



Decoupling of Longitudinal and Lateral Control in Autonomous Vehicles Using Model-Based Predictive Control

Ícaro B. Viana, João P. S. Rodrigues, Alan M. da Rocha and
Marcelo M. S. de Souza

EasyChair preprints are intended for rapid
dissemination of research results and are
integrated with the rest of EasyChair.

October 23, 2023

Desacoplamento de Controle Longitudinal e Lateral em Veículos Autônomos Usando Controle Preditivo Baseado em Modelo

Ícaro B. Viana * João P. S. Rodrigues ** Alan M. da Rocha *
Marcelo M. S. de Souza *

* *Programa de Pós-Graduação em Engenharia Elétrica e Computação (PPGEEC), Campus Sobral, Universidade Federal do Ceará, CE, Brasil*
(e-mail: icaro.viana@ufc.br, eng.alanmarquesrocha@gmail.com, marcelo@ufc.br)

** *Engenharia Elétrica, Campus Sobral, Universidade Federal do Ceará, CE* (e-mail: joaopdrosr@alu.ufc.br).

Abstract: This work addresses the development of a decoupled lateral and longitudinal controller for autonomous vehicles (AVs). The present work uses a model-based predictive controller (*Model Predictive Controller*, MPC) to perform the lateral control and a proportional-integral (PI) controller to perform the longitudinal control of the vehicle. Lateral control aims to keep the vehicle on the desired trajectory. The longitudinal controller intends to keep the vehicle at a fixed speed, previously established, generating the desired acceleration from the reference longitudinal velocity. The trajectories and the reference velocity are generated by a trajectory-planner that uses a receding-horizon control strategy based on mixed integer-quadratic programming (MIQP). The evaluation of the proposed method was performed using the MATLAB/SIMULINK tool. Simulation experiments consider a maneuver of a vehicle traveling along a one-way road in the presence of obstacles.

Resumo: O presente trabalho aborda o desenvolvimento de um controlador lateral e longitudinal desacoplado para veículos autônomos (AVs). A estratégia proposta utiliza um controlador preditivo baseado em modelo (*Model Predictive Controller*, MPC) para realizar o controle lateral e um controlador proporcional-integral (PI) para realizar o controle longitudinal do veículo. O controle lateral visa manter o veículo na trajetória desejada. O controlador longitudinal pretende manter o veículo a uma velocidade fixa, previamente estabelecida, gerando a aceleração desejada a partir da velocidade longitudinal de referência. As trajetórias e a velocidade de referência são geradas por um planejador de trajetórias que utiliza uma estratégia de controle com horizonte-retrocedente baseado em programação quadrática inteira-mista (MIQP). A avaliação do método proposto foi realizada a partir da ferramenta MATLAB/SIMULINK. Experimentos de simulação consideram uma manobra de um veículo que se desloca ao longo de uma estrada de mão única na presença de obstáculos.

Keywords: Autonomous vehicle; proportional-integral control; predictive control; mixed-integer quadratic programming.

Palavras-chaves: Veículos autônomos; controle proporcional-integral; controle preditivo; programação quadrática inteira-mista.

1. INTRODUÇÃO

Com o rápido desenvolvimento da engenharia automotiva, inteligência artificial, comunicação sem fio, processamento computacional e técnicas avançadas de controle, pesquisas sobre veículos autônomos (AVs) cresceram significativamente nas últimas décadas. A tecnologia de AVs, que tem entre seus objetivos reduzir acidentes de trânsito e otimizar o tráfego, possui uma diversidade de aplicações e potencial de grande impacto social. Sua arquitetura geralmente é composta por módulos de percepção do ambiente, localização, planejamento e controle. Esse último é responsável pela condução segura do veículo, e, portanto, parte crítica da arquitetura.

O controle de trajetória de VAs é frequentemente separado em controle longitudinal e controle lateral. O primeiro é responsável pelo ajuste da velocidade do veículo, o que inclui, em muitas aplicações, a manutenção de uma distância segura entre dois veículos, e o segundo, por gerar o ângulo de direção para o seguimento de uma trajetória desejada. Existem variados métodos para lidar com o controle de trajetória de AVs, como o *pure pursuit*, controle proporcional-integral-derivativo (PID) e regulador linear quadrático (*Linear Quadratic Regulator*, LQR) (Wallace et al., 1985; Marino et al., 2011; Chen et al., 2017). As abordagens mais comuns utilizam controladores baseados no modelo cinemático ou no modelo de bicicleta, mas

controladores sem modelos também são encontrados (Yang et al., 2019; Brasch et al., 2022).

Surgido para o controle de processos lentos na indústria, os avanços em processamento computacional viabilizaram o Controle Preditivo baseado em Modelo (Model Predictive Control, MPC) para a tarefa de controle de trajetória. Diferente de controladores mais simples, como o PID, o MPC gera ações de controle a partir da previsão de estados futuros, permitindo ao controlador lidar com dinâmicas complexas e não-lineares. Outra característica importante é a capacidade de incluir múltiplas restrições na lei de controle. Por essas razões, o MPC se tornou uma estratégia de controle popular no rastreamento de trajetória, com importantes trabalhos publicados sobre o tema. Em Falcone et al. (2007), uma abordagem de MPC é aplicada para controlar um sistema de direção frontal ativo para AVs. Nesse trabalho, a cada intervalo de tempo, assume-se que uma trajetória é conhecida em um horizonte finito, e um controlador MPC calcula o ângulo de direção dianteiro para seguir a trajetória em estradas escorregadias. Neste, duas abordagens de MPC são apresentadas. A primeira formula o MPC usando um modelo de veículo não-linear. A segunda abordagem é baseada na linearização do modelo do veículo em tempo real.

Em se tratando de controle de trajetórias de AVs, uma abordagem muito utilizada faz uso do MPC tanto na camada do planejador de trajetória, quanto na camada do controlador de baixo nível. Usualmente, o controlador de trajetória calcula o sinal de controle com um período de amostragem menor do que o período de amostragem do planejador de trajetória. Em Viana et al. (2021), um esquema hierárquico é empregado para resolver o problema de planejamento de trajetória cooperativo, decompondo o problema de controle em duas camadas: uma camada superior de planejamento, que computa uma trajetória livre de colisões com um controlador MPC baseado em Programação Quadrática Inteira Mista (MIQP), e outra inferior, de controle de rastreamento, usando um MPC linear que calcula o sinal de controle dos atuadores para o seguimento da trajetória gerada pela camada superior.

O presente trabalho aborda o controle de AVs para o controle de trajetória e prevenção de colisões. A ênfase desse trabalho está em desacoplar o controle lateral e longitudinal do veículo, onde os comandos de controle dos atuadores são obtidos separadamente. A abordagem aqui utilizada para planejamento de trajetórias se baseia na estratégia com horizonte-retrocedente usando programação inteira-mista, conforme implementado em Viana et al. (2021).

Este trabalho é estruturado como se segue. A seção 2 apresenta a modelagem matemática do veículo. A seção 3 apresenta a metodologia empregada no projeto dos controladores para o planejamento e rastreamento de trajetórias. A seção 4 é destinada à avaliação do método proposto por meio de simulações numéricas no MATLAB/SIMULINK. Finalmente, a seção 5 dedica-se às conclusões do trabalho e apresenta sugestões para trabalhos futuros.

2. DEFINIÇÕES PRELIMINARES E MODELO DO VEÍCULO

2.1 Notação

O diagrama de blocos da estrutura de planejamento é mostrado na Figura 1. O planejador de trajetória gera trajetórias bidimensionais $\mathbf{r}_p^{(e)} \triangleq [r_{p,x}^{(e)} \ v_{p,x}^{(e)} \ r_{p,y}^{(e)} \ v_{p,y}^{(e)}]^T \in \mathbb{R}^4$ de um veículo principal *ego vehicle* e , de acordo com um plano pré-determinado. O vetor $r_p^{(o)} \in \mathbb{R}^2$ representa as coordenadas do obstáculo. O subscrito p denota as trajetórias geradas pelo planejador de trajetória.

Na camada superior da arquitetura, o planejador de trajetórias é implementado com MPC baseado em Programação Quadrática Inteira-Mista (MIQP) que calcula uma trajetória livre de colisão usando um modelo simplificado. Já a camada inferior é responsável por gerar os sinais dos atuadores e rastrear a trajetória $\mathbf{r}_p^{(e)}$, ou seja, a saída da camada superior se torna a trajetória de referência $\bar{\mathbf{r}}_t^{(e)}$ para a camada de controle de trajetória. Nesta, o controle de trajetória é desacoplado em um controlador lateral e longitudinal. Desse modo, um controlador MPC computa o ângulo de direção δ_f , enquanto que um controlador PI calcula a força longitudinal $F_{x,r}$. O subscrito t denota as trajetórias de referência do controle de trajetória na unidade hierárquica.

Suposição 1. Os estados do veículo são estimados usando as medições dos sensores à bordo e eles podem ser usados para realimentação. Um sistema de navegação inercial auxiliado por GPS é adequado para satisfazer esta suposição.

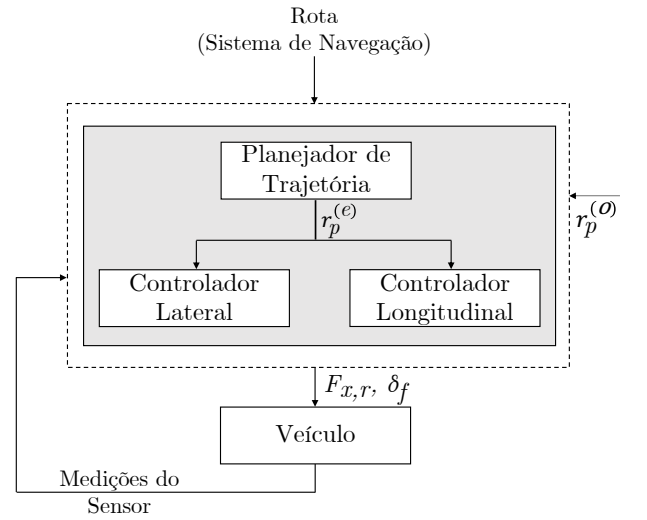


Figura 1. Visão geral da unidade hierárquica de planejamento e controle.

2.2 Modelo de Bicicleta

Para um referencial inercial, uma representação em espaço de estados não-linear de tempo contínuo que descreve o modelo dinâmico de bicicleta (Pacejka, 2005) é dado por

$$\dot{X} = f_c(X, U), \quad (1)$$

onde,

$$\dot{X} = \begin{bmatrix} v_x \cos \psi - v_y \sin \psi \\ v_x \sin \psi + v_y \cos \psi \\ \omega \\ \frac{1}{m}(F_{x,r} - F_{y,f} \sin \delta_f + m v_y \omega) \\ \frac{1}{m}(F_{y,r} + F_{y,f} \cos \delta_f + m v_x \omega) \\ \frac{1}{\Theta}(F_{y,f} l_f \cos \delta_f - F_{y,r} l_r) \end{bmatrix}. \quad (2)$$

O vetor de estado X e o vetor de entrada de controle U é definido como

$$X \triangleq [r_x \ r_y \ \psi \ v_x \ v_y \ \omega]^T \in \mathbb{R}^n, \quad U \triangleq [F_{x,r} \ \delta_f]^T \in \mathbb{R}^m. \quad (3)$$

No modelo do veículo dado em (2), r_x e r_y são as coordenadas do centro de massa representadas no sistema inercial S_I , v_x e v_y são as velocidades do veículo em um sistema de coordenadas fixo ao corpo S_B , conforme ilustrado na Figura 2. Além disso, ψ é o ângulo de guinada do veículo que muda a uma taxa de ω . Os parâmetros geométricos l_r e l_f descrevem a distância do centro de gravidade do veículo ao eixo traseiro e dianteiro, respectivamente.

Assumindo uma tração traseira, o vetor de controle U é composto pela força longitudinal $F_{x,r}$ na roda traseira e o ângulo de direção δ_f da roda dianteira. $F_{y,f}$ e $F_{y,r}$ denotam as forças laterais do pneu nas rodas dianteiras e traseiras, respectivamente.




Figura 2. Modelo de bicicleta.

Um modelo linear do pneu é adotado assumindo pequenos valores do ângulo de escorregamento lateral. Dessa modo, as forças laterais do pneu $F_{y,i}$ podem ser aproximadas de acordo com Rajamani (2006)

$$F_{y,i} = C_{\alpha i} \alpha_i \quad (4)$$

onde $i \in [f, r]$ e $C_{\alpha i}$ é a rigidez em curva dos pneus.

Os ângulos de escorregamento da roda dianteira e traseira α_f e α_r são dados, respectivamente, por:

$$\alpha_f = \delta_f - \tan^{-1} \left(\frac{v_y + l_f \dot{\psi}}{v_x} \right) \quad (5)$$

$$\alpha_r = -\tan^{-1} \left(\frac{v_y + l_r \dot{\psi}}{v_x} \right) \quad (6)$$

A dinâmica de tempo contínuo em (1) pode ser discretizada usando o método de Runge-Kutta levando a um sistema dinâmico de tempo discreto da forma,

$$X_{k+1} = f_k(X_k, U_k). \quad (7)$$

Para projetar o controlador lateral MPC de rastreamento de trajetória, o modelo dinâmico (2) é linearizado em torno de um ponto de equilíbrio (X_e, U_e) :

$$\dot{X}_e + \Delta \dot{X} = f(X_e, U_e) + \frac{\partial f}{\partial X} \Delta X + \frac{\partial f}{\partial U} \Delta U, \quad (8)$$

em que as matrizes do sistema linear invariante no tempo são obtidas a partir da matriz jacobiana,

$$A \triangleq \left. \frac{\partial f}{\partial X} \right|_{\substack{X=X_e \\ U=U_e}} \in \mathbb{R}^{n \times n}, \quad B \triangleq \left. \frac{\partial f}{\partial U} \right|_{\substack{X=X_e \\ U=U_e}} \in \mathbb{R}^{n \times m}. \quad (9)$$

3. PLANEJAMENTO DE TRAJETÓRIA HIERÁRQUICO USANDO MIQP

Nesta seção, apresentamos a abordagem de planejamento de trajetória baseada em programação quadrática inteira-mista com horizonte-retrocedente. Esta solução incorpora restrições com variáveis de otimização do tipo inteiras ou binárias em uma formulação de MPC linear. Uma vez calculada a solução ótima, as trajetórias planejadas são então convertidas em trajetória de referência $\bar{r}_t^{(e)}$ para o controlador de trajetória.

3.1 Modelo de Ponto de Massa

Suposição 2. A curvatura da estrada é adequadamente pequena. Semelhante ao que se encontra nas rodovias, considera-se uma estrada reta.

De acordo com a suposição 2, a trajetória pode ser planejada facilmente com a seguinte equação diferencial,

$$\dot{r}_x = v_x, \quad \dot{v}_x = a_x, \quad \dot{r}_y = v_y, \quad \dot{v}_y = a_y. \quad (10)$$

(10) descreve o modelo de duplo integrador. Consequentemente, pode-se levar em consideração o seguinte modelo de espaço de estados linear invariante no tempo discreto,

$$\begin{aligned} X_{k+1} &= A_d X_k + B_d U_k \\ Y_k &= C_d X_k \end{aligned} \quad (11)$$

onde o vetor de estados $X \triangleq [r_{p,x} \ v_{p,x} \ r_{p,y} \ v_{p,y}]^T \in \mathbb{R}^4$ descreve a posição e a velocidade do veículo na direção longitudinal x e lateral y da estrada no sistema inercial. O vetor de controle $U \triangleq [a_{p,x} \ a_{p,y}]^T \in \mathbb{R}^2$ consiste na aceleração longitudinal e lateral.

3.2 Restrições de Desvio de Obstáculos

As trajetórias planejadas livres de colisão podem ser garantidas se, para cada intervalo de tempo k , as coordenadas $r_{p,x}^{(e)}$, $r_{p,y}^{(e)}$ do veículo estiverem fora do retângulo delimitador de obstáculo mínimo representado por $[r_{p,x}^{(o)} - L^{(o)}, r_{p,x}^{(o)} + L^{(o)}] \times [r_{p,y}^{(o)} - W^{(o)}, r_{p,y}^{(o)} + W^{(o)}]$. Isso pode ser descrito pelo seguinte conjunto de restrições lógicas:

$\forall k \in \{1, \dots, t_f - 1\}$:

$$|r_{p,x}^{(e)}(k) - r_{p,x}^{(o)}(k)| \geq L^{(o)} \quad (12)$$

$$\text{OR } |r_{p,y}^{(e)}(k) - r_{p,y}^{(o)}(k)| \geq W^{(o)},$$

em que $L^{(o)}$ e $W^{(o)}$ são as dimensões longitudinal e lateral do obstáculo.

3.3 Planejador de Trajetória da Camada Superior

A chamada formulação Big-M (Williams and Brailsford, 1996) é empregada para transformar as restrições lógicas (12) em um conjunto de restrições não-convexas. Isso é obtido introduzindo as variáveis binárias $b_p^{(e,o)}(k) \in \{0, 1\}$.

O planejador de trajetória da camada superior calcula o vetor de controle ótimo $U_{k|k}^*$ através da minimização da seguinte função de custo quadrática,

$$\begin{aligned} \min_{U, X} J(k) = & \sum_{j=1}^N [X_{k+j|k} - \bar{X}_{k+j|k}]^T Q [X_{k+j|k} - \bar{X}_{k+j|k}] \\ & + \sum_{j=1}^M [U_{k+j-1|k}]^T R [U_{k+j-1|k}] \end{aligned} \quad (13)$$

sujeito a,

$$\begin{aligned} X_{k|k} &= X_{t_k} \\ X_{k+j|k} &= A_d X_{k+j-1|k} + B_d U_{k+j-1|k} \end{aligned} \quad (14)$$

$$\forall k \in \{1, \dots, t_f - 1\} : \quad \mathbf{r}_{\min} \leq \mathbf{r}_p^{(e)}(k) \leq \mathbf{r}_{\max} \quad (15)$$

$\forall k \in \{1, \dots, t_f - 1\}, \forall o \in \mathcal{O}$:

$$\begin{aligned} r_{p,x}^{(e)}(k) &\leq r_{p,x}^{(o)}(k) - L^{(o)} + M b_1^{(e,o)}(k) \\ \text{AND, } r_{p,x}^{(e)}(k) &\geq r_{p,x}^{(o)}(k) + L^{(o)} - M b_2^{(e,o)}(k) \\ \text{AND, } r_{p,y}^{(e)}(k) &\leq r_{p,y}^{(o)}(k) - W^{(o)} + M b_3^{(e,o)}(k) \\ \text{AND, } r_{p,y}^{(e)}(k) &\geq r_{p,y}^{(o)}(k) + W^{(o)} - M b_4^{(e,o)}(k) \\ \text{AND, } \sum_{p=1}^4 b_p^{(e,o)}(k) &\leq 3 \end{aligned} \quad (16)$$

As restrições convexas em (15) são empregadas para modelar a estrada em linha reta. Os vetores $\mathbf{r}_{\min}, \mathbf{r}_{\max} \in \mathbb{R}^2$ contém os limites da estrada ao longo de cada direção. Para solução deste problema MIQP, utilizou-se a versão acadêmica do pacote de otimização da IBM denominado CPLEX (®12.10 (IBM, 2009)).

3.4 Controle Longitudinal

Controle longitudinal é o sistema que controla o movimento longitudinal do veículo. Para o projeto do controlador, o seguinte modelo é utilizado (Rajamani, 2006):

$$a_{t,x} = \frac{1}{\tau s + 1} \bar{a}_{t,x} \quad (17)$$

onde $a_{t,x}$ é a aceleração longitudinal do veículo e o termo $\frac{1}{\tau s + 1}$ é incluído para simular a latência de resposta do atuador. Assumimos, portanto, que a aceleração do veículo

segue a aceleração desejada $\bar{a}_{t,x}$ gerada pelo controlador, com uma constante de tempo τ .




Figura 3. Malha de controle longitudinal.

Se o objetivo do controle longitudinal é manter o veículo em uma velocidade longitudinal de referência, um simples controlador PI é suficiente. Assim, a aceleração desejada é obtida por:

$$\bar{a}_{t,x} = K_p e(t) + K_i \int e(t) dt \quad (18)$$

onde $e(t)$ é o erro entre a velocidade real $v_{t,x}^e$ e a velocidade desejada $\bar{v}_{t,x}^e$. A função de transferência entre a velocidade longitudinal do veículo e a aceleração desejada é dada por:

$$P(s) = \frac{V(s)}{U(s)} = \frac{1}{s(\tau s + 1)} \quad (19)$$

O diagrama de blocos da malha de controle longitudinal é mostrado na Figura 3. A sintonização do controlador PI é feita usando técnica do Lugar das Raízes (LGR), usando modelo da planta apresentado em (18). Na simulação, a aceleração desejada é transformada em força longitudinal desejada, que é entrada de controle do modelo bicicleta.

3.5 Controle Lateral

O modelo linearizado na Seção 2.2 é usado para a implementação do controlador MPC de rastreamento de trajetória. Como o controle lateral é desacoplado, o controlador MPC calcula o ângulo de direção δ_f usando modelo de predição com as componentes dinâmicas látero-direcionais de (2).

O vetor de controle ótimo $U_{k|k}^*$, do controle de rastreamento de trajetória, é adquirido através da seguinte minimização:

$$\min_{U, X} J(k) = \sum_{j=1}^N \|y_{k+j|k} - \bar{y}_{k+j|k}\|_Q + \sum_{j=1}^M \|U_{k+j-1|k}\|_R, \quad (20)$$

sujeito a

$$U_{\min} \leq U \leq U_{\max} \quad (21)$$

Em (21) U_{\min} e U_{\max} são os limites superior e inferior sobre os comandos de controle, assim definidos:

$$U_{\min} = [\delta_f]^T, U_{\max} = [\delta_f]^T \quad (22)$$

Neste caso, a referência do MPC para rastreamento é dada pelo vetor $\bar{y} \triangleq [\bar{r}_{t,x}^{(e)}, \bar{r}_{t,y}^{(e)}]^T$ obtido do planejador de trajetória, como mostrado na Figura 1.

4. RESULTADOS

Nesta seção, avaliamos o desempenho do controlador desacoplado da estrutura de planejamento de trajetória para diferentes perfis de velocidades, em um cenário com desvio de obstáculos.

4.1 Parâmetros de simulação

O *solver* utilizado nas simulações é o Runge-Kutta 4 com passo de integração de 0,001 s. A implementação dos algoritmos propostos é feita no MATLAB/SIMULINK, e os experimentos são conduzidos em um computador com 8GB de RAM, e CPU Intel Core i5 com 1.4GHz. Os parâmetros do veículo, para qual foram realizados os testes, são observados na Tabela 1.

Tabela 1. Parâmetros do Veículo.

Variáveis	Valores
Massa do veículo, m	1800 kg
Momento de Inércia, Θ	3600 kg m ²
Distância entre eixos, l	4.8 m
Distância do eixo frontal para o CG, l_f	2.4 m
Distância do eixo traseiro para o CG, l_r	2.4 m
Rigidez nas curvas, c_f, c_r	36000 N m/rad

Os parâmetros do MPC para rastreamento de trajetória são observados na Tabela 2. O período de amostragem escolhido foi de $T = 0,01$ s. Para um controle menos agressivo, que gere movimentos mais suaves do veículo, um horizonte de predição relativamente grande ($N = 20$) e um horizonte de controle relativamente pequeno ($M = 5$) são usados. As restrições dos atuadores são definidas conforme os limites de saturação. Para resolver o problema de otimização embutido no algoritmo MPC, é utilizada a função quadprog disponível no MATLAB, com o método *Interior-Point*.

Tabela 2. Parâmetros do MPC para rastreamento de trajetória

Variáveis	Valores
Horizonte de predição	$N = 20$
Horizonte de controle	$M = 5$
Período de amostragem	$T = 0,01$ s
Pesos das saídas de controle	$\eta = [1 \ 1 \ 1 \ 1]^T$
Pesos das entradas de controle	$\rho = 1$
Restrições de controle	$\delta_f = -2^\circ, \delta_r = 2^\circ$

Os parâmetros do controlador PI, sintonizado para o controle longitudinal, são mostrados na Tabela 3.

Tabela 3. Parâmetros do controlador PI

Variáveis	Valores
Ganho proporcional K_p	1,5
Ganho integral K_i	0,375

4.2 Resultados de simulação

A estrutura de planejamento de trajetória é aplicada para demonstrar a viabilidade em cenários de rodovias. O obstáculo retangular é colocado no percurso, e está centrado em $O = [80 \ 1,5]^T$ m. As simulações são feitas para três perfis de velocidade longitudinal $\bar{v}_x = [10 \ 15 \ 30]^T$ m/s.

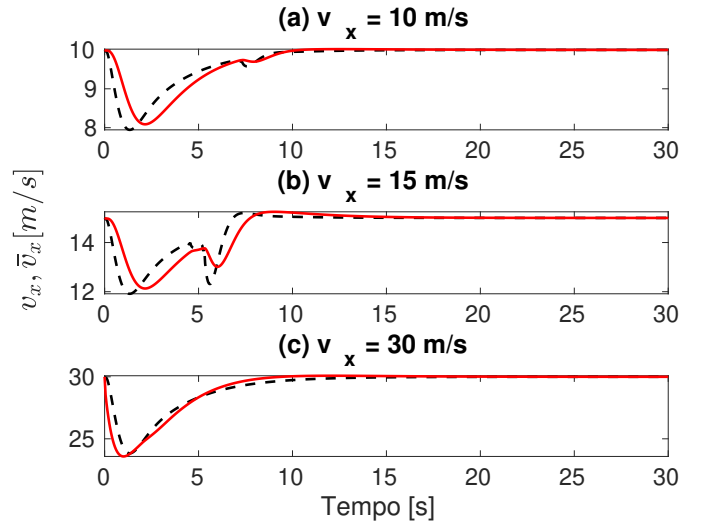


Figura 4. Resposta da velocidade longitudinal para cada perfil de referência \bar{v}_x .

Como pode ser observado na Figura 4, a velocidade do veículo desacelera inicialmente à medida que este se aproxima do obstáculo, como resultado, a força longitudinal diminui. Após ultrapassar o obstáculo, o veículo consegue seguir a velocidade de referência de maneira satisfatória para os três perfis de velocidade, não havendo erro em estado estacionário.

A Figura 5 ilustra as trajetórias planejadas resultantes juntamente com a trajetória real do veículo. A posição inicial do veículo é $\mathbf{r} = [0 \ 2.5]^T$ m e ele se move ao longo de uma estrada reta horizontal. Podemos notar que o veículo realiza a manobra de desvio de obstáculo, realizando mudança de faixa, para os três perfis de velocidade. O melhor desempenho do controlador é visto para o perfil de velocidade mais baixa. Em geral, observa-se um maior descasamento entre a trajetória real e a planejada à medida que a velocidade do veículo aumenta.




Figura 5. Trajetórias do veículo durante manobra para desvio de obstáculos.

A Figura 6 mostra o comportamento da velocidade de guinada ω para os três perfis de velocidade longitudinal.

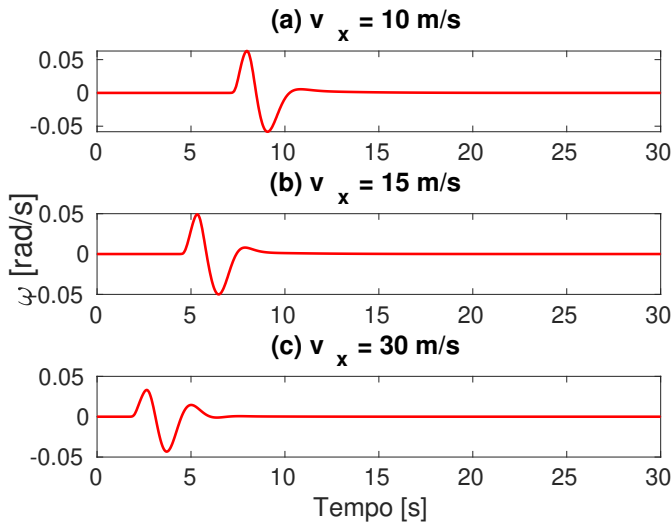


Figura 6. Velocidade de guinada para cada perfil de velocidade.

Pode-se ver que há uma menor velocidade de guinada à proporção que velocidade longitudinal aumenta.

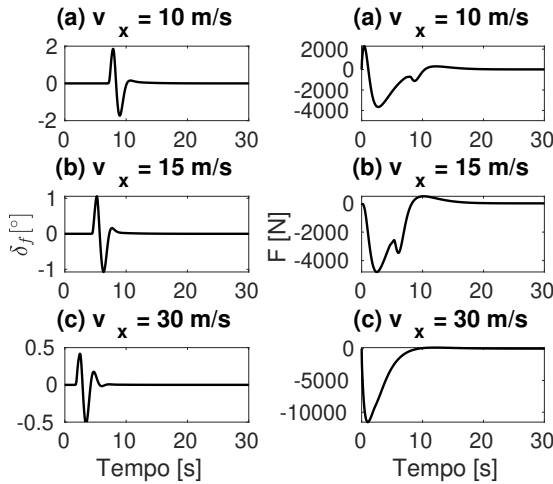


Figura 7. Sinais de controle para cada perfil de velocidade.

A Figura 7 mostra os sinais de controle gerados pelo controlador lateral e longitudinal. Primeiro, o ângulo de direção vira à esquerda para evitar a colisão, depois ele vira à direita para retornar o veículo à sua trajetória de referência. Percebe-se, também, que em perfil de velocidade mais baixa, o veículo produz alterações maiores no ângulo de direção, conseguindo um melhor desempenho na tarefa de desvio de obstáculo. Já os gráficos de força longitudinal mostram que o veículo realiza uma frenagem mais brusca para perfis de velocidades maiores.

5. CONCLUSÃO

Este trabalho produziu a avaliação do comportamento de um controlador desacoplado de veículos autônomos, usando unidade hierárquica de planejamento de trajetória baseada em programação quadrática inteira-mista. Os resultados mostram que o controlador desacoplado da camada interna, utilizando MPC para controle lateral e um controlador PI para o controle longitudinal, apresentou resultado

satisfatório no rastreo de trajetória e de velocidade longitudinal.

Para avaliar o desempenho do método proposto, foram feitas simulações em cenário com desvio de obstáculos para três perfis de velocidade. O veículo foi capaz de desviar o obstáculo, mas com um atraso na execução da manobra que se deve à latência do atuador. Concluímos, que, embora o controlador atenda aos requisitos de desvio de obstáculos, seu desempenho se degrada com o aumento da velocidade longitudinal. Logo, é necessário implementar uma margem de segurança no planejador de trajetórias proposto.

Como trabalhos futuros, pretende-se implementar o controlador proposto em um simulador realista, como o Gazebo Koenig and Howard (2004), que captura as dinâmicas de um veículo real. Isso permitiria uma melhor avaliação sobre o desempenho do controlador em um veículo real.

REFERÊNCIAS

- Brasch, M., Heinz, I.S., and Bayer, A. (2022). Lateral control of a vehicle using reinforcement learning. In *2022 8th International Conference on Control, Decision and Information Technologies (CoDIT)*, volume 1, 451–456. doi:10.1109/CoDIT55151.2022.9804101.
- Chen, J., Zhan, W., and Tomizuka, M. (2017). Constrained iterative lqr for on-road autonomous driving motion planning. 1–7. doi:10.1109/ITSC.2017.8317745.
- Falcone, P., Borrelli, F., Asgari, J., Tseng, E., and Hrovat, D. (2007). Predictive active steering control for autonomous vehicle systems. *Control Systems Technology, IEEE Transactions on*, 15, 566 – 580. doi:10.1109/TCST.2007.894653.
- IBM (2009). *IBM ILOG CPLEX V12.1: user's Manual for CPLEX*.
- Koenig, N. and Howard, A. (2004). Design and use paradigms for gazebo, an open-source multi-robot simulator. In *2004 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)(IEEE Cat. No. 04CH37566)*, volume 3, 2149–2154. IEEE.
- Marino, R., Scalzi, S., and Netto, M. (2011). Nested pid steering control for lane keeping in autonomous vehicles. *Control Engineering Practice - CONTROL ENG PRACTICE*, 19, 1459–1467. doi:10.1016/j.conengprac.2011.08.005.
- Pacejka, H. (2005). *Tire and Vehicle Dynamics*. Elsevier.
- Rajamani, R. (2006). *Vehicle Dynamics and Control*. doi:10.1007/0-387-28823-6.
- Viana, I., Kanchwala, H., Ahiska, K., and Aouf, N. (2021). A comparison of trajectory planning and control frameworks for cooperative autonomous driving. *Journal of Dynamic Systems Measurement and Control*, 143. doi:10.1115/1.4049554.
- Wallace, R., Stentz, A., Thorpe, C., Maravec, H., Whittaker, W., and Kanade, T. (1985). First results in robot road-following. 1089–1095.
- Williams, H.P. and Brailsford, S.C. (1996). *Computational Logic and Integer Programming*. Oxford University Press, Inc., j. e. beasley edition.
- Yang, S., Wang, W., Liu, C., and Deng, W. (2019). Scene understanding in deep learning-based end-to-end controllers for autonomous vehicles. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 49(1), 53–63. doi:10.1109/TSMC.2018.2868372.