

Figura 54: Mapas gerados para o conjunto de dados COPA.

construídos com as três metaheurísticas como se pode observar das Figuras 55(a), 55(b) e 55(c). A Figura 55(b) mostra que nesse trecho a falha mostrou-se menos influente no caso construído pelo FA.

A região 2 apresentou de um trecho de parede e a presença de feixes atravessando objetos sólidos. Esse defeito é observável nos mapas construídos com as três metaheurísticas como se pode observar das Figuras 55(d), 55(e) e 55(f).

A região 3 apresentou uma falha de alinhamento e a consequente replicação de um trecho de parede. Esse defeito é observável nos mapas construídos com as três metaheurísticas como se pode observar das Figuras 55(g), 55(h) e 55(i). A Figura 55(i) mostra que nesse trecho a falha mostrou-se menos influente no caso construído pelo PSO.

A região 4 apresenta a replicação de paredes com grande proximidade entre as réplicas. Esse defeito é observável nos mapas construídos com as três metaheurísticas como se pode observar das Figuras 55(j), 55(k) e 55(l). Mais interessante que isso é observar o trecho da trajetória visível nessa região. Verifica-se pela Figura 55(l) que nesse o PSO estimou a trajetória mais suave.

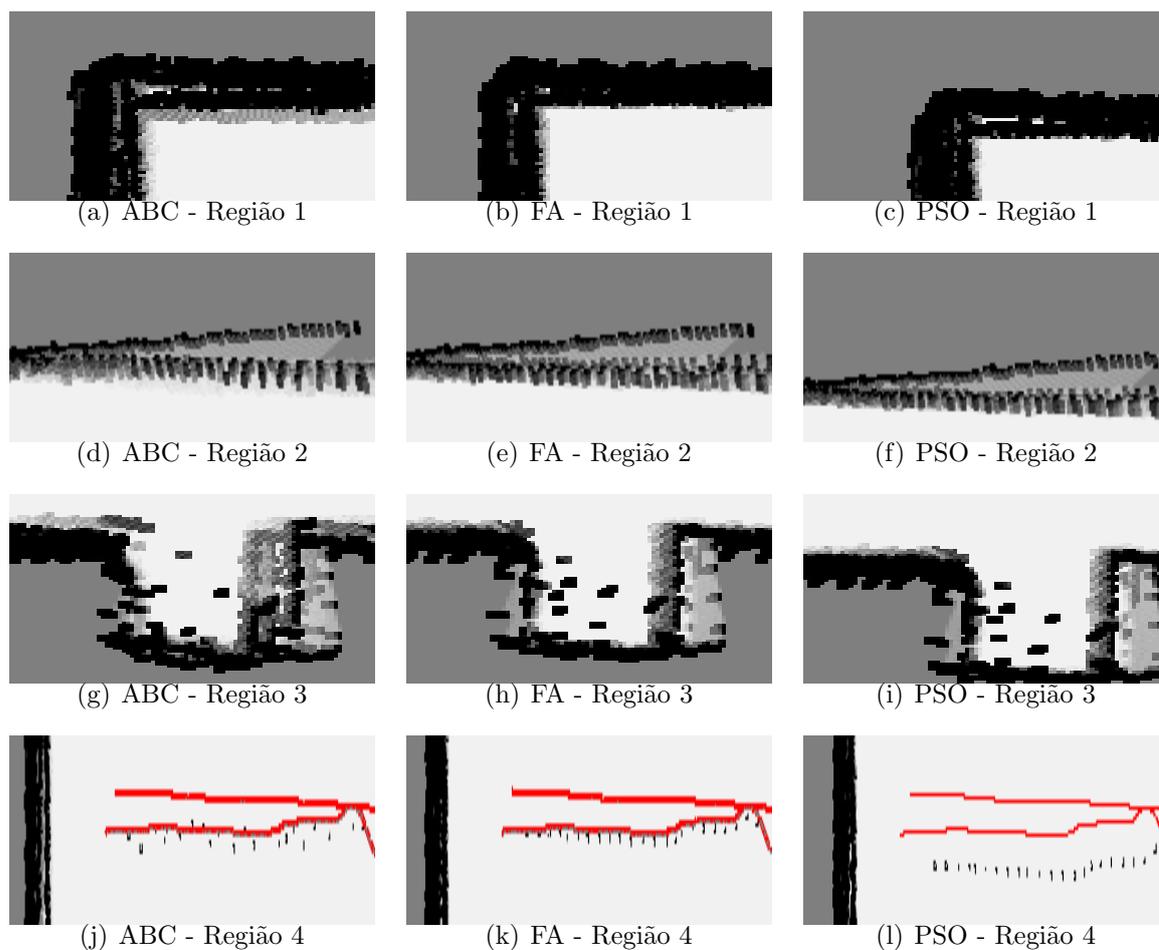


Figura 55: Comparação das quatro regiões de interesse do conjunto de dados COPA.

### 7.5.2 Conjunto de dados CPSL

O segundo percurso realizado, que nessa obra foi denotado copa e sala e cujo nome foi codificado como CPSL, foi realizado entre a o laboratório em que trabalhamos durante a elaboração do trabalho que ora se apresenta e a supramencionada copa. O trajeto escolhido, muito embora tenha uma complexidade similar ao do caso anterior foi realizado em um ambiente mais complexo como pode ser visto na Figura 56.

Os resultados dos experimentos conduzidos com o P3DX estão representados na Figura 57 e os dados correspondentes para os conjuntos COPA e CPSL encontram-se nas Tabelas 14 e 16, respectivamente.

Na Figura 56 observa-se que o ambiente apresenta maiores possibilidades para que se ocorram falhas de alinhamento como, por exemplo portas que podem se abrir, mostrando um cenário mais realista de aplicação. Desse modo, não só verificou-se a capacidade do sistema de produzir resultados verossímeis e razoavelmente acurados, mas

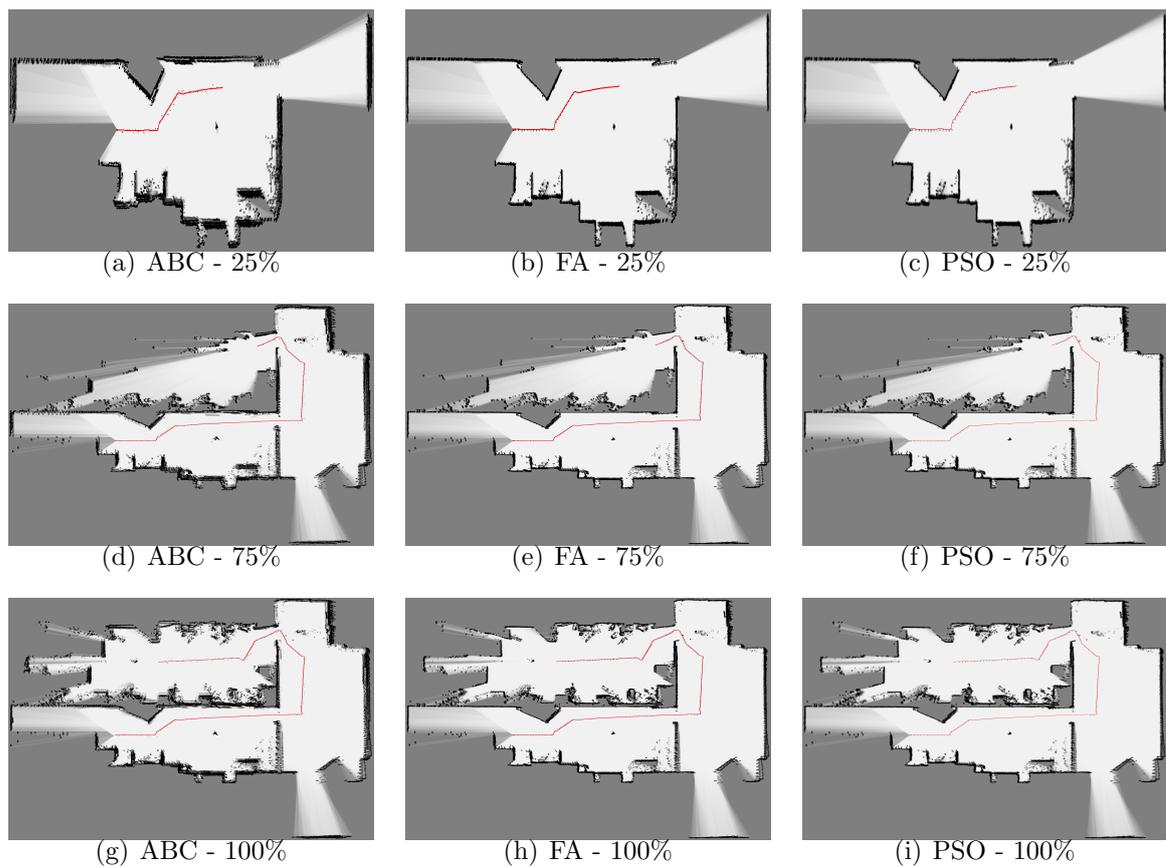


Figura 56: Mapas gerados para o conjunto de dados COPA SALA.

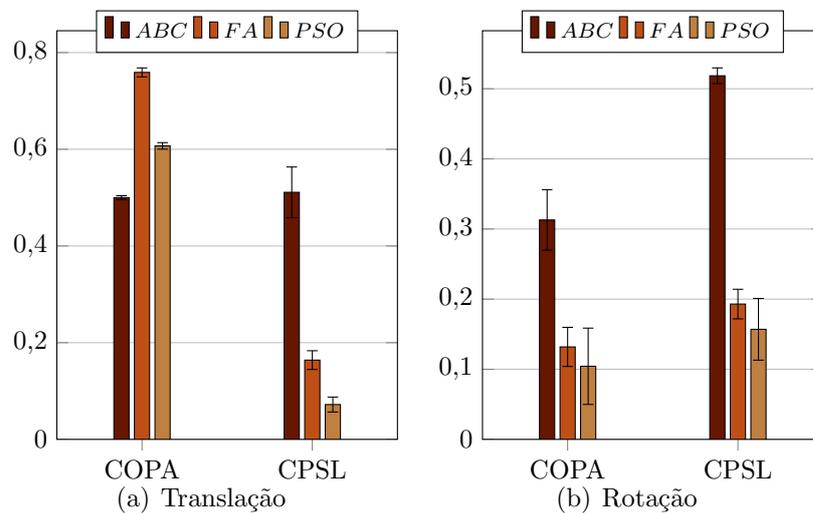


Figura 57: Erros absolutos dos experimentos conduzidos com o P3DX.

também exibiu-se que tal coisa pode ser realizada em ambientes que sofram pequenas alterações durante o processo de exploração. Tal coisa pode ser explicada pelo modo como ocorre atualização de mapas de ocupação, explicada em maiores detalhes na Seção 4.2,

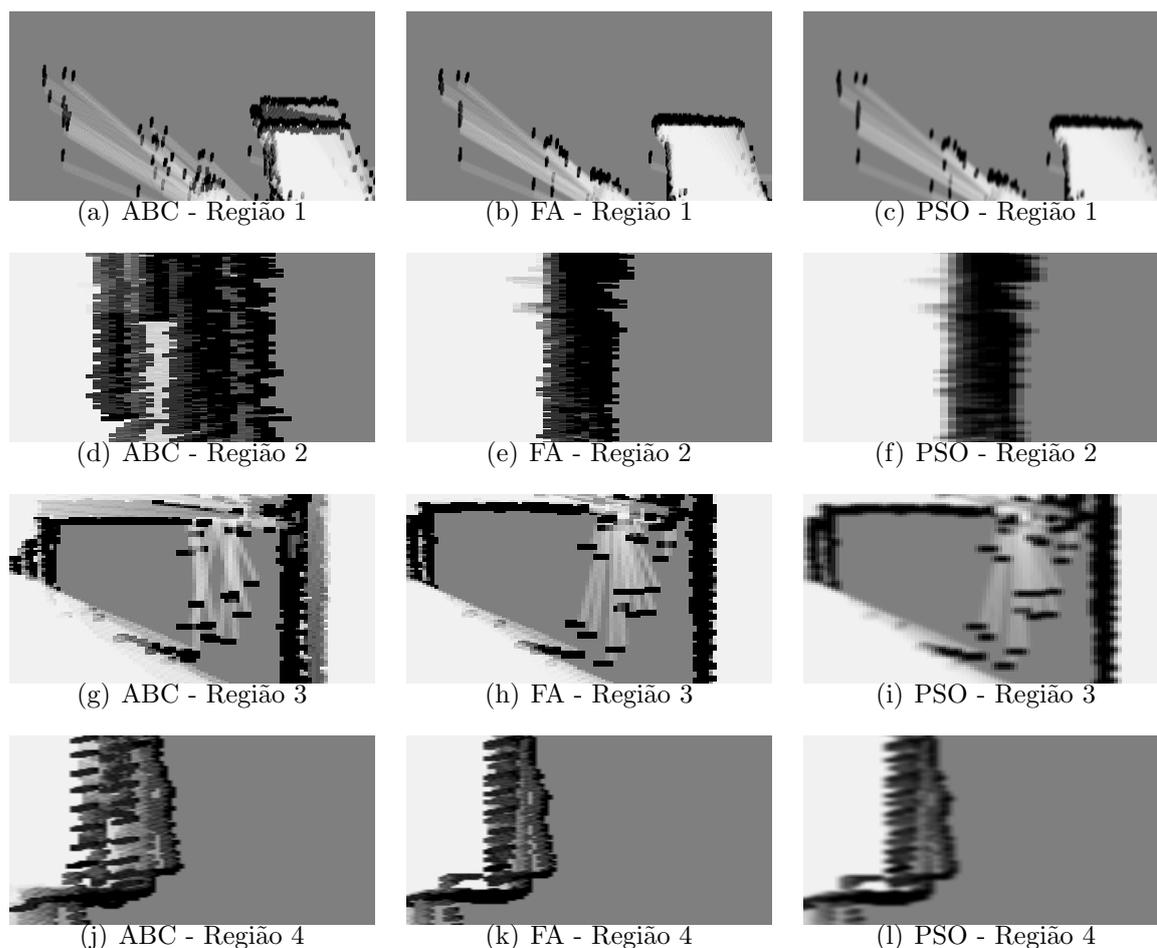


Figura 58: Comparação das quatro regiões de interesse do conjunto de dados CPSL.

que efetivamente filtra alterações em regiões que tenham mudanças de pequena duração desde que essas estejam em regiões reobservadas de maneira suficientemente frequente.

Exibimos na Figura 56 o mapa obtido pela mensuração supramencionada região numa seção de levantamento de dados que em alguns minutos obteve 1576 medições. Na Figura 48 encontram-se os erros absolutos translacionais e rotacionais obtidos com a aplicação de cada técnica, nesse cenário o ABC foi o algoritmo que cometeu os maiores erros, ao contrário do que esperávamos em vista dos resultados que obtivemos com os conjuntos de dados de (HOWARD; ROY, 2003). O algoritmo que obteve o menor erro foi o PSO.

A região 1 apresentou um canto com falha de alinhamento e a consequente replicação de um trecho de parede. Esse defeito é observável apenas na região mapeada com o auxílio do ABC como pode-se observar na Figura 58(a).

A região 2 apresentou replicação de um trecho de parede e a presença de feixes atravessando objetos sólidos. Esse defeito é observável na região mapeada com o uso das três metaheurísticas, porém é mais proeminente na mapeada com o ABC como pode-se observar na Figura 58(d).

A região 3 apresentou feixes que atravessam objetos sólidos. Esse defeito é observável nos mapas construídos com as três metaheurísticas como se pode observar das Figuras 58(g), 58(h) e 58(i). A Figura 58(i) mostra que nesse trecho a falha mostrou-se menos influente no caso construído pelo PSO.

A região 4 apresenta a replicação de paredes e uma clara imprecisão na componente rotacional das poses donde foram realizadas as varreduras visíveis nessa região. Esse defeito é observável nos mapas construídos com as três metaheurísticas como se pode observar das Figuras 58(j), 58(k) e 58(l). Verifica-se pela Figura 58(j) que nesse o ABC obteve o pior resultado no que tange a estimação da componente rotacional da pose. Isso está de acordo com o que é comentado na Seção 7.4.

## 7.6 Considerações Finais do Capítulo

Nesse capítulo expusemos os resultados que foram obtidos pela aplicação do sistema que propusemos a conjuntos de dados de domínio público. A escolha pelo uso desse tipo de fonte de dados teve por objetivo permitir a fácil comparação desse com outros sistemas de SLAM. Os conjuntos de dados em particular foram selecionados com dois critérios principais: diversidade e notoriedade. Por diversidade queremos dizer que buscamos fazer um apanhado de ambientes a mapear que apresentassem características distintas, como pode-se observar tanto das descrições que fizemos de cada um deles quanto dos próprios mapas gerados. A notoriedade de que falamos, por sua vez, refere-se ao uso disseminado de determinada fonte de dados pela comunidade acadêmica, conforme representada pela aparição desses conjuntos de dados em artigos da área em questão. Foi realizada uma análise dos resultados obtidos e os resultados foram, onde pertinente, analisados à luz do que foi afirmado nos capítulos anteriores. Analisou-se de modo separado o desempenho exibido pelas três técnicas de enxame investigadas e a relação entre o desempenho do método proposto e o de outros sistemas existentes. No capítulo 8 serão apresentadas as conclusões do presente trabalho e os trabalhos futuros que se vislumbra.

## Capítulo 8

# CONCLUSÕES E TRABALHOS FUTUROS

**E**STE capítulo discorre sobre as conclusões que se pode retirar com base nos resultados dos experimentos que foram realizados. A Seção 8.1 fala um pouco sobre o processo de desenvolvimento do sistema proposto e trata, especificamente, das conclusões que podem ser retiradas desse trabalho. A Seção 8.2 foi dedicada uma seção à discussão das ramificações desse trabalho, das melhorias que poderiam ser feitas e sobre o desenvolvimento de trabalhos futuros de um modo geral.

### 8.1 Conclusões

Quando foi elaborada a proposta de pesquisa foram estabelecidos como objetivos principais: a elaboração de um sistema de localização e mapeamento simultâneos baseado em técnicas de inteligência de enxame e a comparação do desempenho de diversas meta-heurísticas nessa aplicação. Quanto ao primeiro objetivo, implementamos um sistema de SLAM calcado em dois pilares, quais sejam: o alinhamento de varreduras, mediante a aplicação das técnicas de enxame previamente mencionadas, embasado no princípio da máxima verossimilhança; e a aplicação de um sistema de otimização de grafos de poses como forma de permitir que o sistema mantenha estimativas consistentes ao longo de extensas sessões de mapeamento, que fariam um sistema puramente baseado na simples intercalação do alinhamento de varreduras sucessivas e da composição de poses acumular erros a tal ponto que a incerteza de suas estimativas se tornariam inúteis para qualquer fim prático.

A implementação do alinhamento de varreduras foi a primeira tarefa realizada e, em particular, a primeira técnica de otimização de enxame a ser implementada com su-

cesso para esse fim em nosso trabalho foi o PSO. O sistema trabalhava utilizando mapas de ocupação tanto como forma de fornecer os resultados obtidos ao usuário quanto como representação interna para o alinhamento. O sistema fazia o alinhamento das varreduras ao mapa, corrigia a pose usando a transformação obtida pelo processo de alinhamento como estimativa do movimento que realizara e então atualizava o mapa de ocupação com os dados da varredura. O sistema funcionava bem em ambientes como o que descrevemos anteriormente como características visuais notadamente marcadas, tendo ainda a restrição de que houvesse suficiente superposição entre os pontos observados entre as duas poses. Ao tentar aplicar essa técnica a ambientes maiores observamos que o sistema conseguia usualmente manter suas estimativas para a posição do robô em relação ao mapa dentro de uma região com uma distância Manhattan, também conhecida como distância  $L_1$ , não maior do que cinco células. Note que cada célula nesses experimentos varia entre cinco e quinze centímetros. Dessa primeira implementação, inspirada em (MINGAS; TSARDOULIAS; PETROU, 2012), foi elaborado um artigo de congresso (OLIVEIRA; NEDJAH; MOURELLE, 2017) no qual descrevia-se o funcionamento básico do sistema e a metodologia básica empregada para realizar a calibração dos parâmetros do PSO, além de exibir alguns resultados preliminares.

Em seguida, tentou-se uma abordagem baseada em *backtracking search*, doravante pesquisa por retrocesso. A implementação baseada em pesquisa por retrocesso não se mostrou mais bem-sucedida do que sua predecessora, na verdade o sistema se tornou mais lento por algo como duas ordens de grandeza. O pior, entretanto, foi a conclusão de que para que o processo se tornasse eficaz seria necessário permitir que a busca fosse realizada com profundidade suficiente, o que significava armazenar informação suficiente para reconstruir todo o histórico de mapas e ser capaz de gerar variações deles! Esse procedimento levava a um crescimento do tempo consumido por varredura registrada e de um aumento considerável da quantidade de memória necessária. O sistema estava a consumir aproximadamente 1 Gb para realizar o SLAM em um conjunto de dados com 695 leituras. Esse resultado, no entanto, revelou-se similar ao obtido pelos autores do sistema DP-SLAM no que tange ao aumento do consumo de memória.

Após alguns testes, constatou-se que o desenvolvimento de um sistema baseado puramente no alinhamento de varreduras seria inviável, já que a menos que os ambientes nos quais ele operasse tivessem algumas características bastante peculiares, sua eficácia

e agilidade seria severamente limitada. Ademais, e em consonância com o que há escrito em (FOX; THRUN; BURGARD, 2005) acerca de processos baseados apenas no alinhamento de varreduras no Capítulo denominado *Fast Incremental Mapping*, esse tipo de sistema, embora adequado para ambientes de pequena dimensão, e preferencialmente sem laços grandes, produzem resultados adequados como uma aproximação inicial, embora ambientes mais complexos, ou o simples fato de o erro de alinhamento ser cumulativo, tornem necessário que se tenha um sistema capaz de rever suas hipóteses e alterá-las com base em novas evidências que se disponibilizam ao longo do processo de mapeamento. É fato notório que um sistema que mantenha registro apenas de um mapa de ocupação e de sua presente pose e medições é incapaz de corrigir hipóteses inválidas aceitas em instantes anteriores, deveras os autores de (FOX; THRUN; BURGARD, 2005) afirmam ser necessário que se memorize todas as poses e medições realizadas em uma janela de tempo para que se possa alterar efetivamente as estimativas feitas sobre o ambiente e a trajetória de modo a corrigir o acúmulo de erros e imprecisões como a falha de fechamentos de laço. Segundo o que verificamos por meio de uma pesquisa bibliográfica, para que o sistema mantivesse estimativas razoavelmente verossímeis do mapa e da pose do robô três caminhos estavam disponíveis: o uso de uma técnica de filtragem estatística, o uso de um sistema de *smoothing*, que é similar ao uso de métodos de filtragem, mas geralmente reservado para sistemas que operem *offline*, ou um sistema baseado em otimização de grafos, alguns dos quais operam com sistemas que empregam *smoothers* mas são capazes de operar de modo incremental. Por fim, optamos por um sistema de baseado em grafos de poses incremental.

O uso de um *smoother* em conjunto com o alinhamento de varreduras pelo uso da otimização por inteligência de enxame e com a saída na forma de um mapa de ocupação significa que, em verdade, o sistema opera mantendo simultaneamente uma representação métrica (mapa de ocupação) e uma representação topológica (grafo de poses). Essa dualidade, confere ao sistema um comportamento híbrido já que ele exhibe algumas das vantagens de ambas as representações. O sistema implementado, no entanto, foi realizado de modo a fornecer resultados sob a forma de mapas de ocupação.

O método exposto foi testado em oito conjuntos de dados de domínio público. A partir dos experimentos realizados concluímos que o ABC mostrou-se o algoritmo mais bem adaptado ao problema de alinhamento de varreduras no contexto do SLAM, com um bom compromisso entre precisão e velocidade. Deveras, em todos os testes que realizamos

ele mostrou-se mais rápido que o PSO e no mínimo tão acurado quanto ele. O FA, por sua vez, exibiu um comportamento intermediário entre o PSO e o ABC. De fato, o FA superou em diversos casos o ABC em velocidade, e a escolha entre eles é uma de compromisso entre velocidade e acurácia, já que se por um lado um sistema com um alinhamento rápido é desejável, essa velocidade vem com o custo de que quanto maior o erro cometido nessa etapa mais difícil se torna o problema encontrar uma configuração ótima do grafo de poses. De fato, verificou-se que em muitos casos em que o tempo de alinhamento de uma das três técnicas foi excepcionalmente inferior ao das outras duas, o tempo requerido pela busca de fechamentos de laço e a otimização do grafo de poses subjacente ao problema somados tenderam a compensar a diferença. Observa-se aqui o típico exemplo da máxima *There's no free lunch* (Não há almoço grátis).

O PSO para nossa surpresa, à luz do que observou-se no Capítulo 5 obteve, nos experimentos realizados com conjuntos de dados compostos por registros odométricos e mensurações originárias de um sistema bidimensional de LIDAR do Capítulo 7 um tempo de execução superior ao das outras suas técnicas que selecionamos, se considerarmos apenas o tempo de alinhamento. A causa para isso é, provavelmente, a topologia que escolhemos que implica num alto grau de comunicação dentro do enxame a cada iteração.

O comportamento do FA foi, em verdade um tanto surpreendente, já que o algoritmo tende a ser bastante ágil, mas essa característica depende exacerbadamente do modo como a técnica é implementada. Com efeito, a necessidade de realizar constantes ordenações do enxame por ordem de atratividade aliada à sensibilidade do sistema como um todo ao coeficiente de atratividade, que pode, em verdade, alterar o tempo de execução por ordens de grandeza. A ordenação, em si, mostrou-se mais sensível ao algoritmo selecionado do que antecipáramos, de modo que por fim utilizamos uma combinação de ordenação por inserção, para pequenos enxames (menos de 10 vagalumes), com *quicksort* para enxames maiores.

O ABC, de acordo com o que expusemos, mostrou-se um bom algoritmo para a resolução do tipo de problema de otimização que surge da necessidade de alinhar varreduras, por meio de uma minimização da distância entre curvas amostradas mediante a aplicação de transformações rígidas. Em verdade, esse algoritmo parece ser particularmente bem adaptado a funções com vários modos próximos, em virtude do método usado para exploração de fontes de alimento, em conjunto com o sistema estocástico usado para

selecionar novas fontes de alimento promissoras. Ficou demonstrado nos experimentos e simulações que realizamos que o ABC é a técnica que apresenta a maior acurácia na nossa aplicação e um tempo de execução razoavelmente curto, tendo em vista que o tempo de processamento por varredura ficou em torno de 100ms.

Finalmente, é interessante comparar o desempenho do método proposto ao de outros sistemas conhecidos. Para esse fim, foi realizada no Capítulo 7 uma comparação com outros 4 sistemas de SLAM existentes. A comparação foi realizada com base nos dados e metodologia empregados em (KÜMMERLE et al., 2009).

A comparação entre o método que propomos, quando usada a metaheurística ABC, obteve erros translacionais médios inferiores ao sistema do estado da arte *Cartographer* descrito em (HESS et al., 2016). Com efeito, para os conjuntos de dados ACES e CSAIL o nosso sistema obteve erros translacionais, respectivamente, 44% e 12% inferiores ao reportado para o *Cartographer*. Com relação ao conjunto CSAIL, o erro absoluto rotacional obtido foi ainda 50,95% inferior ao do *Cartographer*. Para o conjunto de dados ACES, no entanto, o nosso método obteve erros absoluto rotacional 242,36% superior ao do mesmo sistema. Ao comparar os resultados obtidos pela aplicação de filtros de partículas, o nosso sistema obteve ainda resultados de mesma, ou maior, precisão em 60% dos casos. Obtivemos ainda erros comparáveis aos apresentados para o *Graph Mapping* em 2 dos 5 casos apresentados, e obtivemos um erro translacional 87,86% inferior ao do *Graph Mapping* para o conjunto de dados ACES. O nosso método mostrou-se, ainda, mais eficaz do que a simples aplicação de alinhamento de varreduras em 80% dos cenários contemplados.

O FA não obteve resultados tão precisos quanto os do ABC, muito embora em 7 dos 8 conjuntos de dados de domínio público que utilizamos ele foi o método mais veloz, consumindo, em média, apenas 23% do tempo gasto pela otimização por colônia artificial de abelhas por varredura. Os conjuntos em que o FA foi a meta-heurística mais veloz foram: INTEL, FR079, CORREDOR INFINITO, OREBRO, MEXICO E SEATTLE.

A otimização por enxame de partículas apresentou uma precisão inferior à do ABC, no entanto, seu consumo de tempo foi intermediário em comparação às duas outras meta-heurísticas empregadas. O fato de a precisão do PSO ter sido inferior em 5 dos 8 casos apresentados na Tabela 17 deixa pouca margem para que se argumente a favor do PSO como uma possível solução de compromisso, ao menos na forma conhecida como PSO com *global best*.

Quanto à contribuição desse trabalho, é importante que se observe que embora algumas das outras técnicas tenham apresentado resultados comparáveis, e até mesmo superiores em alguns casos, a acurácia deles também veio acompanhada de incertezas maiores. Deveras o desvio padrão de alguns dos casos chegou a ser reportado como da mesma ordem ou maior que o valor da média dos erros indicando a presença de valores de erros absolutos bastante dispersos. Nesse sentido, é importante que seja discriminado percentual dos casos em que as técnicas de otimização de enxame que empregamos permitiram à solução proposta, na presente dissertação, apresentaram resultados com dispersões menores do que todas as outras técnicas com as quais essas foram comparadas no Capítulo 7. Apesar de não ter se apresentado como a técnica de otimização mais precisa nos testes realizados, o FA foi o método que mais consistentemente apresentou resultados com menor coeficiente de variação. Com efeito, o nosso sistema, quando empregado com o FA apresentou um coeficiente de variação inferior a todas as outras técnicas empregadas nos cenários apresentados tanto no que tange ao erro absoluto de translação quanto no tocante ao erro absoluto de rotação. Com relação à dispersão dos erros, o emprego do ABC e do PSO apresentou resultados similares em relação à dispersão de seus resultados relativamente à de outros sistemas que tratam do SLAM. A nossa solução com o ABC obteve um coeficiente de variação dos valores de seu erro absoluto translacional inferior a todos os outros sistemas em 80% dos casos e um coeficiente de variação de seus valores de erro absoluto rotacional inferior a dos outros sistemas em 100% dos casos. Conversamente, a nossa solução com o PSO obteve um coeficiente de variação de seu erro absoluto translacional inferior a de todos os outros sistemas em 100% dos casos e um coeficiente de variação de seu erro absoluto rotacional inferior a de todos os outros sistemas em 80% dos casos. É bastante evidente que a nossa técnica além de apresentar resultados que, levando em consideração as margens de incerteza, são iguais, ou até superiores, aos das outras técnicas avaliadas apresentou uma menor dispersão dos resultados. Do ponto de vista prático isso indica que os resultados apresentados pela técnica que descrevemos são mais consistentes no que tange a sua precisão do que os outros métodos com os quais a comparamos. Ou seja, todas as evidências indicam que o nosso sistema apresentará resultados de acurácia mais próximos dos valores médios reportados do que os outros métodos mencionados. Desse modo, a aplicabilidade do método proposto a situações em

que margens menores de incerteza sejam desejáveis, ou necessárias, é substantiada pelos resultados apresentados.

## 8.2 Trabalhos Futuros

Nesta seção, são citadas algumas possíveis modificações nos algoritmos propostos, com o intuito de melhorar seu desempenho. Também são levantadas propostas para futuros trabalhos na área contida na intersecção do SLAM com as técnicas de otimização de enxame.

Quanto ao desempenho, comentamos anteriormente que utilizamos o PSO com *Global best* o que leva a uma grande troca de informações a cada iteração, uma possível linha de investigação no caso do PSO seria o teste de outras topologias, com o intuito de tornar mais ágil o processo de alinhamento. Como argumentamos na conclusão do trabalho, o algoritmo obteve precisão comparável a da meta-heurística que obteve a maior acurácia em nosso trabalho em 5 dos 8 casos apresentados na Tabela 17, de modo que, se for possível aumentar sua velocidade de operação, seria interessante explorar sua possível aplicação em situações que requeiram um *trade-off* entre precisão e velocidade.

O FA mostrou-se, mesmo sem alterações para esse fim, uma meta-heurística mais veloz que o ABC e mais precisa que o PSO. Isso sugere que vale a exploração maior dessa meta-heurística como aplicável a cenários em que o tempo de operação seja de maior preocupação que a precisão do sistema. Dito isso, abrem-se duas vias de investigação futura: a exploração do FA como técnica mais ágil visando obter um sistema mais veloz e a exploração de alterações no FA canônico apresentado em (FISTER; YANG; BREST, 2013) com o intuito de torná-lo mais acurado para o SLAM.

Ainda em relação ao desempenho do nosso sistema, verificou-se que em alguns casos o processo de detecção de retorno mostrou-se um passo bastante custoso do processo, haja vista que cada passo desse requer diversos alinhamentos de varreduras e um processo de tentativa para a inclusão de arestas no grafo de poses. Encorajamos, portanto, o desenvolvimento de heurísticas que ajudem a pré-selecionar o conjunto de nós que devem ser explorados. Outra possível forma de obter um *speedup* nesse processo seria o desenvolvimento de heurísticas que permitissem detectar a similaridade de varreduras sem que se fizesse necessário o alinhamento de varreduras.

Outra sugestão interessante seria o desenvolvimento de sistemas que automaticamente realizassem a seleção da meta-heurística a ser aplicada. Muito embora seja imediata a construção de um sistema que altere a meta-heurística aplicada com base em critérios do tipo tentativa e erro, seria interessante explorar a seleção automática da meta-heurística mais apropriada mediante a análise da estrutura do ambiente sendo explorado e as características intrínsecas das varreduras obtidas. Dos experimentos que conduzimos ficou evidente que o ambiente sendo explorado possui enorme impacto sobre o desempenho do sistema de alinhamento de varreduras e, conseqüentemente, sobre o SLAM como um todo. Especulamos que seja possível usar dados de desempenho, e características que possam ser extraídas das varreduras e da estrutura do grafo de poses para separar os ambientes em *clusters*, cujas características distintivas permitiriam determinar qual a melhor técnica de enxame passível de aplicação.

Uma sugestão interessante, aplicável a todos os métodos de otimização que empregamos seria a implementação desses de modo a tirar vantagem de arquiteturas paralelas como, por exemplo o uso de GPUs. Dependendo do *speed up* alcançado por uma implementação paralela reduzir-se-ia o custo computacional de alinhamento de varreduras o que impacta o sistema como um todo mas, principalmente, aumentaria a crítica parte da busca por fechamentos de laço *loop closures*. Evidentemente a capacidade de verificar um número mais alto de *frames* de dados possibilita que se obtenha mapas mais precisos num tempo igual ou menor que os que se pode obter sem essa vantagem. Vale a ressalva de que uma investigação nesse sentido deveria levar em consideração o tempo de transferência de dados para a GPU e o tempo de recuperação dos resultados, o que poderia anular a vantagem ganha pelo poder de processamento no que tange a aplicação do método a cenários de operação *online*.

Um possível trabalho futuro, extensão direta da presente pesquisa, seria a extensão do funcionamento do sistema sobre o qual dissertamos para operação tridimensional. A operação tridimensional abriria a possibilidade de aplicar esse sistema a robôs que voem ou que operem em ambientes aquáticos. A aplicação do SLAM em sistema aéreos, por exemplo, possui uma ampla gama de usos na área de vigilância. De fato, a capacidade de rapidamente mapear zonas de conflito, ou de intensa atividade criminosa, em que haja modificações significativas no ambiente realizadas em tempos relativamente curto.

O uso de robôs aquáticos capazes de se localizar e mapear as cercanias dos locais onde se encontram poderia ser vantajoso, por exemplo, em operações realizadas em plataformas de petróleo. Ainda nesse sentido, vale investigar a aplicação dos métodos aqui descritos ao problema de localização passiva, em que o robô não pode emitir sinais, que novamente é um problema de interesse na área militar haja vista o fato de que a mensuração ativa pode ser detectada por entes hostis levando a possível captura ou destruição do robô.

Outra possibilidade de trabalho futuro seria a modificação desse sistema de modo que lhe possibilite operar com enxames de robôs trabalhando em equipe. A abordagem híbrida métrico-topológica adotada possibilita, em princípio que cada robô do enxame compartilhe subgrafos, que podem ser unidos por restrições obtidas via alinhamento de varredura da mesma forma que se faz ao introduzir novas observações ao sistema. Há exemplos de sistemas hierárquicos em que a otimização de subgrafos funciona sem maiores obstáculos, de modo que é razoável assumir que a operação independente de robôs sobre partes do grafo não apresentaria maiores dificuldades do que as apresentadas num sistema hierárquico, desde que haja um sistema central capaz de otimizar a configuração relativa dos subgrafos pertencentes a cada robô.

# REFERÊNCIAS

- ADAMS, M. SLAM — algorithmic advances, loop closing, measurement classification and outdoor implementations. v. 55, n. 1, p. 1–2, 2007.
- ARUN, K. S.; HUANG, T. S.; BLOSTEIN, S. D. Least-squares fitting of two 3-d point sets. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PAMI-9, n. 5, p. 698–700, Sept 1987.
- BENTLEY, J. L. Multidimensional divide-and-conquer. *Commun. ACM*, ACM, New York, NY, USA, v. 23, n. 4, p. 214–229, abr. 1980.
- BENTLEY, J. L.; FRIEDMAN, J. H. Data structures for range searching. *ACM Comput. Surv.*, ACM, New York, NY, USA, v. 11, n. 4, p. 397–409, dez. 1979.
- BESL, P.; MCKAY, N. A method for registration of 3-d shapes. v. 14, n. 2, p. 239–256, 1992.
- BLANCO, J. L.; RAI, P. K. *nanoflann: a C++ header-only fork of FLANN, a library for Nearest Neighbor (NN) with KD-trees*. 2014. <https://github.com/jlblancoc/nanoflann>.
- BONARINI, A. et al. Rawseeds: Robotics advancement through web-publishing of sensorial and elaborated extensive data sets. In: *In proceedings of IROS'06 Workshop on Benchmarks in Robotics Research*. Beijing, China: IEEE, 2006. v. 27, p. 353–371.
- BUTKOV, E. *Mathematical Physics*. Boston, USA: Addison-Wesley, 1973. (Addison-Wesley Series in Advanced Physics).
- CARLISLE, A.; DOZIER, G. Adapting particle swarm optimization to dynamic environments. In: *International conference on artificial intelligence*. Las Vegas, Nevada, USA: IEEE Press, 2000. v. 1, p. 429–434.

- CENSI, A. An icp variant using a point-to-line metric. In: *2008 IEEE International Conference on Robotics and Automation*. Pasadena, USA: IEEE, 2008. p. 19–25.
- CENSI, A.; IOCCHI, L.; GRISETTI, G. Scan matching in the hough domain. In: *Proceedings - IEEE International Conference on Robotics and Automation*. Barcelona, Spain: IEEE, 2005. v. 2005, p. 2739–2744.
- CERIANI GIULIO FONTANA, A. G. D. M. S. et al. Rawseeds ground truth collection systems for indoor self-localization and mapping. *Autonomous Robots*, v. 27, n. 4, p. 353–371, 2009.
- CHATTERJEE, A.; MATSUNO, F. A geese pso tuned fuzzy supervisor for ekf based solutions of simultaneous localization and mapping (SLAM) problems in mobile robots. *Expert Systems with Applications*, v. 37, n. 8, p. 5542–5548, 2010.
- COLE, D. M.; NEWMAN, P. M. Using laser range data for 3d SLAM in outdoor environments. In: *Proceedings 2006 IEEE International Conference on Robotics and Automation, 2006. ICRA 2006*. Orlando, FL, USA: IEEE, 2006. p. 1556–1563.
- DELLAERT, F. *Factor Graphs and GTSAM: A Hands-on Introduction*. Atlanta, USA, Sept 2012. Disponível em: <<https://borg.cc.gatech.edu/sites/edu.borg/files/downloads/gtsam.pdf>>.
- DIOSI, A.; KLEEMAN, L. Laser scan matching in polar coordinates with application to SLAM. In: *2005 IEEE/RSJ International Conference on Intelligent Robots and Systems, IROS*. Edmonton, Canada: IEEE, 2005.
- DORIGO, M.; CARO, G. D.; GAMBARDELLA, L. M. Ant algorithms for discrete optimization. *ARTIFICIAL LIFE*, p. 137–172, 1999.
- DURRANT-WHYTE, H.; BAILEY, T. Simultaneous localization and mapping (SLAM): part i the essential algorithms. *Robotics & Automation Magazine*, v. 2, p. 99–110, 2006.
- ELFES, A. Occupancy grids: A stochastic spatial representation for active robot perception. In: *Proceedings of the Sixth Conference on Uncertainty in AI*. New York, NY, USA: Elsevier Science Inc., 1990. v. 2929, p. 6.

- ENGELBRECHT, A. P. *Fundamentals of computational swarm intelligence*. Chichester, West Sussex, England: John Wiley & Sons, 2006.
- FIORAIO, N.; KONOLIGE, K. Realtime visual and point cloud SLAM. In: *Proc. of the RGB-D workshop on advanced reasoning with depth cameras at robotics: Science and Systems Conf.(RSS)*. Saint Paul, MN, USA: IEEE, 2011. v. 27.
- FISTER, I.; YANG, X. S.; BREST, J. A comprehensive review of firefly algorithms. *Swarm and Evolutionary Computation*, v. 13, p. 34–46, 2013.
- FOX, D.; THRUN, S.; BURGARD, W. *Probabilistic robotics*. Cambridge, Mass, USA: the MIT Press, 2005.
- FRIEDMAN, J. H.; BENTLEY, J. L.; FINKEL, R. A. An algorithm for finding best matches in logarithmic expected time. *ACM Trans. Math. Softw.*, ACM, New York, NY, USA, v. 3, n. 3, p. 209–226, set. 1977.
- GAO, M.-L. et al. Object tracking using firefly algorithm. *IET Computer Vision*, v. 7, n. 4, p. 227–237, 2013.
- GIL, A.; JULIÁ, M.; REINOSO, s. Occupancy grid based graph-SLAM using the distance transform, surf features and sgd. *Engineering Applications of Artificial Intelligence*, v. 40, p. 1–10, 2015.
- GOLDSTEIN, H.; POOLE, C.; SAFKO, J. *Classical Mechanics*. Boston,USA: Addison Wesley, 2002.
- GRINSTEAD, C.; SNELL, J. *Grinstead and Snell's Introduction to Probability*. Hanover, NH 03755, EUA: Chance Project, 2006.
- GRISSETTI, G. et al. A tutorial on graph-based SLAM. *IEEE Intelligent Transportation Systems Magazine*, v. 2, n. 4, p. 31–43, 12 2010.
- GRISSETTI, G.; STACHNISS, C.; BURGARD, W. Improved techniques for grid mapping with rao-blackwellized particle filters. *IEEE Transactions on Robotics*, v. 23, p. 34–46, 2007.
- GUENNEBAUD, G.; JACOB, B. et al. *Eigen v3*. 2010. [Http://eigen.tuxfamily.org](http://eigen.tuxfamily.org).

- HESS, W. et al. Real-time loop closure in 2d lidar SLAM. In: *2016 IEEE International Conference on Robotics and Automation (ICRA)*. Stockholm, Sweden: IEEE, 2016. p. 1271–1278.
- HOWARD, A.; ROY, N. *The Robotics Data Set Repository (Radish)*. 2003. Disponível em: <<http://radish.sourceforge.net/>>.
- JIANG, X.; LI, T.; YU, Y. A novel SLAM algorithm with adaptive kalman filter. In: *2016 International Conference on Advanced Robotics and Mechatronics (ICARM)*. Macau, China: IEEE, 2016. p. 107–111.
- KAESS, M.; RANGANATHAN, A.; DELLAERT, F. isam : Incremental smoothing and mapping. v. 24, n. 2006706, November 2008.
- KALLASI, F.; RIZZINI, D. L. Efficient loop closure based on falko lidar features for online robot localization and mapping. In: *2016 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. Daejeon, South Korea: IEEE, 2016. p. 1206–1213.
- KALLASI, F.; RIZZINI, D. L.; CASELLI, S. Fast keypoint features from laser scanner for robot localization and mapping. *IEEE Robotics and Automation Letters*, v. 1, n. 1, p. 176–183, Jan 2016.
- KARABOGA, D. *An idea based on honey bee swarm for numerical optimization*. Kayseri, Turkey, 2005.
- KENNEDY, J. The particle swarm: social adaptation of knowledge. In: *Evolutionary Computation, 1997., IEEE International Conference on*. Indianapolis, USA: IEEE, 1997. p. 303–308.
- KENNEDY, J. *Swarm intelligence*. New York, USA: Springer US, 2006. 187–219 p.
- KENNEDY, J.; EBERHART, R. C. Particle swarm optimization. In: *Proceedings of the 1995 IEEE International Conference on Neural Networks*. Perth, Australia, IEEE Service Center, Piscataway, NJ: IEEE, 1995. p. 1942–1948.
- KJER, H. M.; WILM, J. *Evaluation of surface registration algorithms for PET motion correction*. Dissertação (BSc.) — Technical University of Denmark, Copenhagen, Denmark, 2010.

- KLEINER, A.; PREDIGER, J.; NEBEL, B. Rfid technology-based exploration and SLAM for search and rescue. In: *2006 IEEE/RSJ International Conference on Intelligent Robots and Systems*. Beijing, China: IEEE, 2006. p. 4054–4059.
- KOKOSKA, S.; ZWILLINGER, D. *CRC standard probability and statistics tables and formulae*. Boca Raton, Florida, EUA: Crc Press, 1999.
- KÜMMERLE, R. et al. G2O: A general framework for graph optimization. In: *Proceedings - IEEE International Conference on Robotics and Automation*. Shanghai, China: IEEE, 2011. p. 3607–3613.
- KÜMMERLE, R. et al. On measuring the accuracy of SLAM algorithms. *Autonomous Robots*, v. 27, n. 4, p. 387, Sep 2009.
- LAPLACE, P. de. *Théorie analytique des probabilités*. Amsterdam: Elsevier Science, 2005.
- LU, F.; MILIOS, E. Robot pose estimation in unknown environments by matching 2d range scans. *IEEE Computer Vision and Pattern Recognition Conference(CVPR)*, IEEE, p. 935–938, 1994.
- LU, F.; MILIOS, E. Globally consistent range scan alignment for environment mapping. *Autonomous Rots*, v. 4, n. 4, p. 333–349, 1997.
- MAHALANOBIS, P. C. On the generalized distance in statistics. In: *Proceedings of National Institute of Sciences of India*. Jatani, Odisha, India: NISI, 1936. v. 2, n. 1, p. 49–55.
- MINGAS, G.; TSARDOULIAS, E.; PETROU, L. An fpga implementation of the SMG-SLAM algorithm. *Microprocess. Microsyst.*, Elsevier Science Publishers B. V., Amsterdam, The Netherlands, The Netherlands, v. 36, n. 3, p. 190–204, maio 2012.
- MONTEMERLO, M. et al. Fastslam: A factored solution to the simultaneous localization and mapping problem. *Proc. of 8th National Conference on Artificial Intelligence/14th Conference on Innovative Applications of Artificial Intelligence*, v. 68, n. 2, p. 593–598, 2002.

- MULHOLLAND, H.; JONES, C. Chi-squared distribution. In: *Fundamentals of Statistics*. Boston, MA,USA: Springer, 1968. p. 178–200.
- NIETO, J.; BAILEY, T.; NEBOT, E. Recursive scan-matching SLAM. *Robotics and Autonomous Systems*, v. 55, n. 1, p. 39–49, 2007.
- NUNEZ, P. et al. Feature extraction from laser scan data based on curvature estimation for mobile robotics. IEEE, Orlando, FL, USA, n. 1641867, May 2006.
- OLIVEIRA, P. J. d. A. de; NEDJAH, N.; MOURELLE, L. de M. SLAM baseado em scan-matching com otimização por enxame de partículas. 2017.
- OLSON, E. B. *Robust and Efficient Robotic Mapping*. Tese (Doutorado), Cambridge, MA, USA, 2008. AAI0821013.
- PATHIRANAGE, C. D.; WATANABE, K.; IZUMI, K. A solution to the SLAM problem based on fuzzy Kalman filter using pseudolinear measurement model. In: *SICE, 2007 Annual Conference*. Takamatsu, Japan: IEEE, 2007. v. 55, p. 2364–2371.
- SASAKI, H.; KUBOTA, N.; TANIGUCHI, K. Evolutionary computation for simultaneous localization and mapping based on topological map of a mobile robot. In: . Berlin,Germany: Springer Berlin Heidelberg, 2008. p. 883–891.
- SMITH, R.; SELF, M.; CHEESEMAN, P. Estimating uncertain spatial relationships in robotics. *Autonomous Robot Vehicles*, v. 4, n. April, p. 167–193, 1990.
- SMITH, R. C.; CHEESEMAN, P. On the representation and estimation of spatial uncertainty. *The International Journal of Robotics Research*, v. 5, n. 4, p. 56–68, 1986.
- STACHNISS, C. *The Robotics Data Set Repository (Radish)*. 2018. Disponível em: <<http://www2.informatik.uni-freiburg.de/stachnis/datasets.html>>.
- THRUN, S.; BURGARD, W.; FOX, D. A real-time algorithm for mobile robot mapping with applications to multi-robot and 3d mapping. 2000.
- THRUN, S. et al. A system for volumetric robotic mapping of abandoned mines. In: *In Proceedings of the IEEE International Conference on Robotics and Automation (ICRA)*. Orlando, Florida, USA: IEEE, 2003. p. 4270–4275.

- THRUN, S. et al. Simultaneous localization and mapping with sparse extended information filters. *The International Journal of Robotics Research*, v. 23, n. 7-8, p. 693–716, 2004.
- THRUN, S.; MONTEMERLO, M. The GraphSLAM algorithm with applications to large-scale mapping of urban structures. 2006.
- THRUN, S. et al. Robotic mapping: A survey. *Exploring artificial intelligence in the new millennium*, Morgan Kaufmann, v. 1, p. 1–35, 2002.
- TIPALDI, G. D.; BRAUN, M.; ARRAS, K. O. Flirt: Interest regions for 2d range data with applications to robot navigation. Springer, Berlin, Germany, p. 695–710, 2014.
- WALTER, M. R.; EUSTICE, R. M.; LEONARD, J. J. Exactly sparse extended information filters for feature-based SLAM. *The International Journal of Robotics Research*, Sage Publications Sage UK: London, England, v. 26, n. 4, p. 335–359, 2007.
- WOODS, F. S. *An Introduction to Advanced Methods in Analytic Geometry*. New York, USA: Ginn And Company, 1922.
- ZHANG, Z. Iterative point matching for registration of free-form curves and surfaces. *International Journal of Computer Vision*, v. 13, n. 2, p. 119–152, Oct 1994.
- ZHIRONG, Z.; ZIXING, C.; BAIFAN, C. An improved fastslam method based on niche technique and particle swarm optimization. In: *2011 Chinese Control and Decision Conference (CCDC)*. Mianyang, China: IEEE, 2011. p. 2414–2418.

# APÊNDICE A – RESULTADOS NUMÉRICOS OBTIDOS

Este apêndice apresenta as tabelas de caracterização das experiências mencionadas no Capítulo 7.

Tabela 7: Erro absoluto para o conjunto de dados FR079.

	ABC	FA	PSO
Absoluto Translacional	$0.092 \pm 0.007$	$0.083 \pm 0.005$	$0.085 \pm 0.020$
Absoluto Rotacional	$0.234 \pm 0.337$	$0.617 \pm 0.353$	$0.985 \pm 1.039$

Tabela 8: Erro absoluto para o conjunto de dados Corredor Infinito.

	ABC	FA	PSO
Absoluto Translacional	$1.451 \pm 0.0170$	$0.8019 \pm 0.1863$	$1.3329 \pm 0.1842$
Absoluto Rotacional	$1.68 \pm 0.109$	$2.79 \pm 1.266$	$1.451 \pm 0.557$

Tabela 9: Erro absoluto para o conjunto de dados INTEL.

	ABC	FA	PSO
Absoluto Translacional	$0.0366 \pm 0.015$	$0.255 \pm 0.032$	$0.086 \pm 0.029$
Absoluto Rotacional	$3.33 \pm 0.98$	$2.28 \pm 1.904$	$2.05 \pm 0.321$

Tabela 10: Erro absoluto para o conjunto de dados MIT CSAIL.

	ABC	FA	PSO
Absoluto Translacional	$0.028 \pm 0.007$	$0.232 \pm 0.008$	$0.169 \pm 0.008$
Absoluto Rotacional	$0.181 \pm 0.052$	$0.045 \pm 0.077$	$0.411 \pm 0.007$

Tabela 11: Erro absoluto para o conjunto de dados SEATTLE.

	ABC	FA	PSO
Absoluto Translacional	$0.113 \pm 0.036$	$0.358 \pm 0.003$	$0.269 \pm 0.202$
Absoluto Rotacional	$0.619 \pm 0.039$	$0.128 \pm 0.012$	$0.043 \pm 0.052$

Tabela 12: Erro absoluto para o conjunto de dados OREBRO.

	ABC	FA	PSO
Absoluto Translacional	$0.015 \pm 0.012$	$0.104 \pm 0.006$	$0.253 \pm 0.001$
Absoluto Rotacional	$0.135 \pm 0.075$	$0.200 \pm 0.068$	$0.253 \pm 0.059$

Tabela 13: Erro absoluto para o conjunto de dados ACES.

	ABC	FA	PSO
Absoluto Translacional	$0.021 \pm 0.012$	$0.481 \pm 0.006$	$0.043 \pm 0.1$
Absoluto Rotacional	$1.277 \pm 0.075$	$0.381 \pm 0.068$	$0.253 \pm 0.059$

Tabela 14: Erro absoluto para o conjunto de dados COPA.

	ABC	FA	PSO
Absoluto Translacional	$0.5 \pm 0.07$	$0.759 \pm 0.2$	$0.607 \pm 0.159$
Absoluto Rotacional	$0.956 \pm 0.432$	$1.319 \pm 0.279$	$1.043 \pm 0.544$

Tabela 15: Erro absoluto para o conjunto de dados MEXICO.

	ABC	FA	PSO
Absoluto Translacional	$0.6136 \pm 0.07$	$0.0517 \pm 0.01$	$0.689 \pm 0.159$
Absoluto Rotacional	$0.759 \pm 0.0688$	$0.614 \pm 0.279$	$0.917 \pm 0.0802$

Tabela 16: Erro absoluto para o conjunto de dados CPSL.

	ABC	FA	PSO
Absoluto Translacional	$0.511 \pm 0.164$	$0.164 \pm 0.082$	$0.0721 \pm 0.159$
Absoluto Rotacional	$0.937 \pm 1.124$	$0.193 \pm 0.221$	$0.157 \pm 0.044$

Tabela 17: Tabela comparativa das acurácias obtidas com aquelas de outros métodos mencionados.

	<b>SM<sup>a</sup></b>	<b>RBPF<sup>b</sup></b>	<b>GM<sup>c</sup></b>	<b>Cartographer</b>	<b>ABC</b>	<b>FA</b>	<b>PSO</b>	
Intel (S <sub>1</sub> )	Absoluto	0.220 ± 0.296	0.070 ± 0.083	0.031 ± 0.026	0.0229 ± 0.0239	0.0366 ± 0.15	0.255 ± 0.032	0.086 ± 0.029
	Translacional							
FR079 (S <sub>2</sub> )	Absoluto	1.7 ± 4.8	3.0 ± 5.3	1.3 ± 4.7	0.453 ± 1.335	3.33 ± 0.98	2.28 ± 0.01904	2.05 ± 0.0321
	Rotacional							
CSAIL (S <sub>3</sub> )	Absoluto	0.258 ± 0.427	0.061 ± 0.044	0.056 ± 0.042	0.0452 ± 0.0354	0.092 ± 0.007	0.083 ± 0.005	0.085 ± 0.020
	Translacional							
Killian (S <sub>4</sub> )	Absoluto	1.7 ± 2.1	0.6 ± 0.6	0.6 ± 0.6	0.538 ± 0.718	0.234 ± 0.0337	0.617 ± 0.0353	0.985 ± 0.01039
	Rotacional							
Aces (S <sub>6</sub> )	Absoluto	0.106 ± 0.325	0.049 ± 0.049	0.004 ± 0.009	0.0319 ± 0.0363	0.028 ± 0.007	0.232 ± 0.008	0.169 ± 0.008
	Translacional							
Killian (S <sub>4</sub> )	Absoluto	1.4 ± 4.5	0.6 ± 1.2	0.05 ± 0.08	0.369 ± 0.365	0.411 ± 0.007	1.4191 ± 0.1858	0.0243 ± 1.925
	Rotacional							
Killian (S <sub>4</sub> )	Absoluto	1.651 ± 4.138	0.122 ± 0.386	0.050 ± 0.056	0.0395 ± 0.0488	1.451 ± 0.0170	0.8019 ± 0.1863	1.3329 ± 0.1842
	Translacional							
Aces (S <sub>6</sub> )	Absoluto	2.3 ± 4.5	0.8 ± 0.8	0.5 ± 0.5	0.352 ± 0.353	1.68 ± 0.109	2.79 ± 1.266	1.451 ± 0.557
	Rotacional							
Aces (S <sub>6</sub> )	Absoluto	0.173 ± 0.614	0.173 ± 0.614	0.173 ± 0.614	0.0375 ± 0.0426	0.621 ± 0.16	0.481 ± 0.0381	0.43 ± 0.03
	Translacional							
Aces (S <sub>6</sub> )	Absoluto	1.2 ± 1.5	1.2 ± 1.3	0.4 ± 0.4	0.373 ± 0.469	1.277 ± 0.026	0.381 ± 0.006	0.253 ± 0.0333
	Rotacional							

<sup>a</sup>Scan Matching<sup>b</sup>Usando 50 partículas<sup>c</sup>Graph Mapping