



Filtr cząsteczkowy. Przykład zastosowania w lokalizacji poruszającego się terminala sieci radiowej

Warszawa, 14.04.2016

Michał Okulewicz





FILTR CZĄSTECZKOWY




Przykład motywacyjny

- Robot poruszający się po zamkniętym pomieszczeniu
 - Czujnik odległości (przybliżona odległość do najbliższej ściany)
 - Silniki krokowe (przybliżone przemieszczenie i obroty)
 - Mapa ścian
 - Pozycja początkowa (przybliżona)
- Zadanie
 - Wskazywać kolejne położenia robota



Przykład motywacyjny





Filtr cząsteczkowy

(Sekwencyjne Monte Carlo)

- Zadanie
 - Określić stan wewnętrzny systemu na podstawie zewnętrznych obserwacji
- Założenia

$$\begin{array}{ccccccc} X_0 & \rightarrow & X_1 & \rightarrow & X_2 & \rightarrow & X_3 & \rightarrow & \dots & \text{signal} \\ \downarrow & & \downarrow & & \downarrow & & \downarrow & & \dots & \\ Y_0 & & Y_1 & & Y_2 & & Y_3 & & \dots & \text{observation} \end{array}$$



Filtr cząsteczkowy

(Sekwencyjne Monte Carlo)

- Algorytm (wersja podstawowa)

Wypełnij wektor wag $w_j \leftarrow 1/m$ ($j \in \{1, 2, \dots, m\}$)

Dla Y_i ($i \in \{0, 1, \dots, n\}$)

Wygeneruj m propozycji $X_{i,j}$ ($j \in \{1, 2, \dots, m\}$) wartości sygnału z rozkładu $P(X_i | X_{i-1})$

Oszacuj prawdopodobieństwo $P(Y_i | X_{i,j})$

$w_j \leftarrow w_j * P(Y_i | X_{i,j})$

Zwróć $X_{i,j}$ dla maksymalnego w_j jako rozwiązanie



Filtr cząsteczkowy: Przykładowe modyfikacje

- *Rejection sampling*
 - Nie akceptowanie $X_{i,j}$ o niskim prawdopodobieństwie $P(Y_i|X_{i,j})$
- *Sequential importance resampling*
 - Selekcja ruletkowa (lub inna) z algorytmu genetycznego ciągów X w oparciu o wagi w_j
 - Selekcja wykonywana gdy efektywna wielkość próbek spada poniżej pewnego progu (duża nierównomierność wag cząstek)
- Próbkowanie $X_{i,j}$ z rozkładu $P(X_i|X_{i-1}, Y_i)$



Filtr cząsteczkowy: Wielkości do estymacji

- $P(Y_i | X_{i,j})$
 - Modelowanie dokładności obserwacji i ich związku ze stanem systemu
- $P(X_0)$
 - Modelowanie początkowego stanu systemu
- $P(X_i | X_{i-1})$
 - Modelowanie sposobu zmian stanu systemu




Przykład motywacyjny: Estymacje

- $P(Y_i | X_{i,j})$
 - $(M - |Y_i - \text{dist}(X_{i,j})|) / M$
- $P(X_0)$
 - $\text{position}_0 + u_{[-0.2,0.2]}$
- $P(X_i | X_{i-1})$
 - $X_{i-1} + (\text{move}_i + u_{[-0.0025,0.0025]}) * (\sin(\varphi_i + u_{[-0.05,0.05]}), \cos(\varphi_i + u_{[-0.05,0.05]}))$
 - Nie można wyjść poza ściany zewnętrzne




Przykład motywacyjny: Wyniki



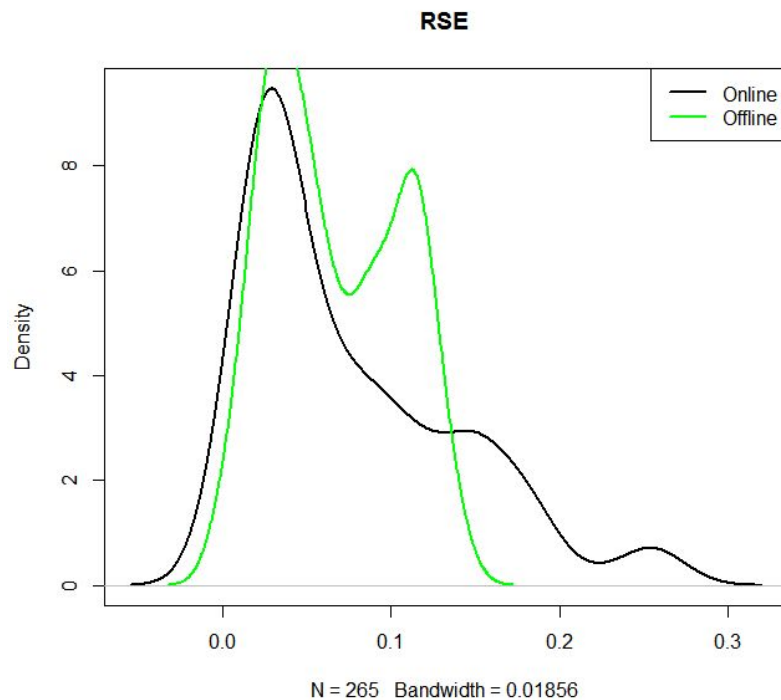


Przykład motywacyjny: Błąd w czasie





Przykład motywacyjny: Rozkład błędu

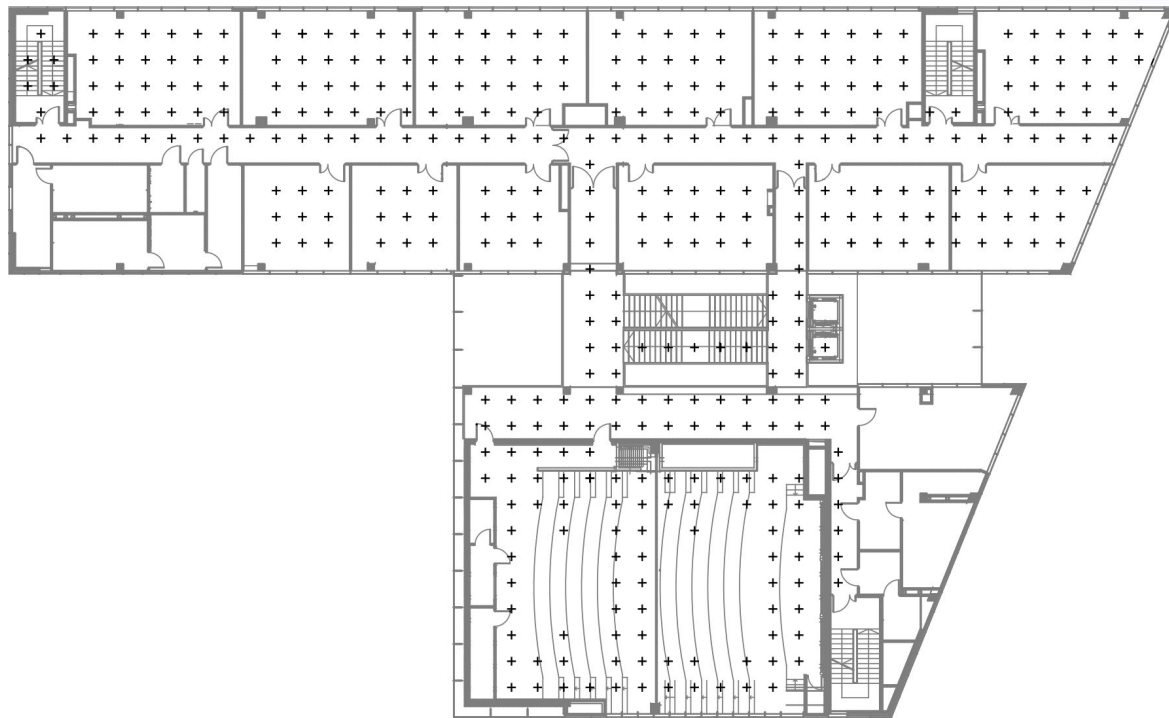




ZASTOSOWANIE FILTRA CZĄSTECZKOWEGO W PROCESIE LOKALIZACJI TELEFONU





Dane referencyjne



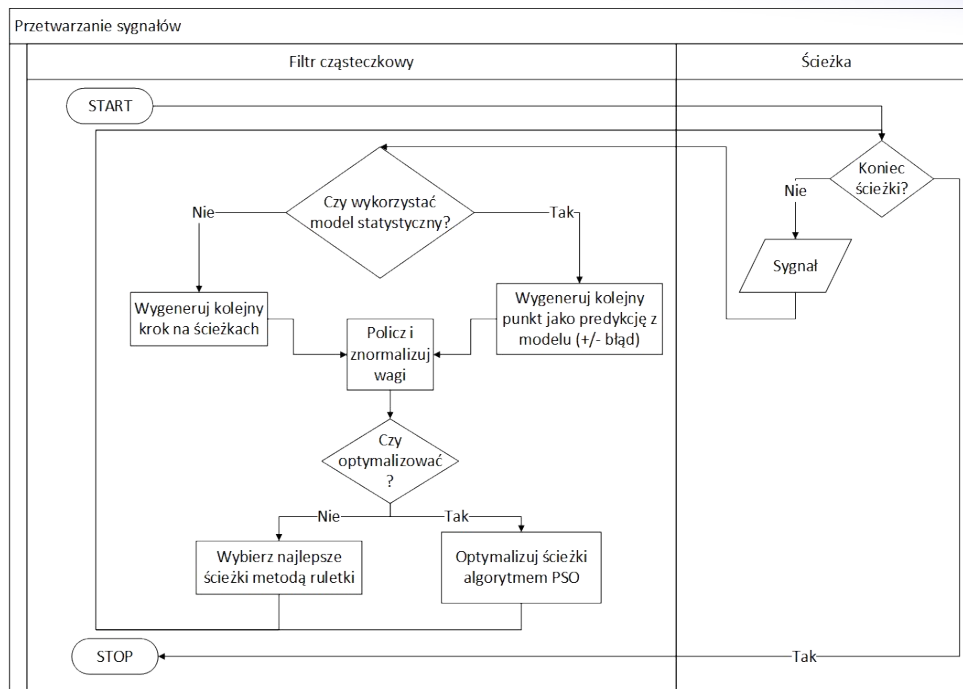


Dane testowe





Architektura







Funkcja oceny

$$\hat{\mathcal{L}}(S_i|L_i) = \frac{M - \rho(s_i, S(l_i))}{M} \frac{\left(\sum_{j=1}^n I(s_{i,j} * S_j(l_i) \neq 0) \right)^2}{\left(\sum_{j=1}^n I(s_{i,j} \neq 0) \right) \left(\sum_{j=1}^n I(S_j(l_i) \neq 0) \right)}$$

Distance distribution vs. likelihood ranges for GSM



Distance distribution vs. likelihood ranges for WiFi





Model poruszania się po budynku

- **W poziomie** przesunięcie z rozkładu jednostajnego w kole o zadanym promieniu r
- **W pionie** prawdopodobieństwo $\frac{p}{2}$ zmiany piętra o 1 oraz $\frac{p}{4}$ zmiany piętra o 2
ALBO
- **W poziomie** wygenerowanie punktu z predykcji modelu statystycznego z dodanym błędem z dwuwymiarowego rozkładu normalnego z σ estymowaną z rozkładu błędów na zbiorze testowym
- **W pionie** wygenerowanie punktu z predykcji modelu statystycznego z prawdopodobieństwem warunkowym $P(f|\hat{f})$



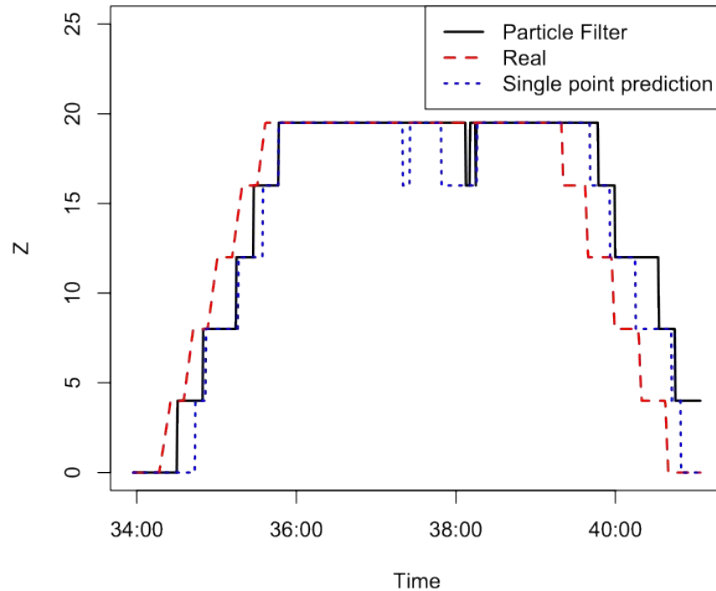
WYNIKI



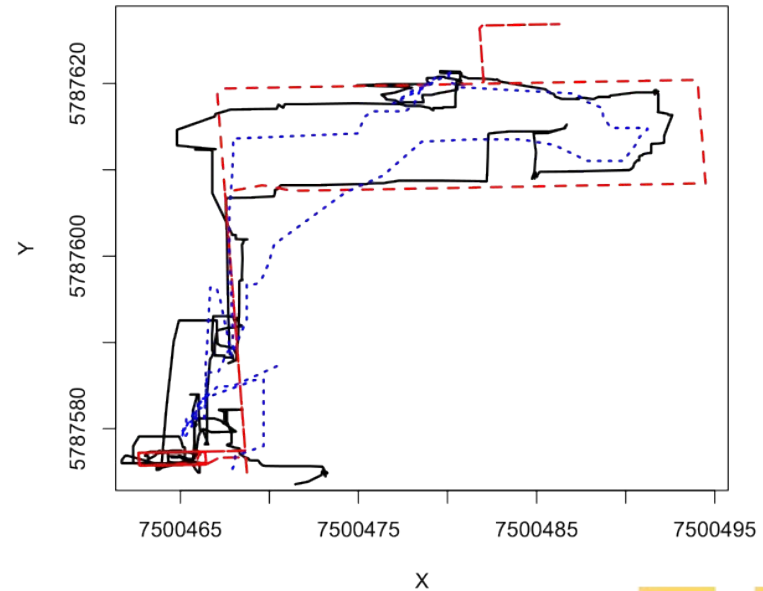
Przykład lokalizacji (WiFi)

WiFi PSO 10x10 p(RF)=0.5 Smoothing=[0,15]

Floor estimation



Horizontal location estimation





Wyniki lokalizacji



GSM

Model	Scenario	Smoothing	Accuracy	$x_{0.5}$	$y_{0.5}$
PF	1	[-15,15]	0.45	4.70	12.02
RF	1	[-15,15]	0.40	5.29	16.14
PF	1	0	0.40	6.28	14.18
RF	1	0	0.38	5.31	15.35
PF	1	[0,5]	0.42	5.58	13.43
RF	1	[0,5]	0.38	5.51	15.34
PF	2	[-15,15]	0.22	4.68	10.95
RF	2	[-15,15]	0.52	2.23	4.54
PF	2	0	0.20	6.00	12.82
RF	2	0	0.50	2.38	4.84
PF	2	[0,5]	0.21	5.30	11.56
RF	2	[0,5]	0.50	2.45	4.84
PF	3	[-15,15]	0.09	4.17	15.23
RF	3	[-15,15]	0.28	4.27	4.27
PF	3	0	0.09	6.36	17.30
RF	3	0	0.30	4.37	4.83
PF	3	[0,5]	0.09	4.80	16.88
RF	3	[0,5]	0.30	4.55	4.82

WiFi

Model	Smoothing	Accuracy	$x_{0.5}$	$y_{0.5}$
PF ($p_{PSO} = 1.0$)	[-15,15]	0.74	2.47	3.56
PF ($p_{PSO} = 0.0$)	[-15,15]	0.71	2.67	3.20
RF	[-15,15]	0.69	3.14	4.80
PF ($p_{PSO} = 1.0$)	0	0.70	2.84	3.83
PF ($p_{PSO} = 0.0$)	0	0.70	2.91	3.80
RF	0	0.67	3.14	4.86
PF ($p_{PSO} = 1.0$)	[0,5]	0.70	2.70	3.84
PF ($p_{PSO} = 0.0$)	[0,5]	0.69	2.66	3.60
RF	[0,5]	0.67	3.22	4.91



WNIOSKI



Wnioski



- Zastosowanie filtra cząsteczkowego pozwoliło na poprawę wyników lokalizacji opartych o dane WiFi oraz jeden ze scenariuszy GSM
- Filtr cząsteczkowy pomaga zwalczyć tendencje do uśredniania / wskazywania najczęstszej klasy przez model
- Zastąpienie fazy selekcji innego rodzaju optymalizacją może dawać poprawę wyników
- Wprowadzenie lepszego modelu poruszania się (uwzględniającego kształt budynku, dane z ciśnieniomierza oraz akcelerometru) powinno wpłynąć na poprawę wyników



Bibliografia

- S.Jaroszewicz, *Wykłady z zaawansowanego uczenia maszynowego*, IPI PAN 2014
- M.Okulewicz, D.Bodzon, M.Kozak, M.Piwowski, P.Tenderenda, *Indoor localization of a moving mobile terminal by an enhanced Particle Filter method*, ICAISC 2016