

Modelowanie Matematyczne, Projekt 3, Dane nr 1.6

Krzysztof Rudnicki, 307585

24 stycznia 2024

0 Wstęp

2 Fabryki, F1, F2

4 Magazyny, M1, M2, M3, M4

6 Klientów, K1, K2, K3, K4, K5, K6

Koszty dystrybucji towaru

zaopatruje	F1	F2	M1	M2	M3	M4
Magazyny						
M1	0.3	-				
M2	0.5	0.4				
M3	1.2	0.5				
M4	0.8	0.3				
Klientów						
K1	1.2	1.8	-	1.4	-	-
K2	-	-	1.2	0.3	1.3	-
K3	1.2	-	0.2	1.8	2.0	0.4
K4	2.0	-	1.7	1.3	-	2.0
K5	-	-	-	0.5	0.3	0.5
K6	1.1	-	2.0	-	1.4	1.5

1 Model Dwukryterialny

Zbiory

- $i, k \in F$ - Fabryki
- $i, l \in M$ - Magazyny
- $j \in K$ - Klienci

Parametry

- $C_{i,j}$ - Koszty transportu dóbr z punktów i (fabryka lub magazyn) do klienta j
- $C_{k,l}$ - Koszty transportu dóbr z fabryki i do magazynu k
- $P_{i,j}$ - Binarnie określa czy preferencja klienta została spełniona (1) czy nie (0)
- S_j - Poziom satysfakcji klienta j - poziom satysfakcji liczymy w zależności od tego ile dany klient zamówił towaru
Zadowolenie klientów którzy zamawiają więcej towarów jest traktowane priorytetowo:

$$S_1 = \frac{50}{60}$$

$$S_2 = \frac{10}{60}$$

$$S_3 = \frac{40}{60}$$

$$S_4 = \frac{35}{60}$$

$$S_5 = \frac{60}{60}$$

$$S_6 = \frac{20}{60}$$

- D_j - Zapotrzebowanie klienta j

Zmienne decyzyjne

- $x_{i,j}$ - Liczba dóbr (w tys. ton) przetransportowana z punktu i (fabryka lub magazyn) do klienta j
- $y_{k,l}$ - Liczba dóbr (w tys. ton) przetransportowana z fabryki k do magazynu l

Funkcja celu

1. Minimalizacja kosztów dystrybucji

$$\text{Min}(\sum_{i,j} C_{i,j} * x_{i,j} + \sum_{i,k} C_{i,k} * y_{i,k})$$

2. Maksymalizacja satysfakcji klienta

W celu maksymalizacji satysfakcji klienta policzymy ile z dostaw do klientów odbyło się z preferencyjnych źródeł

$$\text{Max}(\sum_j S_j * P_{i,j} * x_{i,j})$$

Funkcja celu alpha beta

$$\alpha * (\text{Min}(\sum_{i,j} C_{i,j} * x_{i,j} + \sum_{i,k} C_{i,k} * y_{i,k})) + \beta * (\text{Max}(\sum_j S_j * P_{i,j} * x_{i,j}))$$

Ograniczenia Miesięczne możliwości produkcyjne fabryk

$$\sum_j x_{F1,j} + \sum_k y_{F1,k} \leq 150 \quad (1)$$

$$\sum_j x_{F2,j} + \sum_k y_{F2,k} \leq 200 \quad (2)$$

Miesięczna ilość obsługiwanego towaru przez magazyny

$$\sum_j x_{M1,j} \leq 70 \quad (3)$$

$$\sum_j x_{M2,j} \leq 50 \quad (4)$$

$$\sum_j x_{M3,j} \leq 100 \quad (5)$$

$$\sum_j x_{M4,j} \leq 40 \quad (6)$$

Spełnienie preferencji klienta

$$\sum_i x_{i,j} = D_j \quad (7)$$

Wartości niezerowe

$$x_{i,j}, y_{i,k} \geq 0 \quad (8)$$

2 Implementacja

Do implementacji użyty został python z biblioteką pulp <https://coin-or.github.io/pulp/index.html>. Dzięki temu wykorzystujemy zarówno łatwość pythona jak i możliwości używania różnych solverów (CBC, GLPK, CPLEX, Gurobi...) przez pulp.

Listing 1: Import biblioteki pulp i bibliotek używanych do wykresu

```
import pulp
import sys
```

Listing 2: Inicjalizacja modelu

```
model = pulp.LpProblem("Optimal_Distribution", pulp.LpMinimize)
```

Listing 3: Zdefiniowanie zmiennych i parametrów

```
fabryki = [ 'F1', 'F2' ]
magazyny = [ 'M1', 'M2', 'M3', 'M4' ]
dostawcy = fabryki + magazyny

klienci = [ 'K1', 'K2', 'K3', 'K4', 'K5', 'K6' ]

koszt = {
    'F1': { 'M1': 0.3, 'M2': 0.5, 'M3': 1.2, 'M4': 0.8,
            'K1': 1.2, 'K2': 999, 'K3': 1.2, 'K4': 2.0,
            'K5': 999, 'K6': 1.1 },
    'F2': { 'M1': 999, 'M2': 0.4, 'M3': 0.5, 'M4': 0.3,
```

```

'K1':_1.8,_ 'K2':_999,_ 'K3':_999,_ 'K4':_999,
'K5':_999,_ 'K6':_999},
'M1':_{ 'K1':_999,_ 'K2':_1.2,_ 'K3':_0.2,_ 'K4':_1.7,
'K5':_999,_ 'K6':_2.0},
'M2':_{ 'K1':_1.4,_ 'K2':_0.3,_ 'K3':_1.8,_ 'K4':_1.3,
'K5':_0.5,_ 'K6':_999},
'M3':_{ 'K1':_999,_ 'K2':_1.3,_ 'K3':_2.0,_ 'K4':_999,
'K5':_0.3,_ 'K6':_1.4},
'M4':_{ 'K1':_999,_ 'K2':_999,_ 'K3':_0.4,_ 'K4':_2.0,
'K5':_0.5,_ 'K6':_1.6}
}
P=pulp.LpVariable.dicts(
    "P",[(i,_j)_for i_in_dostawcy_for j_in_klienci],
    cat='Binary')
maksymalne_zamowienie=_60
poziom_satysfakcji=_{
    'K1':_50/_maksymalne_zamowienie,
    'K2':_10/_maksymalne_zamowienie,
    'K3':_40/_maksymalne_zamowienie,
    'K4':_35/_maksymalne_zamowienie,
    'K5':_60/_maksymalne_zamowienie,
    'K6':_20/_maksymalne_zamowienie}
preferencja_klienta=_{
    'K1':_[ 'F2'],_ 'K2':_[ 'M1'],_ 'K3':_[ 'M2',_ 'M3'],
    'K4':_[ 'F1'],_ 'K5':_[ ],_ 'K6':_[ 'M3',_ 'M4']}
suma_satysfakcji=pulp.lpSum(
    [poziom_satysfakcji[j]*P[(i,_j)]
    _for i_in_dostawcy_for j_in_klienci])

```

Listing 4: Zmienne decyzyjne

```

x = pulp.LpVariable.dicts(
    "x",
    [(i, j) for i in dostawcy for j in klienci],
    lowBound=0, cat='Integer')
y = pulp.LpVariable.dicts("y",
    [(i, k) for i in fabryki for k in magazyny],
    lowBound=0, cat='Integer')

```

Listing 5: Funkcje celu

```
koszt_dystrybucji = pulp.lpSum(  
    [koszt[i][j] * x[(i, j)]  
    for i in dostawcy for j in klienci])  
koszt_magazynowania = pulp.lpSum(  
    [koszt[i][k] * y[(i, k)]  
    for i in fabryki for k in magazyny])  
alpha = 0.5  
beta = 0.5  
model += alpha  
* (koszt_dystrybucji + koszt_magazynowania)  
- beta * suma_satysfakcji
```

Listing 6: Ograniczenia

```
for i in fabryki:  
    model += pulp.lpSum(  
        [x[(i, j)] for j in klienci]  
        + [y[(i, k)] for k in magazyny])  
    <= mozliwosci_fabryki[i]  
  
for k in magazyny:  
    model += pulp.lpSum(  
        [x[(k, j)] for j in klienci]  
    ) <= pojemnosc_magazynu[k]  
  
for j in klienci:  
    model += pulp.lpSum(  
        [x[(i, j)] for i in dostawcy]) == zamowienia_klientow[j]
```

Listing 7: Rozwiązanie problemu

```
model.solve()
```

Listing 8: Przedstawienie wyników

```
for v in model.variables():  
    print(v.name, "=", v.varValue)
```

3 Rozwiązanie efektywne

Aby zdefiniować rozwiązanie efektywne sprawdzamy sumaryczy obu funkcji celu dla wartości α i β od 1 do 10 w tym celu napisany został kod który modyfikuje wartości α i β w pętli

Listing 9: Wyznaczanie alpha i beta

```
koszt_wyniki = []
zadowolenie_wyniki = []
wyniki_funkcji = []
maksymalny_wynik = 0;
for alpha in range(0, 11):
    beta = 10 - alpha + sys.float_info.epsilon
    alpha /= 10.0
    beta /= 10.0
    # Update objective function
    model.objective = alpha * koszt_dystrybucji
    - beta * suma_satysfakcji

    # Solve the model
    model.solve()
    print(alpha)

    # Record the wyniki
    calkowity_koszt = pulp.value(koszt_dystrybucji)
    calkowite_zadowolenie = pulp.value(suma_satysfakcji)
    wynik_funkcji = pulp.value(alpha * koszt_dystrybucji
    - beta * suma_satysfakcji)
    koszt_wyniki.append(calkowity_koszt)
    zadowolenie_wyniki.append(calkowite_zadowolenie)
    if wynik_funkcji > maksymalny_wynik:
        maksymalny_wynik = wynik_funkcji
    wyniki_funkcji.append(wynik_funkcji)

print("maksymalny_wynik", maksymalny_wynik, wyniki_funkcji)
```

Najwyższy wynik został uzyskany dla $\alpha = 10$ i $\beta = 0$ i wynosił on **156.5**

Symulacja procesu podejmowania decyzji Przeprowadzone zostały symulacje dla 5 sytuacji:

1. Tylko minimalizacja kosztów $\alpha = 1.0$ $\beta = 0.0$
2. Priorytet na minimalizacji kosztów $\alpha = 0.8$ $\beta = 0.2$
3. Równy podział $\alpha = 0.5$ $\beta = 0.5$
4. Priorytet na satysfakcji klientów $\alpha = 0.2$ $\beta = 0.8$
5. Tylko satysfakcja klientów $\alpha = 0.0$ $\beta = 1.0$

Ponownie w celu przeprowadzenia symulacji napisano kod w pythonie

```
# Pseudo-code, assuming model setup as previously discussed
```

```
scemariusze = [  
    (1.0, sys.float_info.epsilon),  
    (0.8, 0.2),  
    (0.5, 0.5),  
    (0.2, 0.8),  
    (sys.float_info.epsilon, 1.0)]  
wyniki = []  
  
for alpha, beta in scemariusze:  
    model.objective = alpha * koszt_dystrybucji  
        - beta * suma_satysfakcji  
  
    model.solve()  
  
    calkowity_koszt = pulp.value(koszt_dystrybucji)  
    calkowite_zadowolenie = pulp.value(suma_satysfakcji)  
    wyniki.append(  
        (alpha, beta, calkowity_koszt, calkowite_zadowolenie)  
    )  
  
for idx, (alpha, beta, koszt, zadowolenie) in enumerate(wyniki):  
    print(f"Krok_{idx+1}:")  
    print(f"_{koszt}:_{alpha}, _zadowolenie:_{beta}")  
    print(f"
```



```
~~~~~Calkowity_koszt:{koszt},  
~~~~~zadowolenie_klienta:{zadowolenie}\n")
```