

Plánování pohybu – postupy založené na vzorkování (obsah)

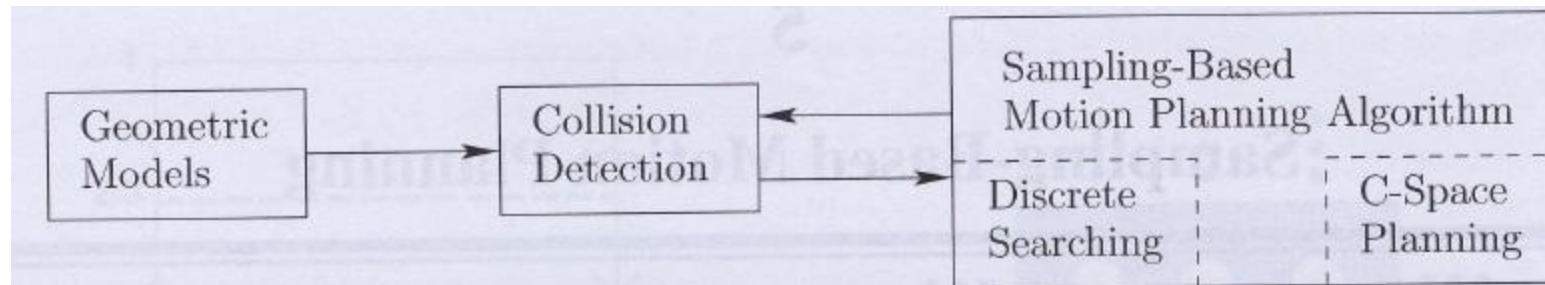
- Plánování - proč metody založené na vzorkování? Filosofie postupu.
- Vlastnosti vzorkovacích postupů pro plánování, srovnání s kombinatorickými postupy, souvislost s konfiguračním prostorem (*C-space*).
- Vzdálenost, metrika, pseudometrika a „hustota“ vzorkovaného prostoru
- Druhy vzorkování, hodnocení náhodnosti výběru vzorku
- Detekce kolizí, hierarchické a inkrementální postupy
- Inkrementální plánování a hledání plánů
- Souvislost s diskretním plánováním

- Metoda cest užitím vzorkování
- Náhodná procházka, randomizovaný potenciál
- Metoda rychle rostoucích stromů, princip a varianty (*RDT a RRT*).

- Reference

Proč vzorkovací postupy (Sampling-Based) plánování?

- Hlavní motivací je obejít nezbytnost rekonstrukce překážek v prostředí (reprezentováno C_{obst}) a nahradit jí vhodným vzorkovacím mechanismem (který následně poskytne lokální potřebnou informaci pro plánování)
 - Vzorkovací postupy nevžadují pro svoji činnost nezbytně existenci úplného modelu prostředí (ale mohou při její znalosti pracovat dobře)
 - Způsob odběru vzorků z konfiguračního prostoru (C -space) de facto realizuje funkcionalitu „předcházení srážkám“, čímž metodě poskytuje potřebnou informaci k rozhodování o dalším vytváření plánu



Vzorkovací postupy plánování používají collision avoidance jako „černou skříňku“ oddávající vlastní plánování od daného geometrického a kinematického modelu situace. Na základě získaných vzorků je prováděno diskrétní plánování.

Vzorkovací postupy plánování – vlastnosti I

- Všechny algoritmy sampling-based plánování jsou *neúplné*, tj. negarantují vlastnost, že existující řešení úlohy je nalezeno v konečném čase (což je naopak vlastnost kombinatorických postupů)
- Nicméně, přijatelného výsledku může být splněno nalezením *přibližného řešení* - to umožňuje existence vlastnosti tzv. „hustoty vzorků“ (*denseness*), jejíž význam je, že jednotlivé vzorky se neomezeně blíží k libovolné konfiguraci, jestliže počet vzorků $\rightarrow \infty$.
- Při deterministickém pohledu (systematické prohledávání) a dostatečně hustém vzorkování (*densely complete*) tedy nastávají alternativy:
 1. Existuje-li přijatelné řešení, je nalezeno v konečném čase.
 2. Při neexistujícím řešení i přes provádění „hustého“ vzorkování algoritmus nikdy nezkončí
- Předchozí implikuje tzv. *pravděpodobnostně úplné* (*probabilistically complete*) algoritmy, což značí, že při dostatečném počtu vzorků je pravděpodobnost, že bude nalezeno (přijatelné) řešení, se blíží $\rightarrow 1$.
- Problémem ale zůstává rychlost konvergence, jejíž zajištění je obtížné... Proto, čím „lépe“ dokážu vzorkovat, tím rychlejší dosáhnou konvergence a méně vzorků musím zpracovat k dosažení přijatelného řešení

Vzorkovací postupy plánování – vlastnosti II

- Sampling-based algoritmy mohou být tzv. s jedním- nebo více- požadavky.
 - Jeden požadavek je reprezentován zadáním párem (*start*, *cíl*), přičemž se očekává, že algoritmus bude pracovat až do dosažení cíle (nebo ohlásí chybu)
 - Postupy schopné zpracovat více požadavků, tj. dodat najednou řešení pro více párů (*start*, *cíl*), investují značné úsilí do fáze předzpracování, tj. vytváření datových struktur, schopných následně jednoduchým výpočtem dodat vícero řešení (při předpokladu neměnných omezení pracovního prostoru - překážek).

Vzdálenost a metrika I

- Veškeré sampling-based postupy vyžadují funkci, která měří vzdálenost mezi dvěma body prostoru → metriku

Def.: metrický prostor (X, ρ) s metrikou (vzdáleností) $\rho: X \times X \rightarrow R$ splňující pro libovolná $a, b, c \in X$ následující axiomy:

1. $\rho(a, b) \geq 0$ (nezáporná vzdálenost)
2. $\rho(a, b) = 0$ tehdy a jen tehdy, když $a=b$ (vzdálenost od sebe samého je nulová, reflexivita)
3. $\rho(a, b) = \rho(b, a)$ (symetrie)
4. $\rho(a, b) + \rho(b, c) \geq \rho(a, c)$ (trojúhelníková nerovnost)

- Nejčastější tzv. L_p -metriky na R^n mají metriku:
$$\rho(a, b) = \left(\sum_{i=1}^n |a_i - b_i|^p \right)^{1/p}$$
 1. L_1 metrika – tzv. Městská, Manhattan, ortogonální.... (pravoúhlá vzdálenost, součet rozdílů souřadnic)
 2. L_2 metrika – Euklidovská metrika (Euklidovská vzdálenost v R^n)
 3. L_∞ metrika – Maximum metrika
$$L_\infty(a, b) = \max_{1 \leq i \leq n} \{|a_i - b_i|\}$$

Vzdálenost a metrika II

- Další metriky pro plánování pohybu v robotice:

1. Metrika komplexních čísel je vhodná pro libovolný C-space, jenž je podmnožinou R^2 , takovou, že:

$$\{(a, b) \in R^2; a^2 + b^2 = 1\} \quad \rho(a_1, b_1, a_2, b_2) = \sqrt{(a_1 - a_2)^2 + (b_1 - b_2)^2}$$

2. Předchozí metrika neuvažuje vzdálenost podél kružnic, což může být žádoucí \rightarrow *metrika úhlů*, prostým uvažováním úhlů Θ_1 a Θ_2 (s ohledem na dosažitelnost Θ_2 z Θ_1 dvěma možnými směry)

$$\rho(\Theta_1, \Theta_2) = \min\{|\Theta_1 - \Theta_2|, 2\pi - |\Theta_1 - \Theta_2|\}$$

Nebo v komplexním oboru (vyjádření bodu je: $a+jb$):

$$\rho(a_1, b_1, a_2, b_2) = \cos^{-1}(a_1 a_2 + b_1 b_2)$$

- Pseudometrika – konstrukce hodnotící funkce / funkce „vzdálenosti“ je taková, že nezajišťuje splnění všech axiomů 1.-4. ale přesto je schopná udat směr pohybu robotu k cíli.

Příklady:

- Vyhodnocování *úspěšnosti* na základě spotřebované energie nemusí splnit podmínku symetrie (při kinematických omezeních nelze couvat)
- *Potenciální funkce* (viz použití potenciálního pole k plánování, odpudivé složky potenciálu mohou generovat lokální extrém, a porušují typicky podmínku trojúhelníkové nerovnosti)

Vzorkování prostoru I – hustota vzorkování

- Náhodné vzorkování/posloupnosti jsou „pravděpodobnostně husté“, čímž garantuje podmínku použitelnosti pro plánovací postupy:
 - Tedy pro interval délky e je při provádění náhodného výběru k vzorků přes celý prostor je pravděpodobnost, že žádný ze vzorků nepadne do tohoto intervalu je $(1-e)^k$.
 - Jestliže $k \rightarrow \infty$, jde hodnota $(1-e)^k \rightarrow 0$, což značí že interval e za těchto podmínek pravděpodobně obsahuje aspoň jeden vzorek, tedy taková nekonečná posloupnost náhodně a nezávisle vybraných vzorků je „hustá s pravděpodobností =1“ (což nemá význam garance; pravděpodobnost výběru určitých konkrétních vzorků je sice nulová ale přesto je jejich výběr možný)
- Náhodné vzorkování – nejjednodušší postup, je velmi vhodné pro C-space neboť lze vzorky vybírat „po souřadnicích“, tj, nezávisle pro jednotlivé dimenze prostoru a přesto dosahuje rovnoměrně náhodné rozložení pokrytí prostoru (daleko složitější je pokrytí kartézského prostoru pro deterministické metody)
- Generování (pseudo)náhodných čísel. Počítačové implementace nejsou korektně plně náhodné!

Klasický lineární kongruenční generátor (pro a , M nesoudělná a c takové, že: $0 \leq c < M$, M pokud možno $\gg 1$)

$$y_{i+1} = ay_i + c \text{ mod } M$$

Kde pseudonáhodná čísla x_i z intervalu $[0,1]$ lze obdržet jako: $x_i = y_i / M$ a jsou periodická.

Vzorkování prostoru II - jak testovat/hodnotit míru náhodnosti vzorkování?

- Počítačem realizované vzorkování je přes svoji „náhodnost“ do jisté míry deterministické → potřeba hodnocení uniformity/náhodnosti odebraných vzorků.
- Nejjednodušším je *Chi-kvadrát* test, který ověřuje, jak vzdálená je vypočtená statistika od očekávané.

Příklad:

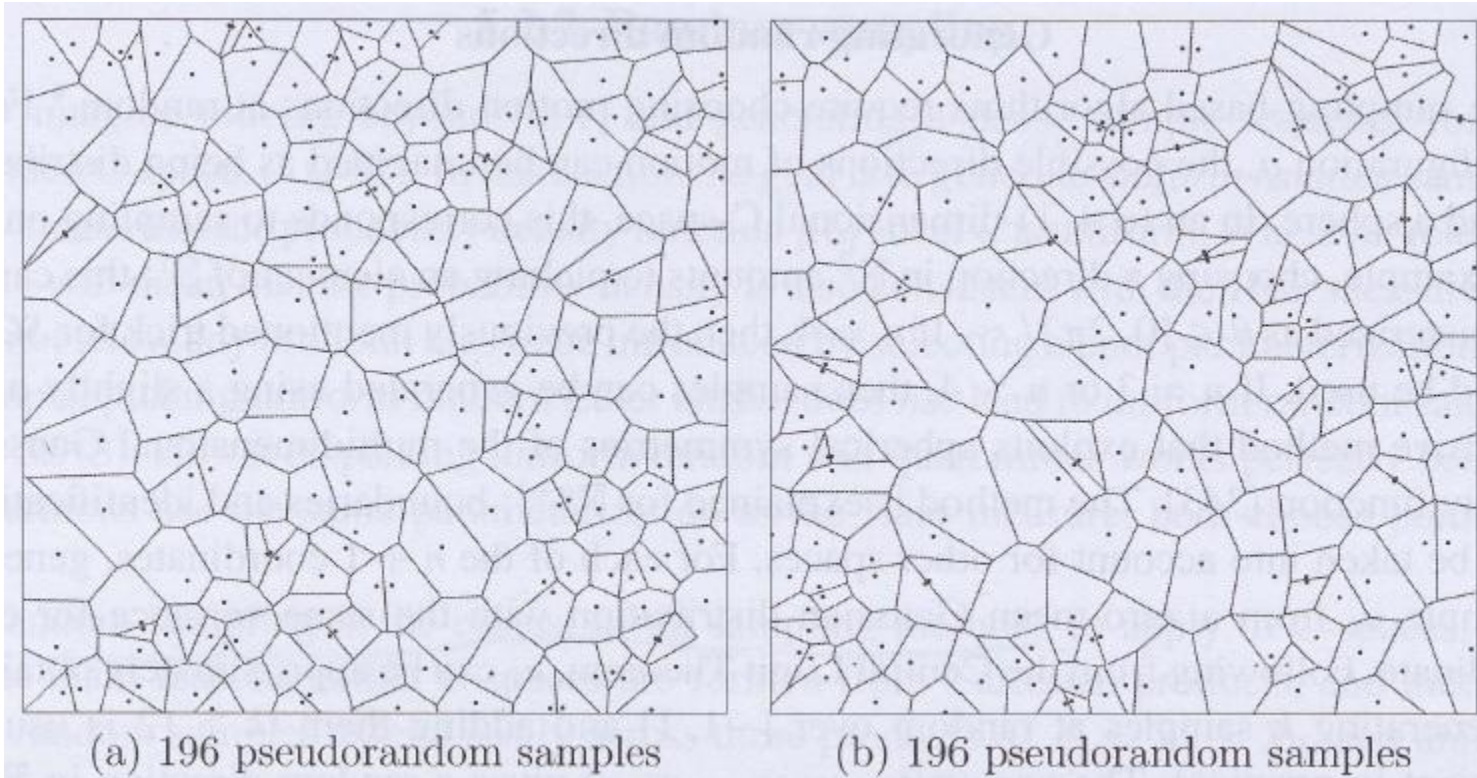
Pracovní prostor necht' je diskretizován na $n \times n$ pixelů. Je-li množina P reprezentující k náhodně vybraných vzorků, každý pixel by intuitivně měl obsahovat k/n^2 vzorků. To umožní zavést chybovou funkci, reprezentující míru s jakou je předchozí předpoklad správný:

$$e(P) = \sum_{i=1}^{n^2} (b_i - k/n^2)^2$$

Kde b značí počet vzorků v pixelu i (chybová funkce $e(P)$ reprezentuje Chi-kvadrát rozložení náhodné proměnné). Hodnota $e(P) = 0$ má význam dokonalé uniformity rozdělení vzorků, tj. nejsou náhodné. Obecně hodnota musí být $e(P) \gg 0$ (statist. tabulky).

- Hodnocení užitím Voroného diagramů – každý vzorek má přiřazenou Voroného oblast $Vor(x)$. Pro každý bod $y \in Vor(x)$, je x nejbližším vzorkem k y při použití Euklidovské metriky. Hodnotí se diverzita velikosti a tvaru Voroného oblastí.

Vzorkování prostoru III



Příklad sad 196ti pseudonáodných vzorků, pro zviditelnění náhodnosti jsou doplněny Voroného oblasti.

Vzorkování prostoru IV – pseudonáhodné vzorkování

- Odběr vzorků podle Van der Corputovy posloupnosti
 Založeno na principu binárního kódování délky intervalu a jeho následné modifikaci půlením binární reprezentace a prohozením (swap) bitů významově nižší a vyšší části. Má vlastnost, že každá otevřená podmnožina (z hlediska kvantizace intervalu binárním vyjádřením, obsahuje aspoň jeden vzorek).

i	Naive Sequence	Binary	Reverse Binary	Van der Corput	Points in $[0, 1] / \sim$
1	0	.0000	.0000	0	
2	1/16	.0001	.1000	1/2	
3	1/8	.0010	.0100	1/4	
4	3/16	.0011	.1100	3/4	
5	1/4	.0100	.0010	1/8	
6	5/16	.0101	.1010	5/8	
7	3/8	.0110	.0110	3/8	
8	7/16	.0111	.1110	7/8	
9	1/2	.1000	.0001	1/16	
10	9/16	.1001	.1001	9/16	
11	5/8	.1010	.0101	5/16	
12	11/16	.1011	.1101	13/16	
13	3/4	.1100	.0011	3/16	
14	13/16	.1101	.1011	11/16	
15	7/8	.1110	.0111	7/16	
16	15/16	.1111	.1111	15/16	

Detekce kolizí

- Detekce kolizí je klíčovou součástí plánování s využitím vzorkování
- Určením místění vzorku je třeba rozhodnout, zda-li vzorek koliduje s prostředím a zda-li je možné jej dále využít pro vytvářený plán.
- Detekce kolizí je často řešena jako „černá skříňka“ a postačí, že poskytuje správná hodnocení kolizích situací (neboť nemá přímou vazbu k plánovacímu postupu). Nicméně její výpočetní náročnost může být velmi vysoká a ovlivní tak negativně činnost plánovače.
- Existuje množství postupů pro detekci kolizí (exaktní a heuristické)...
- Nejčastěji používanými jsou postupy založené na ověřování platnosti vhodné podmínky vzhledem k $\mathcal{C}_{obst...}$ (kterou nejčastěji bývá test na přítomnost daného vzorku v modelu překážek). Výstupem je rozhodnutí, je-li vzorek (konfigurace) kolizní, či nikoliv (logická hodnota)
- V případě 2D světa s konvexními překážkami a robotem je odpovídající algoritmus lineárně náročný. Nicméně, pokud lze, vždy je výpočetně nejjednodušší určit, zda-li je konfigurace kolizní bez nutnosti úplné konstrukce \mathcal{C}_{obst} (model překážek/prostředí).

Detekce kolizí II

- Určování kolizí využívá výpočet *vzdálenosti d mezi dvěma množinami*, $d: \mathcal{C} \rightarrow \langle 0, \infty \rangle$, jenž odpovídá nejmenší vzdálenosti v existujících párech bodů e a f mezi danými množinami E a F :


$$\rho(E, F) = \min_{e \in E} \{ \min_{f \in F} \{ \|e - f\| \} \}$$

kde $\| \cdot \|$ značí Euklidovskou normu a současně platí: $E \cap F = \emptyset \Rightarrow \rho(E, F) = 0$

- Ke zjednodušení výpočtu a úspoře výpočetního času se často detekce kolizí provádí ve 2 stupních, přibližně (na velkou vzdálenost) a přesně (v blízkém okolí):
 - **Přibližná detekce kolizí** – vyšetření vzájemné polohy (konvexních) obalů objektů a robotu, krajních bodů jim opsaných oken, atd. plus využití hashování ke snížení počtu možných kolizních kombinací
 - **Blízká detekce kolizí** – provádí se detailně na úrovni jednotlivých bodů objektů a robotu – hierarchické a inkrementální postupy - viz dále.

Hierarchické postupy I

- Vhodné pro určování vzájemné kolize nebodových objektů (překážka v prostředí a robot).
- Postup provede dekompozici každého objektu na jeho základní primitiva (např. trojúhelníkovou dekompozicí) a uspořádá ji do *stromové struktury*, kde:
 - Každý vrchol ve stromu se váže na oblast ohraničující jeho část (podmnožinu).
 - Kořenový vrchol reprezentuje celý objekt
- Volba způsobu dekompozice je řízena 2-ma protichůdnými požadavky:
 - Ohraničující oblast přiléhá k objektu co možná nejtěsněji
 - Postup k testování průniku takových dvojic oblastí musí být co nejjednodušší



Různé druhy ohraničujících oblastí: (a) kruhová sféra, (b) ohraničující pravoúhelník podle souřadných os, (c) orientovaný pravoúhelník, (d) konvexní obal

Hierarchické postupy II

- Konstrukce stromu probíhá od shora dolů, tj. ohraničující oblast je vždy dělena na dceřiné oblasti o přibližně shodné velikosti (ploše). Jestliže model objektu je složen z primitiv (např. trojúhelníků) je dělení prováděno k dosažení shodného počtu primitiv v každém potomkovi.
- Dělení probíhá až k dosažení elementárních tvarů částí objektu, které je jednoduché testovat na kolize.



Kruhová sféra definuje vrchol, popisující celý objekt. Po rozdělení (přerušovaná čára), 2 menší kruhy reprezentují popis jednotlivých polovin (2 vrcholy na nižší úrovni)

Hierarchické postupy III

- Postup detekce kolize ve stromě:
 1. Mějme objekty E a F s jim odpovídajícími stromy T_e a T_f , jejichž možnou kolizi zkoumáme
 2. Jestliže kořenové vrcholy T_e a T_f nekolidují, oba objekty E a F **nejsou v kolizní situaci** → **konec**.
 3. Jestliže kořenové vrcholy T_e a T_f kolidují, pak ohraničující oblasti všech potomků T_e jsou porovnány s oblastí T_f .
 4. Jestliže žádné z předchozích v bodě 3 nekolidují, ohraničující oblast T_f je nahrazena všemi oblastmi jeho bezprostředních potomků.
 5. Postup rekurzivně pokračuje na bod 2, pokud nebylo dosaženo koncových vrcholů (listů stromu), jinak se oba původní **objekty nalézají v kolizní situaci** → **konec**.

Pozn1.: Pokud byla dekompozice provedena na primitiva (trojúhelníky), pak je testování na kolizi prováděno vzájemně mezi jednotlivými primitivy.


Pozn2.: Doplnění algoritmu o výpočet skutečné vzdálenosti ohraničujících oblastí umožní další prořezávání stromu → zrychlení výpočtu.

Inkrementální postupy I

- *Postup incremental distance computation* – předpokládá, že mezi dvěma požadavky na detekci kolizí nedojde k podstatné změně scény (objekty se přemístí jen málo).
- **Výhoda:** Předchozí předpoklad umožní dosáhnout téměř konstantního času výpočtu pro objekty typu konvexní mnohostrany. Nekonvexní objekty lze vždy dekomponovat na konvexní.
- **Nevýhoda:** Modely objektů/robotů musí být koherentní, tj. všechna jejich primitiva musí bezvadně navazovat, objekty musí být uzavřené... (nepřipouští se výskyt izolovaných segmentů hranic/stěn, těles s chybějící stranou/stěnou pro 2D, resp. 3D situace, model objektů nesmí být prostá sada primitiv) → náročné na předzpracování dat.

Inkrementální postupy II

- Princip detekce kolizí výpočtem na základě vzájemných relací popisů (příznaků) objektů (2D situace)
 - Každý objekt - polygon s n vrcholy je popsán $2n$ příznaky (vrcholy plus strany), jimž odpovídají Voroného oblasti – viz obr.



- Pro každý pár objektů s potenciálním výskytem kolize nastávají výhradně tyto kombinace:
 - *vrchol-vrchol*, kdy oba body z nejbližšího páru jsou vrcholy polygonu
 - *hrana-vrchol*, jeden z nejbližších bodů leží na hraně a druhý je ve vrcholu
 - *hrana-hrana*, oba nejbližší body leží na hranách (hrany jsou paralelní)

Pro něž je možné provést snadno výpočet vzdálenosti obou objektů (množin)

Inkrementální vzorkování a hledání plánu I

- Algoritmy s unikátním zadáním (single query) mají dānu jedinou dvojici start, cíl: (q_s, q_g) pro každý robot a sadu překāžek (model)
 - není třeba činit předběžné výpočty struktur pro plánování s více cíli
 - plánování pohybu lze pojmout jako úlohu *prohledávání s následujícími odlišnostmi, kdy:*
 - Realizace “akce” jej nahrazena generováním „segmentu cesty“ (viz. bod 3 následujícího alg.)
 - Prohledávaný graf je neorientovaný s hranami reprezentujícími cesty (oproti orientovanému grafu s hranami reprezentujícími akce)
- Základní postup – algoritmus plánování cesty s unikátním zadáním
 1. **Inicilalizace.** Mějme $G(V,E)$ reprezentující neorientovaný graf, který je tvořen nejméně jedním vrcholem V , přičemž E neobsahuje žádnou hranu. Typicky, V obsahuje *start* a/nebo *cíl* a případně další body volného prostoru C_{free} .
 2. **Výběr vrcholu.** (Vertex Selection Method, VSM) Zvolte k expanzi vrchol q_{cur}
 3. **Lokální plánování.** (Local Planning Method, LPM) Pro vhodný nový q_{new} , který nemusí nutně být z existující množiny vrcholů V , *se pokuste nalézt cestu z q_{cur} do q_{new} takovou, aby nezpůsobila kolizi.* Pokud tento krok selže, při hledání kolizeproště cesty, jdi na krok 2. Jinak pokračuj.

Inkrementální vzorkování a hledání plánu II

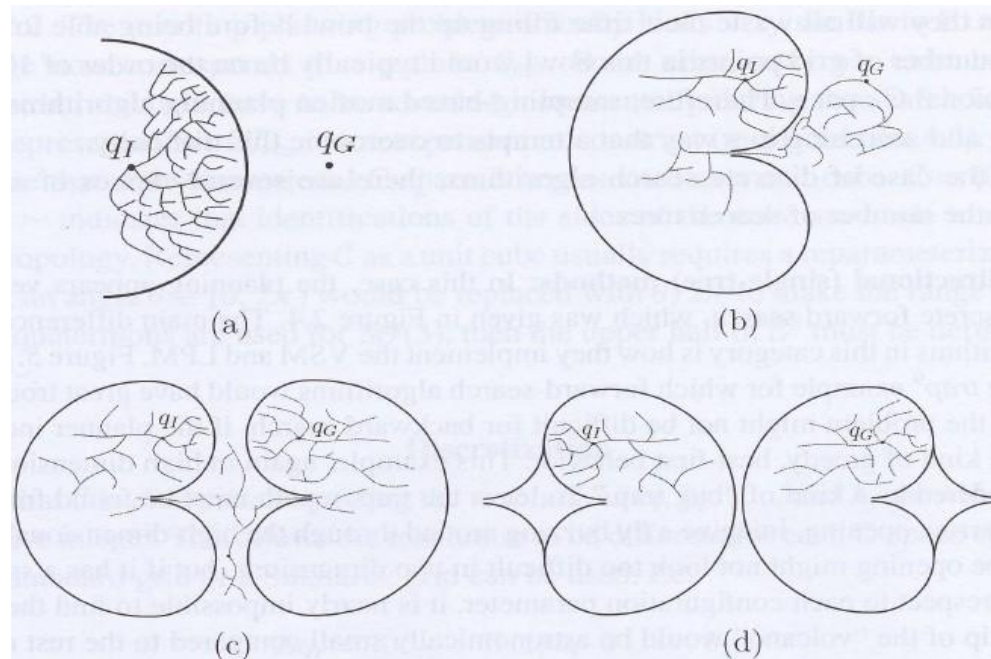
- Základní postup – algoritmus plánování cesty s unikátním zadáním (pokračování)
 4. **Vložení hrany do grafu.** Pokud je q_{new} dosud není prvkem E , vložte do množiny E v předchozím bodě nalezenou cestu (úsek cesty) jako hranu q_{cur} do q_{new} .
 5. **Bylo dosaženo řešení?** Ověřte, zda-li graf G již reprezentuje výslednou požadovanou cestu, řešení? (Krok je jednoduchý v diskrétních případech, kdy existuje jediný prohledávací strom, jinak může být jeho řešení složité a výpočetně náročné)
 6. **Návrat na krok 2.** Iterujte předchozí dokud není dosaženo řešení nebo není splněna vhodná ukončující podmínka (algoritmus může v určitých situacích pracovat neomezeně, viz. předchozí)

Pozn. Výše užitý graf G je topologickým grafem, někdy též označovaným jako *graf cest (roadmap)*.

Inkrementální vzorkování a hledání plánu III

- V případech nepříznivé konfigurace překážek existuje možnost uvíznutí metody („bug-trap“ situace postup obtížně umísťuje vzorky do některých lokalit → vede ke zpomalení řešení, či úplnému uvíznutí)
- K řešení může být využita kombinace odlišných postupů prohledávání (LPM):
 - Jednosměrné prohledávání – expanze stromu hledání od počátku k cíli.
 - Dvousměrné prohledávání – narůstání 2 stromů prohledávání proti sobě, od počátku i cíle (většinou řeší bug-trap situace)
 - Mnohosemrové prohledávání – narůstání více prohledávacích stromů z různých lokalit scény (většinou řeší dougltle bug-trap konfigurace)

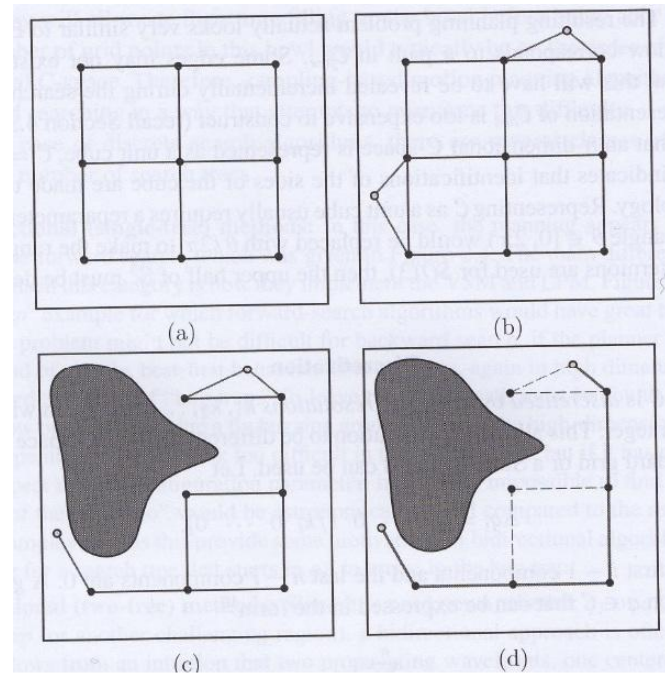
Obtížné situace pro sampling-based plánovací postupy: (a) přednostní prohledávání prostoru v dutině, (b) bug-trap konfigurace s obtížným průnikem ven z oblasti, (c) dvojitá bug-trap vyžaduje mnohosemrové prohledávání s počátkem i mimo oblasti, (d) téměř neřešitelná situace...



Souvislost s diskretním určováním plánu

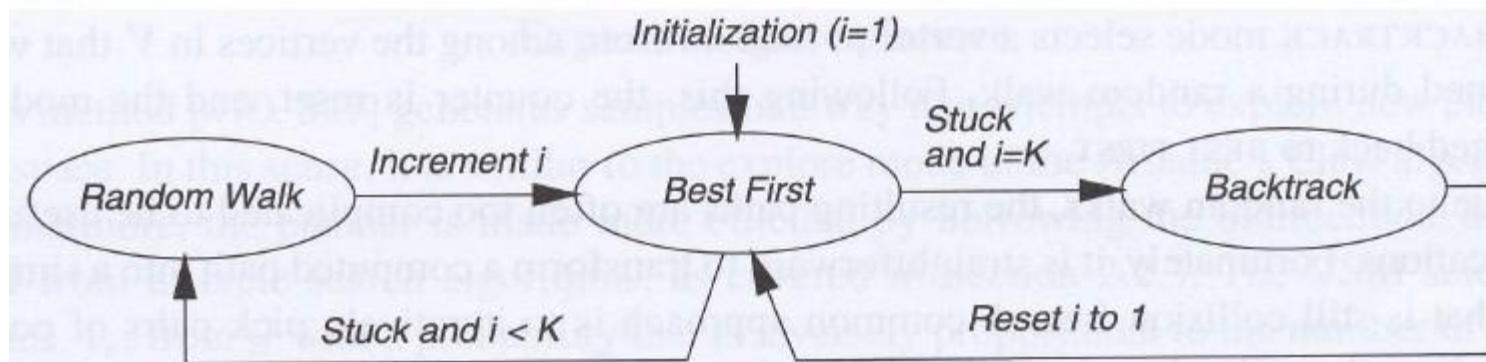
- Plánování s užitím vzorkovacích postupů je možné kombinovat s postupy pro diskretní hledání plánů.
 - Přináší značné zrychlení výpočtu plánu apriorním omezením prohledávacího prostoru, např. definováním mřížky nad konfiguračním prostorem \mathcal{C} , resp. příslušným topologickým grafem - grafem cest.
 - Uzlové body je nutné vhodně zvolit s ohledem na pokrytí prostoru.
 - Nad redukovaným prostorem lze spustit vzorkovací postup, který nalézá řešení v několika málo krocích.

Topologický graf (graf cest) může být zkonstruován během prohledávání prostoru. Vrcholů, v nichž navazují cesty je nižší počet, což umožní nalézt řešení výběrem z mála vzorků poměrně rychleji.



Náhodná procházka a randomizovaný potenciál

- Srovnání náhodných a systematických postupů:
 - Náhodné postupy (random walk) strádají v případech výskytu nevhodných struktur v prostředí (obtížnost nalezení průchodu - viz předchozí „nálevkovité objekty“)
 - Systematické (neinformované) postupy prohledávání stavového prostoru jsou výpočetně náročné (např. 10 dimenzí, 50 vzorků/dimenze $\rightarrow 50^{10}$ alternativ)
 - Obtížná implementace informovaných postupů \rightarrow použití pseudometriky (potenciálové pole) je obtížné k výpočtu a/nebo negarantuje neexistenci dalších extrémů (jiných, než cíle).
- Předchozí nedostatky lze obejít kombinací předchozího – informovaného náhodného prohledávání, kritériem přepínání postupů je „stav uvíznutí“ v lokálním extrému a/nebo počet provedených kroků jedním postupem, viz.:




Rapidly Exploring Dense Trees (RDT) I

- Inkrementální vzorkovací/plánovací postup, který dosahuje dobrých výsledků bez nutnosti nastavování jakýchkoliv parametrů.
 - **Idea:** Postupná konstrukce prohledávacího stromu, který průběžně zvyšuje rozlišení (a nevyžaduje nastavování jakýchkoliv parametrů, které se vztahují k řízení rozlišení). Ve výsledku je chopen postupně pokrýt celý pracovní prostor „hustě“.
 - Konstrukce hustého stromu je deterministická nebo náhodná (RDT), spec. případem jsou *Rapidly Exploring Random Trees (RRT)*.


Algoritmus konstrukce hustého stromu:

```


SIMPLE_RDT( $q_0$ )
1   $\mathcal{G}.init(q_0);$ 
2  for  $i = 1$  to  $k$  do
3     $\mathcal{G}.add\_vertex(\alpha(i));$ 
4     $q_n \leftarrow NEAREST(S(\mathcal{G}), \alpha(i));$ 
5     $\mathcal{G}.add\_edge(q_n, \alpha(i));$ 
  
```



Funkce *NEAREST* určuje nejbližší vrchol dosud existujícího stromu $S(\mathcal{G})$ k nově vygenerovanému vrcholu $\alpha(i)$; s každým novým vrcholem vznikne ve stromě 1 (*nejbližším je vrchol*) nebo 2 (*nejbližším je hrana* → *půlení existující hrany*) nové hrany.



Rapidly Exploring Dense Trees (RDT) II



Chování RDT: v počátečních iteracích rychle dosahuje dosud nenavštívené oblasti, následně pak zpřesňuje pokrytí (v limitním případě zajistí husté pokrytí s pravděpodobností 1)

Rapidly Exploring Dense Trees (RDT) III


- Reprezentace C_{obs} v RDT je řešena ve fázi generování stromu \rightarrow definicí koncové podmínky na „dosažení nejbližšího bodu u hranice objektu“ ve směru generovaného vrcholu $\alpha(i)$, nejbližší bod q_n je definován shodně (bez ohledu na existenci překážky) a jemu příslušná nová hrana je pouze do q_s , viz. obr. :

Algoritmus RDT pro situaci s překážkami:

```

RDT( $q_0$ )
1   $\mathcal{G}.init(q_0)$ ;
2  for  $i = 1$  to  $k$  do
3     $q_n \leftarrow \text{NEAREST}(S, \alpha(i))$ ;
4     $q_s \leftarrow \text{STOPPING-CONFIGURATION}(q_n, \alpha(i))$ ;
5    if  $q_s \neq q_n$  then
6       $\mathcal{G}.add\_vertex(q_s)$ ;
7       $\mathcal{G}.add\_edge(q_n, q_s)$ ;


```




- Nejmenší přípustná vzdálenost bodu q_s od skutečné hranice překážky je dána užitým algoritmem pro collision avoidance; v některých případech malé vzdálenosti q_n od překážky nemusí být hrana $q_n q_s$ vůbec generována.

Rapidly Exploring Dense Trees (RDT) IV

- Realizace funkce *NEAREST* (hledání nejbližšího bodu ve stromě) – dva alternativní postupy:
 - Exaktní řešení:** Založeno na hierarchické přístupu. Výpočet vzdálenosti nového vrcholu $\alpha(i)$ od větví stromu, získaných v ranných fázích jeho generování (hlavní větve) poskytne přibližnou informaci, která část stromu nese kandidáty na nejbližší bod. Výpočet postupy vektorového počtu je lineárně náročný.
 - Následně je hodnota *NEAREST* iterativně zpřeňována až k libovolné požadované přesnosti.



- Přibližné řešení:** Je založeno na převzorkování stromu. Do jednotlivých hran stromu jsou vloženy další přidavné vrcholy tak, že každá po sobě jdoucí dvojice vrcholů není vzdálena navzájem ne více než zvolené Δq . Ostatní vnitřní body hran jsou zanedbány a výpočet vzdálenosti je proveden mezi $\alpha(i)$ a všemi vrcholy stromu.
- Přesnost výpočtu je dána zvolenou vzdáleností vrcholů.



Reference:

- LaValle, S. M.: Planning Algorithms, Cambridge University Press, U.S.A, 2006, 826 pp.
ISBN 0-521-86205-1