

LOCALIZAÇÃO DE ROBÔS MÓVEIS EM TERRENOS IRREGULARES

DOUGLAS G. MACHARET*, MARIO F. M. CAMPOS*, ARMANDO A. NETO*, VÍCTOR C. DA S. CAMPOS*

* *Universidade Federal de Minas Gerais*
Departamento de Ciência da Computação
Laboratório de Visão Computacional e Robótica
Belo Horizonte, MG, Brasil

Emails: doug@dcc.ufmg.br, mario@dcc.ufmg.br, aaneto@dcc.ufmg.br, kozttah@gmail.com

Abstract— A fundamental premise for a mobile robot to perform its tasks is the knowledge of its location. This article addresses the estimating of the attitude of mobile robots navigating in environments with uneven terrain. From the information of different sensors and using the UKF for the calculation of attitude it was possible to obtain good results for the localization in outdoor environments.

Keywords— Localization, Inertial Navigation, UKF.

Resumo— Uma premissa fundamental para que um robô móvel consiga executar suas tarefas é que ele possua conhecimento de sua localização. Portanto, este artigo aborda o cálculo da atitude de robôs móveis navegando em ambientes que possuem terrenos irregulares. A partir das informações providas de diferentes sensores e utilizando-se o UKF para o cálculo da atitude foi possível obter bons resultados para a localização em ambientes externos.

Palavras-chave— Localização, Navegação Inercial, UKF.

1 Introdução

Atualmente, grandes avanços estão sendo obtidos na robótica móvel. Área essa, responsável por estudar os robôs móveis, aqueles que podem locomover-se no ambiente em que estão inseridos. Robôs móveis possuem diversas aplicações, por exemplo a exploração de ambientes perigosos ou de difícil acesso para o ser humano.

Uma das principais linhas de pesquisa na área da robótica móvel está ligada ao estudo de como prover uma maior autonomia aos robôs, principalmente nas questões ligadas à sua locomoção, ou seja, diminuindo a necessidade de auxílio/acompanhamento humano das tarefas designadas aos robôs.

Existem duas divisões básicas de pesquisa baseadas no ambiente onde o robô irá trafegar. Uma aborda agentes que se locomovem principalmente no interior de edificações, a chamada navegação *indoor*, enquanto a outra trata da locomoção de robôs em ambientes externos, como por exemplo campos, estradas e outros, essa sendo chamada de navegação *outdoor*.

Durante a navegação de um robô em um ambiente interno, a condição do piso é de pouca (ou nenhuma) relevância para suas tomadas de decisões, pois não é esperado que se encontrem buracos, rochas ou outros tipos de imperfeições mais graves durante a trajetória.

Já em um ambiente externo o relevo do terreno exerce grande influência na navegação do robô. Dentre os problemas encontrados em um ambiente externo, podemos citar como os principais: buracos, aclives/declives e diferentes tipos de terreno (*e.g.* brita, areia, asfalto, grama).

Estando em um ambiente *outdoor* o robô ao se locomover tende a ocupar posições dispostas nas três dimensões do espaço, além de poder assumir qualquer orientação ao longo dos três eixos de rotação, o que o leva a apresentar seis graus de liberdade. Sua configuração passa a ser representada pelo vetor $[x \ y \ z \ \phi \ \theta \ \psi]^T$, onde ϕ corresponde ao ângulo de rolamento (*roll*), θ ao ângulo de arfagem (*pitch*) e ψ o ângulo de guinada (*yaw*) do robô.

Portanto, o problema de localização a ser abordado está na determinação da posição e orientação do robô no espaço ao navegar em um ambiente externo.

2 Trabalhos Relacionados

Sistemas que envolvem o cálculo da localização do robô são bastante pesquisados na área de Robótica e Visão Computacional, uma vez que essa informação é fundamental. Logo, é possível se encontrar várias referências relacionadas ao tema deste trabalho.

A localização de um robô é uma tarefa difícil, principalmente em terrenos irregulares. A localização baseada somente nas informações de odometria produz resultados com alto nível de erro, entretanto, ainda é vastamente utilizada para navegações em um plano (2D). Porém, sua utilização se torna extremamente limitada quando se deseja saber a posição no espaço (3D).

Para amenizar os problemas inerentes à odometria, a solução é incorporar novos sensores ao sistema e realizar uma fusão dos dados coletados, obtendo uma localização mais robusta e precisa.

Um dos sensores mais utilizados é uma IMU (Borenstein and Feng, 1996), que na maioria dos casos possui três giroscópios e três acelerômetros, dispostos de maneira mutuamente ortogonal. O principal problema na utilização desse sensor está nos ruídos associados aos sinais medidos, como o *bias* que provoca, entre outros efeitos, o problema de deriva (ou *drift*) no processo de integração dos dados.

Existem várias técnicas que podem ser utilizadas para a realização da fusão de dados fornecidos por sensores, dentre as mais conhecidas podemos citar Filtros de Partículas, Filtragem Complementar e Filtro de Kalman.

Filtros de Partículas (*e.g. Monte Carlo Localization* (MCL)) são comumente utilizados para se realizar a localização no plano (2D) (Fox et al., 2001), e principalmente em ambientes internos. Entretanto, o custo computacional da técnica é proporcional ao número de partículas sendo utilizado, logo, ao lidar com localização no espaço (3D) a quantidade de partículas cresce bastante, assim como a complexidade.

Uma outra técnica interessante é a Filtragem Complementar, que permite o casamento de sinais confiáveis em diferentes faixas de frequência. Esta técnica foi utilizada com sucesso em processos de navegação aérea, conforme visto em (Iscold et al., 2007), tendo como principais vantagens, o baixo custo computacional e a simplicidade do ajuste dos parâmetros do algoritmo. A principal dificuldade em utilizar essa técnica está na necessidade de se construir o sistema utilizando-se sensores que forneçam informações em frequências complementares.

Já o Filtro de Kalman (Filtro de Kalman (*Kalman Filter*, ou KF), Filtro de Kalman Estendido (*Extended Kalman Filter*, ou EKF), Filtro de Kalman *Unscented* (*Unscented Kalman Filter*, ou UKF), etc) possui eficácia comprovada, e é uma das técnicas mais utilizadas atualmente. Podemos encontrar em (Liu et al., 2005) um sistema composto por uma IMU e também um GPS. A fusão dos dados dos sensores foi feita utilizando-se um KF padrão, que é utilizado para sistemas lineares. Também temos o uso de IMU/GPS em (Walchko and Mason, 2002), onde foi utilizado o EKF.

Já em (Zhang et al., 2005) temos a adição de um novo sensor, uma bússola digital, útil principalmente no cálculo do ângulo de guinada do robô. A fusão das informações de IMU/GPS/bússola foi realizada com o uso do UKF, também uma implementação do KF para sistemas não-lineares.

3 Metodologia

3.1 Filtro de Kalman

O KF é um estimador ótimo para sistemas lineares, entretanto, a maior parte das aplicações em

robótica são constituídas por sistemas não lineares, como é o caso desse trabalho. Considerado essas dificuldades, uma das especializações do KF para sistemas não lineares desenvolvida foi o UKF (Julier and Uhlmann, 1997).

A partir de uma gaussiana n -dimensional de média \mathbf{v} (estaremos representando essa variável por um vetor de estados \vec{x} de dimensão n) e possuindo covariância \mathbf{P} , temos $2n + 1$ pontos Sigma que são obtidos a partir das Equações (1):

$$\mathcal{X}^{[0]} = \vec{x}, \quad (1a)$$

$$\mathcal{X}^{[i]} = \vec{x} + \left(\sqrt{(n + \lambda)\mathbf{P}} \right)_{[i]} \quad \forall i = 1, \dots, n, \quad (1b)$$

$$\mathcal{X}^{[i]} = \vec{x} - \left(\sqrt{(n + \lambda)\mathbf{P}} \right)_{[i-n]} \quad \forall i = n+1, \dots, 2n. \quad (1c)$$

A notação $[i]$ significa a i -ésima coluna da matriz resultante do cálculo de $\sqrt{(n + \lambda)\mathbf{P}}$. O fator λ é definido de acordo com a Equação (2),

$$\lambda = \alpha^2(n + \kappa) - n, \quad (2)$$

onde α e κ são fatores de escala que determinam a distância em que os pontos Sigma estarão dispersos da média. Geralmente assume-se para α um valor positivo pequeno (*e.g.*, 10^{-3}), já κ costuma ter seu valor fixado em $\kappa = 0$.

Cada ponto Sigma possui associado a si dois pesos, representados por $w_m^{[i]}$ e $w_c^{[i]}$, calculados a partir das Equações (3), com $\beta = 2$ ótimo para distribuições gaussianas:

$$w_m^{[0]} = \frac{\lambda}{n + \lambda}, \quad (3a)$$

$$w_c^{[0]} = \frac{\lambda}{n + \lambda} + (1 - \alpha^2 + \beta), \quad (3b)$$

$$w_m^{[i]} = w_c^{[i]} = \frac{1}{2(n + \lambda)} \quad \forall i = 1, \dots, 2n. \quad (3c)$$

Os pontos Sigma calculados são então propagados por uma função $f(\bullet)$ (Equação (4)),

$$\Upsilon^{[i]} = f(\mathcal{X}^{[i]}). \quad (4)$$

O novo estado (\vec{x}') e sua covariância (\mathbf{P}') podem então ser calculados pela Equação (5) e Equação (6), respectivamente,

$$\vec{x}' = \sum_{i=0}^{2n} w_m^{[i]} \Upsilon^{[i]}, \quad (5)$$

$$\mathbf{P}' = \sum_{i=0}^{2n} w_c^{[i]} (\Upsilon^{[i]} - \vec{x}') (\Upsilon^{[i]} - \vec{x}')^T. \quad (6)$$

O UKF possui algumas vantagens em relação ao EKF. Ambos possuem a mesma complexidade assintótica, e para sistemas não lineares o UKF produz resultados tão bons ou melhores que o *EKF* (Thrun et al., 2005). Além disso o UKF não necessita da computação das jacobianas, aumentando assim sua facilidade de implementação.

3.2 Cálculo da Atitude

Decidiu-se que o vetor de estados deveria conter apenas as informações de localização (x, y, z) e orientação (ϕ, θ, ψ) , tendo então a forma apresentada na Equação (7),

$$\vec{x} = [x \ y \ z \ \phi \ \theta \ \psi]^T. \quad (7)$$

O vetor de controle a ser utilizado contém as informações de g_x, g_y e g_z , que correspondem às velocidades angulares em torno dos eixos de rolamento, arfagem e guinada, respectivamente, e são obtidas pelos giroscópios da Unidade de Medição Inercial (*Inertial Measurement Unit*, ou IMU), além do valor da velocidade linear v fornecido pela odometria.

Temos então o vetor de entrada do modelo apresentado na Equação (8),

$$\vec{u} = [g_x \ g_y \ g_z \ v]^T. \quad (8)$$

Os valores g_x, g_y, g_z e v são recuperados no instante de tempo t . Utilizando então as informações passadas através do vetor de controle é possível calcular a estimativa do estado atual à partir das Equações (9), são elas:

$$x_t = x_{t-1} + \cos \psi_t \cos \theta_t v \Delta t, \quad (9a)$$

$$y_t = y_{t-1} + \sin \psi_t \cos \theta_t v \Delta t, \quad (9b)$$

$$z_t = z_{t-1} + \sin \theta_t v \Delta t, \quad (9c)$$

$$\phi_t = \phi_{t-1} + (g_x + g_y \tan \theta_{t-1} \sin \phi_{t-1} + g_z \tan \theta_{t-1} \cos \phi_{t-1}) \Delta t, \quad (9d)$$

$$\theta_t = \theta_{t-1} + (g_y \cos \phi_{t-1} - g_z \sin \phi_{t-1}) \Delta t, \quad (9e)$$

$$\psi_t = \psi_{t-1} + \left(g_y \frac{\sin \phi_{t-1}}{\cos \theta_{t-1}} - g_z \frac{\cos \phi_{t-1}}{\cos \theta_{t-1}} \right) \Delta t. \quad (9f)$$

O cálculo de ψ_t apresenta pontos de singularidade para $\theta_{t-1} = \pm \pi/2$, entretanto, esse fato não será relevante no contexto desse trabalho, uma vez que o robô não deve obter tais valores de *pitch* durante sua navegação.

O próximo passo a ser realizado é a etapa de correção, que ocorre a partir dos valores presentes no vetor de observações. As informações fornecidas são x_{GPS} e y_{GPS} obtidos do *Global Positioning System* (GPS), os valores das acelerações nos três eixos locais dados pelos acelerômetros da IMU, e também o valor absoluto de orientação ψ_b fornecido pela bússola.

A bússola retorna valores no intervalo $[0, 2\pi[$, onde o 0 representa o Norte magnético da Terra e os valores aumentam no sentido horário, porém, no sistema geométrico convencional é considerado que um giro no sentido anti-horário deve produzir valores positivos de orientação, logo, temos então que $\psi_b = \pi/2 - \psi_{br}$, onde ψ_{br} significa o valor *raw* de orientação retornado pela bússola.

Além disso, um outro fator relacionado à bússola e que deve ser tratado é o fato de que o Norte

magnético referenciado pela bússola não necessariamente é o Norte geográfico da Terra (*true north*). Essa diferença entre os valores que o campo magnético da Terra sofre é chamada de variação ou declinação magnética, e está diretamente ligada ao tempo e localização no globo terrestre. Para obtermos o valor do Norte real, basta realizarmos o cálculo Norte Real = Norte Magnético - Variação, onde o valor da variação para localização onde ocorreu o desenvolvimento desse trabalho possui valor de $\approx 21,7^\circ$.

O vetor de observação é representado pela Equação (10),

$$\vec{z} = [x_{GPS} \ y_{GPS} \ a_x \ a_y \ a_z \ \psi_b]^T \quad (10)$$

Os valores estimados para x, y e ψ na etapa de predição são avaliados diretamente pelos valores da observação x_{GPS}, y_{GPS} e ψ_b . Os valores de ϕ, θ são corrigidos através do cálculo de ϕ_a e θ_a , obtidos a partir das Equações (12) e (11), respectivamente,

$$\theta_a = \arcsin\left(\frac{a_x}{g_r}\right), \quad (11)$$

$$\phi_a = \arcsin\left(\frac{a_y}{-g_r \cos \theta_a}\right). \quad (12)$$

Os cálculos baseiam-se no vetor aceleração da gravidade, entretanto durante experimentos realizados observou-se que os valores ϕ_a e θ_a podem obter valores maiores que a aceleração da gravidade ($g \approx 9,78 \text{ m/s}^2$) caso o terreno onde o robô trafega seja extremamente acidentado, o que gera uma inconsistência trigonométrica nas Equações (12) e (11). Para solucionar tal problema optou-se por realizar os cálculos utilizando como valor do vetor aceleração da gravidade a resultante das acelerações, $g_r = \sqrt{a_x^2 + a_y^2 + a_z^2}$.

Ao utilizarmos dados fornecidos por aparelhos de GPS é preciso lidar com dois problemas: queda de sinal (são necessários no mínimo quatro satélites para que a posição possa ser calculada) e o efeito denominado *random walk* (quando o receptor se encontra em baixas velocidades (ou parado), e valores aleatórios dentro de um raio passam a ser observados).

É proposto então um modelo para o cálculo dinâmico da variância do GPS. Optou-se por desenvolver um modelo próprio, uma vez que as informações de qualidade fornecidas pelo GPS não se mostraram confiáveis.

As variâncias individuais das informações obtidas a partir do GPS (x_{GPS}, y_{GPS}) serão calculadas em cada instante de tempo e fornecidas à matriz de covariância, onde as variâncias serão iguais para as duas informações e são inversamente proporcionais ao número de satélites e à velocidade do robô em um dado momento. Os valores para os demais sensores são constantes no tempo e foram definidos de forma empírica.

A parcela da variância associada à influência do número de satélites (C_n) e velocidade (C_v) são calculadas separadamente através das Equações (13) (n sendo o número de satélites visíveis) e (14) (v sendo a velocidade linear do robô) respectivamente, e depois somadas para se obter o valor da variância dos valores obtidos do GPS e que devem ser atribuídas à matriz de covariância, Equação (15), onde:

$$C_n = \begin{cases} \frac{P_n \times M_n}{n} & \text{se } n > 3, \\ \infty & \text{caso contrário} \end{cases}, \quad (13)$$

$$C_v = \begin{cases} \frac{P_v \times M_v}{v} & \text{se } \geq v_{min}, \\ \infty & \text{caso contrário} \end{cases}, \quad (14)$$

$$C_{GPS} = C_n + C_v. \quad (15)$$

Temos que $P_n + P_v = 1$, e representam a porcentagem de influência no sistema que se deseja atribuir a cada fator (número de satélites, velocidade), e M_n e M_v representam valores médios esperados no sistema para esses mesmos fatores.

4 Experimentos

Para o cálculo da sua atitude o robô utiliza os dados fornecidos por uma IMU, um GPS, uma bússola digital, além de informações da Odometria do robô, a Figura 1 apresenta a disposição dos sensores sobre a plataforma. Durante os experimentos o robô navegou pelo ambiente guiado através de um *joystick*.




Figura 1: Recursos utilizados no trabalho.

4.1 Experimento 1

Este experimento possui como principal objetivo avaliar o método utilizado para o cálculo da variância das informações do GPS quando ocorre uma perda de sinal ou quando o robô está trafegando a uma velocidade muito baixa (ou se encontra parado).

Deve-se salientar que em nenhum momento durante a realização desse experimento o robô possuía um número menor que sete satélites em visada, logo, para a verificação do método será adotado que a partir de um dado momento o robô não recebia mais o sinal de nenhum satélite, simulando assim uma queda completa de sinal.

As imagens da Figura 2 apresentam a trajetória estimada para a navegação realizada pelo robô durante o experimento.




Figura 2: Trajetória realizada no Experimento 1.

A Figura 3 mostra em destaque os momentos em que a baixa velocidade do robô fez com que as informações obtidas do GPS sofressem do efeito de *random walk* (os dados do GPS foram ligados para uma melhor visualização). O cálculo da variância baseada na informação de velocidade produziu bons resultados, reduzindo drasticamente (e em alguns casos eliminando completamente) a influência do *random walk*, exibindo caminhos mais suaves e realistas para o trajeto realizado e mostrando-se uma forma eficaz de melhorar a estimativa de localização do robô.




Figura 3: Tratamento do efeito de *random walk*.

A próxima etapa consistiu em simular a queda do sinal durante um determinado período de tempo, verificando-se que a partir dos valores calculados para a variância os dados fornecidos pelo GPS passam a ser ignorados na etapa de correção.

A Figura 4 exibe os resultados obtidos para a simulação de queda de sinal. É possível observar que um pequeno erro na orientação gera grandes erros na localização, onde grande parte do erro aqui observado está relacionado à odometria, esse fato fica bem evidente na figura que destaca o início do trajeto, onde nota-se o erro na estimativa de deslocamento do robô, erro esse devido principalmente à característica irregular do terreno. Entretanto, tão logo o sinal do GPS se torna disponível novamente a trajetória já começa a ser corrigida.

O robô trafegou por uma distância de $\approx 200m$ sem utilizar o sinal do GPS, e no instante anterior ao sinal se tornar novamente disponível havia uma diferença entre a localização atual e a localização calculada utilizando-se o GPS durante todo o percurso de $30,6m$.

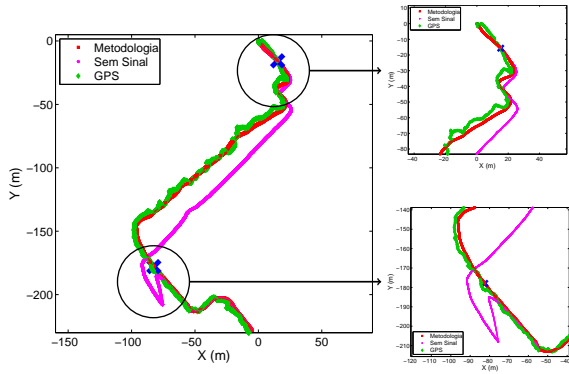


Figura 4: Trajeto completo do Experimento 1 e destaque do início e final da simulação de queda de sinal.

É possível concluir então que apesar de o sistema conseguir lidar de forma satisfatória com as baixas velocidades do robô e quedas do sinal, a ausência da correção fornecida pelo GPS por um longo período de tempo pode prejudicar significativamente a localização do robô, entretanto, assim que os dados do GPS retornam é possível rapidamente realizar a correção da trajetória.

4.2 Experimento 2

Durante a realização desse experimento o robô trafegou por um ambiente com maiores variações de relevo, sendo a principal uma grande subida que o robô deveria primeiramente subir e, em seguida, descer.

É possível observar através dos gráficos presentes na Figura 5 os valores dos ângulos de orientação estimados para o robô. As imagens da Figura 6 exibem os valores de localização calculados pelo sistema e a sua disposição no mundo.

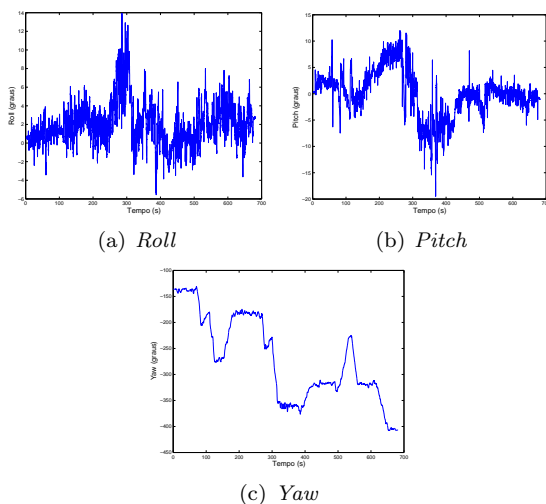


Figura 5: Ângulos de orientação calculados para o Experimento 2.

A Figura 7 exibe a variação do movimento do robô nas três dimensões, onde nota-se claramente

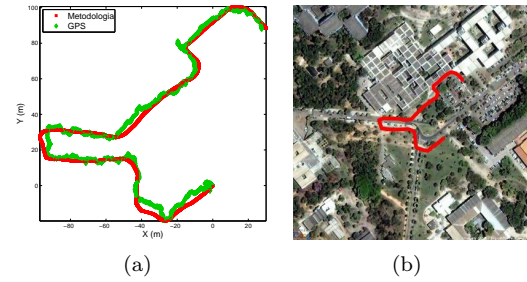


Figura 6: Trajetória realizada no Experimento 2.

a subida e descida realizada pelo robô durante a navegação, os eixos do gráfico encontram-se fora de escala para uma melhor visualização do deslocamento vertical realizado.




Figura 7: Variação de altura obtida durante a realização do Experimento 2.

O valor de altura também pode ser obtido a partir do GPS, entretanto, esse valor possui uma grande variação, não condizendo com o real deslocamento do robô, sendo uma das razões da sua não incorporação ao sistema. A Figura 8 apresenta a comparação entre a altura calculada pela metodologia e o valor retornado do GPS. É possível observar que a diferença entre o valor do ponto mais alto e mais baixo dado pelo GPS é de $\approx 25\text{m}$, um valor não condizente com a movimentação efetivamente realizada pelo robô.




Figura 8: Comparativo entre a variação de altura estimada e o valor fornecido pelo GPS no tempo para o Experimento 2.

As Figuras 9 apresentam os valores de variância obtidos através da metodologia. Observa-se que a variância de x e y possuem comportamento semelhante, destacando-se três picos resultados da atribuição de uma maior variância aos dados do GPS nesses momentos da trajetória. É possível também observar que o comportamento da variância de y é menos suave que x, isso foi observado principalmente devido à uma pequena variação lateral proveniente do GPS.

É possível também verificar pela Figura 9(c) que o erro agregado a z tende a aumentar rapidamente, isso era esperado uma vez que o valor estimado para z não possui valor de correção. Isso tende a ser um problema, uma vez que se o robô navegar por longas distâncias o erro em z pode aumentar até se tornar inutilizável.




Figura 9: Variância das variáveis de localização durante o Experimento 2.

Logo, foi possível estimar a variação tridimensional da posição do robô baseando-se apenas nos dados de orientação e velocidade do robô. Entretanto, apesar de produzir resultados satisfatórios, deve-se considerar que a falta de um sensor de correção para a altura fará com que a navegação por um longo período de tempo acumule grande incerteza.

5 Conclusões e Trabalhos Futuros

Os resultados obtidos para a localização do robô foram satisfatórios, uma vez que através das imagens de satélites é possível observar que o caminho estimado através da fusão sensorial realizada com a utilização da metodologia proposta possui grande fidelidade ao caminho real realizado pelo robô. A partir da reconstrução pós navegação da trajetória realizada pelo robô também foi possível verificar a precisão nos valores calculados para os ângulos de orientação.

Apesar de o robô utilizado nos experimentos ser classificado como um robô *all terrain*, seu sis-

tema de direção *skid-steer* mostrou-se altamente ineficiente para aplicações em ambientes externos. A bússola se mostrou extremamente sensível a variações magnéticas, o que levou à necessidade então de montá-la o mais distante possível de outros equipamentos que pudessem interferir em suas medições.

Como direção futura pretende-se adicionar um novo sensor ao sistema, um altímetro. O principal objetivo é a redução do erro no cálculo da variação de altitude. Após feito isso, deseja-se realizar experimentos com o sistema acoplado a um veículo de maior porte, no caso um carro, onde seria possível verificar o comportamento do sistema em um trajeto de maior escala.

Referências

- Borenstein, J. and Feng, L. (1996). Gyrodometry: A New Method for Combining Data from Gyros and Odometry in Mobile Robots, *Proceedings of IEEE International Conference on Robotics and Automation*, pp. 423–428.
- Fox, D., Thrun, S., Burgard, W. and Dellaert, F. (2001). Particle Filters for Mobile Robot Localization, in A. Doucet, N. de Freitas and N. Gordon (eds), *Sequential Monte Carlo Methods in Practice*, Springer, New York.
- Iscold, P., de Oliveira, G. R. C., Neto, A. A., Pereira, G. A. S. and Torres, L. A. B. (2007). Desenvolvimento de Horizonte Artificial para Aviação Geral baseado em Sensores MEMS, *V Congresso Brasileiro de Engenharia Inercial*, Rio de Janeiro.
- Julier, S. and Uhlmann, J. K. (1997). A new extension of the kalman filter to nonlinear systems, *Proceedings of The 11th Int. Symp. on Aerospace/Defense Sensing, Simulation and Controls, Multi Sensor Fusion, Tracking and Resource Management*.
- Liu, B., Adams, M. and Ibañez-Guzmán, J. (2005). Multi-aided Inertial Navigation for Ground Vehicles in Outdoor Uneven Environments, *Proceedings of IEEE International Conference on Robotics and Automation*.
- Thrun, S., Burgard, W. and Fox, D. (2005). *Probabilistic Robotics*, The MIT Press.
- Walchko, K. J. and Mason, P. A. C. (2002). Inertial navigation, *Florida Conference on Recent Advances in Robotics*.
- Zhang, P., Gu, J., Milios, E. E. and Huynh, P. (2005). Navigation with IMU/GPS/Digital Compass with Unscented Kalman Filter, *Proceedings of IEEE International Conference on Mechatronics & Automation*.