

## Lokalizacja, mapowanie i eksploracja

- \* Określ pozę robota mobilnego.
- \* Wyjaśnij różnicę między lokalizacją, mapowaniem i eksploracją.
- \* Zdefiniuj każdy wyraz w:  $bel(x_{t-1}) = f(bel(x_{t-1}), u_t, z_t, m)$ .
- \* Omów różnicę między algorytmami lokalizacji Markowa, rozszerzonego filtra Kalmana (EKF), opartych na siatce i Monte Carlo.
- \* Opisz różnicę między lokalizacją a jednoczesną lokalizacją i mapowaniem (SLAM).
- \* Zdefiniuj problem zamknięcia pętli.
- \* Opisz różnicę między mapami cyfrowymi danych wysokościowego terenu (DTED), mapami cyfrowego modelu wysokościowego (DEM), cyfrowymi mapami powierzchniowymi (DSM) i obrazem ortomozaiki.
- \* Podaj przynajmniej jeden przykład dwóch rodzajów metod identyfikacji proprioceptywnej i eksteroceptywnej oraz omów ograniczenia każdej z nich.
- \* Wymień i wyjaśnij pięć atrybutów przejezdności: pionowość, właściwości powierzchni, krętość, nasilenie przeszkód i elementy dostępności.
- \* Porównaj i porównaj eksplorację w oparciu o granice i uogólnione wykresy Voronoi (GVG).

## Przegląd

Poprzednie części dotyczyły dwóch z czterech podstawowych pytań dotyczących nawigacji: Dokąd zmierzam? lub problem z planowaniem misji i Jaka jest najlepsza droga? lub problem planowania ścieżki. Pozostają jeszcze dwa pytania: Gdzie jestem? lub problem z lokalizacją i Gdzie byłem? lub problem z mapowaniem. Ta część obejmie lokalizację i mapowanie oraz algorytmy dla powiązanego tematu eksploracji. Pozornie lokalizacja i mapowanie wydają się być problemami, które zostały rozwiązane. Osoby niezaznajomione z robotyką AI często pytają: Dlaczego jest to problem? Nie możesz po prostu użyć GPS, jakiegoś rodzaju beaconów RFID lub skanów 3D z czujników RGB-D? Rzeczywiście GPS zapewnia dokładne informacje o pozycji na zewnątrz, a środowiska wewnętrzne mogą być zaprojektowane za pomocą RFID lub innych mechanizmów do śledzenia robota. Te mechanizmy śledzenia robota różnią się od tych, które mapują świat wzdłuż tego toru. Generalnie mapa zawiera więcej informacji o szerszym kontekście niż tylko lokalizacja robota. „Mapa” kopalni może oznaczać cyfrową mapę wysokościową, której można użyć do określenia, w jaki sposób usunięto materiał. „Mapa” budynku biurowego może oznaczać plan piętra 2D, który pokazuje wszystkie drzwi i wyjścia w celu przygotowania do ewakuacji w nagłych wypadkach. „Mapa” podwodnej części mostu może zawierać model 3D pali i dna morskiego. Robotycy zadają bardziej szczegółowe pytania. Po pierwsze: jak możesz jednocześnie mapować świat i mieć pewność, gdzie jesteś? Innymi słowy, jakie są konkretne techniki tworzenia mapy świata pomimo wszelkich błędów popełnionych podczas poruszania się. Kolejne pytanie brzmi: jak skutecznie lub przynajmniej konsekwentnie odkrywać nowe obszary? Bardziej subtelne pytanie dotyczące sztucznej inteligencji brzmi: Jak oznaczyć mapę obiektami i cechami lub terenem? Rozdział zaczyna się od lokalizacji jako pierwszego kroku w mapowaniu. Następnie przechodzi do technik jednoczesnej lokalizacji i mapowania, czyli SLAM. SLAM był używany głównie w budynkach lub strukturach miejskich lub wokół nich; dlatego osobna sekcja poświęcona jest mapowaniu zewnętrznemu. Jeden aspekt mapowania na zewnątrz dotyczy ogólnie zrozumienia map terenu a priori, a inny aspekt dotyczy generowania map terenu. Obie umiejętności są niezbędne do

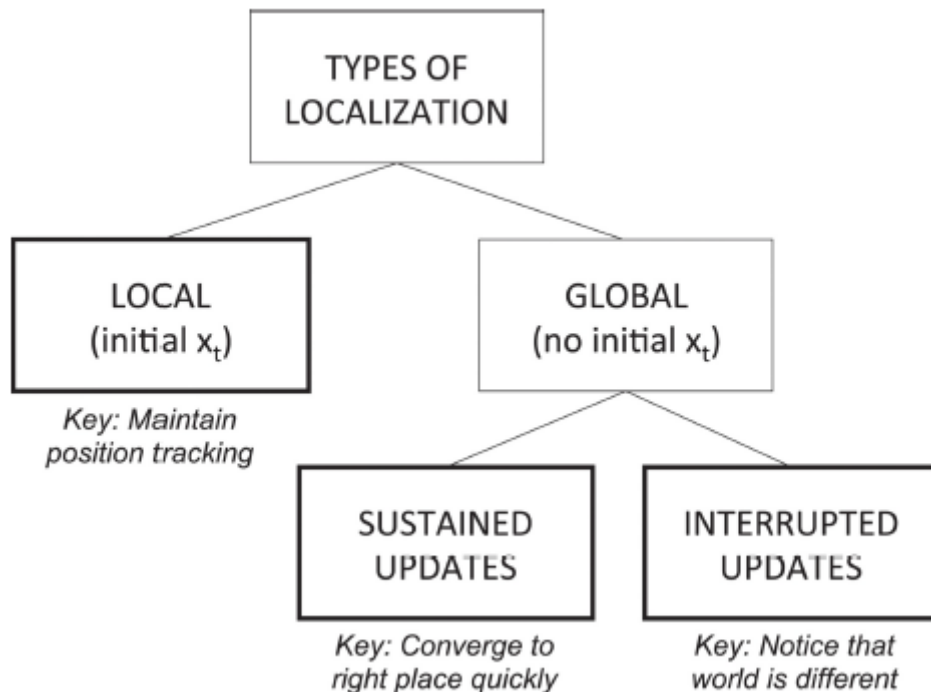
nawigacji na zewnątrz. Inny aspekt mapowania zewnętrznego, na przykład w zastosowaniach geoprzestrzennych lub rolniczych, opiera się na stereofotogrametrii. W robotyce naziemnej mapowanie służy do planowania ścieżek lub reagowania na przeszkody. Sukces robota zależy od tego, czy świat jest przejezdny. Tak więc poświęcimy się temu tematowi. Następnie omawiamy pragmatykę eksploracji nieznanego. Część dotyczy lokalizacji, mapowania i eksploracji tematów związanych ze sztuczną inteligencją, zwłaszcza wiedzy o świecie semantycznym, zanim zakończy się ponownym omówieniem często zadawanych pytań.

## **LOKALIZACJA**

### **POZA**

Thrun, Burgard i Fox definiują lokalizację robota mobilnego jako „problem określenia pozycji robota względem danej mapy otoczenia”. Przypomnij sobie, że poza robota to jego pozycja plus jego orientacja. Dla dwóch wymiarów poza jest  $x = (x, y, \theta)$ . Lokalizacja robota mobilnego jest czasami nazywana szacowaniem pozycji, ale ponieważ orientacja robota jest ważna w większości przypadków, lokalizacja jest pojęciem pełniejszym. Zauważ, że lokalizacja zakłada, że istnieje mapa a priori i robot lokalizuje się względem niej. Lokalizacja jest trudna z wielu powodów opisanych poniżej. Aby problem był jeszcze trudniejszy, istnieją trzy ogólne typy lokalizacji. Każdy z typów wykorzystuje inną klasę algorytmów, które zostaną szczegółowo opisane w kolejnych rozdziałach. Thrun, Burgard i Fox podają listę powodów, dla których lokalizacja jest trudna:

- \* Wymaga modelu, który zawiera siłowniki robota, jego czujniki oraz dokładność i powtarzalność tych czujników w różnych środowiskach.
- \* Mogą występować szumy czujnika, zarówno proprioceptywne, jak i eksteroceptywne, które wprowadzają niepewność.
- \* Metody lokalizacji są kosztowne obliczeniowo.
- \* W przypadku niektórych problemów z lokalizacją robot może nie znać swojej początkowej pozycji. \* Robot może działać w dynamicznej przestrzeni roboczej, w której poruszają się obiekty, co powoduje, że robot musi rozważyć, czy odczyty czujnika są wynikiem ruchu robota, czy też poruszania się obiektu A.
- \* Ścieżka lub zadanie może nie obsługiwać lokalizacji. Na przykład, jeśli robot porusza się po dużym, otwartym magazynie bez cech charakterystycznych, może nie być w stanie wykryć żadnych cech, na których mógłby się zlokalizować. Istnieją trzy rodzaje problemów z lokalizacją, które mają inny charakter. Rysunek pokazuje relację między tymi trzema.



W lokalizacji lokalnej robot zaczyna się od początkowego  $x_t$ , być może wyraźnie wprowadzonego na początku misji, a wyzwaniem jest utrzymanie lokalizacji od tego momentu. Generalnie lokalizacja lokalna polega na śledzeniu pozycji i orientacji robota. Problem globalnej lokalizacji występuje, gdy robot nie ma początkowego  $x_t$ . Niezależnie od tego, dlaczego robot nie ma początkowego  $x_t$ , problem jest dalej podzielony na to, czy robot może liczyć na ciągłe aktualizacje czujników, czy te aktualizacje mogą zostać przerwane. Przykładem przerwanej aktualizacji jest wyłączenie robota i przeniesienie go do innej części budynku bez wyraźnego resetowania robota w miejscu, w którym się teraz znajduje; jest to żartobliwie określane jako problem „porwanego robota”. W globalnym problemie lokalizacji z ciągłymi aktualizacjami celem jest stworzenie algorytmów, które pozwolą robotowi szybko zbliżyć się do jego prawdziwej lokalizacji. W przypadku globalnego problemu z przerwanymi aktualizacjami, wyzwaniem dla robota jest zauważenie, że świat się zmienił i w wyniku tej zmiany powinien ponownie uruchomić lokalizację globalną, zamiast zaakceptować błędną lokalizację. Te trzy rodzaje problemów lokalizacyjnych to nie to samo, co algorytmy lokalizacyjne. Algorytmy lokalizacji są wariantami algorytmów filtra Bayesa, które wykorzystują bayesowskie metody probabilistyczne do oszacowania prawdopodobnej lokalizacji. Algorytmy te zazwyczaj są klasyfikowane według ich podejścia - lokalizacji lub lokalizują się, dopasowując surowe odczyty czujnika (lokalizacja ikoniczna). Algorytmy w ramach kategorii mogą być używane do dowolnego z trzech problemów lokalizacyjnych, chociaż niektóre algorytmy są bardziej odpowiednie dla określonych typów. W praktyce lokalizacje dominują metody Monte Carlo, zarówno w przypadku danych wejściowych opartych na cechach, jak i ikonicznych.

### **Lokalizacja oparta na funkcjach**

Lokalizacja oparta na funkcjach wyodrębnia cechy z surowych danych i dopasowuje te cechy do mapy. Tymi elementami mogą być narożniki, ściany, drzwi lub cokolwiek, co można jednocześnie dostrzec i zidentyfikować na mapie. Zaletą lokalizacji opartej na funkcjach jest to, że dzieli świat na mały zestaw funkcji, a zatem dopasowanie wykrytych obiektów do odpowiadających im obiektów na mapie powinno zająć mniej czasu. Wadą jest to, że trudno jest wiarygodnie wyodrębnić funkcje.

### **LOKALIZACJA MARKOWA**

Najpopularniejszą lokalizacją opartą na funkcjach jest lokalizacja Markowa. Lokalizacja Markowa oblicza wiarę w każdą z możliwych pozycji, przy czym najwyższe przekonanie jest najbardziej prawdopodobną pozycją. Wiara jest funkcją,

$$\text{bel}(x_t) = f(\text{bel}(x_{t-1}), u_t, z_t, m)$$

gdzie

$x$ : jest zbiorem możliwych pozycji; w praktyce przestrzeń może być dyskretyzowana

$\text{bel}(x_t)$ : jest przekonaniem, że robot jest w  $x$  w czasie  $t$

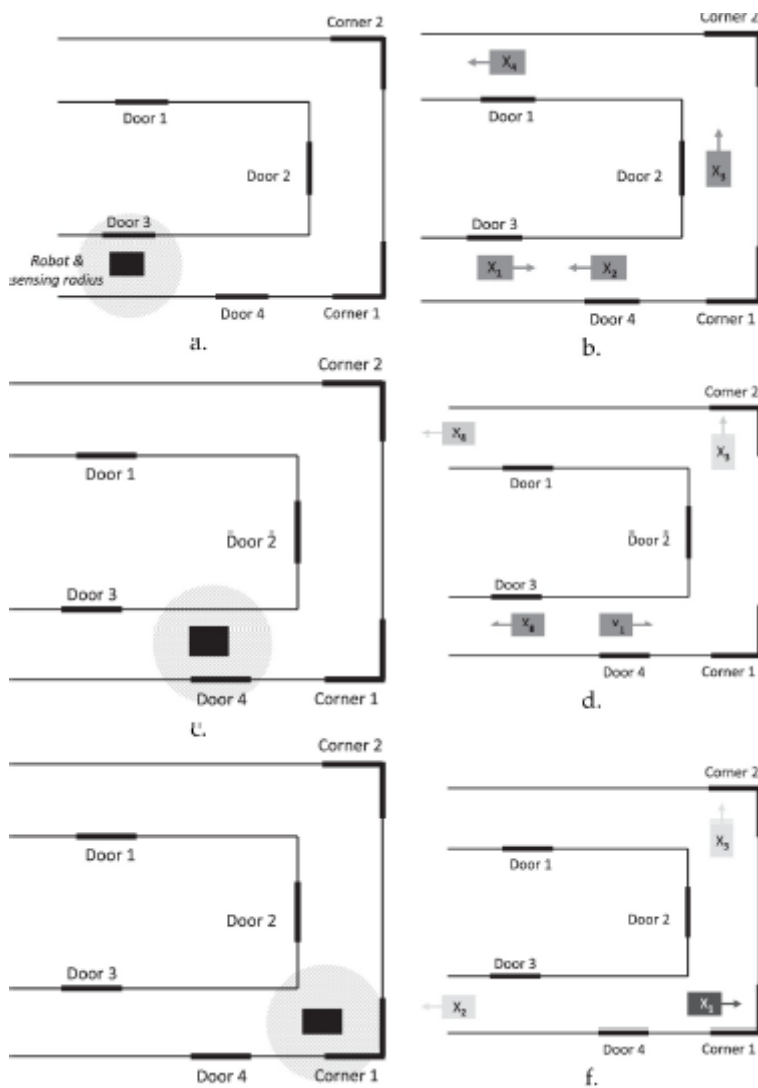
$\text{bel}(x_{t-1})$ : to przekonanie, że robot był w  $x_{t-1}$  w poprzednim kroku czasowym

$u_t$ : czy zestaw czynności kontrolnych lub jakie ruchy ma wykonać robot w czasie  $t$

$z_t$ : to zbiór pomiarów, czyli to, co robot zaobserwował w czasie  $t$

$m$ : to mapa

Lokalizacja Markowa jest atrakcyjna dla globalnych problemów lokalizacyjnych, ponieważ powinna dość szybko zbiegać się do właściwej pozycji. Aby to skonceptualizować, rozważmy rysunek.



Robot startuje w nieznanym położeniu,  $x_{t1}$ . Po lewej stronie może obserwować drzwi  $z_{t1}$ , które może dopasować do mapy  $m$  (rysunek a). Daje to  $bel(x)$ , gdzie  $x$  jest zbiorem czterech równie prawdopodobnych pozycji, pokazanych na rysunku b. Robot porusza się do przodu,  $u_{t2}$  i aktualizuje wykrywanie  $z_{t2}$ . Teraz widzi drzwi po swojej prawej stronie (rysunek c). Dopasowanie tej cechy do mapy daje dwie wysoce prawdopodobne pozycje i dwie mniej prawdopodobne pozycje, pokazane na rysunku d. Wiara w  $x_3$  może nie spaść do zera z powodu niepewności czujnika. Robot porusza się do przodu i ponownie aktualizuje detekcję i może teraz wykryć Narożnik 1. Przekonanie, że robot jest w  $x_1$  w  $t_3$  wzrasta, podczas gdy  $bel(x_2)$  maleje, a  $bel(x_4)$  może wynosić zero.  $bel(x_3)$  mógł wzrosnąć, ponieważ możliwe jest wykrycie drzwi po lewej i rogu, a nie wykrycie drzwi po prawej stronie.

### **ROZSZERZONY FILTR KALMANA (EKF)**

Rozszerzony filtr Kalmana (EKF) jest często używany do lokalnej lokalizacji. Algorytmy EKF mają na celu przewidywanie, co robot wyczuje w następnym kroku czasowym, biorąc pod uwagę działanie sterowania. Następnie bierze różnicę między przewidywaniem a tym, co faktycznie wyczuło, aby poprawić lub dostroić swoje szacunki. Na przykład robot może dryfować nieco w lewo zamiast poruszać się prosto do przodu, a EKF w końcu się do tego dostosuje. W tym przypadku EKF wyodrębniłby zestaw obserwacji dotyczących cech, które dostrzegł,  $z$ . Następnie dopasowywałby te cechy do mapy; cechy te nazywane są zmiennymi korespondencyjnymi. Im dokładniej robot może dostroić swoje przewidywania dotyczące tego, jak się porusza, tym pewniej może zlokalizować swoją pozycję w stosunku do cech.

### **Ikoniczna lokalizacja**

Lokalizacja ikoniczna wykorzystuje nieprzetworzone odczyty czujnika, aby dopasować rzeczywiste obserwacje do oczekiwanych obserwacji, jeśli robot znajdował się w określonej lokalizacji. W poprzednim przykładzie lokalizacji Markowa robot pasował tylko do sześciu funkcji, czterech drzwi i dwóch narożników. Mogą istnieć setki odczytów czujników z samego LIDARU, co stanowi ogromne wyzwanie obliczeniowe. Istnieją dwie popularne metody lokalizacji: metody oparte na siatce i lokalizacja Monte Carlo.

### **LOKALIZACJA W OPARCIU O SIATKĘ**

W lokalizacji opartej na siatce wyczuwany świat jest podzielony na teselację wielokątów wypukłych. Algorytm następnie oblicza prawdopodobieństwo wszystkich możliwych położeni w każdym wielokącie, biorąc pod uwagę obserwację. Zaletą jest to, że siatka działa w celu zmniejszenia złożoności obliczeniowej poprzez dyskretyzację przestrzeni. W praktyce algorytmy lokalizacji oparte na siatce często dodatkowo zmniejszają złożoność, ograniczając dopasowanie do lokalnej „mapy podrzędnej”. Wadą jest to, że podejście podmapy działa tylko w przypadku lokalizacji lokalnej, w której robot zawsze wie, w jakim ogólnym regionie mapy się znajduje.

### **LOKALIZACJA MONTE CARLO (MCL)**

Lokalizacja Monte Carlo (MCL) jest podobna do metod Monte Carlo dla RTT i innych aplikacji. Częsteczki lub przykładowe pozycje są rozproszone w przestrzeni. Następnie algorytm oblicza przekonanie, że robot znajduje się w pozycji, biorąc pod uwagę obserwacje. W następnym kroku czasowym dodawane są kolejne cząstki, a niektóre cząstki „giną”, jeśli mają małe prawdopodobieństwo. Z technicznego punktu widzenia lokalizacja Monte Carlo nie jest ograniczona do stosowania z surowymi obserwacjami czujnika, ale zwykle jest używana w ten sposób.

### **Środowiska statyczne i dynamiczne**

## **POWIĘKSZENIE STANU**

### **ODRZUCENIE WYJĄTKOWE**

Do tej pory lokalizację opisywano tak, jakby świat był miejscem statycznym. Niestety robot może pracować na terenach zamieszkałych przez ludzi, gdzie ludzie poruszają się w sposób nieprzewidywalny lub na placach budowy lub kopalniach, gdzie zmienia się struktura otoczenia, a mapy nie są aktualne. Większość algorytmów psuje się z powodu dynamicznych zmian na świecie. Zmiany często przekraczają to, co może zniwelować szum czujnika. Skutecznie dodają również „stan ukryty” w procesie lokalizacji, reprezentujący oszacowanie tego, co robot powinien zaobserwować w następnym kroku czasowym. Istnieją dwie podstawowe techniki radzenia sobie z lokalizacją w dynamicznym środowisku: wzmacnianie stanu i odrzucanie wartości odstających. W augmentacji stanu celem jest ujawnienie stanu ukrytego, czyli oszacowanie wpływu ludzi na obserwacje. Przeprowadzono pewne badania nad wizją komputerową w szacowaniu przepływów tłumu. W przypadku odrzucania wartości odstających celem jest wykorzystanie wiedzy o czujnikach i środowisku w celu wyeliminowania podejrzanych odczytów. Na przykład robot może odrzucić odczyty z zaskakująco krótkiego zasięgu, które mogą dotyczyć ludzi, jeśli uzna, że znajduje się w szerokim korytarzu. Najgorsze, co mogłoby się wydarzyć po wyeliminowaniu wartości odstających, to to, że oszacowanie pozycji na podstawie pozostałych obserwacji zajęłoby więcej czasu. W bardzo zatłoczonym korytarzu robot może nie mieć wystarczających pomiarów, aby wzbudzić przekonanie.

### **Jednoczesna lokalizacja i mapowanie**

#### **MAPOWANIE**

#### **JEDNOCZESNA LOKALIZACJA I MAPOWANIE (SLAM)**

Mapowanie odpowiada na pytanie: Gdzie byłem? z reprezentacją środowiska. Mapowanie nieznanego środowiska oczywiście oznacza, że nie ma mapy, ale bez mapy a priori robot nie może się zlokalizować. Tak więc w praktyce mapowanie oznacza, że robot musi zbudować mapę i jednocześnie lokalizować się na tej mapie, gdy się przemieszcza; nazywa się to symultaniczną lokalizacją i mapowaniem (SLAM). Ogólnie rzecz biorąc, interesująca jest ścieżka, którą robot przebył przez świat. W idealnym przypadku robot obserwowałby świat (zt1), przesunąłby niewielką ilość (ut2) tak, aby następny zestaw obserwacji zt2 nachodził na zt1, wykorzystałby to nałożenie do połączenia zt1 i zt2 w mapę, a następnie zlokalizowałby się względem nowej mapy. Nowa mapa reprezentuje maksymalne prawdopodobieństwo świata, to znaczy mapa reprezentuje najwyższe prawdopodobieństwo tego, czym naprawdę jest świat. Problem polega na tym, że robot może nie poruszać się dokładnie zgodnie z oczekiwaniami, a zatem istnieje wiele możliwych pozycji, a tym samym wiele możliwych map.

#### **FILTROWANIE RAO-BLACKWELLIZED**

Filtrowanie Rao-Blackwellized jest dominującą metodą w SLAM do obliczania mapy największej prawdopodobieństwa. Podobnie jak w przypadku lokalizacji Monte Carlo, Rao-Blackwellized Filtering wykorzystuje filtrowanie cząstek. W tym przypadku każda cząstka reprezentuje ścieżkę i mapę lokalną, a nie tylko jedną wersję mapy. Po każdej obserwacji algorytm aktualizuje tylko wykryty obszar map i oblicza wiarę w każdą cząstkę, odrzucając mało prawdopodobne cząstki i zwiększając liczbę cząstek w obiecujących próbkach. Ciekawą uwagą obliczeniową jest to, że algorytm używa drzewa do zapisywania wszystkich cząstek, które tworzą historię bieżącego zestawu cząstek.

#### **ZAMKNIĘCIE PĘTLI**

SLAM jest ogólnie niezawodny w lokalnym regionie, ale możliwe jest, że mapa zawiera błędy w większym regionie. W rezultacie robot może obejść zestaw łączących się hal i, z powodu narastających błędów w mapowaniu, albo nie zdaje sobie sprawy, że powrócił do punktu początkowego, albo wytworzył mapę, która pokazuje fizyczne rozbieżności między początkiem mapy i końcem mapy; jest to zasadniczo ten sam problem, który został zgłoszony w przypadku odometrii. Dlatego należy zastosować dodatkową metodę, aby w razie potrzeby sprawdzić i dostosować mapę. Mechanizm, dzięki któremu robot zauważa, że powrócił do wcześniej odwiedzanego miejsca, nazywa się zamknięciem pętli. Ta metoda wymaga dodatkowego wykrywania większej liczby cech, innego czujnika lub kombinacji cech hybrydowych z czujnikiem lub dodatkowego przetwarzania statystycznego dopasowania oczekiwania. Na szczęście zamknięcie pętli zapewnia lepsze oszacowanie ścieżki, która będzie się rozchodzić do tyłu i poprawiać ogólną mapę i lokalizację.

Istnieją cztery główne podejścia do rozwiązania problemu zamykania pętli:

- \* **Dopasowanie funkcji:** Dopasuj cechy geometryczne na mapie. Proces ten jest podobny duchem do dopasowywania wyróżniających się miejsc do mapy topologicznej. Podobnie jak wyróżniające się miejsca, robot może napotkać problemy, jeśli otoczenie jest jednorodne, na przykład tylko narożniki i drzwi.

- \* **Dopasowanie skanowania czujnika:** czy skan czujnika pasuje do pełnego profilu obszaru? W tym podejściu, zamiast dopasowywać odczyty czujników tylko przed robotem lub w kierunku jazdy, robot okresowo uwzględnia wszystkie odczyty czujników i dopasowuje odczyty do większego obszaru. Dopasowanie skanowania czujnika może nadal generować błędy, jeśli środowisko jest jednorodne, ponieważ nie ma do czego dopasować.

- \* **Hybrydowe dopasowanie skanowania cech:** Czy widoczne cechy i odczyty zasięgu mają ten sam profil? Jest to lepsze rozwiązanie, ponieważ łączy odczyty czujników multimodalnych.

- \* **Dopasowanie oczekiwań:** czy statystycznie prawdopodobne jest, że robot powrócił do lokalizacji początkowej? Jest to mniej podatne na błędy i nie zależy od wielu modalności czujników, ale metoda ta jest kosztowna obliczeniowo.

## **Identyfikacja terenu i mapowanie**

Dyskusja na temat lokalizacji i mapowania dotyczyła ogólnie warunków wewnętrznych lub zewnętrznych w pobliżu struktur miejskich, takich jak pojazd naziemny mapujący miasto, gdzie teren jest uważany za poziomy i podatny na mobilność. Pojazd naziemny podróżujący w terenie lub wędrujący po planecie musi rozpoznać teren, ponieważ różnica między poziomą twardą powierzchnią a piaszczystą wydmą wpływa na jego mobilność. Bezzałogowy statek powietrzny mapujący hrabstwo lub prowincję w celu zidentyfikowania obszarów zagrożonych powodzią działa w innej skali w celu pomiaru wysokości terenu. Dlatego przydatne jest zrozumienie identyfikacji i mapowania terenu.

## **TEREN NATURALNY**

Nie ma dokładnej definicji terenu ani katalogu tego, jakie cechy terenu są ważne dla robota. Jednak armia amerykańska intensywnie badała teren, zwłaszcza w kontekście pojazdów naziemnych, takich jak czołgi, a ich praca służy jako podstawa do dyskusji na temat identyfikacji cech terenu. Armia amerykańska zakłada, że żołnierz jest w stanie zidentyfikować teren na podstawie mapy terenu. W taksonomii armii amerykańskiej 59 mapy terenu zawierają na ogół dwa rodzaje informacji: naturalny teren i obiekty stworzone przez człowieka. Istnieją cztery kluczowe atrybuty informacji o naturalnym terenie. Konfiguracja powierzchni reprezentuje ukształtowanie terenu, rzeźbę i nachylenie (lub nachylenie) terenu. Mapa terenu stara się również uchwycić elementy roślinności, takie jak drzewa lub

krzewy, elementy gleby i elementy wodne, które mają wpływ na nawigację. Przestrzeń zewnętrzna będzie również miała cechy stworzone przez człowieka. Obiekty stworzone przez człowieka mogą być tymi, które ułatwiają mobilność (autostrady, linie kolejowe, mosty itp.) lub mogą służyć jako funkcje do lokalizacji (lotniska, wieże komórkowe, punkty zainteresowania itp.).

### **CYFROWE DANE O WYSOKOŚCI TERENU (DTED)**

Robotycy na ogół mają dostęp do cyfrowych danych o ukształtowaniu terenu (DTED) lub map pokazujących ukształtowanie terenu. W USA są one produkowane przez Narodową Agencję Obrazowania i Mapowania (NIMA), a mapy mają pięć poziomów rozdzielczości. Mapy DTED 1 podają średnie wzniesienie dla fragmentów gruntu o powierzchni 100 metrów kwadratowych. Mapy DTED 2 są z rozdzielczością 30 m, DTED 3 z 10 m, DTED 4 z 3 m, a DTED 5 z 1 m. Niższe rozdzielczości 4 cm są teoretycznie możliwe przy danych zebranych z UAV lecących na niższych wysokościach. Cyfrowe mapy wysokości terenu są bardzo przydatne dla planistów misji lub kartografów, aby określić bezpieczną trasę dla robota naziemnego. Rozdzielczość 10 m × 10 m lub 30 m × 30 m jest zwykle wystarczająca do planowania ścieżki, szacowania czasu przejazdu oraz przewidywania przydatności mobilności i kosztów energii. Mapy DTED mogą umożliwić planistom misji pokierowanie robotem w taki sposób, aby pozostawał ukryty za linią grzbietu lub unikał pewnych funkcji stworzonych przez człowieka.

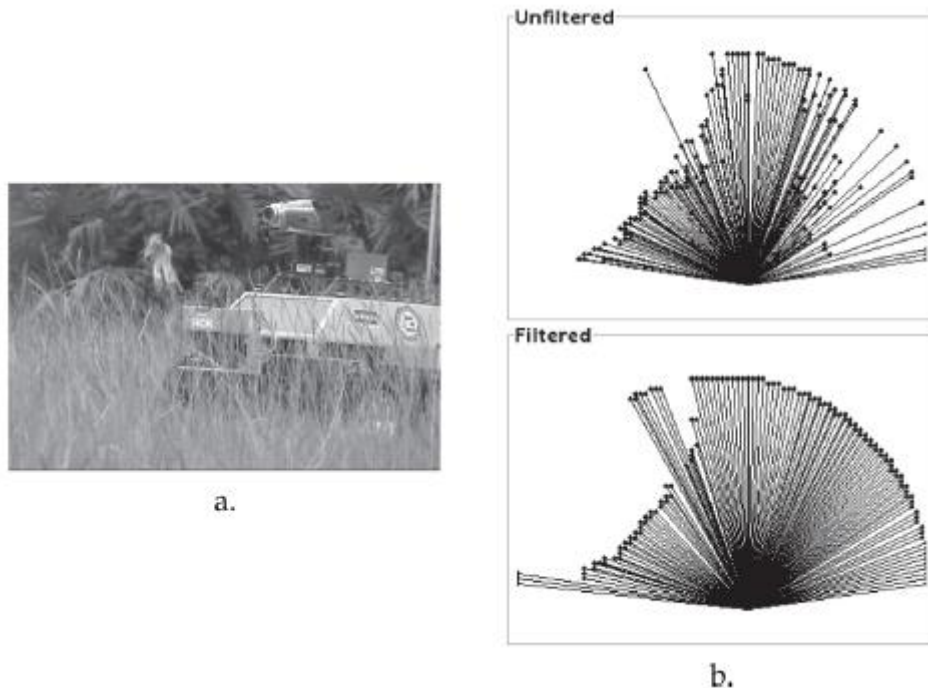
### **Identyfikacja terenu**

Cyfrowe mapy wysokości terenu nie są wystarczające do nawigacji, ponieważ nie pokazują lokalizacji drzew, dużych skał, śliskich błotnistych obszarów o niskiej przyczepności i tak dalej. Właściwości powierzchniowe wody, piasku i różnych gleb mogą wpływać na ruch. Liście mogą wydawać się przeszkodą, gdy zamiast tego można je bezpiecznie przejechać. Innym powodem, dla którego nie są one wystarczające do nawigacji, jest to, że mapy mogą być nieaktualne, a zatem nie odzwierciedlać prawdziwych warunków. Dlatego roboty potrzebują algorytmów do identyfikacji terenu, aby umożliwić robotowi przystosowanie się do otoczenia na cztery sposoby. Po pierwsze, wprowadzają zmiany sensomotoryczne, w których zmieniają się parametry lub wzmocnienia aktywnych zachowań, na przykład gdy klerometry zgłaszają nierówny ruch, spowalniają robota. Po drugie, wprowadzają schematyczne zmiany, w których zestaw aktywnych zachowań zmienia się w jakiś sposób, być może w celu zastąpienia innego czujnika, lepiej dostosowanego do nawigacji w roślinności. Po trzecie, dokonają przemysłanych zmian, na przykład uczenie maszynowe może zostać wykorzystane do powiązania, które zachowania i czujniki najlepiej sprawdzają się w obecnej sytuacji. Wreszcie identyfikacja terenu może zostać przekazana innym robotom, aby mogły zmienić i dostosować swoją strategię nawigacyjną. Informacje o terenie zazwyczaj pochodzą z jednego z trzech źródeł. Mapa terenu może być skonstruowana na podstawie zdjęć satelitarnych lub samolotów na dużych wysokościach i dostarczona do robota jako mapa a priori (np. mapa DTED), ale, jak wspomniano wcześniej, informacje te zwykle nie są wystarczające do bezpiecznej nawigacji. Robot może uzyskać nowsze lub aktualne informacje od innego robota, który bada obszar przed nim. Częściej robot może konstruować własną mapę terenu podczas poruszania się.

Wyzwaniem dla robotów poruszających się po złożonym terenie jest to, czy mają wbudowane czujniki do identyfikacji terenu. Korzystając z projekcyjnej identyfikacji terenu, robot może zidentyfikować teren, zanim faktycznie go przemierzy, podczas gdy reaktywna identyfikacja terenu jest wykonywana, gdy robot doświadcza terenu. Identyfikacja terenu projektu opiera się na czujnikach eksteroceptywnych, takich jak kamery, kamery wielospektralne i lidar, aby zobaczyć teren przed robotem. Badacze skupili się na wykorzystaniu kamer kolorowych, bo każdy robot będzie miał kamerę. Większość prac w zakresie wizji komputerowej dotyczących identyfikacji terenu obejmowała uczenie nadzorowane. Powszechnym podejściem od późnych lat 90. XX wieku jest wykrywanie zmian tekstury



na obrazach wielospektralnych, które oznaczają zmianę terenu. Lidar (czasami nazywany LADAR lub pisany jako LIDAR) może zwracać dokładne mapy głębokości i jest używany od początku 2000 roku. Wiele prac związanych z identyfikacją terenu zarzucono, ponieważ wyspecjalizowane czujniki były zbyt duże, zbyt ciężkie lub zbyt drogie do praktycznego zastosowania, ale identyfikacja terenu jest obecnie ponownie analizowana ze względu na postępy w miniaturyzacji czujników. Wszystkie metody eksteroeptywne nadal zmagają się z określeniem różnicy między skałą a wysoką trawą. Rozważ rysunek.



Robot naziemny traktował wysoką trawę jak przeszkodę. Niefiltrowany wykres z dalmierza laserowego SICK pokazuje, w jaki sposób źdźbła trawy po prawej stronie robota blokowały światło i zwracały krótkie odległości. Wykorzystanie tylko niefiltrowanych danych wykazało, że robot mógł poruszać się do przodu tylko przez wąską szczelinę w roślinności. Wysoka rozdzielczość lidara faktycznie utrudniła problem, ponieważ mógł dostrzec pojedyncze źdźbła wysokiej trawy. Jednak zastosowano wariant filtrowania mediany, aby zgłosić maksymalny odczyt w oknie odczytów, które były większe niż źdźbło trawy, co wyeliminowało cienkie profile wysokiej trawy. Reaktywna identyfikacja terenu opiera się na wykrywaniu proprioceptywnym w celu wywnioskowania terenu. Popularne metody wykorzystują inklinometr lub inny mechanizm do wykrywania nachylenia. Inna metoda nasłuchuje zmian we wzorze interakcji koła z terenem

### **Stereofotogrametria**

Poczyniono znaczne postępy w stereofotogrametrii, które umożliwiają tworzenie map podobnych do map ze zdjęć satelitarnych, ale o wyższej rozdzielczości, ze zdjęć wykonanych przez robota. Stereofotogrametria staje się powszechnie stosowana w przypadku małych bezzałogowych statków powietrznych, ale algorytmy sprawdzają się również w przypadku pojazdów naziemnych i morskich.

### **PRZEKSZTAŁCENIE FUNKCJI NIEZMIENNEJ SKALI (SIFT)**

„Stereo” w stereofotogrametrii odnosi się do używania obrazów tej samej lokalizacji, zrobionych z dwóch pozycji, a nie ze stereo kamery. Na obu obrazach musi znajdować się wystarczająca ilość tej samej lokalizacji, co nazywa się nakładaniem się obrazu, aby algorytm SIFT mógł znaleźć i dopasować

cechy na obu obrazach. Jeśli pozycja kamery jest znana dla każdego obrazu, na przykład współrzędne GPS, wysokość i kąt kamery na UAV, do wyodrębnienia odległości można użyć geometrii.

### **ORTOMOZAIKA**

Aby zrozumieć, w jaki sposób stereofotogrametria jest wykorzystywana w robotyce, należy podać pewne definicje. Termin ortomozaika zwykle odnosi się do obrazu wzorcowego o wysokiej rozdzielczości skompilowanego z wielu obrazów, które zostały ułożone razem, chociaż termin ten jest często używany jako synonim wszystkich produktów stereofotogrametrii. Rysunek 15.4 jest przykładem obrazu ortomozaiki.




### **CYFROWY MODEL ELEWACJI (DEM)**


Kolejnym produktem stereofotogrametrii jest mapa cyfrowego modelu terenu (DEM). DEM jest odpowiednikiem wojskowej mapy DTED i zwykle składa się z mapy siatek lub pikseli, gdzie każdy element siatki zawiera średnią lub maksymalną wysokość obszaru objętego elementem siatki. DEM są przydatne, ponieważ są niezależne od roślinności i pokrycia gruntu, a tym samym wychwytyją podstawową strukturę. Ponieważ są to cyfrowe trójwymiarowe reprezentacje, użytkownicy mogą wchodzić w interakcje z mapą tak, jak w grze wideo. Użytkownik może powiększać, obracać i przeglądać mapę. W wielu programach użytkownik może kliknąć piksel, aby uzyskać odczyt wysokości w tym punkcie. Mapa topograficzna jest podobna do DEM i przedstawia kontury terenu, zarówno naturalne, jak i stworzone przez człowieka, ale bez roślinności. Termin ten ogólnie odnosi się do mapy papierowej wykorzystującej dwuwymiarowe reprezentacje, takie jak koncentryczne linie przedstawiające skrawki ziemi o tej samej wysokości.

### **CYFROWE MAPY POWIERZCHNIOWE (DSM)**

Kolejnym produktem są cyfrowe mapy powierzchni (DSM). DSM to DEM, które obejmują roślinność i okrywą gruntową. W przeciwieństwie do modeli DEM, każdy piksel na mapie DSM ma wzniesienie najwyższej powierzchni, a nie ziemi, dla obszaru siatki. DSM są pokazane jako wzniesienie z nałożonymi obrazami ideowymi (patrz rysunek a) lub jako „naga” chmura punktów na rysunku b. Jednak DSM mogą nie mieć dokładności chmury punktów generowanej przez lidar lub inną formę bezpośredniego wykrywania zasięgu.



a.



System bezzałogowy może wykorzystywać stereofotogrametrię do wytwarzania DSM. Komercyjnie dostępne są pakiety oprogramowania dla UAV, które wytwarzają produkty fotogrametryczne na podstawie zdjęć ze znacznikami geograficznymi; oprogramowanie nie jest wykonywane w czasie rzeczywistym, ale raczej jako przetwarzanie końcowe partii obrazów. Rzeczywiście, wielu producentów UAV i aplikacji innych firm zapewnia planowanie toru lotu i skoordynowane algorytmy sterowania kamerami w celu optymalizacji zbierania obrazów. Jednak stereofotogrametria jest daleka od doskonałości. Jakość stereofotogrametrii w dużym stopniu zależy od zebranych danych. Niektóre ogólne zasady optymalizacji wyników mówią, że loty obszaru powinny być wykonywane możliwie najbliżej, aby zmiany w cieniach i jasności nie zmieniały cech. Loty około południa redukują cienie, a tym samym poprawiają produkt. Nie wszystkie sceny można pomyślnie przetworzyć. Na przykład obszary z bieżącą wodą często prowadzą do nieostrych rekonstrukcji. Wysokość jest spójna na mapie DSM (tj. współrzędne lokalne), ale mapa musi być zakotwiczona w pomierzonych punktach, aby wygenerować dokładne odczyty we współrzędnych bezwzględnych. Produkty stereofotogrametryczne obciążone są co najmniej czterema rodzajami błędów. Są to: zjawy, w których obiekt nakłada się na siebie, niewspółosiowość struktur, nieprawidłowe proporcje, w których struktury lub obiekty są nieproporcjonalne, oraz wirująca rozmycie nazwane efektem Dalego na cześć surrealistycznego stylu artysty Salvadora Dali. W przypadku zastosowań rolniczych błędy te mogą nie być znaczące, ale mogą stanowić poważny problem w przypadku kontroli strukturalnej.

### **Skala i przejeźdność**

Identyfikacja terenu jest tylko jednym z elementów większego problemu, czy dany region może przemierzać robot. Rozmiar i zawartość regionu, poza określeniem rodzaju terenu przed robotem, stwarzają również szanse i zagrożenia dla robota. Dlatego warto bardziej formalnie zastanowić się nad

rozmiarem robota w stosunku do jego zamierzonego środowiska lub skali i przejezdności środowiska, postępując zgodnie z metrykami. Obszar roboczy lub środowisko E dla robota składa się z jednego lub więcej regiony, a każdy region może mieć różne ograniczenia rozmiaru i unikalne cechy przejezdności. Na przykład robot naziemny badający zawalenie kopalni może być zmuszony do przejścia przez wąski, gładki, symetryczny odwiert (jeden region), a następnie wejść w błotniste dno kopalni pokryte gruzem (drugi region). Te dwa regiony sugerują różne ograniczenia mobilności, które należy połączyć w skuteczny system. Duży robot z łatwością poradziłby sobie z błotnistą podłogą i wspinał się po gruzach, ale nie mógł przejść przez otwór wiertniczy. Jako inny przykład, mały UAV może być w stanie latać w długich misjach na wysokościach powyżej linii drzew (region), ale wymaga dużej łąki, wolnej od drzew i zarośli do startu i lądowania (inny region niż niebo nad ziemią). Linie drzew). Podobnie ROV badający wrak statku musi być w stanie poruszać się na otwartej wodzie, ale także wewnątrz wraku.

## Skala

Zdolność robota do działania w środowisku zależy od względnej skali robota w porównaniu do środowiska - mały robot może pracować w mniejszych regionach niż duży robot. Wielkość robota lub środowiska można wyrazić jako wymiar charakterystyczny  $c_d$ . Charakterystycznym wymiarem robota naziemnego jest jego promień skrętu. W przypadku UAV jest to odległość, w której może bezpiecznie zawisnąć od obiektów lub jak blisko UAV może wygodnie latać w pobliżu przedmiotów. Charakterystycznym wymiarem środowiska jest przekrój najwęższego miejsca, przez które robot mógłby się poruszać. Gdyby robot miał wejść do rury, która stopniowo stawała się coraz mniejsza lub większa, charakterystycznym wymiarem byłby najmniejszy przekrój rury.

## TRZY SYSTEMY MOBILNOŚCI

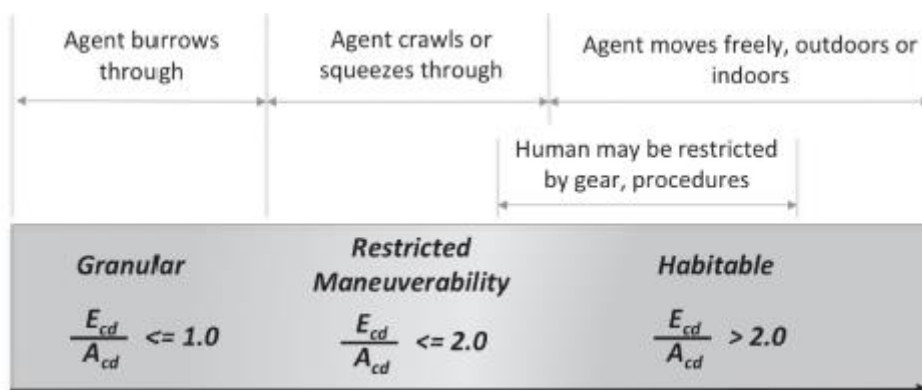
Stosunek charakterystycznego wymiaru środowiska  $E_{cd}$  do robota (lub człowieka lub psiego agenta)  $A_{cd}$  z grubsza dzieli środowiska na trzy reżimy mobilności:

$E_{cd}/A_{cd} < 2.0$  : zamieszkały reżim. W tym reżimie robot ma przestrzeń do swobodnego poruszania się. Robot naziemny może się zawrócić, zamiast cofać się i cofać. Mobilność może być zagrożona przez przejezdność, ale nie jest ona ograniczona wielkością regionu

$E_{cd}/A_{cd} \leq 2.0$  : ograniczony reżim manewrowości. W tym trybie robot może się poruszać, ale niekoniecznie obracać się w miejscu. Robot ma znacznie mniejszy margines błędów.

$E_{cd}/A_{cd} \leq 1.0$  : granularny reżim. Ten reżim przedstawia trudniejszy przypadek ograniczonej manewrowości, ponieważ robot zasadniczo zagłębia się w otoczenie i ma fizyczny kontakt z otoczeniem poza normalną mobilnością pojazdu

Rysunek



ilustruje trzy systemy. Należy pamiętać, że człowiek może normalnie poruszać się w obszarach, takich jak elektrownia jądrowa, które można by uznać za przestrzeń mieszkalną, ale gdy człowiek założy sprzęt ochronny, stosunek charakterystyczny do wymiarów może się zmienić i umieścić osobę w bliższej odległości od ściany, wyposażenie i tak dalej.


## Atrybuty przejezdności

### PRZEJAZD

Przejezdność to możliwość poruszania się po regionie. Na zdolność poruszania się dowolnego robota w regionie mają wpływ co najmniej cztery właściwości środowiska wymienione poniżej.

\* Pionowość. Pionowość to maksymalne nachylenie regionu. Robot oddziału bombowego, zaprojektowany do poruszania się poziomo po płaskich podłogach, może nie być w stanie zjechać w dół po ostrym spadku w zawalonym budynku. UAV rzadko zmieniają wysokość podczas nawigacji w pomieszczeniach.<sup>2</sup> Dlatego ważne jest, aby spekulować, czy region będzie wymagał od robota pionowego ruchu w górę lub w dół, a jeśli tak, to o ile.

\* Zakręt. Krętość jest miarą używaną przez biologów do analizy ruchów zwierzęcia; jest to liczba tur, które agent wykonuje w kierunku jednostki. Ścieżka o wysokiej krętości wskazuje, że zwierzę szuka lub jest często zdezorientowane. Środowisko o dużej krętości wskazuje, że robot będzie musiał być w stanie poruszać się po znaczących zakrętach.



\* Dotkliwość przeszkód. Dotkliwość przeszkód jest podobna do krętości. Jest to oszacowanie bałaganu lub ingerencji w przestrzeń. A priori mapa środowiska może sugerować, że ma on region o niskiej krętości, ale mapa może nie pokazywać lokalizacji mebli, roślinności lub skał, które zmniejszyłyby możliwości poruszania się robota naziemnego przez ten region. Teoretycznie bezzałogowy statek powietrzny może latać na nominalnej wysokości nad meblami i pod wiszącymi oprawami oświetleniowymi, ale w praktyce może wymagać odchylenia. W ten sposób może zetknąć się z przeszkodami, co może spowodować poważne uszkodzenie UAV.

\* Właściwości powierzchni. Środowisko będzie miało powierzchnie wpływające na mobilność. Na przykład pojazd gąsienicowy, który doskonale sprawdza się w zabłoconych wnętrzach betonowych rur kanalizacyjnych, może mieć problemy z grubą włochatą wykładziną.

\* Elementy ułatwień dostępu. Są to elementy architektoniczne, takie jak drzwi, okna, windy i schody, które łączą regiony. Problem napotkany podczas wypadku jądrowego w Fukushima Daiichi polegał na tym, że roboty naziemne zostały w dużej mierze zaprojektowane do użytku w jednym regionie zewnętrznym. Budynki wymagały od robotów wejścia do szeregu pokoi i korytarzy, przejścia przez drzwi oraz wchodzenia i schodzenia po schodach. Środowisko składało się z wielu regionów z trudnymi do poruszania się schodami lub trudnymi do otwarcia drzwiami.

Zwróć uwagę, że krętość, powaga przeszkód i elementy dostępności są funkcją skali robota w odniesieniu do otoczenia. Próg drzwi między pokojami, powszechny element dostępności, może być niemożliwie duży dla bardzo małego robota lub nieistotny dla dużego robota. Problemy z przejezdnością robota naziemnego obejmują również właściwości powierzchni, takie jak cechy gleby lub nawierzchnia. Pojazd morski musiałby również zmagać się z prądami, falami i prawdopodobnie wiatrem. UAV miałby również wiatr i czynniki, takie jak wilgotność, które wpłynęłyby na jego zdolność do poruszania się w regionie.

## **BADANIE**

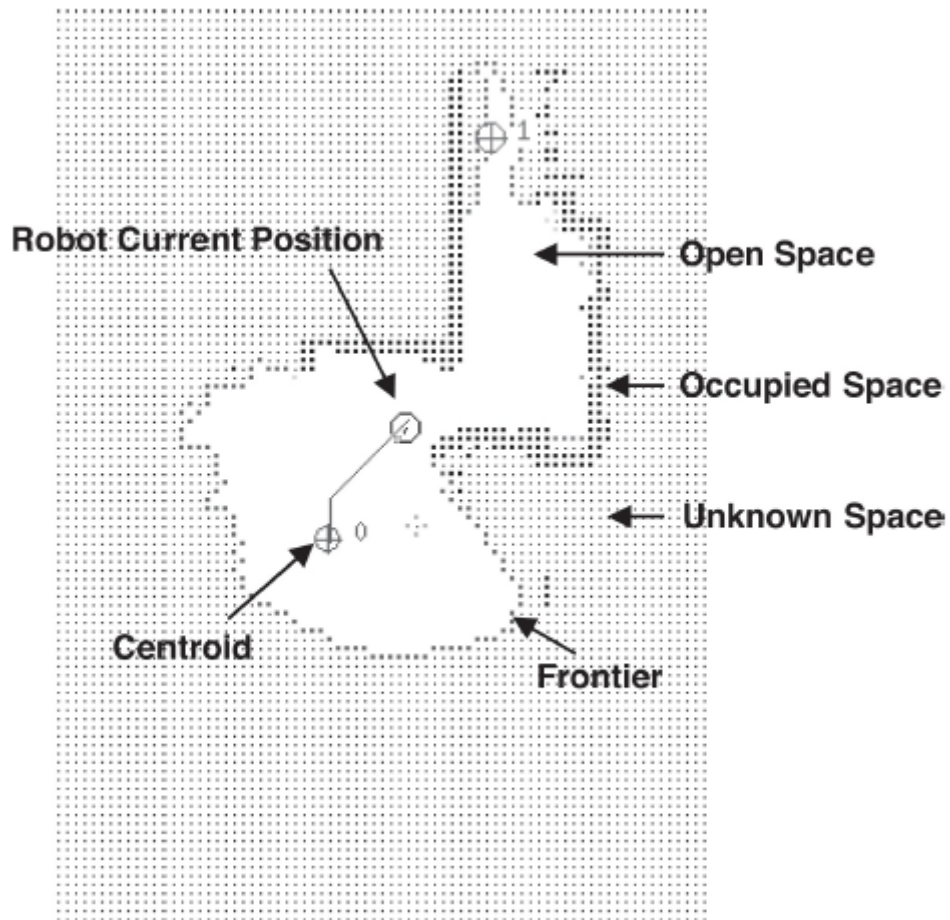
Eksploracja, być może przeciwieństwo mapowania, pyta: Gdzie ja nie byłem? zamiast: Gdzie byłem? Chociaż eksplorację można przeprowadzić w sposób reaktywny, głównym problemem w eksploracji jest skuteczne pokrycie nieznanego obszaru. Istnieją dwie ogólne kategorie algorytmów eksploracji deliberatywnej: podejście oparte na granicach i uogólnione podejście grafu Voronoi (GVG). Podejścia te działają zadowalająco w pomieszczeniach, ale ich użyteczność w przypadku miejsc pracy na zewnątrz nie została ustalona.

### **Reaktywna eksploracja**

Eksplorację można przeprowadzić behawioralnie. Jednym ze sposobów jest losowe wyszukiwanie; robot dosłownie wędruje losowo (używając losowego pola potencjalnego). Po pewnym (często bardzo długim) czasie statystyki wskazują, że powinien być objąć cały obszar. Inną reaktywną metodą jest umożliwienie krótkotrwałego utrzymywania się propriocepcji (odometrii), w której robot jest odpychany przez obszary, które były ostatnio odwiedzane; unikaj przeszłych zachowań. Unikanie przeszłego zachowania może być zaimplementowane jako odpychające pole, generowane przez każdą odwiedzaną komórkę w zgrubnej siatce zajętości lub dla każdego poprzedniego nagłówka. Innym podejściem behawioralnym jest wykorzystanie informacji dowodowych w siatce obłożenia. Gdy robot eksploruje nowy obszar, wiele komórek w siatce będzie nieznanymi, a robot może wykorzystać środek ciężkości nieznanego obszaru jako cel do przejścia do celu. Chociaż powyższe podejścia zorientowane na zachowanie są proste i łatwe do wdrożenia, często są nieefektywne, zwłaszcza gdy są prezentowane w dwóch lub więcej niezbadanych obszarach. Załóżmy, że robot napotkał skrzyżowanie korytarza; jak wybiera obszar do zbadania? Dwa podstawowe style metod eksploracji, które się pojawiły, klasyfikujące niezbadane obszary i dokonujące przemyślanych wyborów, to: oparte na granicach i uogólnione metody grafów Voronoi. Oba działają dobrze w środowiskach wewnętrznych; mniej jasne jest, jak działają one na dużych otwartych przestrzeniach. Oba używają zachowań do nawigacji, ale różnią się sposobem wyznaczania celów nawigacyjnych. Ta sekcja zawiera bardzo uproszczony przegląd każdej metody.

### **Eksploracja graniczna**

Eksplorację pogranicza zapoczątkował Brian Yamauchi. Podejście to zakłada, że robot używa Bayesowskiej siatki zajętości (można również użyć siatki Dempstera-Shafera). Jak pokazano na rysunku, kiedy robot wchodzi do nowego obszaru, istnieje granica między każdym obszarem, który został wykryty i jest otwarty, a obszarem, który nie został wykryty. (Granice między zajętymi obszarami a obszarami nieznanymi nie są interesujące, ponieważ robot nie może przejść przez zajęty obszar, aby wyczuć, co jest za nim.) Na rysunku 15.8 są dwie takie granice; każda z tych linii tworzy granicę, którą należy zbadać.




Wyboru, którą granicę zbadać jako pierwszą, można dokonać na wiele sposobów. Prostą strategią jest najpierw zbadanie najbliższej granicy. Innym jest najpierw zbadanie największej granicy. Ponieważ świat jest nieznan, robot nie może wiedzieć, że po dotarciu do dużej granicy odkryje ścianę zaledwie metr dalej. Oznacza to, że robot może poruszać się po pokoju, na krótko zbadać jeden obszar, a następnie wrócić prawie do punktu wyjścia, zbadać ten obszar, a następnie przejść do innego miejsca i tak dalej. W praktyce nie zdarza się to tak często w środowiskach wewnętrznych.

### **Uogólnione metody grafów Voronoi**


Inną metodą decydowania o tym, jak badać przestrzeń, jest zbudowanie przez robota zredukowanego uogólnionego grafu Voronoi (GVG) podczas poruszania się po świecie i wykrywanie bramek lub okazji dla swoich wyborów ruchu. Ta metoda była szeroko stosowana, począwszy od Howie Choset.

### **UOGÓLNIONY WYKRES WORONOA (GVG)**

W podejściu GVG robot stara się utrzymać ścieżkę, która umieszcza go w równej odległości od wszystkich obiektów, które wyczuwa podczas ruchu. Zasadniczo robot próbuje poruszać się do przodu, ale pozostaje pośrodku między otaczającymi obiektami lub styknie do nich. Ta ścieżka jest krawędzią GVG, taką samą, jaka zostałaby wygenerowana przez rozłożenie przestrzeni na wykres Voronoi. Generowanie i podążanie wygenerowaną ścieżką jest proste dzięki zachowaniu. Gdy robot znajdzie się w ślepych zaułku lub bramie, istnieje wiele krawędzi GVG, za którymi robot może podążać. Jak pokazano na rysunku, ślepe zaułki tworzą dwie krawędzie GVG.




a.




b.

Ale w tym przypadku robot może dostrzec, że obie krawędzie kończą się na przedmiotach, więc nie ma powodu, aby za nimi podążać. Robot może następnie cofnąć się po ścieżce, którą był, albo do punktu początkowego, albo do innej gałęzi. Jeśli robot napotka gałąź na krawędziach GVG, może wybrać losowo jedną, za którą podąży. Powyższy rysunek pokazuje, w jaki sposób robot eksplorowałby dany obszar. Dla wygody rysunek pokazuje cały GVG, który zostałby narysowany po tym, jak robot w pełni zbadał obszar. Robot zaczynał od wyczuwania ścian z każdej strony (bez rozpoznania, że znajduje się w hali). Wykrywany obszar jest pokazany w kolorze jasnoszarym. Robot próbowałby wyśrodkować się między ścianami, poruszając się prostopadle do linii przecięcia. W końcu dochodzi do skrzyżowania. Przecięcie tworzy dwie krawędzie, z których żadna nie kończy się na obiekcie. Robot arbitralnie wybiera lewą krawędź i przechowuje prawą na wypadek, gdyby algorytm musiał się cofnąć. Robi to wielokrotnie, jak widać na rysunku b, i kontynuuje w górę korytarza, aż dojdzie do ślepego zaułka. Robot następnie cofa się, używając tego samego zachowania na krawędzi (pozostań w środku). Nadal faworyzuje eksplorację w lewo, aż dojdzie do ślepego zaułka w lewym dolnym rogu, a następnie cofa się, jak pokazano na rysunku poniżej a. Robot kontynuuje eksplorację i cofanie się, aż cały obszar zostanie pokryty, jak pokazano na rysunku poniżej b.





a.



### Lokalizacja, mapowanie, eksploracja i sztuczna inteligencja

Lokalizacja, mapowanie i eksploracja obejmują wiele z siedmiu kluczowych obszarów sztucznej inteligencji przedstawionych w rozdziale 1. Funkcje te są z natury percepcyjne, łącząc postrzegany świat z symbolicznymi mapami; polegają na wizji. Eksploracja może polegać na planowaniu deliberatywnym, ale może być również wykonywana w sposób reaktywny. Większość algorytmów obejmuje wyszukiwanie probabilistyczne i wnioskowanie w celu znalezienia pozycji, które pasują do mapy lub najlepiej pasują do poprzedniego skanowania. Na pierwszy rzut oka lokalizacja, mapowanie i eksploracja wymagałyby przede wszystkim uczenia się, tak jak w przypadku uczenia się nowego środowiska. Jednak algorytmy postrzegają i konstruują reprezentacje, a nie uczą się w klasycznym rozumieniu tego terminu. Klasyczne uczenie maszynowe jest wykorzystywane do identyfikacji terenu, gdzie system kojarzy sygnały proprioceptywne lub eksteroceptywne z typami terenu. Lokalizacja, mapowanie i eksploracja nie wymagają zrozumienia języka naturalnego. Mogą angażować rozproszoną sztuczną inteligencję za pomocą wielu robotów, aby jednocześnie mapować duży lub złożony obszar. Jednak potrzeba więcej pracy w AI, zwłaszcza w reprezentacji wiedzy. To stwierdzenie może być sprzeczne z intuicją, ponieważ mapa jest reprezentacją wiedzy. Wyzwaniem jest problem podstawy symbolu, który może być czynnikiem ograniczającym w mapowaniu. Jak widać w przypadku algorytmów lokalizacji i SLAM, niezawodne dopasowywanie funkcji na mapie do funkcji w środowisku lub poznanie, jakie funkcje powinny być włączone do mapy, jest trudne. Lokalizacja, mapowanie i eksploracja mogą być obszarami, w których bardziej wyrafinowane rozwiązywanie problemów, wnioskowanie i uczenie się doda wartości do nawigacji robota jako całości.

### Podsumowanie

Lokalizacja robota mobilnego wymaga określenia pozycji robota względem danej mapy otoczenia. Algorytmy lokalizacji to warianty algorytmów filtrów Bayesa, w których wiara w pozę jest funkcją pozycji robota, czynności kontrolnych i mapy. Lokalizacja ikoniczna jest bardziej powszechna niż lokalizacja oparta na funkcjach ze względu na problemy z niezawodnością podczas wyodrębniania funkcji. Lokalizacja oparta na cechach historycznie wykorzystywała rozszerzone rozwiązania filtrowania Kalmana, ale te metody wymagają zmiennych korespondencji, aby połączyć obserwacje cech z cechami symbolicznymi na mapie. W praktyce dominują metody lokalizacji Monte Carlo (MCL), zarówno w przypadku podejścia ikonicznego, jak i opartego na cechach. Lokalizacja działa bardzo dobrze w środowiskach statycznych z dobrymi modelami, ale środowiska dynamiczne są trudne. Algorytmy jednoczesnej lokalizacji i mapowania (SLAM) dobrze sprawdzają się w pomieszczeniach, zwłaszcza jeśli robot wykorzystuje skanowanie odległości i może wykonać wiele pętli przez obszar i zamknąć pętle. Oparte na granicy i uogólnione metody grafu Voronoi to dwa rodzaje eksploracji, ale niekoniecznie są one tak intuicyjnie wydajne, jak można by się spodziewać. Mapy terenu, teraz dostępne w niskich rozdzielczościach, są dobre do planowania, ale straszne do wykonania. Nawigacja w terenie wymaga umiejętności wyczuwania terenu. Nie ma wiarygodnych metod proprioceptywnych lub eksteroceptywnych do identyfikacji terenu, chociaż propriocepcja wydaje się bardziej obiecująca do praktycznego zastosowania w najbliższym czasie. Stereofotogrametria umożliwia robotom tworzenie ortomozai, cyfrowych map wysokościowych i cyfrowych map powierzchniowych. Mobilność robota w środowisku można częściowo określić ilościowo pod względem względnej skali otoczenia w stosunku do robota i przejezdności otoczenia. W praktyce większość środowisk składa się z wielu regionów o różnej skali i przejezdności. Względna skala środowiska  $E$  do robota lub innego rodzaju środka  $A$  jest stosunkiem ich charakterystycznych wymiarów. Wskaźniki można wykorzystać do podziału regionów na trzy kategorie mobilności. Jeśli środowisko jest duże i przestronne w porównaniu z robotem,  $E_{cd}/A_{cd} < 2/0$  wtedy region jest łatwy do zamieszkania dla robota. Jeśli środowisko i robot mają podobną skalę,  $E_{cd}/A_{cd} \leq 2.0$  wtedy robot ma ograniczoną manewrowość. Jeśli środowisko jest mniejsze niż robot, a robot zasadniczo zakupuje się w regionie,  $E_{cd}/A_{cd} \leq 1.0$  wtedy region jest ziarnisty. Przejezdność ma cztery ogólne cechy: pionowość, krętość, powagę przeszkód i elementy dostępności. Ponadto na roboty naziemne mają wpływ właściwości powierzchni, pojazdy powietrzne wiatr, a pojazdy morskie fale. Lokalizacja, mapowanie i eksploracja obejmują większość podstawowych obszarów sztucznej inteligencji. Jednak problem podstawy symbolu pozostaje ogólnym wyzwaniem dla sztucznej inteligencji, a istniejące rozwiązania są ograniczone i wysoce specyficzne dla domeny. Wracając do pytań postawionych we wstępie, odpowiedź na pytanie Dlaczego jest to problem? Nie możesz po prostu użyć GPS, jakiegoś rodzaju beaconów RFID lub skanów 3D z czujników RGB-D? powinno być jasne. Lokalizacja, mapowanie i eksploracja są złożone. Odpowiedź na pytanie Jak możesz jednocześnie mapować świat i mieć pewność, gdzie jesteś? jest adresowany przez badania nad symultaniczną lokalizacją i mapowaniem (SLAM). Techniki SLAM w dużej mierze opierają się na teorii prawdopodobieństwa. Jak skutecznie lub przynajmniej konsekwentnie eksplorować nowe obszary? można odpowiedzieć za pomocą metod granicznych, które kierują robota do największego niezbadanego obszaru w dowolnym momencie lub metod GVG, które działają ręcznie lokalnie i agregują globalnie. Pytanie: Jak oznaczyć mapę obiektami i cechami lub terenem? pozostaje nierozwiązany i jest obszarem aktywnych badań. Lokalizacja i mapowanie uzupełniają omówienie nawigacji, przy czym eksploracja jest czynnością związaną z nawigacją, ale odrębną od niej. Podczas gdy nawigacja jest tylko jednym z zastosowań rozważań w inteligentnym robocie, jest niezbędna dla mobilności i dlatego pojawia się w każdej architekturze technicznej. Kolejne części zwracają uwagę na warstwę interaktywną.