LOCALIZAÇÃO EM ROBÓTICA TERRESTRE: FUSÃO ENTRE ODOMETRIA POR MÚLTIPLOS ENCODERS E GPS

Renato José Martins^{§,*}, Samuel Siqueira Bueno*, Luiz G. Bizarro Mirisola[†], Ely Carneiro de Paiva[‡], Paulo A. Valente Ferreira[§]

*Centro de Tecnologia da Informação Renato Archer - CTI Divisão de Robótica e Visão Computacional - DRVC Campinas, São Paulo, Brasil

† Universidade Federal do ABC - UFABC Centro de Matemática, Computação e Cognição - CMCC Santo André, São Paulo, Brasil

[‡] Universidade Estadual de Campinas - UNICAMP Faculdade de Engenharia Mecânica - FEM Campinas, São Paulo, Brasil

§ Universidade Estadual de Campinas - UNICAMP Faculdade de Engenharia Elétrica e de Computação - FEEC Campinas, São Paulo, Brasil

Emails: renato.martins@cti.gov.br, samuel.bueno@cti.gov.br, luiz.mirisola@ufabc.edu.br, elypaiva@fem.unicamp.br, valente@dt.fee.unicamp.br

Abstract— Robot localization (i.e pose estimation) in outdoor environments is the basis for control and autonomous navigation strategies. This paper proposes a localization methodology based on GPS and odometry fusion. An important aspect is a new odometry formulation, wich results from a least squares optimization of the information gathered from multiple encoders (four wheels and steering) of an outdoor robotic vehicle. Sensor fusion is developed by using both the Extended Kalman Filter and the Unscented Kalman Filter. Experimental data are used to validate the methodology and to compare the results of both filters.

Keywords— Localization, Multisensor Fusion, Odometry, Outdoor Robotics.

Resumo— A determinação da localização (i.e. estimação da pose) de um robô em ambiente externo constitui a base para estratégias de controle e navegação autônoma. Esse artigo propõe uma metodologia de localização de robôs baseada na fusão entre dados de GPS e odometria. Um aspecto relevante é uma nova formulação de odometria, que resulta da otimização, por mínimos quadrados, das informações provenientes de múltiplos encoders (das quatro rodas e da direção) de um veículo robótico terrestre. A fusão sensorial é desenvolvida usando tanto o Filtro de Kalman Estendido quanto o Unscented Kalman Filter. Dados experimentais são usados para validar a metodologia e comparar os resultados de ambos os filtros.

Palavras-chave— Localização, Odometria, Fusão Sensorial, Robótica de Exterior.

1 Introdução

A localização de um veículo robótico é uma das mais importantes tarefas no desenvolvimento de estratégias de controle e navegação autônoma. Entende-se por localização a determinação da pose (posição e orientação) do veículo no ambiente onde ele evolui. De uma maneira simples, a pose pode ser obtida através da integração da odometria das rodas, de sensores inerciais de velocidade e aceleração (chamados proprioceptivos), através de sistemas de posicionamento absoluto (Global Position System - GPS) ou utilizando-se sensores externoceptivos como câmeras, lasers e sonares. Entretanto em alguns cenários (ambientes externos e/ou urbanos) o simples uso da percepção proprioceptiva é inaceitável, devido à acumulação de imprecisões com o tempo (erro em posição ilimitado), ao passo que o sistema GPS pode não estar disponível ou fornecer medidas aberrantes (devido a oclusões, interferências, transições entre satélites). Dentre estas alternativas de localização, a odometria simples é, sem dúvida, um dos métodos mais utilizados em estruturas de locomoção a rodas. No entanto além de sofrer com a integração de imprecisões, ela considera a hipótese limitadora de planaridade do movimento.

Uma maneira de melhorar a estimativa de pose consiste em combinar as diferentes fontes de informação de maneira a considerar as incertezas intrínsecas de cada sensor, processo comumente chamado de fusão multisensorial (Durrant-Whyte and Henderson, 2008). O processo de fusão frequentemente utilizado consiste em variantes simples de filtragem Bayesiana, como o Filtro de Kalman (Kalman Filter - KF). O Filtro de Kalman apresenta grande versatilidade de aplicação, tendo como únicas restrições que os ruídos do modelo e de observação sejam normais (gaussianos) não-correlacionados e que os modelos empregados sejam lineares. Uma vez que a

distribuição normal é completamente conhecida a partir dos dois primeiros momentos (média e variância), este estimador calcula a média e a variância condiconal do estado atual dada todas as observações passadas, como sendo a melhor estimativa do estado atual, segundo um critério quadrático.

No entanto, muitos processos apresentam modelagens não-lineares e/ou perturbações que não podem ser representadas como gaussianas. Nestes casos, momentos estatísticos de ordem superior devem ser calculados para a determinação da propagação da função de distribuição. As implementações que consideram a estimação dos momentos adicionais possuem o revés de dimensionalidade, visto que a complexidade computacional do algoritmo é exponencial em relação ao tamanho do vetor de estados (Crassidis and Junkins, 2004). Para permitir a factibilidade computacional, adota-se usualmente uma solução aproximada que se restringe a dois momentos (média e variância), ou seja, sub-ótima; exemplos são o Filtro de Kalman Estendido - Extended Kalman Filter - EKF e, mais recentemente, Unscented Kalman Filter - UKF (Julier et al., 2000).

Este trabalho tem como foco a localização de veículos robóticos terrestres de quatro rodas, com propulsão nas duas rodas traseiras e dirigibilidade assegurada pela orientação das duas rodas dianteiras. Ele apresenta uma estratégia de estimação da pose do veículo, calcada na fusão entre dados de GPS e de odometria, usando tanto EKF quanto o UKF e comparando os desempenhos obtidos. A contribuição, neste caso, consiste justamente na formulação da odometria, como detalhado em (Martins et al., 2011), a saber: i) a odometria explora os cinco encoders presentes no veículo (deslocamentos das quatro rodas e ângulo de direção), o que resulta em um conjunto de equações apresentando não-linearidade; ii) uma transformação executada nessas equações permite estabelecer uma formulação linear; iii) a odometria é determinada como a solução de um processo de otimização por mínimos quadrados.

A metodologia é validada com dados experimentais obtidos a partir do veículo elétrico do projeto VERO (VEículo RObótico de Exterior) (Bueno et al., 2009) (Mirisola et al., 2011).

Na sequência do artigo: A Seção 2 introduz a modelagem do problema. A Seção 3 resume a formulação da odometria usando múltiplos *encoders*. A fusão entre odometria e GPS, via EKF e UKF, é tratada na Seção 4. A Seção 5 apresenta os resultados experimentais e a Seção 6 as conclusões.

2 Modelagem do Problema

A evolução da pose do veículo pode ser determinada geometricamente como exemplificado na Figura 1, segundo a notação fornecida pela Tabela 1. Assim, entre dois instantes consecutivos (t_k) e (t_{k+1}) , o ponto **P** percorre uma distância $\triangle d$ e tem uma variação na orientação de $\triangle \theta$, conforme as equações cinemáticas:

$$\begin{bmatrix} x_{k+1} \\ y_{k+1} \\ \theta_{k+1} \end{bmatrix} = \begin{bmatrix} x_k + \triangle d \operatorname{sinc}(\frac{\triangle \theta}{2}) \cos(\theta_k + \frac{\triangle \theta}{2}) \\ y_k + \triangle d \operatorname{sinc}(\frac{\triangle \theta}{2}) \sin(\theta_k + \frac{\triangle \theta}{2}) \\ \theta_k + \triangle \theta \end{bmatrix}$$
(1)

onde o vetor de estados do sistema é dado por:

$$\mathbf{x}(t_k) = [x(t_k) \ y(t_k) \ \theta(t_k)]^T \tag{2}$$

Tem-se também $\operatorname{sinc}(x) = \frac{\sin(x)}{x}$ e $\triangle d = v \triangle T$, sendo $\triangle T$ o período de amostragem. Adota-se no entanto, em (1), a simplificação comumente usada para altas taxas de amostragem: $\operatorname{sinc}(\triangle \theta/2) \approx 1$.

O modelo de observação adotado corresponde às coordenadas x e y, aqui determinadas pelos dados obtidos de um GPS embarcado.

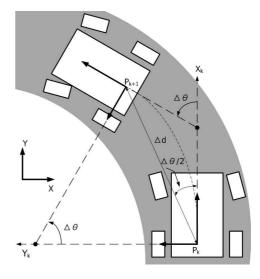


Figura 1: Evolução da pose do veículo entre dois instantes.

Tabela 1: Notação e Parâmetros Geométricos do Veículo

P	centro do eixo das rodas traseiras.
ψ	ângulo da direção.
θ	orientação.
δ_L,δ_R	ângulos rodas esquerda e direita.
v	veloxidade no ponto P.
$\triangle d_{rl}$, $\triangle d_{rr}$	deslocamento rodas traseiras esqu. e dir.
$\triangle d_{fl}$, $\triangle d_{fr}$	deslocamento rodas dianteiras esqu. e dir.
$\mathbf{u}_1 =$	$\triangle d$.
$\mathbf{u}_2 =$	$\triangle \theta$.
D	distância entre as rodas.
L	distância entre os eixos.

$$\mathbf{y}(t_{k+1}) = \begin{bmatrix} x(t_{k+1}) \\ y(t_{k+1}) \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \end{bmatrix} \mathbf{x}(t_{k+1})$$
(3)

Ressalta-se que, embora o GPS também forneça uma informação de orientação que poderia ser acrescentada como terceiro elemento no vetor de observação, esta informação apresenta sensibilidade, principalmente a baixas velocidades do veículo, sendo portanto descartada na presente formulação.

Odometria Usando Múltiplos Encoders

Para veículos com rodas, frequentemente adota-se a simplificação da cinemática como sendo a de um veículo diferencial. Nesse caso, as equações de odometria são desenvolvidas utilizando-se somente as informações dadas pelos encoders montados nas duas rodas traseiras. Outra simplificação comumente usada, mas mais completa que a precedente, é o modelo triciclo o qual resulta do acréscimo, nas equações de odometria, da informação dada pelo encoder de direção. A simplificação pelo modelo bicicleta também usa a informação da direção mas substitui as duas rodas traseiras por uma única. No entanto, para fins de odometria, pode-se também explorar as informações advindas dos encoders montados nas duas rodas dianteiras. Essas diferentes formulações da cinemática e das equações de odometria para veículos de quatro rodas da classe considerada nesse trabalho, são discutidas em (Martins et al., 2011).

Para a estimação da pose do veículo usando os quatro encoders das rodas e o encoder de direção em um esquema de otimização por mínimos quadrados (Martins et al., 2011), parte-se do modelo cinemático dado pela equação (1), em que as entradas são as variações em distância $\triangle d$ e angular $\triangle \theta$. Estabelece-se um conjunto de equações que relacionam essas entradas aos dados dos cinco encoders, que podem ser descritas em cinco funções dependentes de $\triangle d$ e $\triangle \theta$, segundo a notação dada na Tabela 1:

$$\begin{cases}
\tan(\psi) &= L\frac{\Delta\theta}{\Delta d} \\
\Delta d_{rr} &= \frac{2\Delta d + D\Delta\theta}{2} \\
\Delta d_{rl} &= \frac{2\Delta d - D\Delta\theta}{2} \\
\Delta d_{fr} &= \frac{2\Delta d + D\Delta\theta}{2\cos(\delta_R)} \\
\Delta d_{fl} &= \frac{2\Delta d - D\Delta\theta}{2\cos(\delta_L)}
\end{cases}$$

Tem-se assim um sistema de equações sobredeter-

minado não-linear, na forma, $y_i = \mathbf{H}_i(\Delta d, \Delta \theta)$. A primeira equação, não-linear, pode ser facilmente reescrita de maneira a obter um sistema de equações lineares:

$$\begin{cases}
0 &= y_1 \triangle d - L \triangle \theta + m_1 \\
y_2 &= \frac{2\triangle d + D \triangle \theta}{2} + m_2 \\
y_3 &= \frac{2\triangle d - D \triangle \theta}{2} + m_3 \\
y_4 &= \frac{2\triangle d + D \triangle \theta}{2\cos(\delta_R)} + m_4 \\
y_5 &= \frac{2\triangle d - D \triangle \theta}{2\cos(\delta_L)} + m_5
\end{cases}$$
(5)

em que w_i é uma variável aleatória (V.A) com distribuição normal, representando a incerteza de cada medida. A minimização do erro quadrático ponderado por M é usado como critério para a solução do sistema. Ou seja:

$$\hat{\mathbf{\Phi}} = \underset{\phi_1, \phi_2}{\operatorname{argmin}} \sum_{i=1}^{5} \|z_i - \mathbf{H}_i \mathbf{\Phi}\|_{\mathbf{M}}^2$$
 (6)

Em que

- $\Phi = [\phi_1 \ \phi_2]^T = [\triangle d \ \triangle \theta]^T$;
- $\mathbf{H}_1 = [y_1 L], \ \mathbf{H}_2 = \mathbf{H}_4 = [1 \ D/2] \ \mathbf{e} \ \mathbf{H}_3 = \mathbf{H}_5 = [1 D/2];$
- $z_1 = 0$; $z_2 = z_3 = y_i$ para i = 2, 3; $z_4 = y_4 \cos(\delta_R)$ e $z_5 = y_5 \cos(\delta_L)$;
- $\mathbf{M} = \text{diag} \left(\eta_1^{-2}, \eta_2^{-2}, \eta_3^{-2}, \eta_4^{-2}, \eta_5^{-2} \right)$, com η_i^2 sendo a variância de cada V.A m_i .

Tem-se como solução:

$$\hat{\mathbf{\Phi}} = [\mathbf{H}^{\mathbf{T}} \ \mathbf{M} \mathbf{H}]^{-1} \mathbf{H}^{\mathbf{T}} \mathbf{M} \mathbf{z} \tag{7}$$

conhecida como Estimador de Markov ou Mínimos Quadrados Ponderados.

Fusão entre GPS e Odometria: Estimação de Estados

Esta seção apresenta as soluções de estimação de estados não-linear para fusão de GPS e odometria usando o EKF e o UKF. Para tanto, considere o sistema representado pelas equações

$$\mathbf{x}(t_{k+1}) = \mathbf{F}(\mathbf{x}(t_k), \mathbf{u}(t_k), \mathbf{v}(t_k))$$

$$\mathbf{y}(t_{k+1}) = \mathbf{C}(\mathbf{x}(t_{k+1}), \mathbf{u}(t_{k+1}), \mathbf{w}(t_{k+1}))$$
(8)

com $\mathbf{F}(.)$ dado pelo modelo cinemático em (1) e C(.) pelo modelo de observação em (3). Os ruídos do modelo $\mathbf{v}(t_k)$ e de observação $\mathbf{w}(t_k)$ são considerados gaussianos e não-correlacionados entre si, satisfazendo a:

- $\mathbb{E}\{\mathbf{v}\} = \mathbf{0}_{(3\times 1)}$ e $\mathbb{E}\{\mathbf{v}\mathbf{v}^T\} = \mathbf{Q}_{(3\times 3)}$
- $\mathbb{E}\{\mathbf{w}\} = \mathbf{0}_{(2\times 1)}$ e $\mathbb{E}\{\mathbf{w}\mathbf{w}^T\} = \mathbf{R}_{(2\times 2)}$

4.1 Filtragem pelo EKF

A utilização do EKF supõe que os modelos de evolução/observação sejam contínuos e diferenciáveis. O princípio básico deste filtro consiste na linearização do modelo de evolução em (1), onde a matriz $\mathbf{A}(.)$ (Jacobiano) é obtida da aproximação do primeiro termo da série de Taylor.

$$\mathbf{x}(t_{k+1}) = \mathbf{A}(\mathbf{x}(t_k), \mathbf{u}(t_k))\mathbf{x}(t_k)$$

$$\mathbf{y}(t_{k+1}) = \mathbf{C}\mathbf{x}(t_{k+1})$$
(9)

com,

$$\mathbf{A}(\mathbf{x}, \mathbf{u}) = \begin{bmatrix} 1 & 0 & -\mathbf{u}_1 \sin(\mathbf{x}_3 + \mathbf{u}_2/2) \\ 0 & 1 & \mathbf{u}_1 \cos(\mathbf{x}_3 + \mathbf{u}_2/2) \\ 0 & 0 & 1 \end{bmatrix}$$
(10)

As equações para o cálculo da média e variância condicionais do EKF correspondem às etapas de predição e atualização convencionais do Filtro de Kalman (Bar-Shalom et al., 2002)(Crassidis and Junkins, 2004).

4.2 Filtragem pelo UKF

O princípio básico do filtro UKF consiste em criar um conjunto de partículas (sigma points) cuja média corresponda ao estado, enquanto que a covariância é calculada a partir da variância das partículas e não propagadas explicitamente como no caso do EKF.

No UKF os ruídos/incertezas das funções nãolineares também devem ser estimados. Assim, para o sistema determinístico em (1-3) e sua versão estocástica em (8), nos quais o modelo de evolução é não-linear, deve-se criar o vetor de estados aumentado \mathbf{x}_a pela inclusão da incerteza \mathbf{v} do modelo:

$$\mathbf{x}_a(t_k) = \begin{bmatrix} \mathbf{x}(t_k) \\ \mathbf{v}(t_k) \end{bmatrix} \tag{11}$$

resultando em $dim\{\mathbf{x}_a\} = N = 6$.

Este filtro apresenta uma primeira etapa de geração de partículas, que é seguida pelas etapas de predição e atualização como no EKF.

4.2.1 Geração de Partículas

No início de cada ciclo são criados o vetor de estados aumentado \mathbf{x}_a e sua matriz de covariância aumentada correspondente \mathbf{P}_a , tais que:

$$\mathbf{x}_a(t_k) = \begin{bmatrix} \hat{\mathbf{x}}^+(t_{k-1}) \\ \mathbf{0}_{3\times 1} \end{bmatrix}$$
 (12)

$$\mathbf{P}_{a}(t_{k}) = \begin{bmatrix} \mathbf{P}_{\mathbf{x}}^{+}(t_{k-1}) & \mathbf{0}_{3\times3} \\ \mathbf{0}_{3\times3} & \mathbf{Q} \end{bmatrix}$$
(13)

onde $\hat{\mathbf{x}}^+(t_{k-1})$ e $\mathbf{P}_{\mathbf{x}}^+(t_{k-1})$ correspondem respectivamente ao estado e sua matriz de covariância

estimados após a última fase - de atualização, na interação precedente do filtro.

A geração das (2N+1) partículas ${}^{i}\mathcal{X}_{a}$ no instante atual, é feita a partir desses estado e variância aumentados - equações (12) e (13), segundo:

$${}^{0}\mathcal{X}_{a}(t_{k}) = \mathbf{x}_{a}(t_{k})$$

$${}^{i}\mathcal{X}_{a}(t_{k}) = \mathbf{x}_{a}(t_{k}) + \left(\sqrt{(N+\lambda)\mathbf{P}_{a}(t_{k})}\right)_{j},$$

$$i = j = 1, \dots, N$$

$${}^{i}\mathcal{X}_{a}(t_{k}) = \mathbf{x}_{a}(t_{k}) - \left(\sqrt{(N+\lambda)\mathbf{P}_{a}(t_{k})}\right)_{j},$$

$$i = N+1, \dots, 2N, \quad j = 1, \dots, N$$

$$(14)$$

O termo $\left(\sqrt{(N+\lambda)\mathbf{P}_a(t_k)}\right)_j$ equivale a j-ésima coluna da matriz obtida a partir de uma decomposição de Cholesky, onde λ corresponde a um fator de normalização:

$$\lambda = \alpha^2 (N + \kappa) - N \tag{15}$$

Segundo (Julier et al., 2000) α e κ indicam a disperção das partículas em torno da média (sugerindo $\alpha=0.001$ e $\kappa=0$). As ponderações associadas a cada partícula são tais que

$${}^{0}\mathbf{W}_{m} = \frac{\lambda}{\lambda + N}$$

$${}^{0}\mathbf{W}_{c} = \frac{\lambda}{\lambda + N} + (1 - \alpha^{2} + \beta)$$

$${}^{i}\mathbf{W}_{m} = {}^{i}\mathbf{W}_{c} = \frac{1}{2(\lambda + N)}, \quad i = 1, \dots, 2N$$

$$(16)$$

onde \mathbf{W}_m são utilizados para o cálculo da média e \mathbf{W}_c para a covariância, sendo determinados apenas uma vez. O fator β aplica correções para momentos de ordem superior dada a distribuição da incerteza dos estados (sugerindo $\beta=2$ para o caso gaussiano). Geradas as partículas, dá-se sequência aos processos de predição e estimação do filtro.

4.2.2 Predição

A etapa de predição se inicia com a inserção das partículas resultantes de (14) e denotadas como:

$$^{i}\mathcal{X}_{a} = [\mathbf{x_1} \ \mathbf{x_2} \ \mathbf{x_3} \ \mathbf{v_1} \ \mathbf{v_2} \ \mathbf{v_3}]^{T} ;$$

no modelo de evolução em (17), esse último advindo de (1).

$$^{i}\mathcal{X}(t_{k+1}) = \mathbf{F}(^{i}\mathcal{X}_{a}(t_{k}), \mathbf{u}(t_{k})), \quad i = 0, \dots, 2N$$

Com

$$\mathbf{F}(^{i}\mathcal{X}_{a},\mathbf{u}) = \begin{bmatrix} \mathbf{x}_{1} + \mathbf{v}_{1} + \mathbf{u}_{1}\cos(\mathbf{x}_{3} + \mathbf{v}_{3} + \mathbf{u}_{2}/2) \\ \mathbf{x}_{2} + \mathbf{v}_{2} + \mathbf{u}_{1}\sin(\mathbf{x}_{3} + \mathbf{v}_{3} + \mathbf{u}_{2}/2) \\ \mathbf{x}_{3} + \mathbf{v}_{3} + \mathbf{u}_{2} \end{bmatrix}$$

$$(17)$$

Após a passagem das partículas pelo modelo, o cálculo da média ponderada segundo (18) resulta no próximo estado, enquanto que a covariância é estimada por (19).

$$\hat{\mathbf{x}}^{-}(t_{k+1}) = \sum_{i=0}^{2N} {}^{i}\mathbf{W}_{m}{}^{i}\mathcal{X}(t_{k+1})$$
(18)

$$\mathbf{P}_{\mathbf{x}}^{-}(t_{k+1}) = \sum_{i=0}^{2N} {}^{i}\mathbf{W}_{c} \left[{}^{i}\mathcal{X}(t_{k+1}) - \hat{\mathbf{x}}^{-}(t_{k+1}) \right] \left[{}^{i}\mathcal{X}(t_{k+1}) - \hat{\mathbf{x}}^{-}(t_{k+1}) \right]^{T}$$
(19)

É importante salientar que $dim\{^{i}\mathcal{X}_{a}(t_{k})\}=(6\times1)$ e $dim\{^{i}\mathcal{X}(t_{k})\}=(3\times1)$. A observação prevista consiste em aplicar as partículas preditas no modelo de observação:

$${}^{i}\mathcal{Y}(t_{k+1}) = \mathbf{C}({}^{i}\mathcal{X}(t_{k+1})), \quad i = 0, \dots, 2N \quad (20)$$

$$\hat{\mathbf{y}}(t_{k+1}) = \sum_{i=0}^{2N} {}^{i}\mathbf{W}_{m}{}^{i}\mathcal{Y}(t_{k+1})$$
(21)

4.2.3 Cálculo do Ganho e Atualização

O cálculo do ganho necessita das medidas de covariância da saída $\mathbf{P_{yy}}$ e da covariância cruzada entre os estados e a saída $\mathbf{P_{xy}}$, definidas como:

$$\mathbf{P}_{\mathbf{x}\mathbf{y}}(t_{k+1}) = \sum_{i=0}^{2N} {}^{i}\mathbf{W}_{c} \left[{}^{i}\mathcal{X}(t_{k+1}) - \hat{\mathbf{x}}^{-}(t_{k+1}) \right]$$

$$\left[{}^{i}\mathcal{Y}(t_{k+1}) - \hat{\mathbf{y}}(t_{k+1}) \right]^{T}$$

$$(22)$$

$$\mathbf{P}_{\mathbf{y}\mathbf{y}}(t_{k+1}) = \sum_{i=0}^{2N} {}^{i}\mathbf{W}_{c} \left[{}^{i}\mathcal{Y}(t_{k+1}) - \hat{\mathbf{y}}(t_{k+1}) \right]$$

$$\left[{}^{i}\mathcal{Y}(t_{k+1}) - \hat{\mathbf{y}}(t_{k+1}) \right]^{T} + \mathbf{R}$$

$$(23)$$

A atualização do estado obtido na etapa de predição é realizado em (25) através da inovação ponderada pelo ganho computado em (24)

$$\mathbf{K}(t_{k+1}) = \mathbf{P}_{\mathbf{x}\mathbf{y}}(t_{k+1}) \left[\mathbf{P}_{\mathbf{y}\mathbf{y}}(t_{k+1}) \right]^{-1}$$
(24)
$$\hat{\mathbf{x}}^{+}(t_{k+1}) = \hat{\mathbf{x}}^{-}(t_{k+1}) + \mathbf{K}(t_{k+1}) \left[\mathbf{y}(t_{k+1}) - \hat{\mathbf{y}}(t_{k+1}) \right]$$
(25)

Finalmente, a covariância do estado é atualizada segundo (26) e um novo ciclo do processo de filtragem é iniciado.

$$\mathbf{P_x}^+(t_{k+1}) = \mathbf{P_x}^-(t_{k+1}) - \mathbf{K}(t_{k+1})\mathbf{P_{yy}}(t_{k+1})\mathbf{K}^T(t_{k+1})$$
(26)

5 Resultados Experimentais

A avaliação experimental foi realizada com dados adquiridos pelo sistema embarcado do veículo elétrico do projeto VERO, durante duas voltas realizadas em um percurso retangular sob controle de trajetória por pontos de passagem (Mirisola

et al., 2011). Os sensores usados foram: i) encoder incremental das 4 rodas (HOHNER/Série 13) de 2048 pulsos por volta - o que resulta em uma resolução de 4096 bits na configuração de montagem utilizada; ii) encoder absoluto de direção (HOHNER/Série 65), resolução de 4096 bits - embora, pela variação dos ângulos de direção, apenas aproximadamente 1/6 dessa faixa seja efetivamente utilizada; iii) GPS (NOVATEL/Superstar II - SSII-5-5Hz), de 12 canais e Circular Error Probability (CEP) de 5m. Os encoders são amostrados a 40Hz e o GPS a 5Hz. A fusão odometria-GPS é computada na taxa de 20Hz.

A Figura 2 apresenta a posição do veículo segundo a odometria otimizada, o GPS e a fusão por UKF entre ambos. Apesar da imprecisão inerente do GPS, os dados por ele fornecidos são consistentes visto que o ambiente é aberto e não apresenta oclusões (árvores, edifícios), embora haja ocorrências de saltos. O efeito desses saltos é reduzido pelo esquema de fusão como ilustra o detalhe do canto superior esquerdo, que é retratado na figura 3. Extrapola-se que, em casos de ambientes mais propensos a oclusões e/ou mudanças na constelação de satélites, os resultados sejam mais significativos.

A estimação da orientação do veículo é ilustrada na figura 4, que mostra o heading resultante da fusão por UKF em comparação ao sinal fornecido pelo GPS. Ressalta-se que esta informação do GPS não é utilizada no processo de filtragem. Observa-se que o sinal de GPS é ruidoso e apresenta um dado aberrante aos 340 segundos; a fusão fornece uma estimativa com menor variância e elimina a informação aberrante.

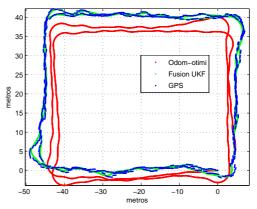


Figura 2: Estimativas de posição: GPS (azul); Odometria otimizada (vermelho); Fusão GPSodometria (verde).

O mesmo caso de estimação foi também implementado usando EKF (com as mesmas matrizes de sintonização). Os resultados obtidos foram similares aos anteriores; no entanto, a diferença da estimativa de orientação entre ambos os filtros chega a atingir 10°, como mostra a figura 5.

Ressalta-se que, para comparações conclusivas acerca do desempenho dos filtros e avaliação da robustez da própria metodologia em si, é necessária uma análise baseada no conhecimento do ground truth, o que será realizado futuramente com a utilização de um sistema de localização AP-PLANIX, integrado ao sistema embarcado do veículo.

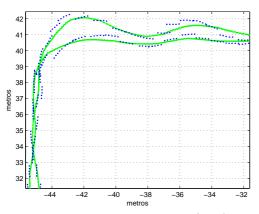


Figura 3: Detalhe da posição: GPS (azul) e Fusão GPS-odometria (verde).

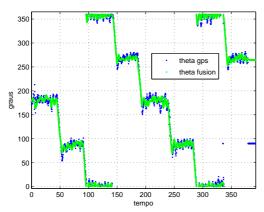


Figura 4: Estimativa da orientação pela fusão por UKF (verde) em comparação com o *heading* do GPS (azul).

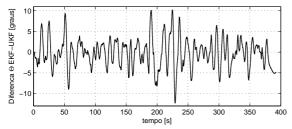


Figura 5: Diferença nas estimativas de orientação pelo UKF e EKF com mesma sintonização.

6 Conclusões

Este artigo apresentou uma metodologia para a localização de um veículo robótico terrestre em ambiente externo, caracterizada por duas etapas. Na primeira, partindo da cinemática do veículo, as informações provenientes de múltiplos encoders (das quatro rodas e de direção) fornecem uma odometria mais precisa que a odometria simples diferencial. Na segunda etapa, essa odometria é combinada com dados de posição proveniente de GPS, em um esquema de fusão sensorial empregando-se tanto o Filtro de Kalman Estendido (EKF) quanto o Unscented Kalman Filter (UKF). A metodologia proposta reduz os efeitos de deriva da odometria e de saltos/dados aberrantes advindos do GPS. Trabalhos futuros abordarão a sua avaliação face a ground truth e fusão com outros sensores.

Agradecimentos

Os autores agradecem os financiamentos do programa PCI-CTI/MCT (551022/2011-6) e dos projetos NAGUIVA (490722/2010-5-CNPq/FCT-Portugal) e INCT-SEC (573963/2008-8-CNPq-608/57870-9-FA-PESP), bem como a atuação de Douglas Figueiredo e Tiago Tarossi no veículo e seus sistemas, e aos pesquisadores do projeto VERO.

Referências

Bar-Shalom, Y., Li, X. and Kirubarajan, T. (2002). Estimation with Application to Tracking and Navigation, Wiley & Sons, Inc.

Bueno, S., Azevedo, H., Mirisola, L., Paiva, E. D., Ramos, J., Victorino, A. and Azinheira, J. (2009). Uma plataforma para pesquisa e desenvolvimento em robótica terrestre de exterior, IX Simpósio Brasileiro de Automação Inteligente, Brasília-DF, Brasil.

Crassidis, J. L. and Junkins, J. L. (2004). Optimal Estimation of Dynamic Systems, Chapman & Hall Inc.

Durrant-Whyte, H. and Henderson, T. C. (2008). Multisensor data fusion, *Handbook of Robotics*, Springer Verlag.

Julier, S., Uhlmann, J. and Durrant-Whyte, H. F. (2000). A new method for the nonlinear transformation of means and covariances in filters and estimators, *IEEE Transactions on Automatic Control* 45(3): 477–482.

Martins, R. J., Bueno, S. S., Mirisola, L. G. B., de Paiva, E. C. and Ferreira, P. A. V. (2011). Cinemática e localização em robótica terrestre usando múltiplos encoders, *X Simpósio Brasileiro de Automação Inteligente*, São João del-Rei, Brasil.

Mirisola, L., Azevedo, H., Ramos, J., Bueno, S., Azinheira, J. and de Paiva, E. (2011). Validação experimental de um veículo robótico terrestre para ambientes externos, *X Simpósio Brasileiro de Automação Inteligente*, São João del-Rei, Brasil.