



Controle de Veículos Aéreos

Prof. Dr. Mário Sarcinelli Filho

Universidade Federal do Espírito Santo – UFES

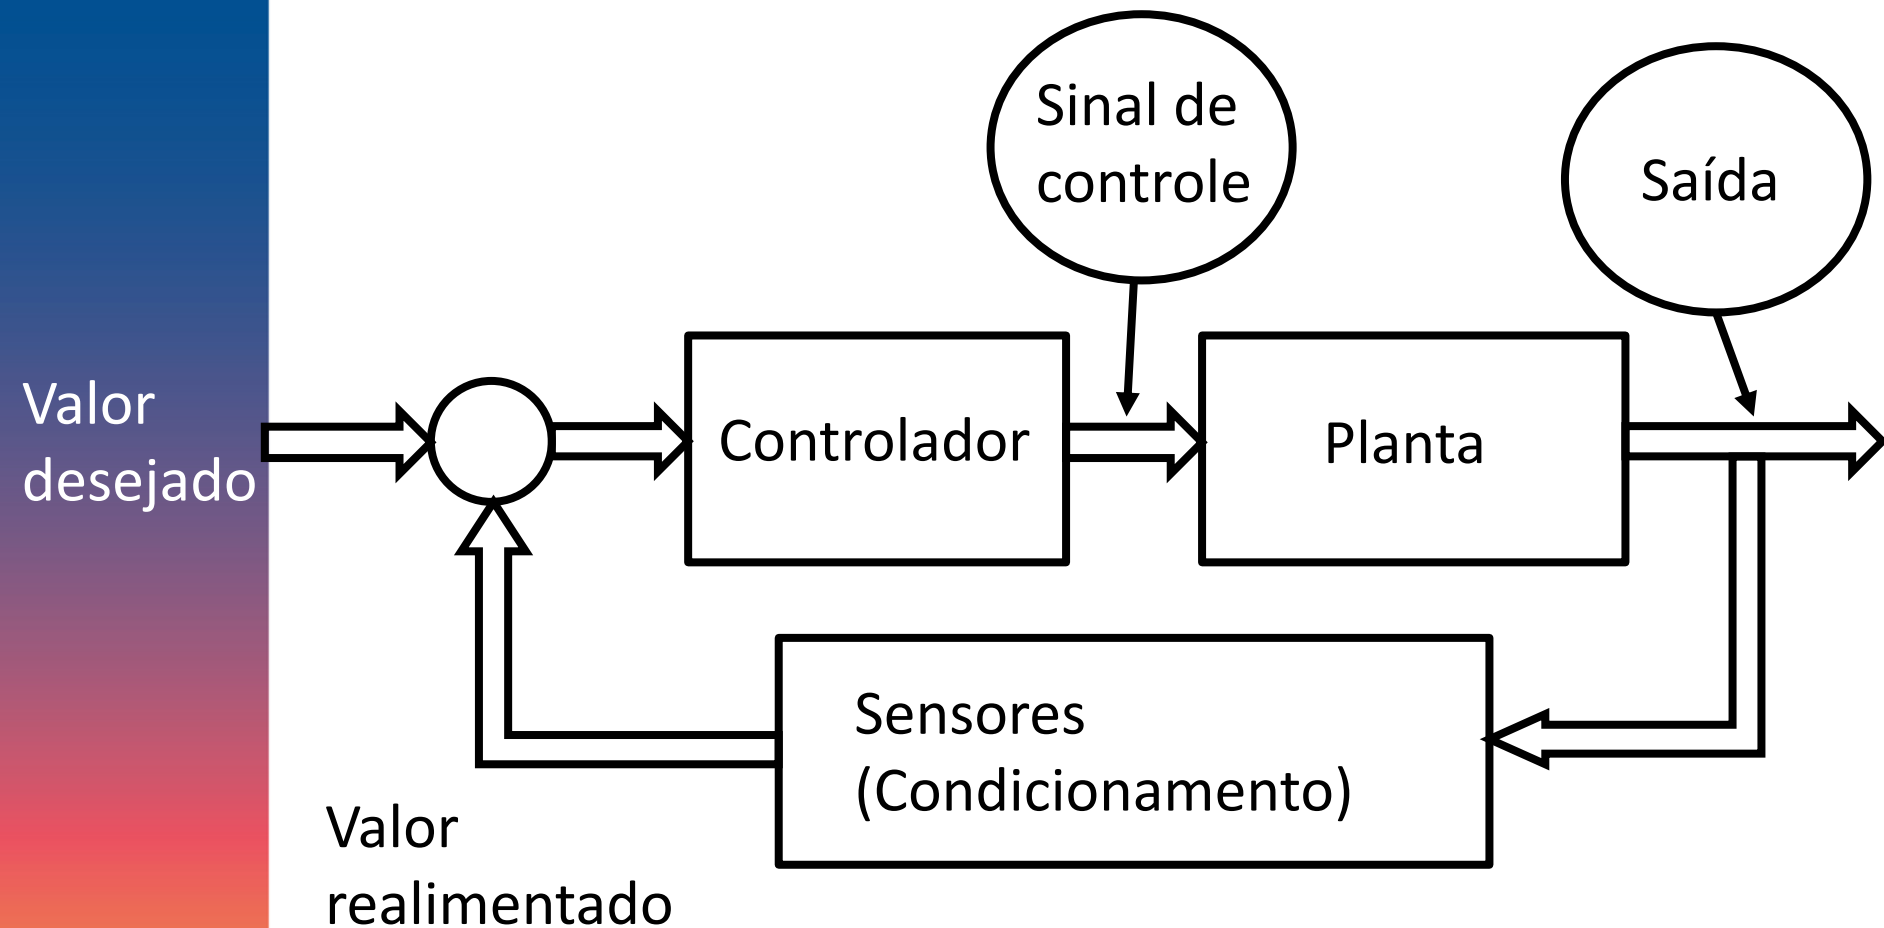
Bolsista de Produtividade em Pesquisa PQ-2 do CNPq

Orientador de Mestrado e Doutorado

Sumário

- **O que é controle?**
- **O quadrimotor Ar.Drone 2.0**
- **Correção dos erros de posição**
- **Fusão de dados de posição usando Filtro de Kalman**
- **Modelo adotado para o veículo**
- **Controlador projetado para navegação autônoma**
- **Controle de posição**
- **Controle de seguimento de trajetória**
- **Controle de formação líder-seguidor**

O que é controle?



O quadrimotor Ar.Drone 2.0

- AR.Drone 2.0, da Parrot, Inc. (www.parrot.com/usa), juntamente com os sistemas de coordenadas adotados:



O quadrimotor Ar.Drone 2.0

- Comercialmente disponível a baixo custo (US\$ 300) com computador de bordo com uma distribuição Linux;
- Comunicação Wi-Fi com protocolos de comunicação fornecidos pelo fabricante;
- Processamentos disponíveis para estabilização, decolagem e pouso.
- Sensores de bordo: unidade de medida inercial com acelerômetros, giroscópios e magnetômetros, um par ultrassônico (transmissor e receptor), um sensor barométrico e duas câmaras de vídeo, uma apontada para baixo e outra para a frente;
- Conjunto de variáveis disponibilizadas (após algum processamento):

$$\mathbf{q} = [z \quad v_x \quad v_y \quad \phi \quad \theta \quad \psi]$$

- Conjunto de sinais de controle:

$$\mathbf{u} = [u_{\dot{z}} \quad u_{\dot{\psi}} \quad u_{v_x} \quad u_{v_y}] \in [-1.0, +1.0]$$

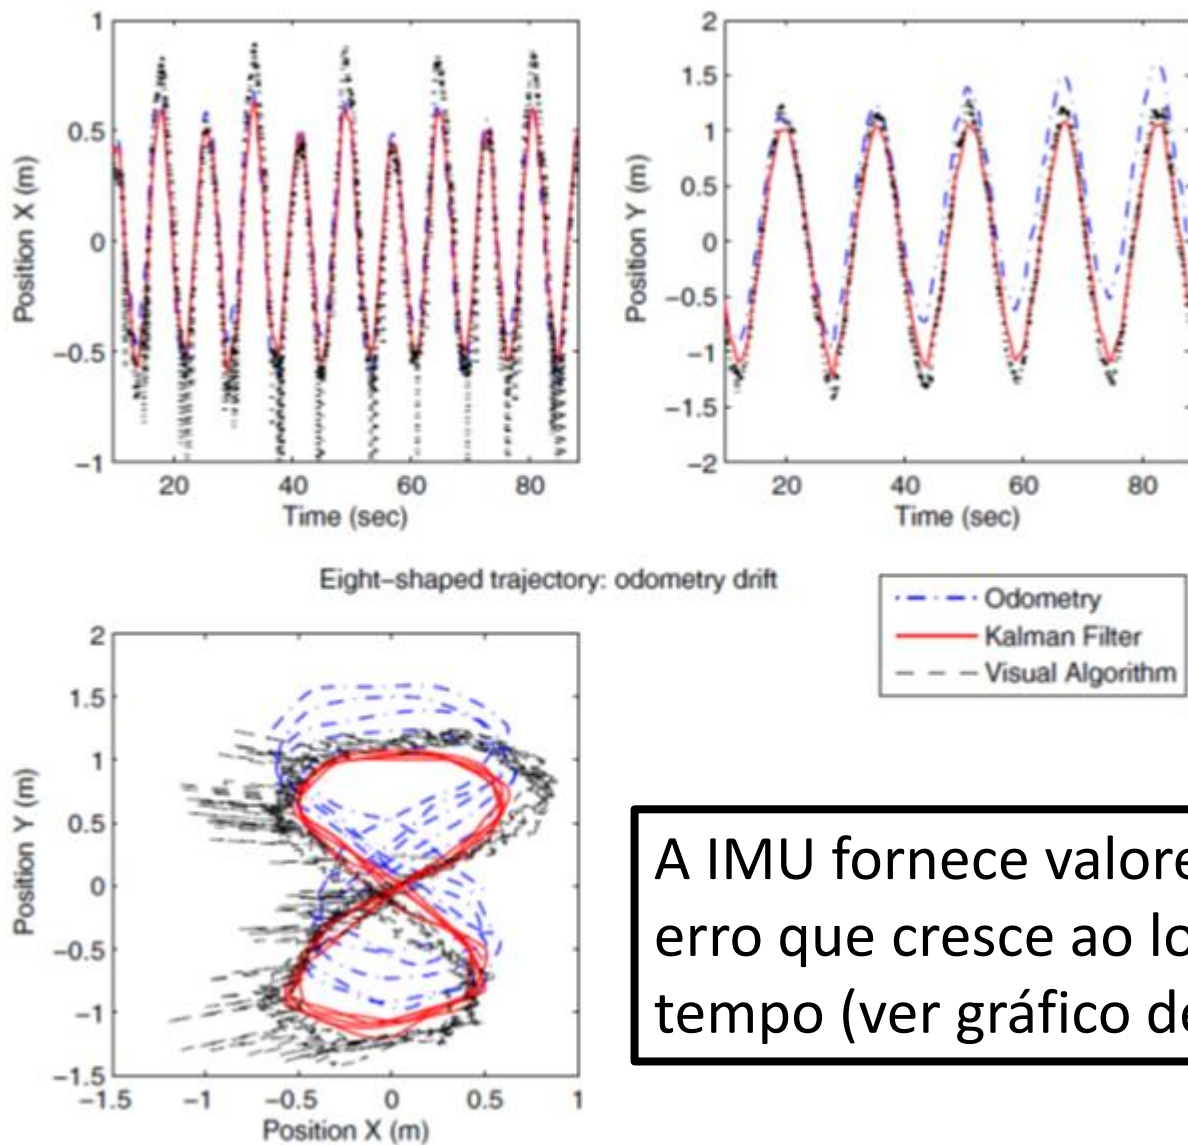
$u_{\dot{z}}$ – comando de velocidade linear ao longo do eixo z_w ;

$u_{\dot{\psi}}$ – comando de velocidade angular ao redor do eixo z_w (guinada);

u_{v_x} – comando de velocidade linear em x_b (deslocamento lateral);

u_{v_y} – comando de velocidade linear em y_b (deslocamento longitudinal).

Correção dos erros de posição

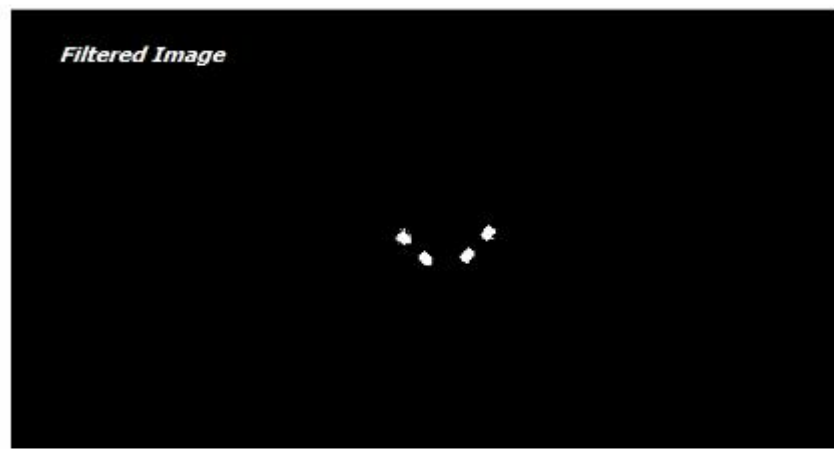




A IMU fornece valores com erro que cresce ao longo do tempo (ver gráfico de Y).

Fig. 12. Demonstration of the odometry drift in the case of the Experiment 4.

Correção dos erros de posição

É utilizada informação visual obtida com a câmara frontal da aeronave. Usando o algoritmo *SolvePnP* pode-se estimar a pose do veículo em relação ao marco visual.



Correção dos erros de posição

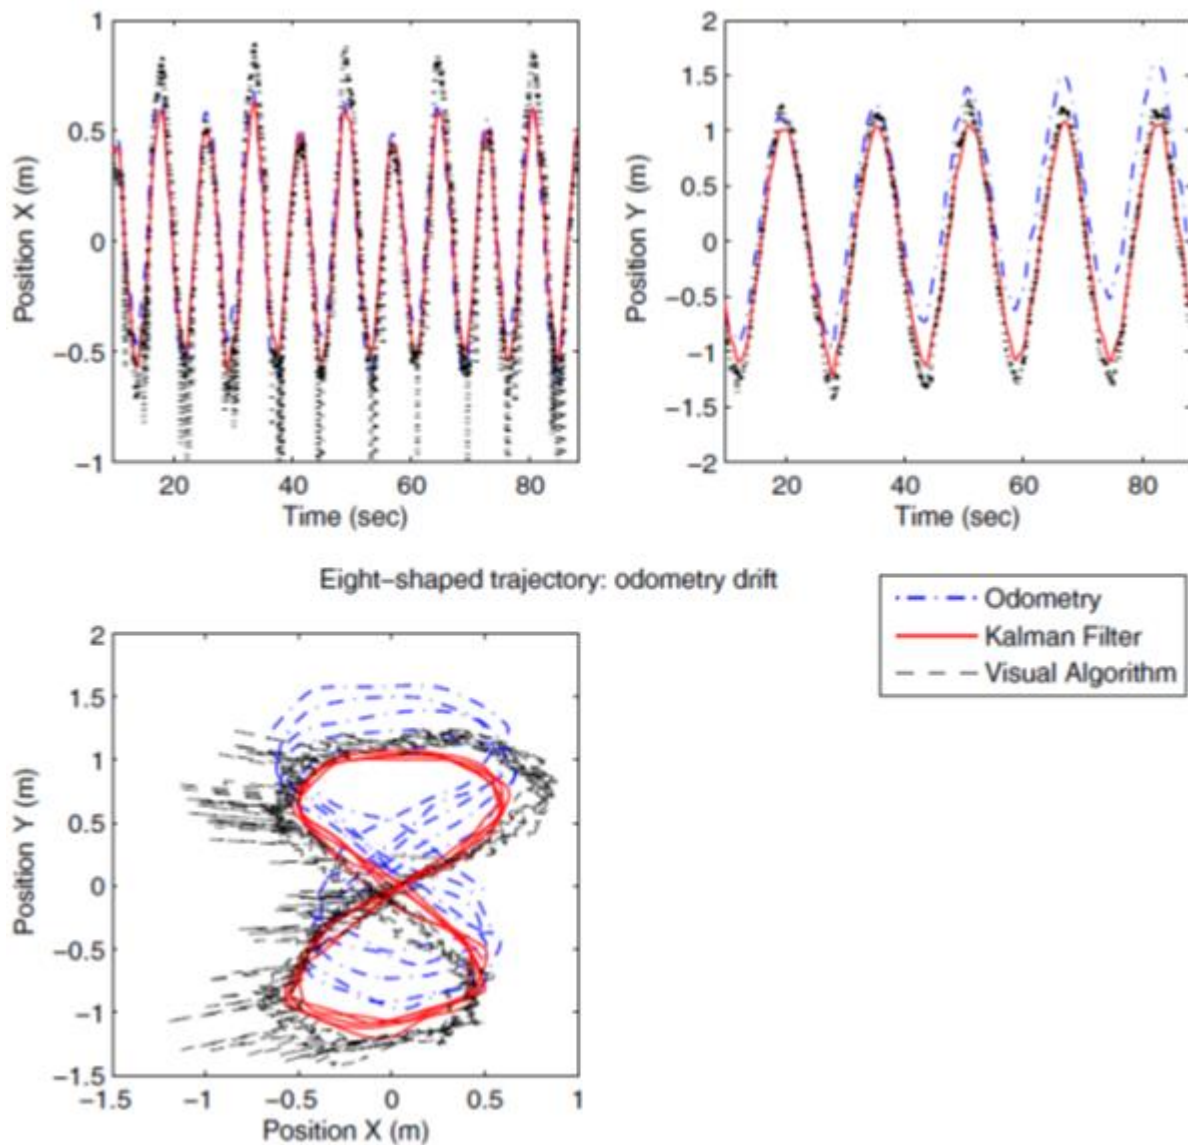


Fig. 12. Demonstration of the odometry drift in the case of the Experiment 4.

Fusão de dados de posição usando Filtro de Kalman

Filtro de Kalman

$$\mathbf{x}_k = \mathbf{F}\mathbf{x}_{k-1} + \mathbf{B}\mathbf{u}_k + \mathbf{w}_k$$

$$\mathbf{z}_k = \mathbf{H}\mathbf{x}_k + \mathbf{v}_k$$

Algorithm 1: The Kalman Filter procedure.

- 1: $\bar{\mathbf{x}}_k = \mathbf{F}\hat{\mathbf{x}}_{k-1} + \mathbf{B}\mathbf{u}_k$
 - 2: $\bar{\mathbf{P}}_k = \mathbf{F}\hat{\mathbf{P}}_{k-1}\mathbf{F}^T + \mathbf{Q}$
 - 3: $\mathbf{K}_k = \bar{\mathbf{P}}_k\mathbf{H}^T (\mathbf{H}\bar{\mathbf{P}}_k\mathbf{H}^T + \mathbf{R})^{-1}$
 - 4: $\hat{\mathbf{x}}_k = \bar{\mathbf{x}}_k + \mathbf{K}_k (\mathbf{z}_k - \mathbf{H}\bar{\mathbf{x}}_k)$
 - 5: $\hat{\mathbf{P}}_k = (\mathbf{I} - \mathbf{K}_k\mathbf{H})\bar{\mathbf{P}}_k$
-

Fusão de dados de posição usando Filtro de Kalman

- \mathbf{x} é o vetor de estados do sistema
- \mathbf{F} é a matriz de transição de estados do modelo
- \mathbf{B} é a matriz de entradas de controle
- \mathbf{z} é o vetor de medidas dos estados (sensores)
- \mathbf{H} é a matriz do modelo de observação dos sensores
- \mathbf{w} e \mathbf{v} são ruídos Gaussianos com média zero
- k se refere ao instante de tempo atual
- $\hat{\mathbf{x}}$ é o estado estimado pelo filtro
- $\hat{\mathbf{P}}$ é a matriz de covariância do erro
- \mathbf{K} é o ganho de Kalman
- \mathbf{Q} é a matriz de covariância do ruído do processo
- \mathbf{R} é a matriz de covariância do ruído de medição

Fusão de dados de posição usando Filtro de Kalman

Modelo do processo

$$\begin{bmatrix} x_{k+1} \\ y_{k+1} \\ z_{k+1} \\ \psi_{k+1} \\ \dot{x}_{k+1} \\ \dot{y}_{k+1} \\ \dot{z}_{k+1} \\ \dot{\psi}_{k+1} \end{bmatrix} = \begin{bmatrix} x_k + \delta t \dot{x}_k \\ y_k + \delta t \dot{y}_k \\ z_k + \delta t \dot{z}_k \\ \psi_k + \delta t \dot{\psi}_k \\ \dot{x}_k \\ \dot{y}_k \\ \dot{z}_k \\ \dot{\psi}_k \end{bmatrix}$$

Aqui δt é o período de amostragem e as posições são obtidas por integração das velocidades, consideradas constantes entre dois instantes de amostragem.

Fusão de dados de posição usando Filtro de Kalman

Modelo de observação sem Informação Visual

$$\mathbf{z}_1 = \begin{bmatrix} z \\ \psi \\ \dot{x} \\ \dot{y} \end{bmatrix} = \begin{bmatrix} z \\ \psi \\ \cos \psi v_x - \sin \psi v_y \\ \sin \psi v_x + \cos \psi v_y \end{bmatrix}$$

$$\mathbf{H}_1 = \begin{bmatrix} 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \end{bmatrix}$$

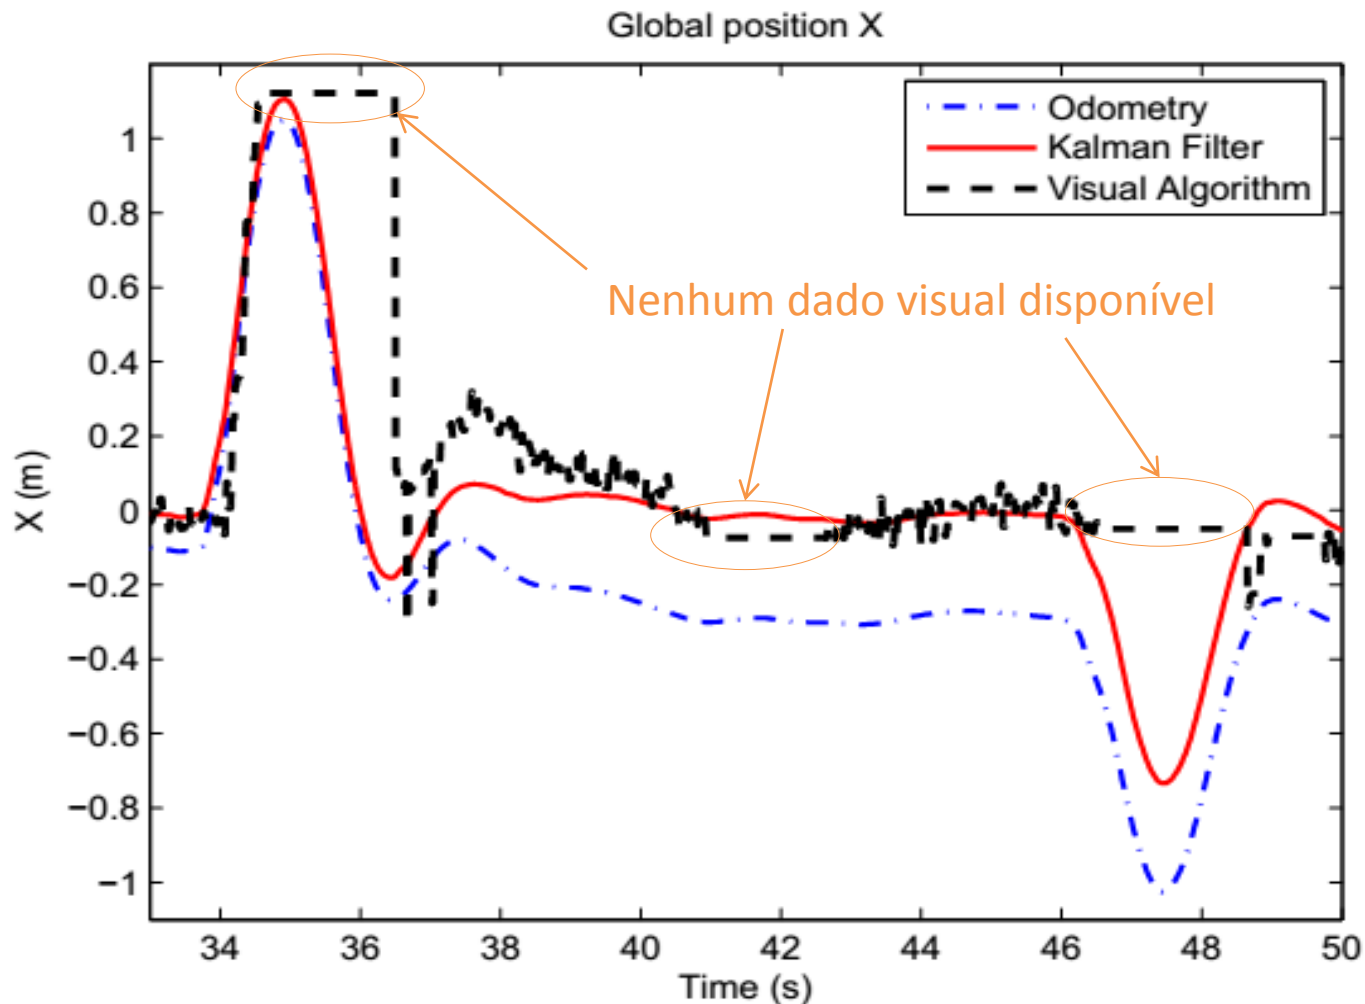
Fusão de dados de posição usando Filtro de Kalman

Modelo de observação com Informação Visual

$$\mathbf{z}_2 = \begin{bmatrix} x \\ y \\ z \\ \psi \\ \dot{x} \\ \dot{y} \end{bmatrix} = \begin{bmatrix} x_w \\ y_w \\ z \\ \psi \\ \cos \psi v_x - \sin \psi v_y \\ \sin \psi v_x + \cos \psi v_y \end{bmatrix}$$

$$\mathbf{H}_2 = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \end{bmatrix}$$

Fusão de dados de posição usando Filtro de Kalman



Modelo adotado para o veículo

- Da literatura e de nossa experiência com o AR.Drone Parrot, notamos que a sua dinâmica pode ser aproximada por quatro sistemas lineares independentes, cada um respondendo a uma das entradas de controle disponíveis;
- Esta proposta, apesar de suas limitações práticas, foi validada através de experimentos, alguns deles apresentados adiante.

Modelo adotado para o veículo

- Considerando a observação do slide anterior, a dinâmica do Ar.Drone Parrot pode ser expressa como função dos seus sinais de controle, o que significa escrever

$$\begin{cases} \dot{v}_x = K_1 u_{v_x} - K_2 v_x \\ \dot{v}_y = K_3 u_{v_y} - K_4 v_y \\ \ddot{z} = K_5 u_{\dot{z}} - K_6 \dot{z} \\ \ddot{\psi} = K_7 u_{\dot{\psi}} - K_8 \dot{\psi} \end{cases}$$

onde K_1, \dots, K_8 são constantes de proporcionalidade identificadas experimentalmente



Modelo adotado para o veículo

- Em coordenadas globais:

$$\begin{bmatrix} \ddot{x} \\ \ddot{y} \\ \ddot{z} \\ \ddot{\psi} \end{bmatrix} = \begin{bmatrix} K_1 \cos \psi & -K_3 \sin \psi & 0 & 0 \\ K_1 \sin \psi & K_3 \cos \psi & 0 & 0 \\ 0 & 0 & K_5 & 0 \\ 0 & 0 & 0 & K_7 \end{bmatrix} \begin{bmatrix} u_{v_x} \\ u_{v_y} \\ u_{\dot{z}} \\ u_{\dot{\psi}} \end{bmatrix} - \begin{bmatrix} K_2 \cos \psi & -K_4 \sin \psi & 0 & 0 \\ K_2 \sin \psi & K_4 \cos \psi & 0 & 0 \\ 0 & 0 & K_6 & 0 \\ 0 & 0 & 0 & K_8 \end{bmatrix} \begin{bmatrix} v_x \\ v_y \\ \dot{z} \\ \dot{\psi} \end{bmatrix}$$

- Outra representação:

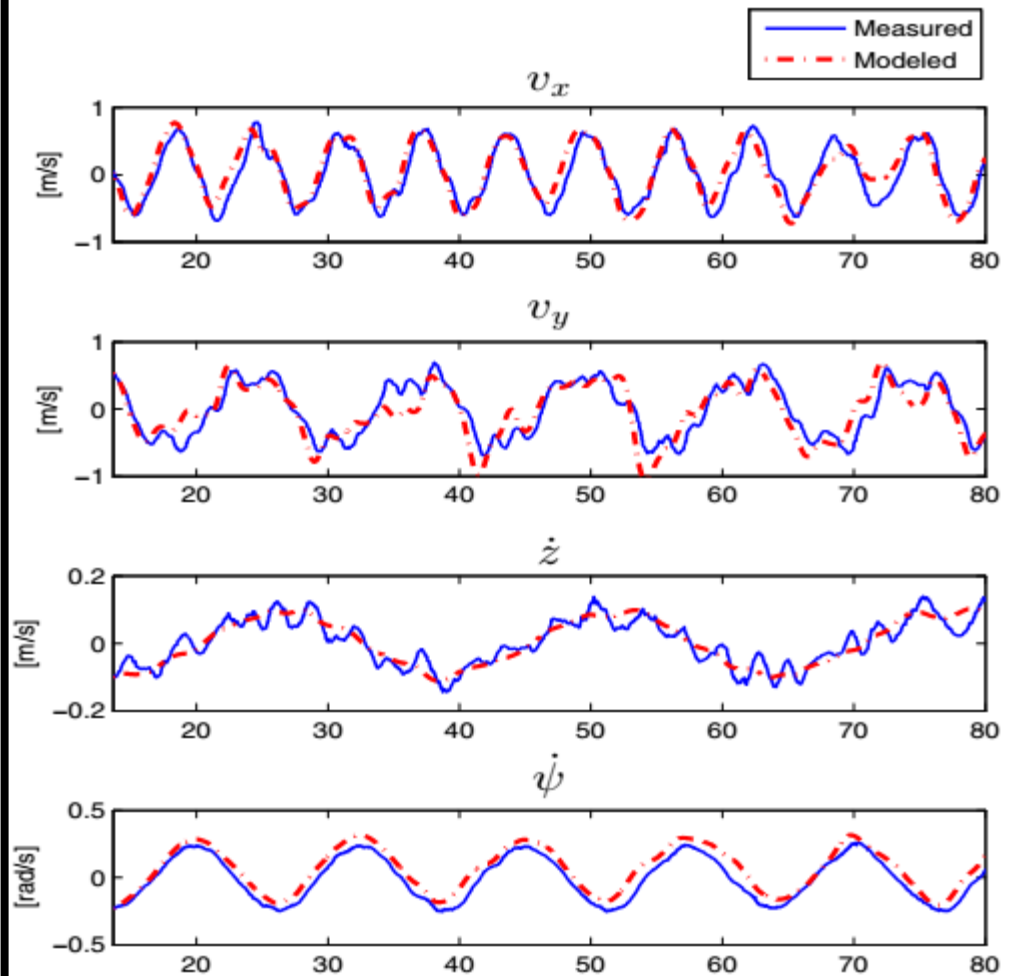
$$\ddot{\mathbf{X}} = \mathbf{f}_1 \mathbf{U} - \mathbf{f}_2 \dot{\mathbf{X}}$$

onde

$$\ddot{\mathbf{X}} = \begin{bmatrix} \ddot{x} \\ \ddot{y} \\ \ddot{z} \\ \ddot{\psi} \end{bmatrix}, \quad \mathbf{U} = \begin{bmatrix} u_{v_x} \\ u_{v_y} \\ u_{\dot{z}} \\ u_{\dot{\psi}} \end{bmatrix}, \quad \dot{\mathbf{X}} = \begin{bmatrix} v_x \\ v_y \\ \dot{z} \\ \dot{\psi} \end{bmatrix}$$

Modelo adotado para o veículo

- Comparação entre os dados reais medidos durante um voo conduzido por sinais de entrada selecionados e os dados resultantes da simulação do modelo prévio com os mesmos sinais de entrada. Conclui-se que o modelo segue os dados reais, sendo, assim, adequado para fins de controle.



Controlador projetado para navegação autônoma

- Propõe-se um algoritmo de controle baseado no modelo

$$\ddot{\mathbf{X}} = \mathbf{f}_1 \mathbf{U} - \mathbf{f}_2 \dot{\mathbf{X}}$$

- A lei de controle adotada (baseada em dinâmica inversa, usando linearização por realimentação) é

$$\mathbf{U} = \mathbf{f}_1^{-1}(\boldsymbol{\nu} + \mathbf{f}_2 \dot{\mathbf{X}})$$

resultando em

$$\ddot{\mathbf{X}} = \boldsymbol{\nu}$$

Controlador projetado para navegação autônoma

- Definindo o vetor de erro de posição como

$$\tilde{\mathbf{X}} = \mathbf{X}_d - \mathbf{X}$$

e considerando

$$\nu = \ddot{\mathbf{X}}_d + \kappa_p \tilde{\mathbf{X}} + \kappa_d \dot{\tilde{\mathbf{X}}}$$

onde

- \mathbf{X}_d é o vetor de posições desejadas, e
- κ_p e κ_d são matrizes de ganho diagonais e positivas definidas,

a equação de malha fechada resultante é

$$\ddot{\tilde{\mathbf{X}}} + \kappa_p \tilde{\mathbf{X}} + \kappa_d \dot{\tilde{\mathbf{X}}} = 0$$

Controlador projetado para navegação autônoma

- Para analisar a estabilidade da solução $\tilde{\mathbf{X}}$ de

$$\ddot{\tilde{\mathbf{X}}} + \kappa_p \dot{\tilde{\mathbf{X}}} + \kappa_d \tilde{\mathbf{X}} = 0$$

a função candidata de Lyapunov

$$V(\tilde{\mathbf{X}}, \dot{\tilde{\mathbf{X}}}) = \frac{1}{2} \tilde{\mathbf{X}}^T \kappa_p \tilde{\mathbf{X}} + \frac{1}{2} \dot{\tilde{\mathbf{X}}}^T \dot{\tilde{\mathbf{X}}} \geq 0$$

é considerada, cuja primeira derivada é

$$\begin{aligned} \dot{V}(\tilde{\mathbf{X}}, \dot{\tilde{\mathbf{X}}}) &= \dot{\tilde{\mathbf{X}}}^T \kappa_p \tilde{\mathbf{X}} + \dot{\tilde{\mathbf{X}}}^T \ddot{\tilde{\mathbf{X}}} \\ &= \dot{\tilde{\mathbf{X}}}^T \kappa_p \tilde{\mathbf{X}} + \dot{\tilde{\mathbf{X}}}^T \left(-\kappa_p \dot{\tilde{\mathbf{X}}} - \kappa_d \tilde{\mathbf{X}} \right) \\ &= -\dot{\tilde{\mathbf{X}}}^T \kappa_d \tilde{\mathbf{X}} \leq 0. \end{aligned}$$

Com base na teoria de Lyapunov para sistemas não lineares, conclui-se que

$$\tilde{\mathbf{X}}(t) \rightarrow 0, \text{ when } t \rightarrow \infty,$$

ou seja, o sistema de controle em malha fechada é assintoticamente estável.

Controlador projetado para navegação autônoma

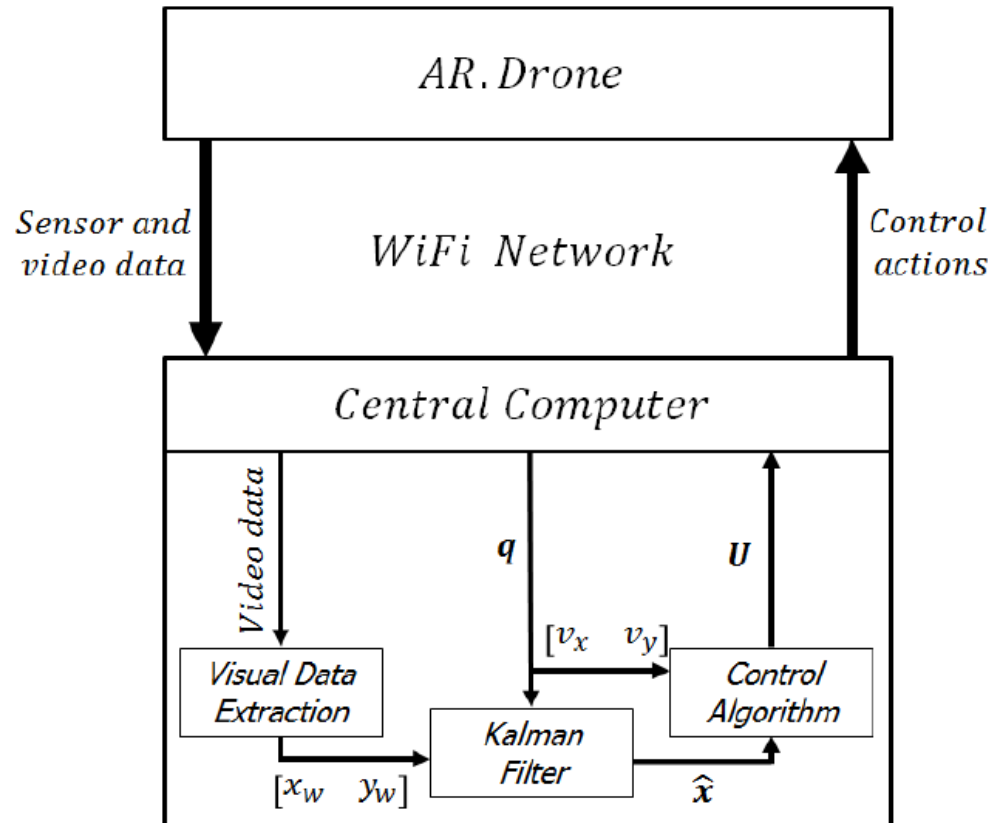


Fig. 7. System software architecture. x_w and y_w are the global position coordinates from the visual system. q is the set of variables from the AR.Drone sensor board. \hat{x} is the KF state estimation output and U is the set of control actions of the AR.Drone.

Controle de posição


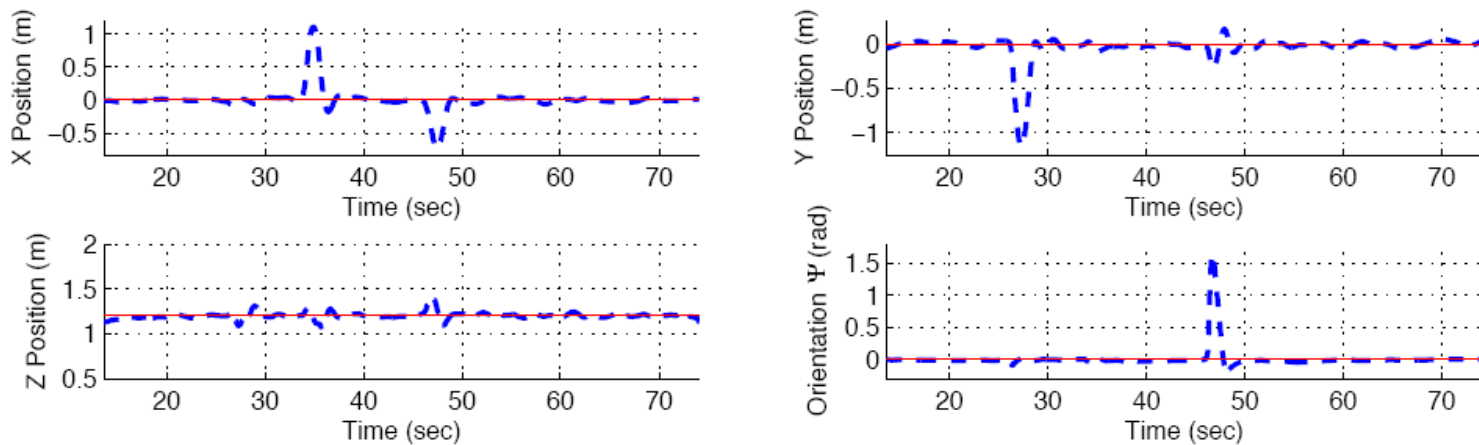


Fig. 8. Experiment 1: Hovering.

Controle de posição





Fig. 9. Experiment 2: Positioning task (the successive desired positions are the corners of the polygon).

Controle de seguimento de trajetória

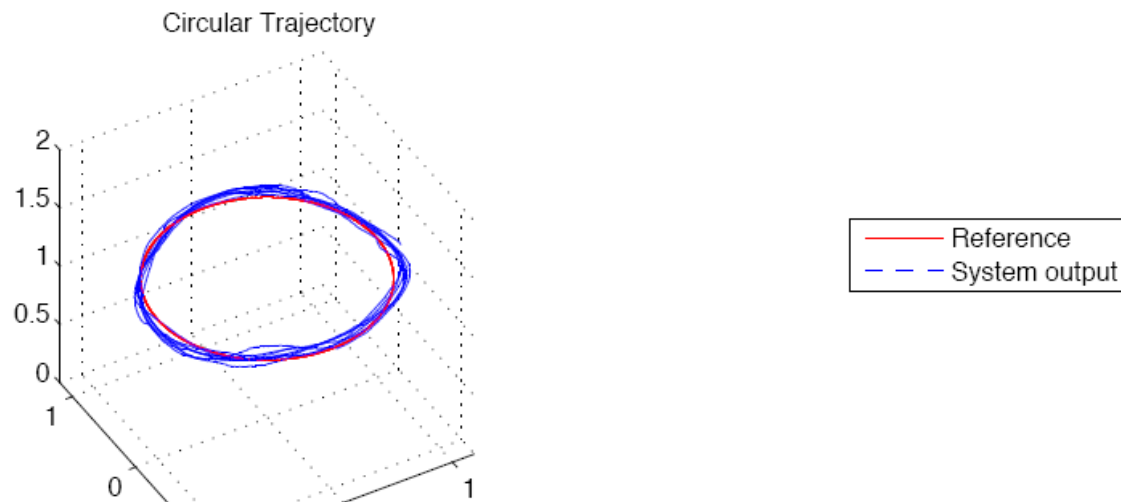
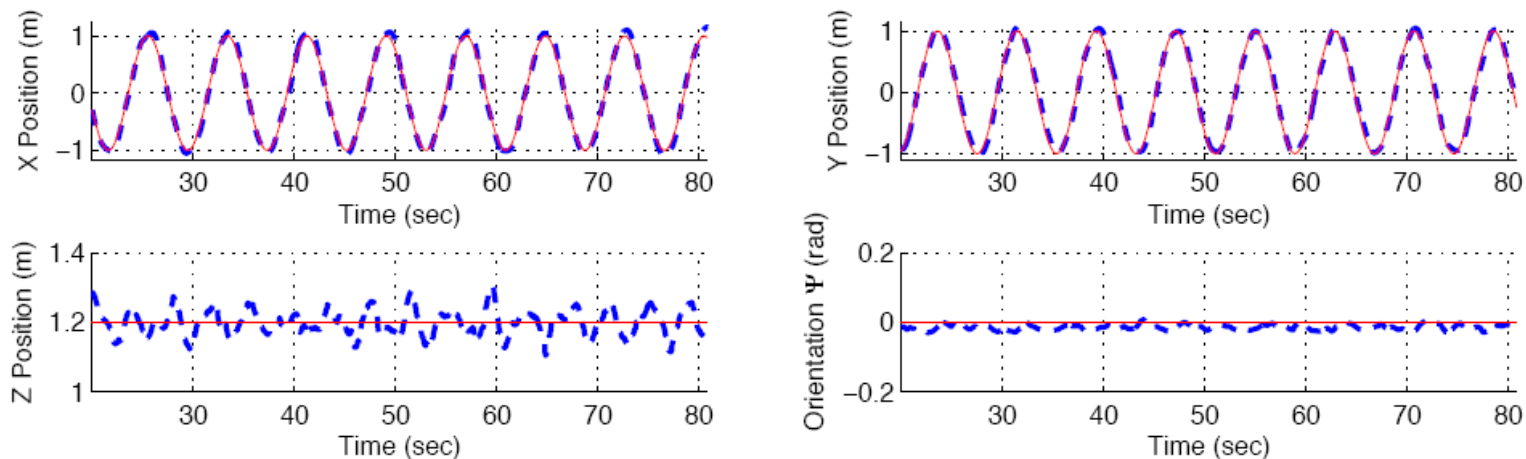
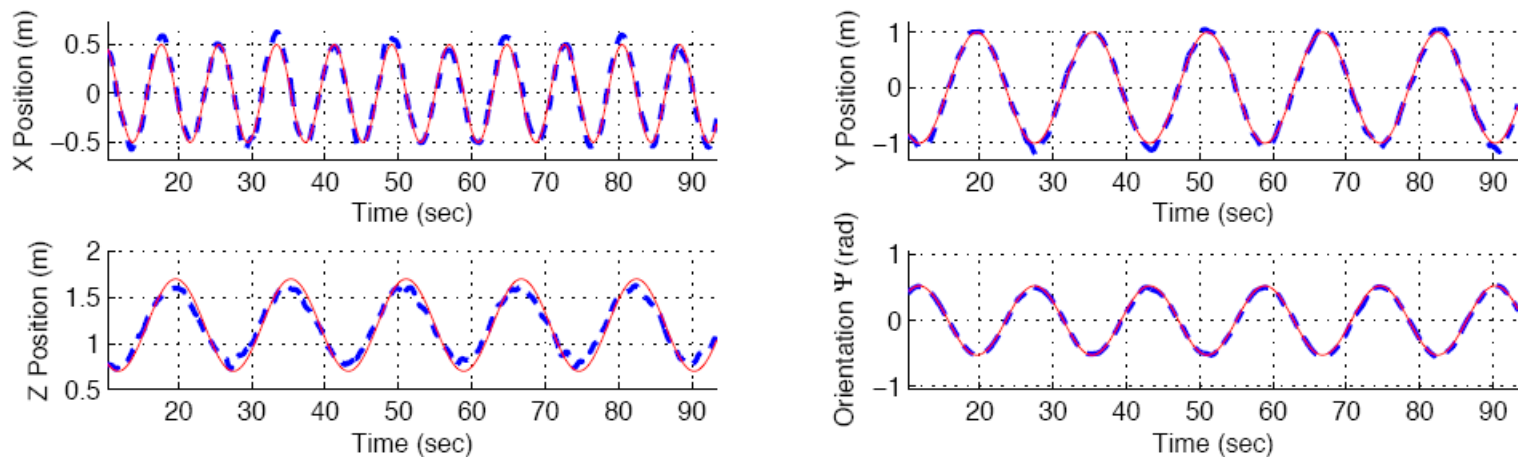


Fig. 10. Experiment 3: Circular trajectory.

Controle de seguimento de trajetória



Eight-shaped trajectory





Fig. 11. Experiment 4: Eight-shaped trajectory.

Controle de formação líder-seguidor

O controle de formação líder-seguidor exige que se conheça a posição relativa entre os dois veículos em um referencial fixo.



Controle de formação líder-seguidor

Modelagem da Formação:

- Considerando as variáveis globais de interesse do líder:

$$\mathbf{X}_1 = [x_1 \quad y_1 \quad z_1 \quad \psi_1]^T$$

- Considerando as variáveis globais de interesse do seguidor:

$$\mathbf{X}_2 = [x_2 \quad y_2 \quad z_2 \quad \psi_2]^T$$

- Define-se a estrutura da formação como:

$$\mathbf{X}_f = \mathbf{X}_1 - \mathbf{X}_2 = \begin{bmatrix} x_1 - x_2 \\ y_1 - y_2 \\ z_1 - z_2 \\ \psi_1 - \psi_2 \end{bmatrix}$$

Controle de formação líder-seguidor

Modelagem da Formação:

- Tomando a segunda derivada da estrutura de formação, temos

$$\ddot{\mathbf{X}}_f = \ddot{\mathbf{X}}_1 - \ddot{\mathbf{X}}_2 \quad (\text{I})$$

- Lembrando o modelo do AR.Drone

$$\ddot{\mathbf{X}} = \mathbf{f}_1 \mathbf{U} - \mathbf{f}_2 \dot{\mathbf{X}} \quad (\text{II})$$

e substituindo (II) em (I), obtém-se a dinâmica da formação, a saber,

$$\ddot{\mathbf{X}}_f = \left(\mathbf{f}_{1d1} \mathbf{U}_{d1} - \mathbf{f}_{2d1} \dot{\mathbf{X}}_{d1} \right) - \left(\mathbf{f}_{1d2} \mathbf{U}_{d2} - \mathbf{f}_{2d2} \dot{\mathbf{X}}_{d2} \right) \quad (\text{III})$$

onde os índices d_1 e d_2 , se referem ao líder e ao seguidor, respectivamente.

Controle de formação líder-seguidor

Controle da Formação:

- Adotando um controlador por dinâmica inversa, o sinal de controle do veículo **seguidor** é definido como

$$\mathbf{U}_{d2} = -\mathbf{f}_{1d2}^{-1} \left(-\mathbf{f}_{2d2} \dot{\mathbf{X}}_{d2} - \mathbf{f}_{1d1} \mathbf{U}_{d1} + \mathbf{f}_{2d1} \dot{\mathbf{X}}_{d1} + \boldsymbol{\nu} \right)$$

- Substituindo-se este sinal em (III), obtém-se

$$\ddot{\mathbf{X}}_f = \boldsymbol{\nu}$$

Controle de formação líder-seguidor

Controle da Formação:

- Definindo ν como uma função auxiliar no formato

$$\nu = \ddot{\mathbf{X}}_{f_d} + \kappa_p \tilde{\mathbf{X}}_f + \kappa_d \dot{\tilde{\mathbf{X}}}_f \quad \text{com}$$

- \mathbf{X}_{f_d} sendo o valor desejado para as variáveis da formação, definido como

$$\mathbf{X}_{f_d} = \begin{bmatrix} x_{1d} - x_{2d} \\ y_{1d} - y_{2d} \\ z_{1d} - z_{2d} \\ \psi_{1d} - \psi_{2d} \end{bmatrix}$$

- $\tilde{\mathbf{X}}_f = \mathbf{X}_{f_d} - \mathbf{X}_f$ sendo o erro de formação; e
- κ_p e κ_d sendo matrizes de ganho diagonais, definidas positivas.

Controle de formação líder-seguidor

Controle da Formação:

- O que se tem em malha fechada é

$$\ddot{\tilde{\mathbf{X}}}_f + \kappa_p \tilde{\mathbf{X}}_f + \kappa_d \dot{\tilde{\mathbf{X}}}_f = 0$$

O que caracteriza um sistema assintoticamente estável, para o qual

$$\tilde{\mathbf{X}}_f \rightarrow 0 \text{ quando } t \rightarrow \infty$$

Controle de formação líder-seguidor

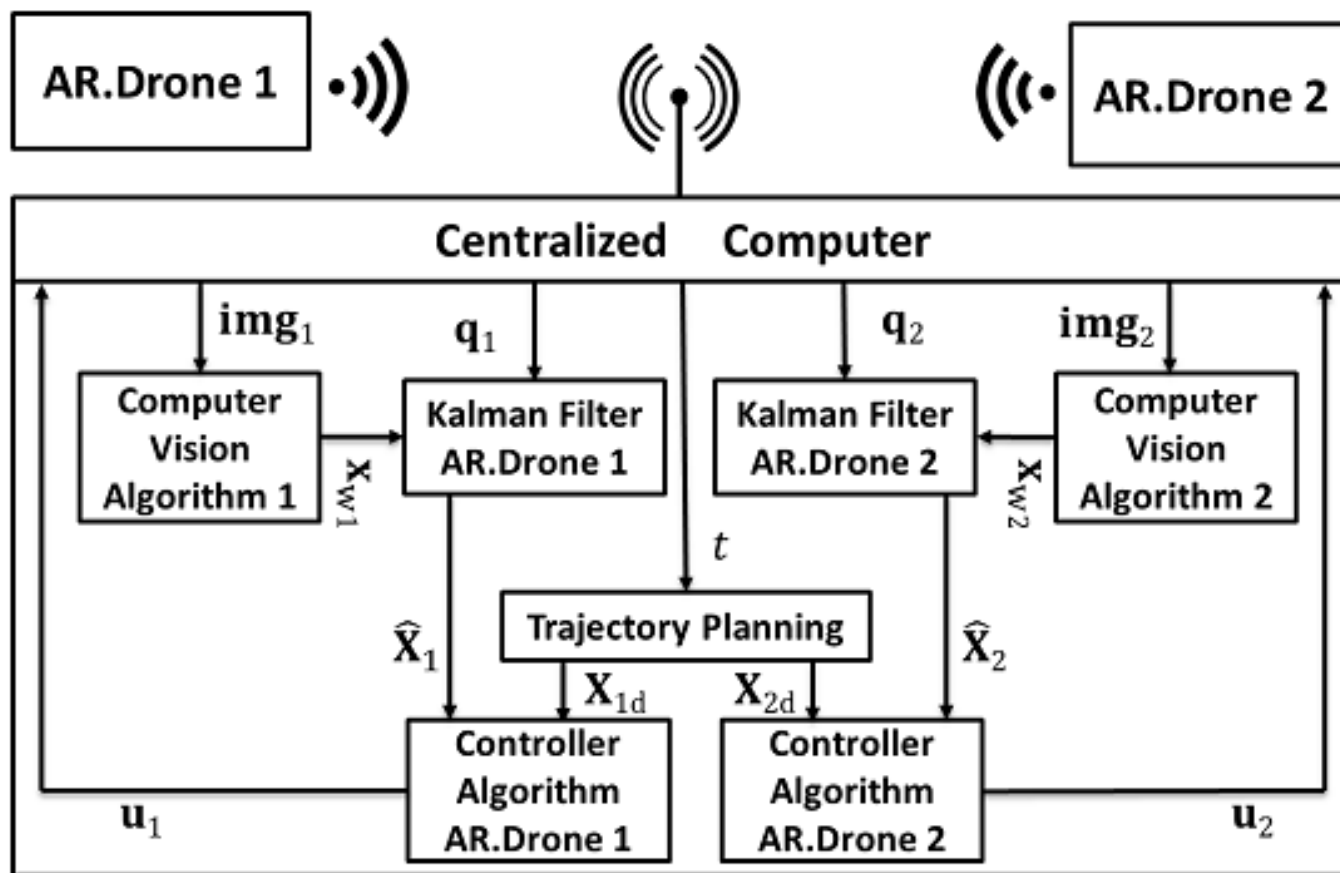


Fig. 3. System architecture adopted.

Controle de formação líder-seguidor

