinâmica, Controle e Aplicações*.
- Rajamani, R. (2011). *Vehicle dynamics and control*, Springer Science & Business Media.