



## Zastosowanie metody PSO w Dynamic Vehicle Routing Problem (kontynuacja)

Michał Okulewicz 26.10.2012



# Plan prezentacji



- Problem VRP+DR
- Algorytm PSO
- Podejścia
  - MAPSO + 2-Opt
  - 2-phase PSO
- Wyniki
- Dane testowe



# VRP+DR



- Pojazd
  - Ładowność
- Magazyn
  - Położenie
  - Godziny otwarcia
- Zamówienie
  - Położenie
  - Wielkość
  - Godzina zamówienia
  - Czas wyładunku



# VRP+DR



- Znalezienie sumarycznie najkrótszej trasy dla pojazdów
- Zrealizowanie każdego zamówienia w ciągu dnia roboczego
- Powrót pojazdów do magazynu przed jego zamknięciem
- Znalezienie  $f(n)$  oraz  $\pi_i(j)$ 
  - $f: POJAZDY \rightarrow 2^{ZAMÓWIENIA}$
  - $(\pi_{|POJAZDY|})$

# PSO




1.  $P_0 := n$  losowych punktów z dziedziny funkcji
2. Oceń każdy z punktów z  $P_k$
3. Dla  $i := 1$  do  $n$ 
  - $P_{k+1}[i] += a * (\text{NajlepszySąsiad}(P[i]) - P_k[i]) + b * (\text{Najlepszy}(P[i]) - P_k[i]) + c * (P_k[i] - P_{k-1}[i])$
4. Jeżeli nie KONIEC wróć do 2.



# MAPSO + 2-Opt



- Optymalizacja wieloma rojami
- Wektory prędkości i położenia cząstek składają się z liczb całkowitych  $x_t, v_t \in [0; n]^{m(t)}$
- PSO odpowiada tylko za przynależności zamówienia do pojazdu
- Trasa dla każdego z pojazdów jest następnie optymalizowana przy użyciu algorytmu 2-opt



Wymiana par krawędzi



# Zaproponowane kodowanie



- Pojazdom przydzielamy centrum  $(x,y)$  obszaru operacyjnego
- Ocena rozwiązania przydziału to suma odległości centrum obszaru operacyjnego od zajezdni (koszt utworzenia trasy) oraz suma odległości centrum obszaru operacyjnego od przydzielonych zamówień (szacunkowy koszt trasy)
- Klientom przydzielamy rangę decydującą o kolejności ich obsługi



# Zaproponowane kodowanie c.d.



- Zamówienia przydzielamy do najbliższego dostępnego pojazdu
  - Niedostępny pojazd to taki, który ma bliską zeru rezerwę czasową i aktualnym kroku czasowym miał przydzielone więcej zamówień niż mógł zrealizować w ciągu dnia roboczego
- Optymalizację przydziału zamówień do pojazdów (położenia obszarów operacyjnych) dokonujemy niezależnie od optymalizacji tras poszczególnych pojazdów (również dokonywanych niezależnie)





# Algorytm




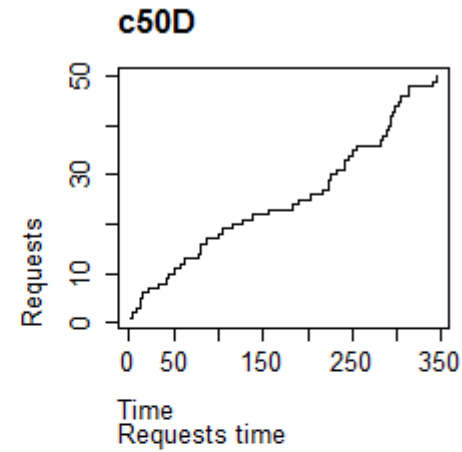
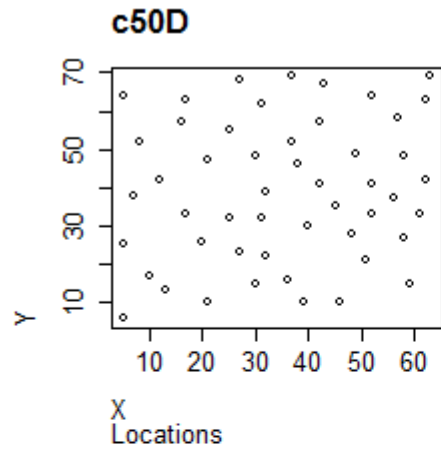
1. Wykorzystaj wstępne (być może puste) rozwiązanie w inicjalizacji cząstek dla PSO
2. Dla zamówień znanych w chwili czasu  $t_i$  uruchom optymalizację centrum obszarów operacyjnych (**klasteryzacja**)
3. Przypisz zamówienia do dostępnych pojazdów
4. Dla przypisanych zamówień optymalizuj trasy dostępnych pojazdów (**komiwojażer**)
5. Odrzuć zamówienia, których realizacja jest niemożliwa ze względu na ograniczenie czasowe i wróć do 3. (lub przejdź do 6. jeżeli nie ma takich zamówień)
6. Ustal trasę do czasu nie mniejszego niż  $t_{i+2}$  dla pojazdów o rezerwie czasowej do zamknięcia magazynu nie mniejszej niż  $t_{i+3} - t_i$





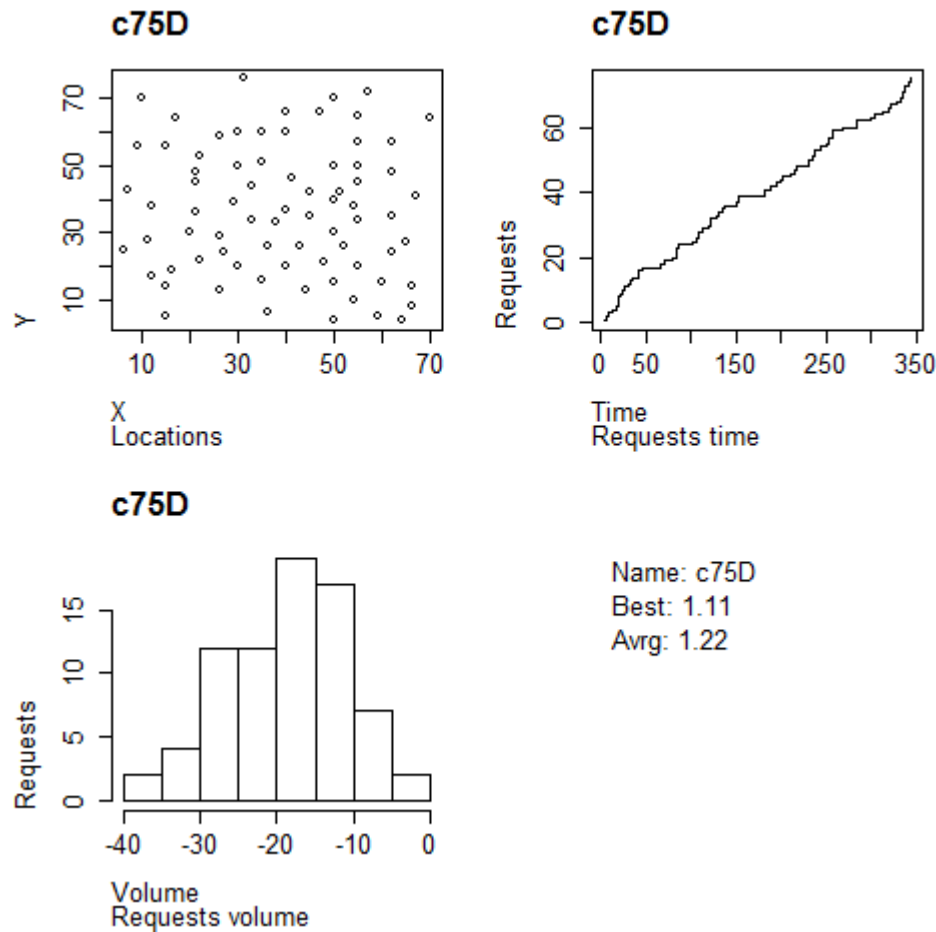
Name	Avg	Best	Bestratio	MAPSO Avg	MAPSO Best
c50D	668,41	588,08	1,12	<b>610,67</b>	<b>571,34</b>
c75D	1016,30	<b>923,30</b>	<b>1,11</b>	<b>965,53</b>	931,59
c100D	1142,05	996,40	1,21	<b>973,01</b>	<b>953,79</b>
c100bD	<b>848,82</b>	<b>828,94</b>	<b>1,01</b>	882,39	866,42
c120D	<b>1209,48</b>	<b>1104,29</b>	<b>1,06</b>	1295,79	1223,49
c150D	<b>1335,82</b>	<b>1242,41</b>	<b>1,21</b>	1357,71	1300,43
c199D	<b>1581,26</b>	<b>1451,47</b>	<b>1,12</b>	1646,37	1595,97
f71D	356,77	315,79	1,31	<b>296,76</b>	<b>287,51</b>
f134D	<b>13462,55</b>	<b>12972,08</b>	<b>1,12</b>	16193,00	15150,50
tai75aD	2140,53	1871,06	1,16	<b>1849,37</b>	<b>1794,38</b>
tai75bD	1567,95	1460,95	1,09	<b>1426,67</b>	<b>1396,42</b>
tai75cD	1812,23	1500,23	1,16	<b>1518,65</b>	<b>1483,10</b>
tai75dD	1577,94	1462,82	1,07	<b>1413,83</b>	<b>1391,99</b>
tai100aD	2713,03	2320,95	1,13	<b>2214,61</b>	<b>2178,86</b>
tai100bD	2503,53	2212,90	1,14	<b>2218,58</b>	<b>2140,57</b>
tai100cD	1673,05	1577,72	1,12	<b>1550,63</b>	<b>1490,40</b>
tai100dD	2189,13	1859,70	1,18	<b>1928,69</b>	<b>1838,75</b>
tai150aD	4158,55	3652,98	1,20	<b>3389,97</b>	<b>3273,24</b>
tai150bD	3302,02	3146,61	1,15	<b>2956,84</b>	<b>2861,91</b>
tai150cD	2947,63	2781,02	1,18	<b>2671,35</b>	<b>2512,01</b>
tai150dD	3492,42	3126,92	1,18	<b>2989,24</b>	<b>2861,46</b>

# c50

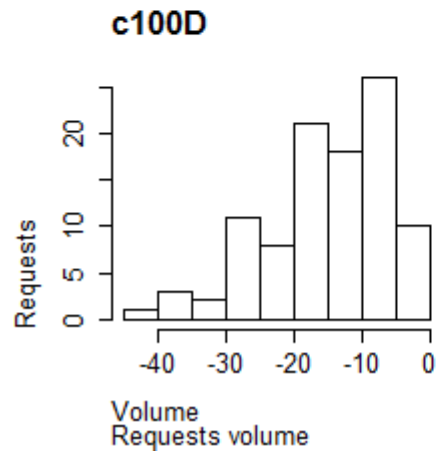
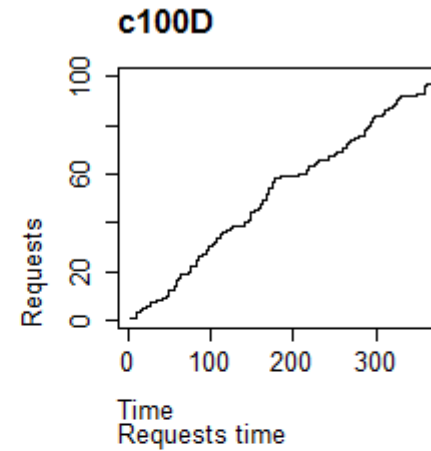
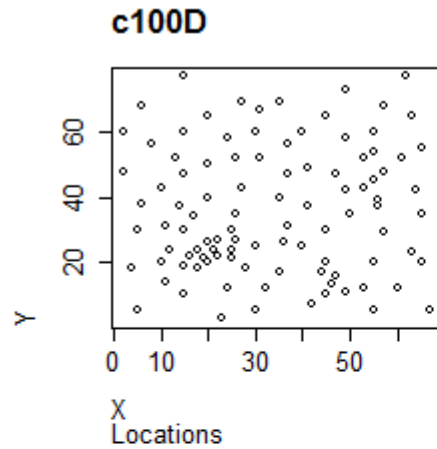


Name: c50D  
Best: 1.12  
Avg: 1.27

# c75






# C100



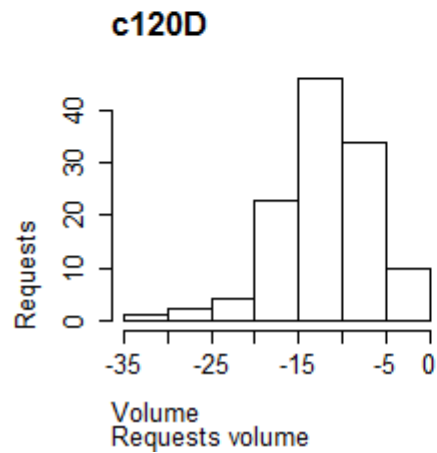
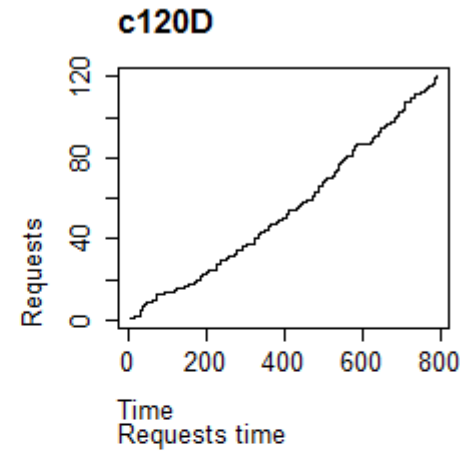

Name: c100D  
Best: 1.21  
Avg: 1.38

# C100B



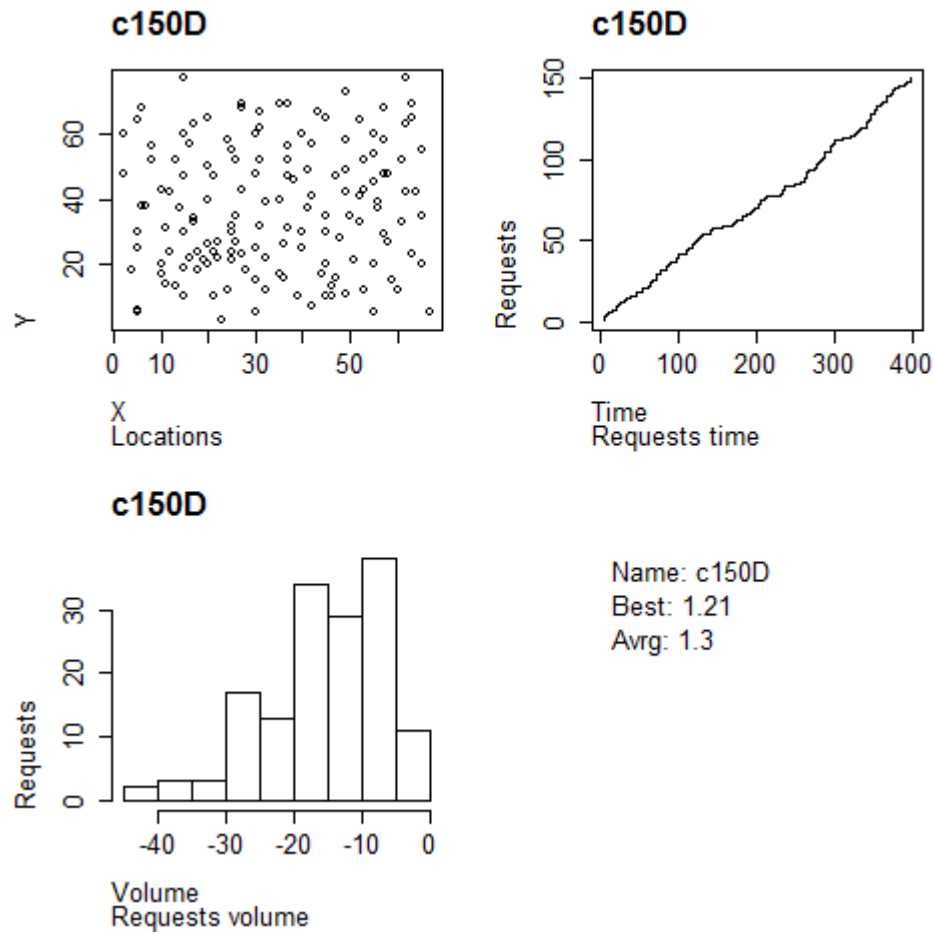
Name: c100bD  
Best: 1.01  
Avg: 1.04

# C120



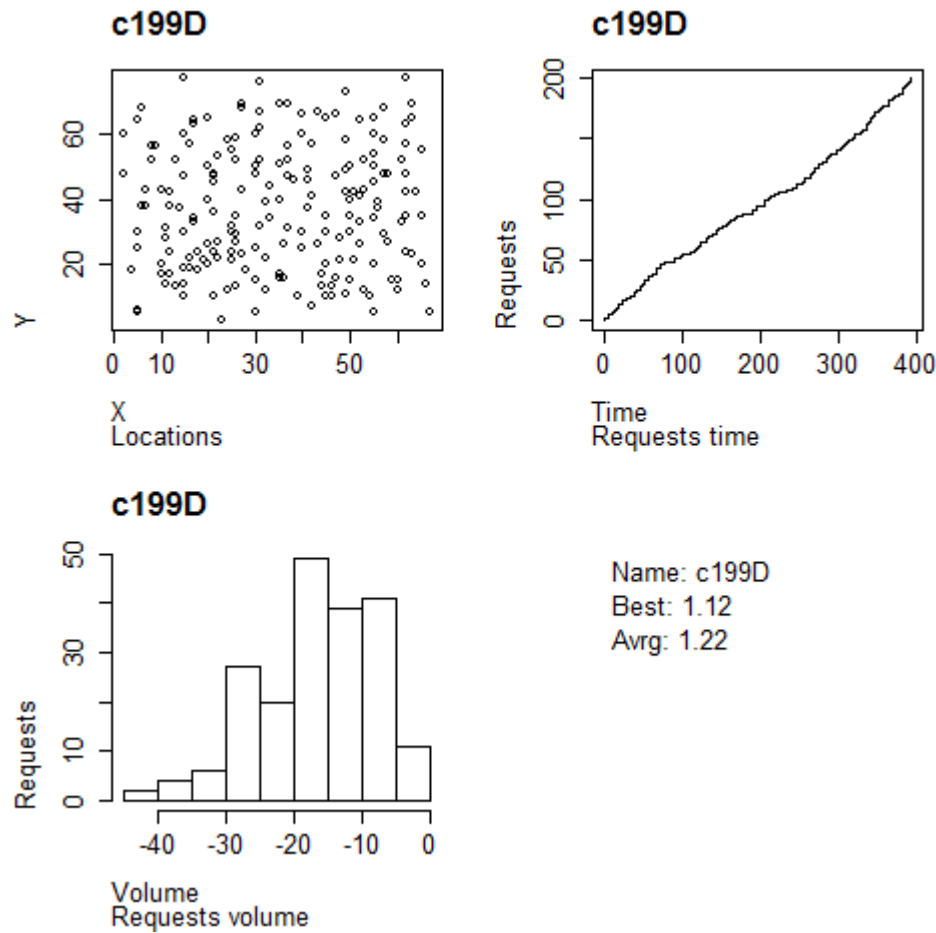
Name: c120D  
Best: 1.06  
Avg: 1.16

# C150

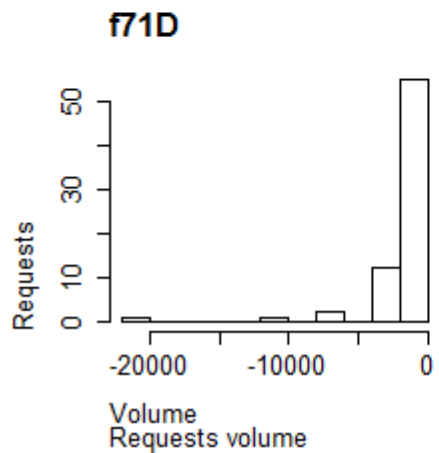







# C199

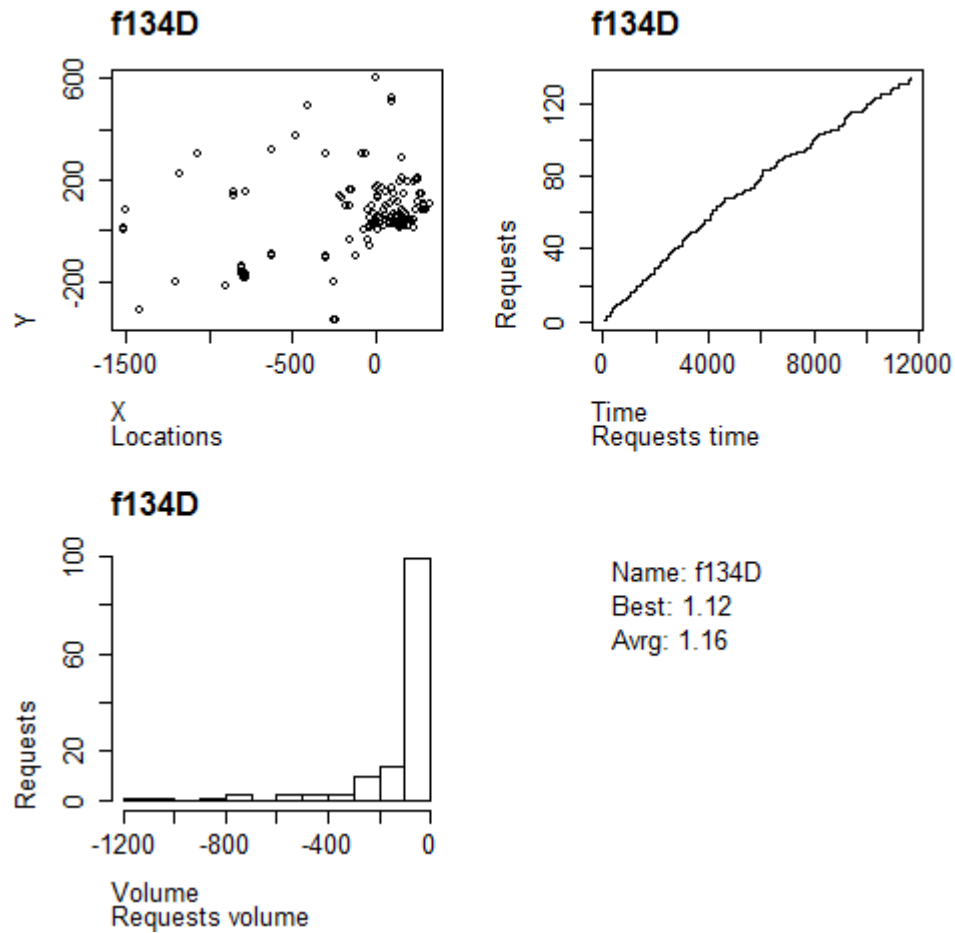


# f71

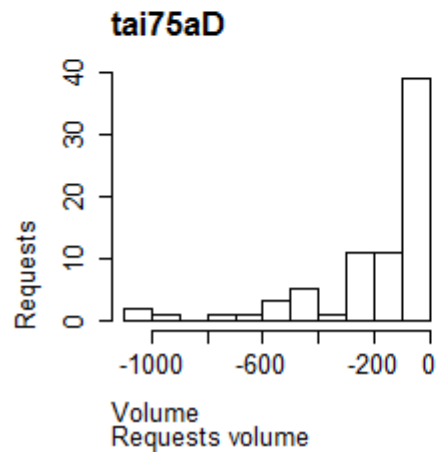




Name: f71D  
Best: 1.31  
Avg: 1.47

# f134



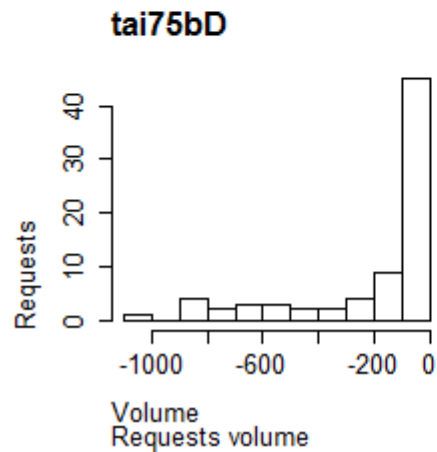

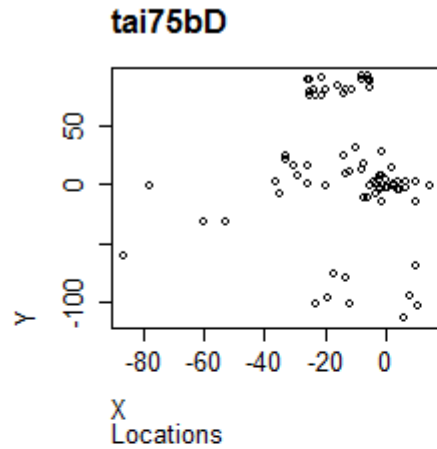
# tai75<sub>A</sub>



Name: tai75aD  
Best: 1.16  
Avg: 1.32

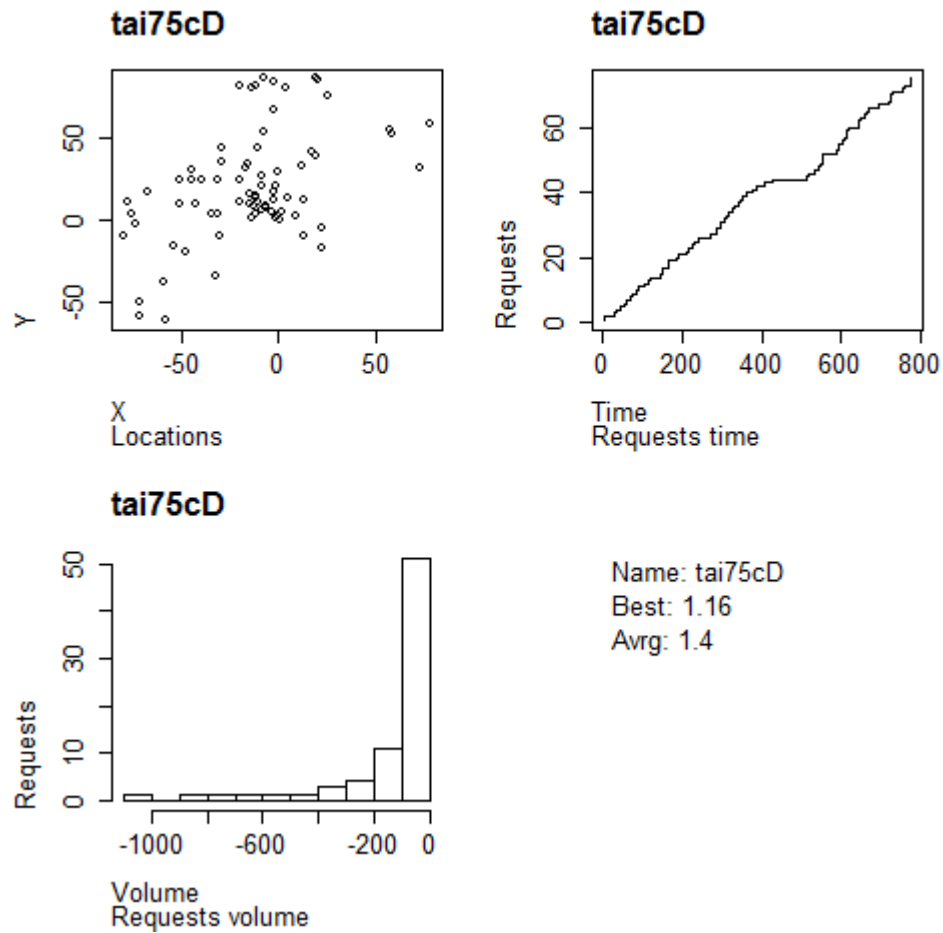


# tai75<sub>B</sub>

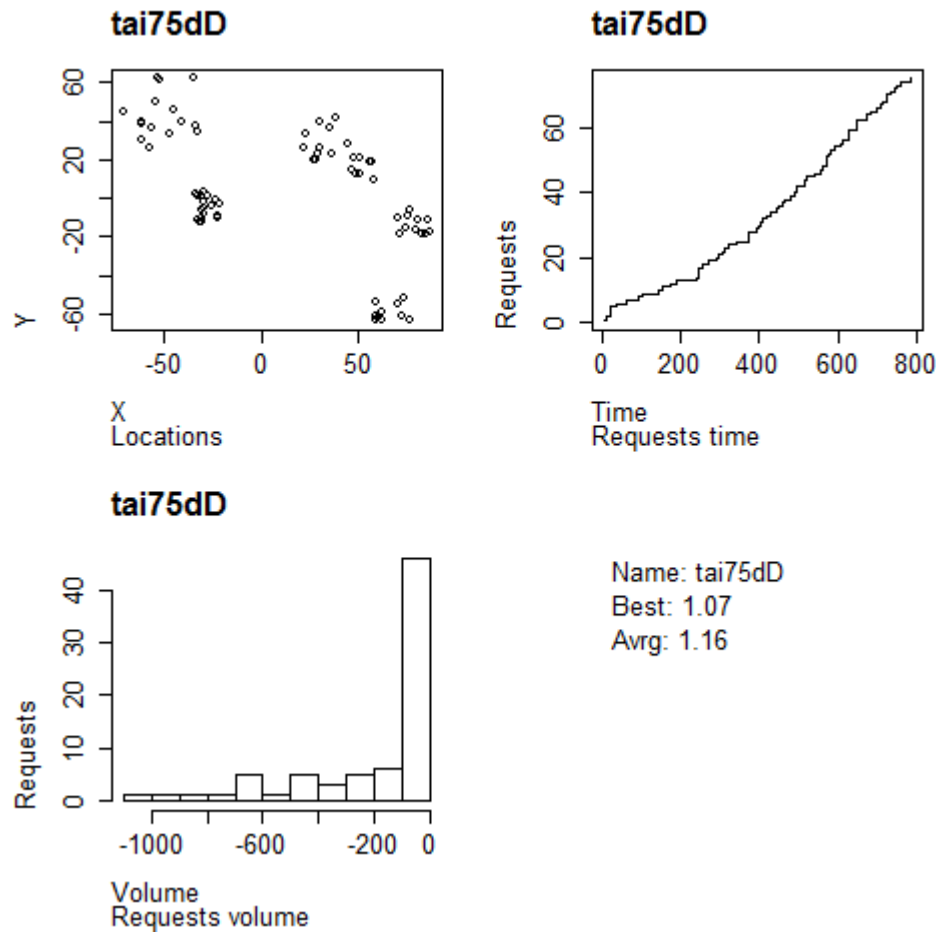


Name: tai75bD  
Best: 1.09  
Avg: 1.17


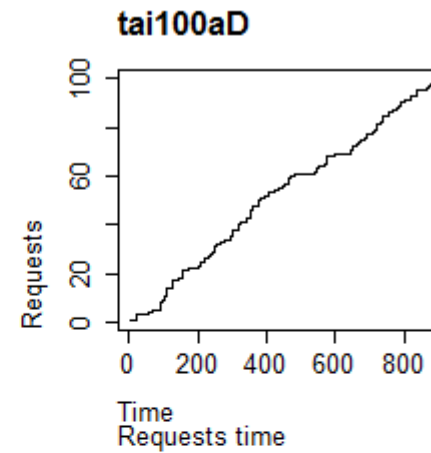
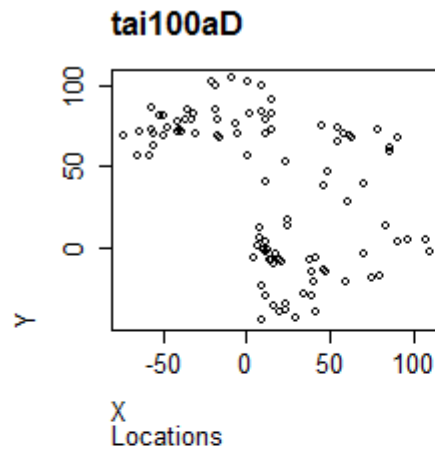
# tai75<sub>c</sub>



# tai75<sub>D</sub>






# tai100A



Name:  
tai100aD Best:  
1.13 Avg: 1.32

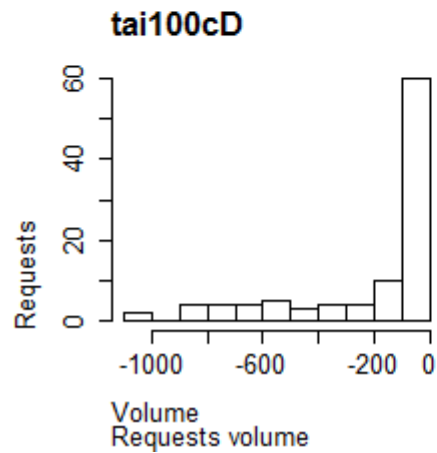




# tai100<sub>B</sub>






Name:  
tai100bD Best:  
1.14 Avg: 1.29

# tai100c




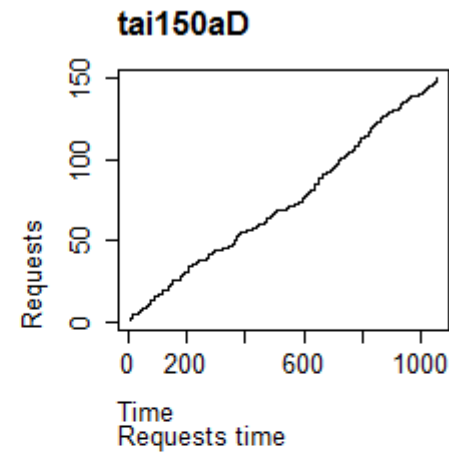

Name:  
tai100cD Best:  
1.12 Avg: 1.19

# tai100D



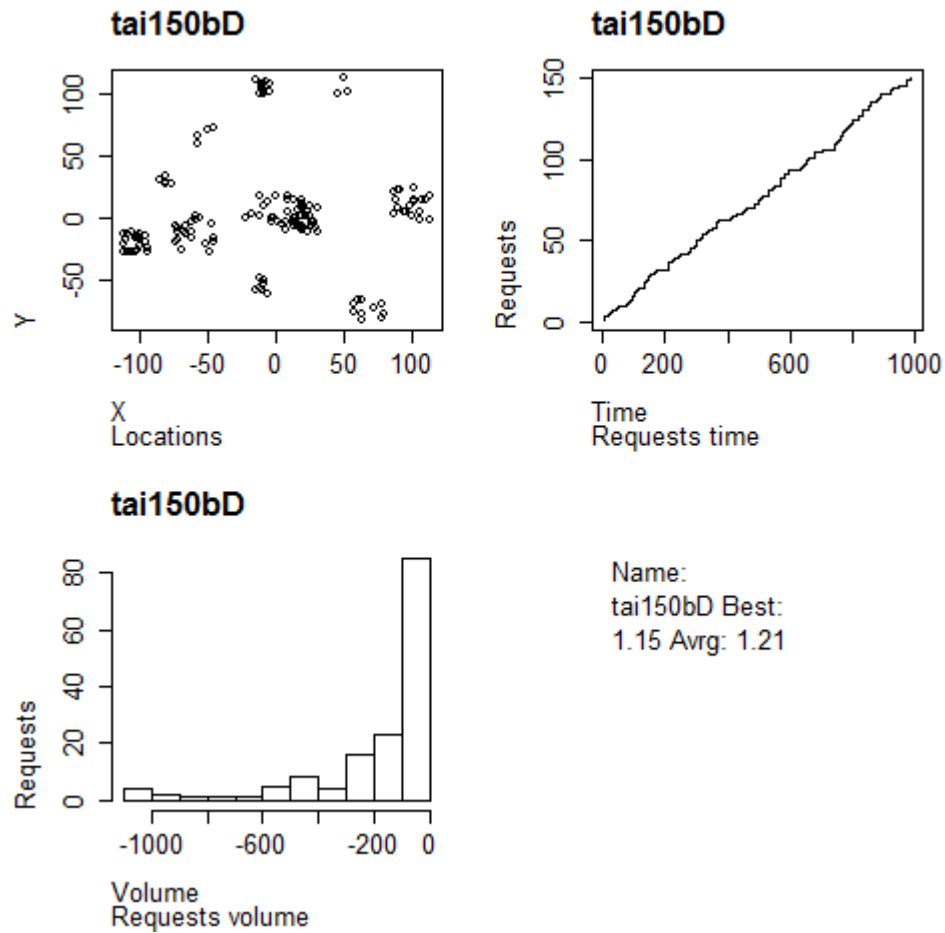
Name:  
tai100dD Best:  
1.18 Avg: 1.38

# tai150<sub>A</sub>






Name:  
tai150aD Best:  
1.2 Avg: 1.36

# tai150<sub>B</sub>






# tai150c



Name:  
tai150cD Best:  
1.18 Avg: 1.25

# tai150<sub>D</sub>



Name:  
tai150dD Best:  
1.18 Avg: 1.32

# Co dalej...?



- Przeanalizowanie zależności pomiędzy wynikami a charakterystykami rozkładu zamówień (przestrzenną i rozmiaru)
- Przeprowadzenie testów w warunkach „biznesowych”
- Modyfikacja algorytmu do pracy w sposób ciągły (możliwość dokładania nowych zamówień jak tylko się pojawią)
- Zaproponowanie kodowania przydziału zamówień do pojazdu, które będzie dopuszczało więcej przypadków przydziałów.





# Literatura



- Multi-Swarm Optimization for Dynamic Combinatorial Problems: A Case Study on Dynamic Vehicle Routing Problem, Khouadjia et al., 2010, Lecture Notes in Computer Science vol. 6234, pp. 227-238
- A comparative study between dynamic adapted PSO and VNS for the vehicle routing problem with dynamic requests, Khouadjia et al., Applied Soft Computing 12 (2012) 1426–1439
- Benchmarki DVRP, [http://www.fernuni-hagen.de/WINF/inhalte/benchmark\\_data.htm](http://www.fernuni-hagen.de/WINF/inhalte/benchmark_data.htm)
- PSO 2011, <http://www.particleswarm.info/>