

PLANEJAMENTO DE ROTAS

Seminário de Robótica
Bruno de Abreu Silva

SUMÁRIO

- ◉ Introdução
- ◉ Conceitos gerais
- ◉ Métodos de planeamento de rotas

DEFINIÇÃO DO PROBLEMA

- ◉ Dadas as configurações inicial e final de um robô, descobrir uma sequência de movimentos a ser executada pelo robô para que ele saia da primeira e chegue à segunda sem colidir com obstáculos.

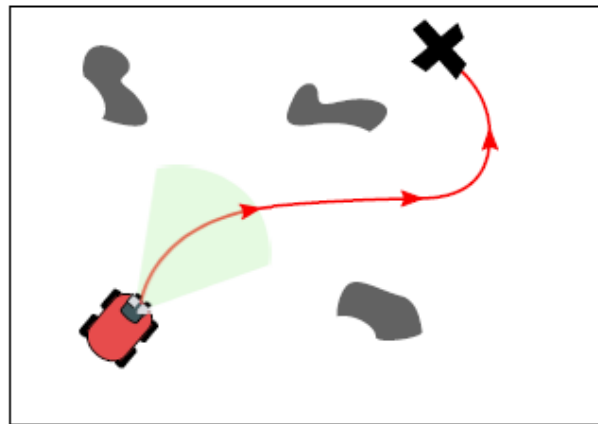


Figura 1.1: Exemplo típico de planejamento de rotas em robótica móvel. \mathcal{C} é tridimensional e \mathcal{W} é bidimensional.

- ⊙ O planejamento de rotas geralmente ocorre em C e não em W
- ⊙ A solução é dada por uma função contínua π tal que $\pi: [0, 1] \rightarrow C_{livre}$, em que $\pi(0) = q_{início}$ e $\pi(1) = q_{fim}$
- ⊙ Dificuldade do planejamento de rotas determinístico:
 - tempo de execução que cresce exponencialmente com o número de graus de liberdade do robô.
- ⊙ Assim, têm sido pesquisados métodos que aproximam C_{livre} por meio de amostras do mesmo e que são computacionalmente eficientes.

- ◎ O grande desafio é projetar planejadores que tenham:
 - Bom desempenho computacional
 - Produzam rotas com boa qualidade
 - Que não sejam dependentes do espaço de trabalho
- ◎ Métodos para planejamento de rotas foram amplamente investigados na teoria e na prática e suas aplicações extrapolam a robótica

APLICAÇÕES

- ◉ Animação de atores artificiais
- ◉ Biologia molecular
- ◉ Problemas de montagens complexas
- ◉ Planejamento de movimento para objetos flexíveis e planejamento para robôs humanóides
- ◉ Planejamento multirrobo
- ◉ Planejamento em ambientes com obstáculos que se movem

SUMÁRIO

- ◉ Introdução

- ◉ Conceitos gerais

- Espaço de configurações
- Representação dos objetos em W
 - *Representação por polígonos convexos*
 - *Modelos semi-algébricos*
 - *Grades de ocupação*

- ◉ Métodos de planejamento de rotas

ESPAÇO DE CONFIGURAÇÕES

- ◉ Permite resolver com o mesmo algoritmo diferentes problemas de planejamento
- ◉ Permite representar conceitos físicos como força e atrito
- ◉ O planejamento de rotas acontece em C_{livre}

$$C_{livre} = C \setminus \bigcup_{i=1}^n C\mathcal{O}_i = \left\{ q \in C \mid \mathcal{A}(q) \cap \left(\bigcup_{i=1}^n \mathcal{O}_i \right) = \emptyset \right\}. \quad (1.1)$$

REPRESENTAÇÃO DOS OBJETOS EM W

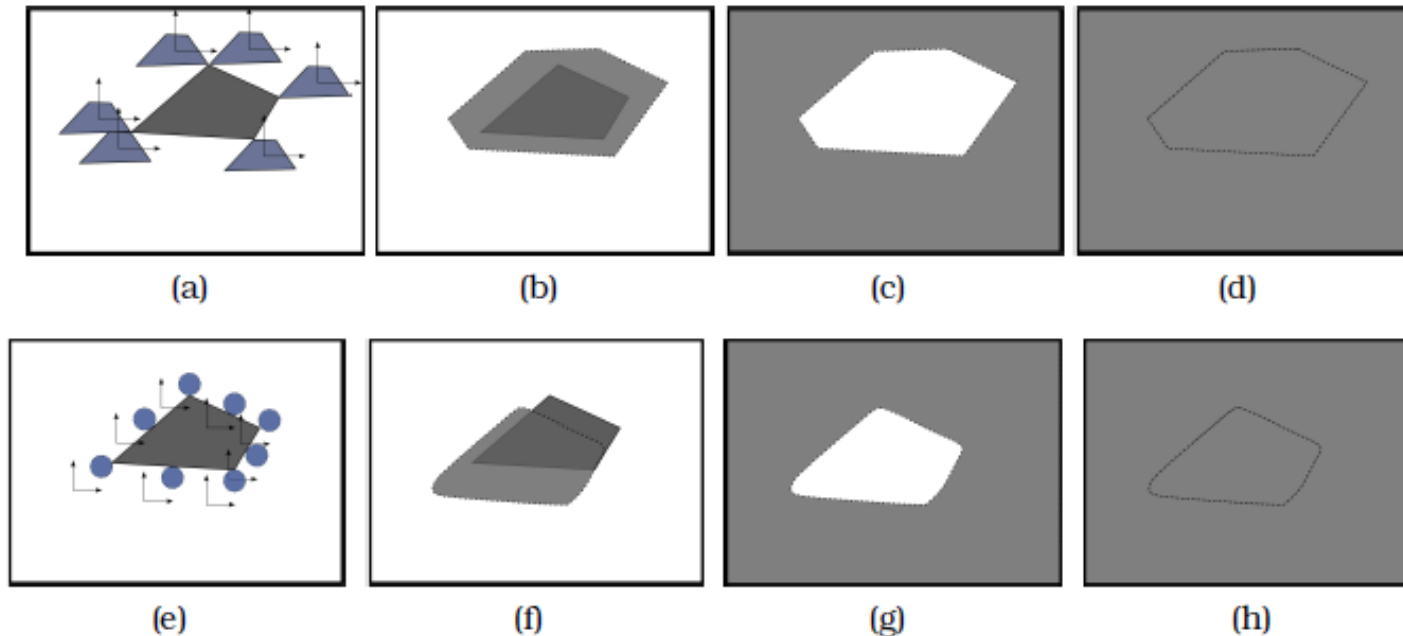
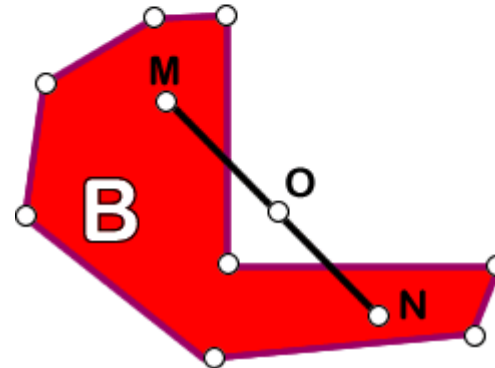
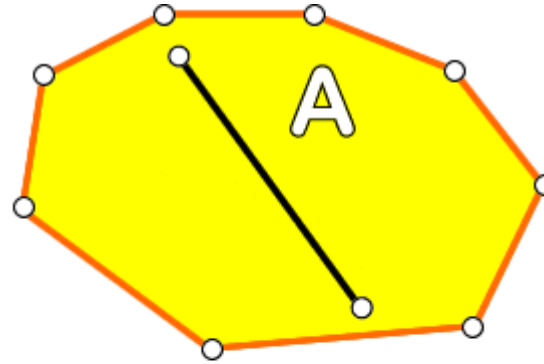



Figura 1.2: Exemplo mostrando que o espaço de configurações independe do formato do robô. (a) Mapeamento de um robô trapezoidal. (b) C_{obs} dentro da região tracejada. (c) C_{livre} hachurado. (d) $C_{obs} \cup C_{livre} = C$. (e) Mapeamento de um robô circular. (f) C_{obs} dentro da região tracejada. (g) C_{livre} hachurado. (h) $C_{obs} \cup C_{livre} = C$.


POLÍGONOS CONVEXOS

- ◉ Uma região plana é chamada de região convexa se e somente se todo o segmento de reta cujas extremidades pertencem à região só tem pontos na mesma região






(a)



(b)




(c)

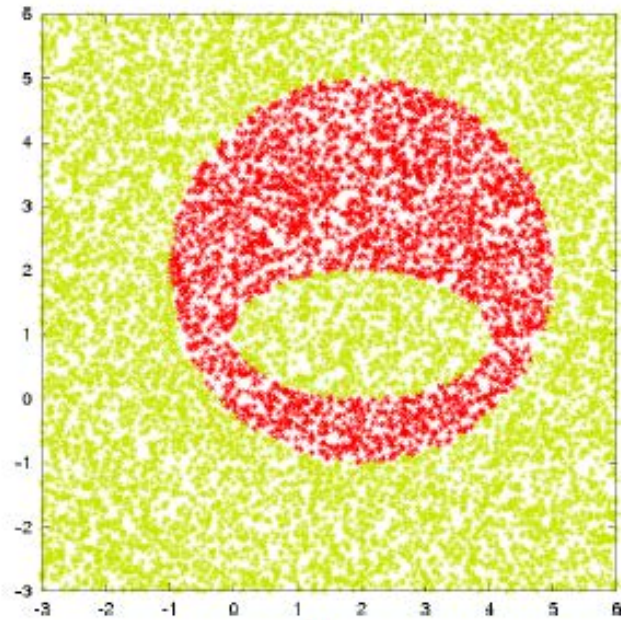
Figura 1.3: Triângulo construído pela intersecção de três semiplanos. (a) Construção do primeiro semiplano. (b) Intersecção entre dois semiplanos. (c) Triângulo resultante da intersecção entre três semiplanos.

MODELOS SEMI-ALGÉBRICOS

- ◉ Um conjunto de pontos determinado por uma única primitiva polinomial é dito algébrico. Uniões e intersecções de conjuntos algébricos formam um conjunto semi-algébrico.
- ◉ Modelos semi-algébricos são uma generalização da representação por polígonos convexos



(a)



(b)

Figura 1.4: Detecção de colisão usando representação por (a) polígonos convexos e (b) por primitivas semi-algébricas.

GRADES DE OCUPAÇÃO

- ◉ O espaço é dividido em células que contém uma probabilidade de ocupação associada.
- ◉ Consegue representar as incertezas relacionadas ao mapeamento do espaço de trabalho
- ◉ *Bitmap* - útil para fins de mapeamento de rotas e pode ser obtido atribuindo 0 ou 1 para cada probabilidade das células de acordo com um limiar



(a)



(b)

Figura 1.5: (a) Grade de ocupação e (b) sua transformação em *bitmap*.

SUMÁRIO

- ◉ Introdução
- ◉ Conceitos gerais
- ◉ Métodos de planeamento de rotas
 - Campos potenciais
 - Planeamento por frente de onda
 - Decomposição celular
 - Métodos probabilísticos
 - Suavização de rotas

MÉTODOS DE PLANEJAMENTO DE ROTAS

- Podem ser divididos em:
 - Algoritmos que utilizam mapa de rotas
 - Algoritmos que fazem decomposição em células
 - Algoritmos que utilizam funções potenciais

- ⊙ Podem ser divididos também em:
 - De questionamento único
 - De múltiplos questionamentos
- ⊙ Por fim, também dividem-se em:
 - Determinísticos
 - Probabilísticos

CAMPOS POTENCIAIS

- ◉ A idéia básica é atribuir um potencial de atração gerado pela configuração de destino e um potencial de repulsão gerado pelos obstáculos. Assim, naturalmente o robô tende a ir de encontro à configuração desejada enquanto automaticamente desvia dos obstáculos.

$$U(\mathbf{q}) = U_{\text{att}}(\mathbf{q}) + U_{\text{rep}}(\mathbf{q}), \quad (1.15)$$

$$\mathbf{f} = \mathbf{f}_{\text{att}} + \mathbf{f}_{\text{rep}}. \quad (1.16)$$




Figura 1.6: Campos potenciais: o gradiente do campo é equivalente a uma força atuando no robô. (a) Gradiente do potencial de atração. (b) Gradiente do potencial de repulsão. (c) Gradiente do potencial resultante.

Algoritmo 1 Planejador que utiliza campos potenciais artificiais.

Require: Configurações inicial $q_{\text{início}}$ e final q_{fim}

Ensure: Rota

- 1: $q \leftarrow q_{\text{início}}$
 - 2: **enquanto** $\|f\| > \varepsilon$ **faí** $\frac{1}{2}\mathbf{a}$
 - 3: Calcula a resultante f_{rep} das forças de repulsão geradas pelos obstáculos
 - 4: Calcula a força de atração f_{att} gerada pela configuração de destino q_{fim}
 - 5: $f \leftarrow f_{\text{att}} + f_{\text{rep}}$
 - 6: $q \leftarrow q + \alpha f$
 - 7: **fim enquanto**
-




Figura 1.7: Planejador baseado em campos potenciais. A cavidade do obstáculo não-convexo constitui um mínimo local.

- ◎ Abordagens que visam eliminar o problema de mínimos locais:
 - Passeios aleatórios
 - Outras funções potenciais que resultam em um único mínimo localizado na configuração final
 - Campos eletrostáticos
 - Funções harmônicas.

PLANEJADOR POR FRENTE DE ONDA (PFO)

- ⦿ Técnica simples e determinística
- ⦿ Utiliza grade no espaço de configurações
- ⦿ Algoritmo:
 - Rotulam-se as células ocupadas pelos obstáculos com 1 e o espaço livre em 0.
 - A configuração final é rotulada com 2 e a partir dela as células vizinhas livres são numeradas com o valor de seu rótulo mais 1, ou seja, 3.
 - O processo é repetido com todas as células vizinhas e assim por diante.
- ⦿ Solução: partindo da configuração inicial e seguindo sequencia decrescente até a célula com rótulo 2



(a)



(b)

Figura 1.8: Potencial gerado pela frente de onda cujo mínimo global está localizado no centro do espaço de configurações. (a) Espaço de trabalho. (b) Potencial gerado pela frente de onda em $\mathcal{C}_{\text{livre}}$.

VANTAGENS DO PFO

- ◉ É de resolução completa;
- ◉ Existe só um ponto de mínimo, localizado no ponto de destino;
- ◉ A solução é ótima no sentido de ter a menor distancia de Manhattan;
- ◉ É de fácil implementação, sem estruturas de dados complexas.

DESVANTAGENS DO PFO


- ⦿ por ser determinístico, o PFO pode se tornar computacionalmente impraticável para espaços de configuração de ordem mais alta;
- ⦿ rotas geradas são muito próximas dos obstáculos, que pode comprometer a segurança do robô;
- ⦿ o critério da distancia de Manhattan não gera rotas ótimas segundo o critério da distancia Euclidiana.

DECOMPOSIÇÃO CELULAR

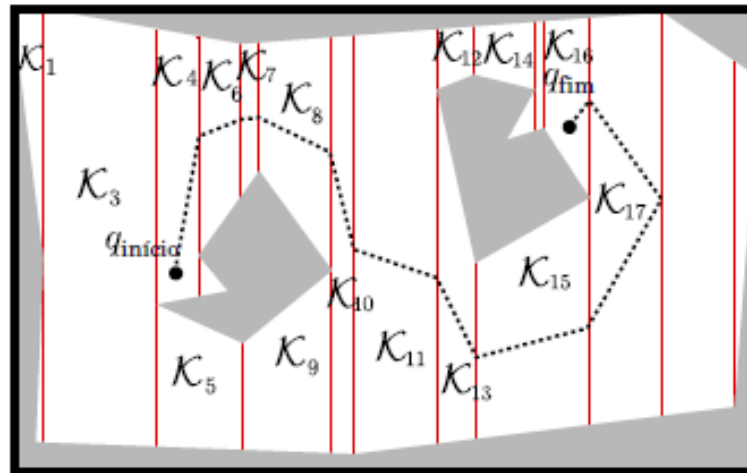
- ◉ Dividem-se em duas categorias principais: decomposição exata e decomposição aproximada.
- ◉ Em ambas as categorias, o princípio básico do planejador é particionar C_{livre} em um conjunto de células K_i cujas regiões interiores não se sobrepõem.
- ◉ O objetivo é achar uma sequência de células adjacentes $K_1 \dots K_n \in C_{livre}$, tal que $K_1 = K_{inicio}$, $K_n = K_{fim}$.

DECOMPOSIÇÃO CELULAR EXATA

- ⊙ O espaço de configurações livre é particionado tal que a união das células resulta exatamente nele mesmo.
- ⊙ O planejador resultante é considerado completo.
- ⊙ Uma vez que C_{livre} foi particionado, a solução para o planejamento de rotas consiste em achar uma sequência de células adjacentes ligando q_{inicio} a q_{fim} .



(a)



(b)

Figura 1.10: Decomposição celular exata. (a) Decomposição trapezoidal. (b) Rota resultante.

DECOMPOSIÇÃO CELULAR APROXIMADA

- ◉ Não permitem a representação exata de C_{livre}
- ◉ É mais fácil de se implementar que as versões exatas
- ◉ São de resolução completa
- ◉ O espaço de configurações é dividido sucessivamente em células denominadas *vazias*, *cheias* ou *mistas*.
- ◉ O objetivo é refinar a amostragem de células mistas até que elas sejam divididas apenas em células vazias ou cheias, ou então até uma resolução máxima.

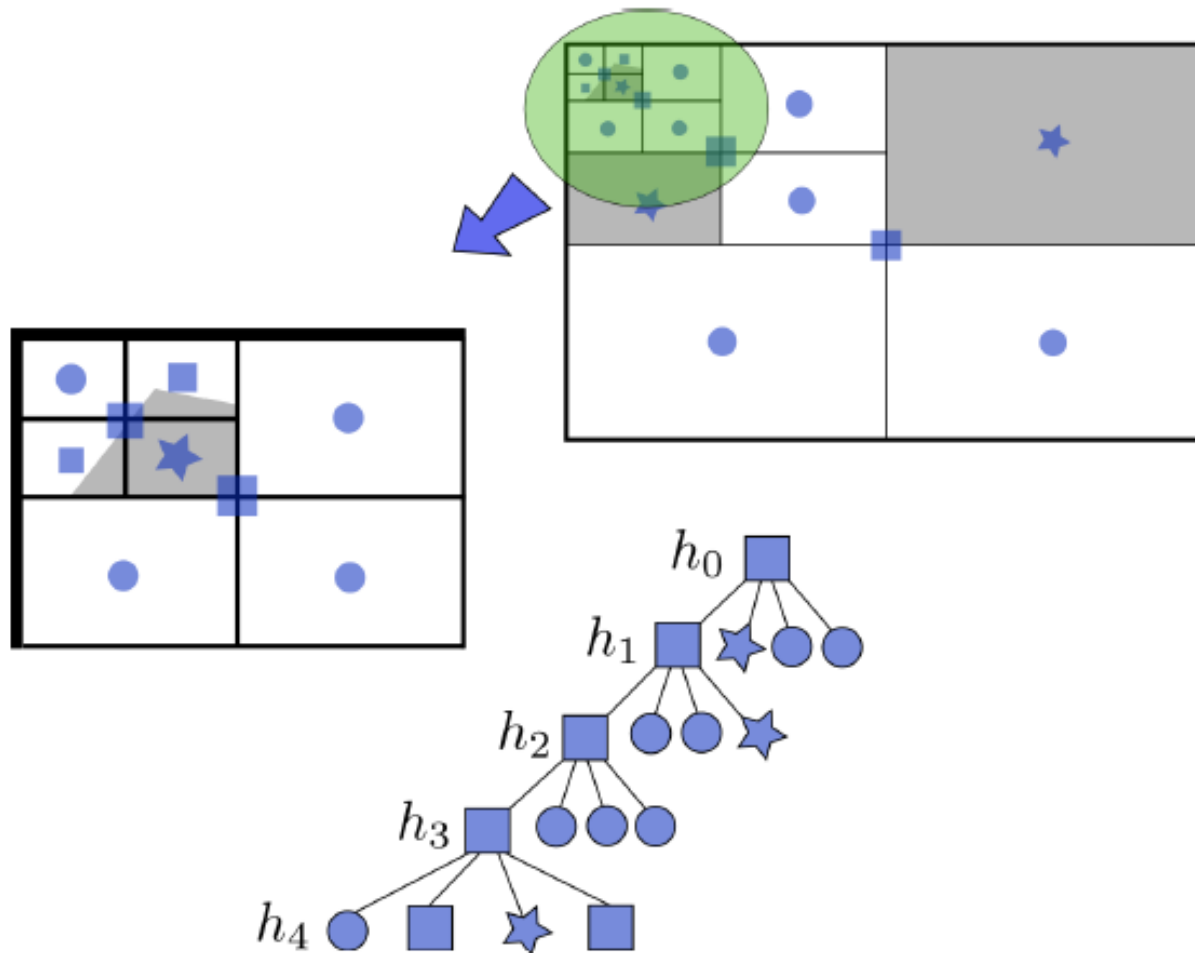


Figura 1.11: Decomposição celular aproximada para $\mathcal{C} \in \mathbb{R}^2$ e a árvore equivalente.

MÉTODOS PROBABILÍSTICOS

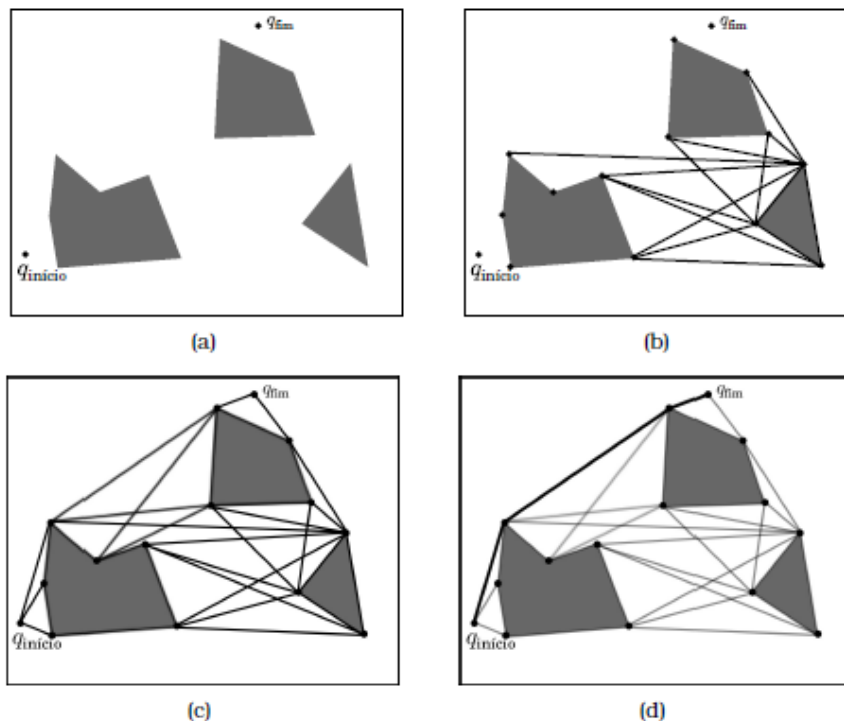


Figura 1.12: Construção do mapa de visibilidade. (a) Espaço de configurações bidimensional com os obstáculos representados por polígonos. (b) Etapa intermediária da construção do mapa de visibilidade: os vértices dos polígonos correspondem aos nós do grafo; observa-se a criação das arestas para o triângulo, sendo que todas as rotas que ligam os seus vértices aos vértices dos outros polígonos e que se encontram em C_{livre} são armazenadas no mapa de rotas; nota-se que as arestas dos polígonos também são armazenadas. (c) Mapa de visibilidade final. (d) Rota ligando as configurações inicial e final.

MAPA DE ROTAS PROBABILÍSTICO (PRM)

- ◉ A estrutura básica deste algoritmo é um grafo localizado em C_{livre}
- ◉ O algoritmo PRM é dividido em duas etapas: aprendizado e questionamento. A primeira consiste em expandir o grafo na região C_{livre} para poder gerar rotas rapidamente na etapa seguinte.
- ◉ Uma das premissas utilizadas no PRM padrão é que o espaço de trabalho seja estático ou que as mudanças ocorrem lentamente.

Algoritmo 2 Etapa de aprendizado do PRM

Require: max_nós, max_vizinhos e D_n

Ensure: Mapa de rotas.

```
1:  $i \leftarrow 0$ 
2:  $N \leftarrow \emptyset$ 
3:  $E \leftarrow \emptyset$ 
4: enquanto  $i < \text{max\_nós}$  faça  $i \leftarrow i + 1$ 
5:    $q_{\text{nova}} \leftarrow$  configuração aleatória em  $\mathcal{C}$ 
6:   se  $q_{\text{nova}} \in \mathcal{C}_{\text{livre}}$  então
7:      $i \leftarrow i + 1$ 
8:     Adiciona  $q_{\text{nova}}$  ao grafo por meio de um nó em  $N$ 
9:     Seleciona max_vizinhos vizinhos  $q_j$  em torno de  $q_{\text{nova}}$  que estejam a
       uma distância inferior a  $D_n$ 
10:    para  $j = 1$  até max_vizinhos faça  $i \leftarrow i + 1$ 
11:      se planejador_local( $q_{\text{nova}}, q_j$ ) e não mesmo componente conexo então
12:        Adiciona uma aresta em  $E$  conectando o nó referente a  $q_{\text{nova}}$  ao nó
          referente a  $q_j$ 
13:      fim se
14:    fim para
15:  fim se
16: fim enquanto
```

Algoritmo 3 planejador_local

Require: As configurações $q_i, q_j \in \mathcal{C}_{livre}$ e $\alpha \in (0, 1)$

Ensure: 1, se q_i puder ser conectado a q_j e 0, caso contrário.

1: $q \leftarrow q_i$

2: $t \leftarrow 0$

3: **enquanto** $t < 1$ **faça** $\frac{1}{2}$

4: **se** detecção_colisão(q) **então**

5: **return** 0

6: **senão**

7: $t \leftarrow t + \alpha$

8: $q \leftarrow (1 - t)q_i + t q_j$

9: **fim se**


10: **fim enquanto**

11: {Se chegou até este ponto, é porque não houve colisão.}


12: **return** 1




(a)



(b)



(c)



(d)

Figura 1.13: Evolução da construção do mapa de rotas no algoritmo PRM. (a) Dois nós são gerados em \mathcal{C}_{livre} . (b) Mais dois nós são gerados e, após a conexão com os vizinhos, dois componentes conexos são formados. (c) Mais nós são gerados e os dois componentes conexos se fundem em apenas um. (d) Mapa de rotas resultante após a geração de 10 configurações.

- ⦿ Número de amostras não pode ser nem muito pequeno inviabilizando o encontro da solução e nem muito grande desperdiçando recursos computacionais
- ⦿ O PRM pode ser utilizado em espaços de configuração de dimensões grandes, pois uma vez que o mapa de rotas é construído, basta verificar o grafo.

ÁRVORES ALEATÓRIAS PARA EXPLORAÇÃO RÁPIDA (RRT)

- ◉ Foi desenvolvido inicialmente para planejamento kinodinâmico.
- ◉ Versão bidirecional específica do RRT para buscas no espaço de configurações: RRT-conecta.
- ◉ O objetivo é fazer com que duas árvores cresçam da configuração inicial e final do robô por meio de um processo de amostragem em C e expansão destas árvores em C_{livre} .

Algoritmo 4 RRT

Require: $q_{\text{início}}$ e q_{fim}

Ensure: Rota resultante

```
1:  $\mathcal{T}_a$ .inicia( $q_{\text{início}}$ )
2:  $\mathcal{T}_b$ .inicia( $q_{\text{fim}}$ )
3: para  $k = 1$  até  $K$  faça  $\frac{1}{2}$  a
4:   gera uma configuração aleatória  $q_{\text{aleatória}}$  em  $\mathcal{C}$  de acordo com uma distribuição uniforme
5:   se RRT-conecta( $\mathcal{T}_a, q_{\text{aleatória}}$ ) não BLOQUEADO então
6:      $q_{\text{nova}} \leftarrow q_{\text{aleatória}}$  (ou a configuração que está mais perto de  $q_{\text{aleatória}}$  que encontra-se em  $\mathcal{C}_{\text{livre}}$ )
7:     se RRT-conecta( $\mathcal{T}_b, q_{\text{nova}}$ ) = ALCANÇOU então
8:       return rota( $\mathcal{T}_a, \mathcal{T}_b$ )
9:     fim se
10:  senão
11:    alterna( $\mathcal{T}_a, \mathcal{T}_b$ )
12:  fim se
13: fim para
14: return NULL
```

Algoritmo 5 RRT-conecta

Require: $q_{\text{aleatória}}$ e a árvore \mathcal{T}

Ensure: Status de q_{nova}

```
1:  $q_{\text{próx.}} \leftarrow \text{vizinho\_mais\_próximo}(q_{\text{aleatória}}, \mathcal{T})$ 
2:  $q_{\text{nova}} \leftarrow \text{planejador\_local\_ganancioso}(q_{\text{próx.}}, q_{\text{aleatória}})$ 
3: se  $q_{\text{nova}}$  não NULL então
4:    $\mathcal{T}.\text{adiciona\_nó}(q_{\text{nova}})$ 
5:    $\mathcal{T}.\text{adiciona\_aresta}(q_{\text{próx.}}, q_{\text{nova}})$ 
6:   se  $q_{\text{aleatória}} = q_{\text{nova}}$  então
7:     return ALCANÇOU
8:   senão
9:     return AVANÇOU
10: fim se
11: senão
12:   return BLOQUEADO
13: fim se
```




Figura 1.14: Exemplo de árvore criada pelo algoritmo RRT. Foram geradas 50 amostras.

- ⦿ Como a busca é feita de forma bidirecional, a solução em geral é encontrada bem antes do espaço de busca ter sido todo explorado.
- ⦿ Assim como o PRM, um problema do RRT é que a busca por vizinhos mais próximos é feita ao adicionar um novo nó na árvore de exploração.

ÁRVORES EM ESPAÇOS EXPANSIVOS (EST)

- ◉ É de questionamento único
- ◉ Assim como o RRT, visa explorar de maneira uniforme o espaço de configurações.
- ◉ Duas árvores são geradas a partir das configurações iniciais *q_{inicio}* e *q_{fim}* e o objetivo é que uma árvore seja alcançável pela outra, o que caracteriza a solução do problema.

Algoritmo 6 constrói-EST

Require: q_0 e N

Ensure: Árvore \mathcal{T} com nó raiz q_0

- 1: Adiciona q_0 à árvore \mathcal{T}
 - 2: **para** $i = 1$ até N **fai** $\frac{1}{2}$ **a**
 - 3: $q_{\text{aleatória}} \leftarrow$ conf. aleatória escolhida em \mathcal{T} com probabilidade $\pi(q_{\text{aleatória}})$
 - 4: $q_{\text{nova}} \leftarrow$ conf. aleatória na vizinhança de $q_{\text{aleatória}}$, tal que $\text{distância}(q_{\text{aleatória}}, q_{\text{nova}}) < d$
 - 5: **se** $\text{planejador_local}(q_{\text{aleatória}}, q_{\text{nova}})$ **então**
 - 6: adiciona q_{nova} a \mathcal{T}
 - 7: adiciona uma aresta ligando $q_{\text{aleatória}}$ a q_{nova}
 - 8: **fim se**
 - 9: **fim para**
 - 10: **return** \mathcal{T}
-

Algoritmo 7 fusiona-EST

Require: $\mathcal{T}_{\text{início}}$ e \mathcal{T}_{fim}

```
1: for all  $q_a \in \mathcal{T}_{\text{início}}$  e  $q_b \in \mathcal{T}_{\text{fim}}$  faça  $\frac{1}{2}a$   
2:   se  $\text{dist}(q_a, q_b) < l$  então  
3:     se  $\text{planejador\_local}(q_a, q_b)$  então  
4:       return ROTA  
5:   fim se  
6: fim se  
7: fim para
```




Figura 1.15: Árvore gerada pelo algoritmo EST. Foram geradas 50 amostras. (a) EST com intervalo de amostragem igual a 30. (b) EST com intervalo de amostragem igual a 60. (c) EST com intervalo de amostragem igual a 90 (d) EST com intervalo de amostragem igual a 120.

- ⦿ Se a distância D for muito grande, áreas que não são relevantes para a solução podem ser amostradas. Por outro lado, se for muito pequeno, o algoritmo pode demorar para convergir.
- ⦿ Outra dificuldade inerente a este algoritmo é à escolha da função $PI(q)$. Ela deve balancear a exploração de áreas pouco densas e muito densas

PASSEIO ALEATÓRIO ADAPTATIVO (ARW)

- ◉ É de questionamento único.
- ◉ Ênfase no tempo de execução.
- ◉ Utiliza um passeio aleatório para explorar o espaço de configurações livres até que a última amostra gerada possa ser conectada ao ponto de destino por meio de um planejador local.

Algoritmo 8 ARW simples.

Require: Configurações inicial e final.

Ensure: Lista que contém a rota ligando $q_{\text{início}}$ a q_{fim} .

- 1: $k \leftarrow 0$
 - 2: $q_k \leftarrow q_{\text{início}}$
 - 3: Inicia a matriz de covariâncias Σ_0 com Σ_{min}
 - 4: **enquanto não** planejador_local(q_k, q_{fim}) **faí** $\frac{1}{2}\mathbf{a}$
 - 5: Gera uma nova configuração aleatória $v_k \in N(0, \Sigma_k)$
 - 6: $s \leftarrow q_k + v_k$
 - 7: **se** planejador_local(q_k, s) **então**
 - 8: $k \leftarrow k+1$
 - 9: $q_k \leftarrow s$
 - 10: Atualiza a matriz de covariâncias Σ_k usando a Eq. (1.20)
 - 11: Insere q_k na lista de configurações intermediárias
 - 12: **fim se**
 - 13: **fim enquanto**
-

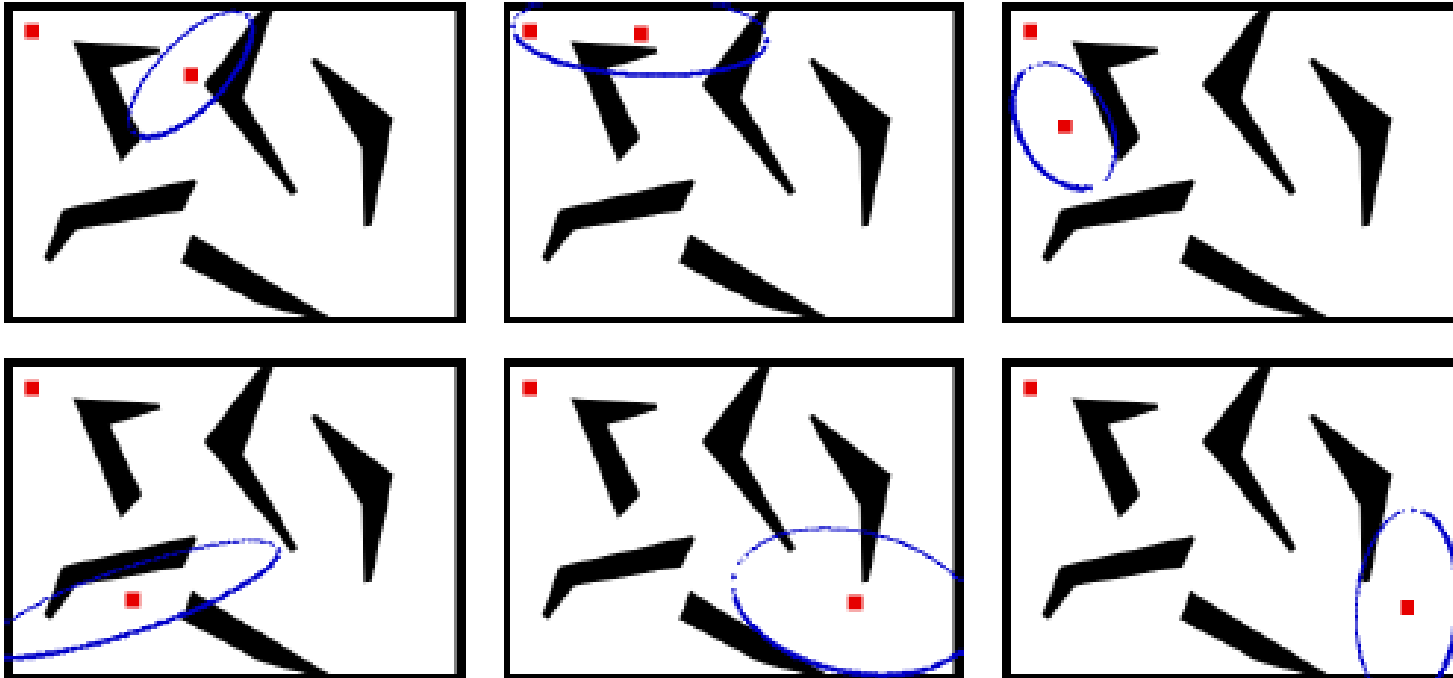


Figura 1.16: xxx

VANTAGENS DO ARW

- ◉ Sua implementação é a mais simples dentre os quatro algoritmos.
- ◉ Por não fazer busca de configurações vizinhas mais próximas, o custo de gerar uma nova amostra também é muito baixo.
- ◉ Se adapta à estrutura do espaço de configurações para gerar uma nova amostra.
- ◉ A amostragem é polarizada em C_{livre} .

DESVANTAGEM DO ARW

- ◉ Já a maior desvantagem do ARW é que a rota resultante possui uma péssima qualidade, com muitas sinuosidades e ciclos desnecessários.

SUAVIZAÇÃO DE ROTAS

- ◉ Dividir para conquistar
- ◉ Utilização de atalhos e remoção de ciclos


DIVIDIR PARA CONQUISTAR

Algoritmo 9 dividir_para_conquistar


Require: $q_{\text{início}}$, q_{fim} e a lista contendo a rota a ser suavizada

Ensure: Lista que contém a rota suavizada


- 1: **se** ($q_{\text{início}} = q_{\text{fim}}$) **ou** ($q_{\text{início}+1} = q_{\text{fim}}$) **então**
 - 2: **return** {A rota não pode mais ser dividida, então interrompe esta execução.}
 - 3: **senão se** planejador_local($q_{\text{início}}, q_{\text{fim}}$) **então**
 - 4: remove_nós_intervalo($q_{\text{início}+1}, q_{\text{fim}-1}$)
 - 5: **senão**
 - 6: {Faz chamadas recursivas ao algoritmo dividir_para_conquistar}
 - 7: dividir_para_conquistar($q_{\text{início}}, q_{\frac{\text{início}+\text{fim}}{2}}$)
 - 8: dividir_para_conquistar($q_{\frac{\text{início}+\text{fim}}{2}+1}, q_{\text{fim}}$)
 - 9: **fim se**
 - 10: **return** Rota suavizada
-




(a)



(b)



(c)



(d)

Figura 1.17: Algumas chamadas ao algoritmo `dividir_para_conquistar`. (a) Rota original. (b) Primeira chamada. (c) Segunda chamada. (d) Quarta chamada.

UTILIZAÇÃO DE ATALHOS E REMOÇÃO DE CICLOS

Algoritmo 10 remoção_de_ciclos

Require: $q_{\text{início}}$, q_{fim} e lista com a rota a ser suavizada

Ensure: Lista que contém a rota suavizada

```
1: para  $q_i \leftarrow q_{\text{início}}$  até  $q_{\text{fim}-1}$  faça  $\frac{1}{2}a$ 
2:   para  $q_j \leftarrow q_{\text{fim}}$  até  $q_{i+1}$  faça  $\frac{1}{2}a$ 
3:     se planejador_local( $q_i$ ,  $q_j$ ) então
4:       remove_nós_intervalo( $q_{i+1}$ ,  $q_{j-1}$ )
5:        $q_i \leftarrow q_j$ 
6:       Interrompe o laço mais interno da linha 2
7:     fim se
8:   fim para
9: fim para
```
