

See discussions, stats, and author profiles for this publication at: <https://www.researchgate.net/publication/313899023>

Optymalizacja problemu rozmieszczenia w szafach kancelarii z dokumentami ze znacznikami RFID

Chapter · January 2016

CITATIONS

0

READS

38

4 authors, including:



[Maciej Kiedrowicz](#)

Military University of Technology

70 PUBLICATIONS 70 CITATIONS

[SEE PROFILE](#)

Some of the authors of this publication are also working on these related projects:



Analiza danych [View project](#)



Inne projekty [View project](#)

All content following this page was uploaded by [Maciej Kiedrowicz](#) on 04 August 2017.

The user has requested enhancement of the downloaded file.

Rozdział IX

Optymalizacja problemu rozmieszczenia w szafach kancelarii z dokumentami ze znacznikami RFID

Maciej Kiedrowicz, Tadeusz Nowicki, Zbigniew Wesołowski, Kazimierz Worwa

1. Wprowadzenie

Jednym z ważnych zagadnień związanych z użytkowaniem systemu archiwizacji dokumentów wykorzystującym technologię RFID (ang. *radio-frequency identification*) [1, 2] jest kwestia takiego rozmieszczenia zbioru dokumentów na poszczególnych półkach w szafach RFID, aby minimalizować długość przedziału czasu rejestracji danych o tych dokumentach w bazie danych systemu informatycznego wspomagającego zarządzanie obiegiem dokumentów z tagami RFID. Do rozwiązania tego problemu można zastosować klasyczne podejście optymalizacyjne [3, 4]. Jednym z zagadnień, z jakim należy uporać się stosując to podejście, jest kwestia zgromadzenia danych niezbędnych do aproksymacji funkcji kryterialnej. Ponieważ zbieranie danych jest długotrwałe i pracochłonne, to w celu przyspieszenia tego procesu zastosowano metodę symulacji stochastycznej [5–7]. Polega ona na generowaniu, przy pomocy generatorów liczb pseudolosowych o odpowiednich rozkładach prawdopodobieństwa, liczb zmiennopozycyjnych, których wartości interpretuje się jako długości przedziałów czasu archiwizacji informacji o dokumentach z tagami RFID. Dzięki takim cechom jak możliwość szybkiego generowania wielu różnorodnych danych oraz elastyczność planowania i wykonywania różnorodnych eksperymentów, symulacja komputerowa stała się w ostatnich latach swoistym modus operandi wielu specjalności naukowych [8]. Na podstawie danych pochodzących z symulacji wykonuje się lokalne aproksymacje funkcji kryterialnej stosując metodę analizy regresji [9–11]. Dzięki zastosowaniu techniki planowania dwupoziomowego całkowitego [12, 13] zmniejszono złożoność obliczeniową procesu estymacji parametrów lokalnych liniowych funkcji regresji.

W punkcie 3 sformułowano zasadniczy problem pracy, jako zadanie optymalizacji nieliniowej z ograniczeniami liniowymi. W punkcie 2 omówiono metodę rozwiązania tego zadania. W szczególności, w punkcie 3.1 zaprezentowano metodę estymacji parametrów lokalnych liniowych funkcji regresji, a w punkcie 3.2 szczegółowo omówiono algorytm rozwiązania zadania optymalizacji odwzorowujący zmodyfikowaną metodę gradientu sprzężonego z rzutowaniem [14, 15].

Niech (Ω, F, P) będzie przestrzenią probabilistyczną, na której będą zdefiniowane wszystkie zmienne losowe. Wprowadźmy oznaczenia: N – zbiór liczb naturalnych,

R – zbiór liczb rzeczywistych, $WN(0, \sigma^2)$ – biały szum o zerowej wartości oczekiwanej i wariancji σ^2 .

2. Sformułowanie zadania optymalizacji

Załóżmy, że szafa RFID składa się z S , $S > 0$, półek na dokumenty z tagami RFID. Niech $S = \{1, \dots, S\}$ będzie zbiorem numerów półek. Niech m_s , $m_s \geq 0$, będzie liczbą wolnych miejsc na dokumenty na półce o numerze s , $s \in S$.

Niech x_s , $0 \leq x_s \leq m_s$, będzie liczbą dokumentów składowanych na półce o numerze s . Przyjmiemy, że w szafie ma być składowanych D , $D > 0$, dokumentów.

Niech $D = \{1, \dots, D\}$ będzie zbiorem numerów tych dokumentów. Problem polega na takim rozmieszczeniu dokumentów ze zbioru D , aby minimalizować długość przedziału czasu ich archiwizacji. Niech $y \in R$ oznacza długość tego przedziału.

Rozważany problem można sformułować w postaci zadania optymalizacji o postaci:

$$f(\hat{\mathbf{x}}) = \min_{\mathbf{x} \in \mathbf{X}_0} f(\mathbf{x}), \quad (1)$$

gdzie:

- $f: R^S \rightarrow R$ jest funkcją kryterialną o nieznannej explicite postaci, której wartości interpretuje się jako długości przedziałów czasu archiwizacji danych o dokumentach ze zbioru D ;
- \mathbf{X}_0 jest zbiorem rozwiązań dopuszczalnych o postaci

$$\mathbf{X}_0 = \{x \in R^S : x \geq 0, g(x) \leq 0, g_{s+1}(x) = 0\}, \quad (2)$$

oraz $\mathbf{g}(\mathbf{x}) = [g_1(\mathbf{x}), g_2(\mathbf{x}), \dots, g_S(\mathbf{x})]^T$ jest wektorową funkcją ograniczeń, przy czym

$g_s: R^S \rightarrow R$ jest funkcją ograniczeń o postaci $g_s(\mathbf{x}) = \mathbf{x}^T \mathbf{a}_s - m_s$, $\mathbf{a}_s = \begin{bmatrix} 0, \dots, 0, 1, 0, \dots, 0 \\ s \end{bmatrix}$

dla $s \in S$; $g_{s+1}: R^S \rightarrow R$ jest funkcją ograniczeń o postaci $g_{s+1}(\mathbf{x}) = D - \mathbf{x}^T \mathbf{1}$, gdzie $\mathbf{1}$ jest wektorem jednostkowym.

Lemat 1. Jeżeli $\sum_{s \in S} m_s \geq D$, $m_s \geq 0$, $s \in S$, $D > 0$, to zbiór rozwiązań dopuszczalnych \mathbf{X}_0 (2) jest niepusty, domknięty i wypukły.

Dowód. Zbiór \mathbf{X}_0 jest domknięty, gdyż funkcje $\mathbf{x}^T \mathbf{a}_s \leq m_s$, $m_s \geq 0$, $s \in S$, ograniczają go od góry, natomiast ograniczenia $\mathbf{x} \geq \mathbf{0}$ i $\mathbf{x}^T \mathbf{1} \geq D$ limitują ten zbiór od dołu. Zbiór \mathbf{X}_0 jest niepusty, ponieważ jeżeli $\sum_{s \in S} m_s \geq D$ oraz $m_s \geq 0$, $s \in S$, $D > 0$, to zbiór \mathbf{X}_0 zawiera punkty $\mathbf{x} \geq \mathbf{0}$ spełniające ograniczenia $\mathbf{x}^T \mathbf{a}_s \leq m_s$, $s \in S$. Wypukłość zbioru \mathbf{X}_0 wynika z faktu, że wszystkie ograniczenia są liniowe. ■

3. Sformułowanie zadania optymalizacji

Zadanie (1) jest nieliniowym zadaniem programowania matematycznego z ograniczeniami liniowymi. Jeżeli odwzorowanie $f : R^s \rightarrow R$ jest różniczkowalne oraz zbiór \mathbf{X}_0 jest domknięty i wypukły, to zadanie to można rozwiązać przy pomocy zmodyfikowanej metody gradientu sprzężonego z rzutowaniem. Metoda ta polega na generowaniu ciągu przybliżeń:

$$\mathbf{x}^{k+1} = \mathbf{x}^k + \tau_k \mathbf{d}^k, \quad K = 0, 1, 2, \dots \quad (3)$$

gdzie: $\mathbf{x}^0 \in \mathbf{X}_0$ jest ustalonym punktem początkowym, $\tau_k > 0$ jest długością k-tego kroku, a $\mathbf{d}^k \in R^s$, jest kierunkiem, w którym jest poszukiwane minimum funkcji celu f . Ponieważ postać tej funkcji nie jest znana, to należy przeprowadzić eksperyment symulacyjny, którego celem jest zgromadzenie danych statystycznych, na podstawie których możliwe będzie wykonanie lokalnej aproksymacji funkcji f w otoczeniu punktu \mathbf{x}^k (3), gdzie $\delta = S$. Aproksymację można przeprowadzić metodą analizy regresji.

3.1. Lokalna liniowa aproksymacja funkcji kryterialnej

Przyjmijmy, że modelem probabilistycznym procesu zmian liczby dokumentów na półce s jest zmienna losowa $\xi_s : \Omega \rightarrow R$, dla $s \in S$. Wielkość x_s interpretuje się jako realizację zmiennej losowej ξ , tj. $\xi_s = x_s$. Zatem, wartość wektora $\mathbf{x} = [x_1, x_2, \dots, x_s]^T$ interpretuje się jako realizację wielowymiarowej zmiennej losowej $\boldsymbol{\xi} = [\xi_1, \xi_2, \dots, \xi_s]^T$, tj. $\boldsymbol{\xi} = \mathbf{x}$. Przyjmijmy dalej, że modelem probabilistycznym procesu zmian długości przedziału czasu archiwizacji dokumentów ze zbioru D jest zmienna losowa $\psi : \Omega \rightarrow R$. Wielkość y interpretuje się jako realizację tej zmiennej losowej, tj. $\psi = y$.

Załóżmy, że modelem stochastycznym oddziaływań niezależnych zmiennych losowych (ang. *independent random variables*) $\xi_1, \xi_2, \dots, \xi_s$ na zależną zmienną losową (ang. *dependent random variable*) ψ jest równanie:

$$\psi = \eta(\xi_1, \xi_2, \dots, \xi_s) + \varepsilon,$$

gdzie: $\eta : R^s \rightarrow R$ jest powierzchnią odpowiedzi (ang. *response surface*), $\varepsilon \in \text{WN}(0, \sigma^2)$. Do aproksymacji funkcji η często stosuje się metodę analizy regresji.

Twierdzenie 1 (o regresji). Jeżeli $\boldsymbol{\xi}$ oraz ψ są zmiennymi losowymi określonymi na przestrzeni probabilistycznej (Ω, F, P) , przy czym $E(\psi) < \infty$, oraz jeżeli $f : R^s \rightarrow R$ jest funkcją borelowską, to błąd średniokwadratowy modelu, tzn.

$$Q(f) = E\left\{[\psi - f(\boldsymbol{\xi})]^2\right\},$$

przyjmuje wartość najmniejszą dla funkcji f określonej wzorem

$$\hat{f}(\mathbf{x}) = E(\psi | \{\xi = \mathbf{x}\}).$$

■

Funkcję \hat{f} nazywa się modelem regresyjnym zmiennej losowej ψ względem zmiennej losowej ξ .

Przyjmijmy, że nieznaną funkcją η należy do klasy funkcji H obejmującej wszystkie liniowe funkcje regresji z wektorem parametrów $\beta \in R^{p \times 1}$. Oznacza to, że powierzchnia odpowiedzi spełnia równanie $E(\psi) = \eta(\mathbf{x}, \beta)$. Główna idea metodologii powierzchni odpowiedzi (ang. *response surface methodology*) [16] polega na planowaniu eksperymentów w taki sposób, aby minimalizować błąd średniokwadratowy modelu z wektorem parametrów β .

Przyjmijmy, że w otoczeniu $\mathbf{Q}(\mathbf{x}^k, \delta)$ punktu \mathbf{x}^k (3), lokalnym modelem powierzchni odpowiedzi jest liniowa funkcja regresji o postaci

$$f^k(\mathbf{x}) = \mathbf{z}^T \beta_k, \quad \mathbf{x} \in \mathbf{Q}(\mathbf{x}^k, \delta) \quad (4)$$

gdzie: $\mathbf{z} = [1, \mathbf{x}^T]^T$, $\beta_k = [\beta_{k0}, \beta_{k1}, \dots, \beta_{ks}]^T$ jest wektorem nieznanych parametrów funkcji f^k . Oszacowanie modelu f^k polega na estymacji wektora parametrów β_k . W tym celu należy zaprojektować plan eksperymentów symulacyjnych umożliwiających zgromadzenie materiału statystycznego, na podstawie którego możliwa będzie estymacja tego wektora.

Niech

$$P_k = \begin{pmatrix} \mathbf{z}_1 & \mathbf{z}_2 & \cdots & \mathbf{z}_N \\ p_{k1} & p_{k2} & \cdots & p_{kN} \end{pmatrix}, \quad \mathbf{x} \in \mathbf{Q}(\mathbf{x}^k, \delta), \quad (5)$$

będzie unormowanym planem dyskretnym eksperymentu, gdzie: $\mathbf{z}_1, \dots, \mathbf{z}_N$ są punktami skupienia planu, w których obserwuje się realizacje zmiennej losowej ψ dla ustalonych wartości wielowymiarowej zmiennej losowej ξ , tj. $\xi_{\omega_n} = \mathbf{x}_n$, dla $n = 1, \dots, N$; p_{k1}, \dots, p_{kN} są wagami dobranymi tak, że $\sum_{n=1}^N p_{kn} = 1$. Niech $N = \{1, \dots, N\}$ będzie zbiorem numerów punktów skupienia planu P_k . Przyjmijmy, że w punktach skupienia tego planu wpływ realizacji zmiennej losowej ξ na realizacje zmiennej losowej ψ opisują równania o postaci

$$y_n = f^k(\mathbf{x}_n) + \varepsilon_n = \mathbf{z}_n^T \beta_k + \varepsilon_n, \quad n \in N, \quad (6)$$

gdzie: y_n jest zaobserwowaną długością przedziału czasu archiwizacji danych o D dokumentach rozlokowanych na półkach szafy RFID w sposób określony przez wartość wektora \mathbf{x}_n , $\mathbf{x}_n \in \mathbf{Q}(\mathbf{x}^k, \delta)$; $\mathbf{z}_n = [1, \mathbf{x}_n^T]^T$; $\varepsilon \in WN(0, \delta^2)$.

Poszukujemy liniowego modelu regresyjnego \hat{f}^k układu (6) o postaci

$$\hat{y}_n = \hat{f}^k(\mathbf{x}_n) = \mathbf{z}_n^T \mathbf{b}_k, \quad n \in N, \quad (7)$$

gdzie $\mathbf{b}_k = [b_{k0}, b_{k1}, \dots, b_{kS}]^T$. Jak można zauważyć, model \hat{f}^k jest strukturalnie zgodny z funkcją f^k (7).

Równania (6) zapiszmy w postaci macierzowej:

$$\mathbf{y} = \mathbf{Z}\mathbf{b}_k + \boldsymbol{\varepsilon},$$

gdzie:

$$\mathbf{y} = [y_1, \dots, y_N] \in R^{N \times 1},$$

$$\mathbf{Z} = [\mathbf{Z}_1^T, \dots, \mathbf{Z}_N^T] \in R^{N \times (S+1)},$$

$$\boldsymbol{\varepsilon} = [\varepsilon_1, \dots, \varepsilon_N] \in R^{N \times 1}.$$

Z kolei równania (7) przyjmują następującą postać macierzową

$$\hat{\mathbf{y}} = \mathbf{Z}\mathbf{b}_k,$$

gdzie: $\hat{\mathbf{y}} = [\hat{y}_1, \dots, \hat{y}_N]^T \in R^{N \times 1}$. Macierz \mathbf{Z} jest nazywana planem eksperymentu.

Problem oszacowania modelu \hat{f}^k sprowadza się do zagadnienia estymacji wektora parametrów $\hat{\mathbf{b}}_k$ minimalizującego sumę kwadratów błędów modelu $\mathbf{e} = \mathbf{y} - \mathbf{Z}\mathbf{b}_k$. Zagadnienie to można sformułować jako zadanie optymalizacji o postaci

$$q(\hat{\mathbf{b}}_k) = \min_{\mathbf{b}_k \in R^{(S+1)}} [q(\mathbf{b}_k) = \mathbf{e}^T \mathbf{e}]. \quad (8)$$

Zadanie (8) jest liniowym zadaniem najmniejszych kwadratów [9–11]. Minimalizowaną sumę kwadratów błędów zapiszmy w postaci

$$\begin{aligned} q(\mathbf{b}_k) &= (\mathbf{y} - \mathbf{Z}\mathbf{b}_k)^T (\mathbf{y} - \mathbf{Z}\mathbf{b}_k) \\ &= \mathbf{y}^T \mathbf{y} - \mathbf{y}^T \mathbf{Z}\mathbf{b}_k - \mathbf{b}_k^T \mathbf{Z}^T \mathbf{y} + \mathbf{b}_k^T \mathbf{Z}^T \mathbf{Z}\mathbf{b}_k \\ &= \mathbf{y}^T \mathbf{y} - 2\mathbf{b}_k^T \mathbf{Z}^T \mathbf{y} + \mathbf{b}_k^T \mathbf{Z}^T \mathbf{Z}\mathbf{b}_k. \end{aligned}$$

Różniczkując funkcję q względem wektora \mathbf{b}_k mamy:

$$\frac{\partial q(\mathbf{b}_k)}{\partial \mathbf{b}_k} = -2\mathbf{Z}^T \mathbf{y} + 2\mathbf{Z}^T \mathbf{Z}\mathbf{b}_k.$$

Z powyższego wzoru otrzymujemy układ równań normalnych:

$$\mathbf{Z}^T \mathbf{Z}\mathbf{b}_k = \mathbf{Z}^T \mathbf{y}.$$

Jeżeli macierz $\mathbf{Z}^T \mathbf{Z}$ jest nieosobliwa, to rozwiązaniem zadania (8) jest estymator o postaci

$$\hat{\mathbf{b}}_k = (\mathbf{Z}^T \mathbf{Z})^{-1} \mathbf{Z}^T \mathbf{y}. \quad (9)$$

W celu uproszczenia estymacji wektora parametrów $\hat{\mathbf{b}}_k$ (9) często wykorzystuje się metodę planowania dwupoziomowego całkowitego [13]. W tej metodzie przyjmuje się, że liczba punktów skupienia N planu P_k (5) wynosi $N = 2^S$, a składowe planu eksperymentu przyjmują wartości ze zbioru $\{-1, 1\}$. Niech $\mathbf{U} = [u_{ij}]_{N \times (S+1)}$ będzie planem eksperymentu, której składowe u_{ij} , $i = 1, \dots, N$, $j = 1, \dots, S+1$, przybierają wartości z tego zbioru. Na rysunku 1 przedstawiono postać macierzy \mathbf{U} dla $S = 3$.

$$\mathbf{U} = \begin{bmatrix} 1 & -1 & -1 & -1 \\ 1 & 1 & -1 & -1 \\ 1 & -1 & 1 & -1 \\ 1 & 1 & 1 & -1 \\ 1 & -1 & -1 & 1 \\ 1 & 1 & -1 & 1 \\ 1 & -1 & 1 & 1 \\ 1 & 1 & 1 & 1 \end{bmatrix}$$

Rys. 1. Przykładowy plan eksperymentu

Dla planu \mathbf{U} odpowiednikiem estymatora $\hat{\mathbf{b}}_k$ (9) jest estymator $\hat{\mathbf{a}}_k$ o postaci

$$\hat{\mathbf{a}}_k = (\mathbf{U}^T \mathbf{U})^{-1} \mathbf{U}^T \mathbf{y}, \quad (10)$$

gdzie: $\hat{\mathbf{a}}_k = [\hat{a}_{k0}, \hat{a}_{k1}, \dots, \hat{a}_{kS}]^T$, przy czym składowe $\hat{a}_{k1}, \hat{a}_{k2}, \dots, \hat{a}_{kS}$ tego wektora są równe odpowiednim składowym wektora $\hat{\mathbf{b}}_k$, tj., $\hat{a}_{ks} = \hat{b}_{ks}$, dla $s = 1, \dots, S$. Ponieważ macierz kowariancji $(\mathbf{U}^T \mathbf{U})^{-1}$ wynosi

$$(\mathbf{U}^T \mathbf{U})^{-1} = \frac{1}{N} \mathbf{I}_S,$$

to estymator (10) przybiera następującą ostateczną postać

$$\hat{\mathbf{a}}_k = \frac{1}{N} \mathbf{U}^T \mathbf{y}, \quad (11)$$

gdzie \mathbf{I}_S jest pewną $S \times S$ macierzą identyfikacji.

3.2. Rozwiązanie zadania optymalizacji

Wektor $\hat{\mathbf{a}}_k = [\hat{a}_{k0}, \hat{a}_{k1}, \dots, \hat{a}_{kS}]^T$ (11) zapiszmy w postaci $\hat{\mathbf{a}}_k = [\hat{a}_{k0}, \hat{\mathbf{c}}_k^T]^T$, gdzie $\hat{\mathbf{c}}_k = [\hat{a}_{k1}, \dots, \hat{a}_{kS}]^T$.

Jak można zauważyć, gradient funkcji \hat{f}^k (4) przybiera w punkcie \mathbf{x}^k następującą postać:

$$\nabla \hat{f}^k(\mathbf{x}^k) = \hat{\mathbf{c}}_k.$$

Zastosowanie algorytmu (3) do rozwiązania zadania (1) wymaga wyodrębnienia zbioru ograniczeń aktywnych w punkcie \mathbf{x}^k , który jest określony przez zbiór indeksów

$$A(\mathbf{x}^k) = \{i \in \{1, 2, \dots, S+1\} : \mathbf{e}_i^T \mathbf{x}^k = n_i\},$$

gdzie:

$$\mathbf{e}_i = \begin{cases} \mathbf{a}_i, & \text{dla } 1 \leq i \leq S, \\ \mathbf{1}, & \text{dla } i = S+1, \end{cases}$$

$$n_i = \begin{cases} m_i, & \text{dla } 1 \leq i \leq S, \\ D, & \text{dla } i = S+1. \end{cases}$$

Na podstawie zbioru $A(\mathbf{x}^k)$ konstruuje się macierz $\tilde{\mathbf{A}}_k$, której wierszami są wektory \mathbf{e}_i , dla $i \in A(\mathbf{x}^k)$. Następnie tworzy się macierz \mathbf{A}_k ograniczeń istotnie aktywnych w punkcie \mathbf{x}^k w ten sposób, że z macierzy $\tilde{\mathbf{A}}_k$ usuwa się wiersze liniowo zależne od pozostałych.

Kierunek \mathbf{d}^k (3) oblicza się ze wzoru:

$$\mathbf{d}^k = \begin{cases} -\mathbf{w}^k + \beta_k \mathbf{d}^{k-1}, & \text{dla } k > 0, \\ -\mathbf{w}^k, & \text{dla } k = 0, \end{cases}$$

gdzie:

- β_k jest współczynnikiem określonym przez formułę

$$\beta_k = \begin{cases} 0, & \text{dla } k = 0, \\ \frac{(\mathbf{w}^k)^T (\mathbf{w}^k - \mathbf{w}^{k-1})}{\|\mathbf{w}^{k-1}\|^2}, & \text{dla } k > 0, \end{cases}$$

- \mathbf{w}^k jest wektorem definiowanym przez

$$\mathbf{w}^k = \begin{cases} \nabla \hat{f}^k(\mathbf{x}^k), & \text{dla } k = 0, \\ \mathbf{P}_k \nabla \hat{f}^k(\mathbf{x}^k), & \text{dla } k > 0, \end{cases}$$

- \mathbf{P}_k jest rzutem ortogonalnym macierzy w postaci

$$\mathbf{P}_k = \mathbf{I}_S - \mathbf{A}_k^T (\mathbf{A}_k \mathbf{A}_k^T)^{-1} \mathbf{A}_k.$$

Ponowne stosowanie powyższej procedury, polegającej na stosowaniu podstawienia $\mathbf{d}^k = \mathbf{w}^k$, przeprowadza się w następujących przypadkach:

- \mathbf{d}^k nie jest kierunkiem malenia wartości funkcji f^k ,
- kiedy macierz \mathbf{A}_k jest zmieniona, to jest kiedy $\mathbf{A}_k \neq \mathbf{A}_{k-1}$,

- jeśli od poprzedniego cyklu było $S - \text{rank}(A_k)$ iteracji.

Podstawowym kryterium zakończenia powyższej procedury jest to, gdy normą wektora \mathbf{w}^k osiąga wartość zerową, z dokładnością $\varepsilon > 0$, to znaczy $\|\mathbf{w}^k\| \leq \varepsilon$.

Przykład. Rozważmy zagadnienie optymalizacji rozmieszczenia dokumentów z tagami RFID w szafie wyposażonej w $S = 4$ półki na dokumenty. Liczby wolnych miejsc na poszczególnych półkach wynoszą: $m_1 = 100$, $m_2 = 10$, $m_3 = 5$, $m_4 = 40$. Załóżmy, że w szafie należy rozmieścić $D = 100$ dokumentów z tagami RFID. Na podstawie przeprowadzonych badań symulacyjnych oraz stosując algorytm optymalizacji opisany w punkcie 6, otrzymano dla $\mathbf{x}^0 = [50, 50, 50, 50]^T$ rozwiązanie o postaci $\hat{\mathbf{x}} = [45, 10, 5, 40]^T$.

4. Podsumowanie i kierunki dalszych prac

W pracy omówiono podejście optymalizacyjne do zagadnienia rozmieszczania dokumentów w szafie RFID. Ponieważ postać funkcji kryterialnej nie jest explicite znana, to w celu rozwiązania zadania optymalizacji zastosowano metodę symulacji komputerowej, której celem jest wygenerowanie danych o długościach przedziałów czasu archiwizacji danych o dokumentach z tagami RFID. Na podstawie tych danych przeprowadzono lokalną liniową aproksymację funkcji celu wykorzystując metodę analizy regresji. Metoda ta wymaga między innymi opracowania planów eksperymentów symulacyjnych. W tym zakresie zastosowano technikę planowania dwupoziomowego całkowitego.

Kierunki dalszych prac powinny dotyczyć, ważnych z praktycznego punktu widzenia, zagadnień grupowania dokumentów oraz ich przemieszczania między różnymi szafami RFID. Do rozwiązania tych problemów można zastosować metody opracowane do rozwiązania problemu alokacji obiektów (ang. *facility location problem*) [17–19].

LITERATURA

- [1] Hunt V.D., Puglia A., Puglia M., *RFID: A Guide to Radio Frequency Identification*, Wiley-Blackwell, 2007.
- [2] Heinrich C., *RFID and Beyond: Growing Your Business Through Real World Awareness*, Wiley Publishing, Indianapolis, 2005.
- [3] Zangwill W.I., *Nonlinear Programming: A Unified Approach*, Prentice Hall, Englewood Cliffs, N.J., 1969.
- [4] Polak E., *Computational Methods in Optimization: A Unified Approach*, Academic Press, 1971.
- [5] Fishman G.S., *Discrete-Event Simulation: Modeling, Programming, and Analysis*, Springer-Verlag, Berlin, 2001.
- [6] Wainer G.A., Mosterman P.J. (Eds.), *Discrete-Event Modeling and Simulation: Theory and Applications*, CRC Press, 2010.
- [7] Kleijnen P.C., *Design and Analysis of Simulation Experiments*, Springer, 2010.

- [8] Zeigler B., Sarjoughian H.S., *Guide to Modeling and Simulation of Systems of Systems*, Springer, 2012.
- [9] Box G.E.P., Jenkins G.M., Reinsel G.C., *Time Series Analysis. Forecasting and Control*, John Willey and Sons, 2008.
- [10] Fan J., Yao Q., *Nonlinear Time Series. Nonparametric and Parametric Methods*, Springer-Verlag Inc., 2003.
- [11] Ljung L., *System Identification. Theory for the User*, PTR Prentice Hall, 1999.
- [12] Pukelsheim F., *Optimal Design of Experiments*, Society for Industrial & Applied Mathematics, Philadelphia 2006.
- [13] Morris M., *Design of Experiments: An Introduction Based on Linear Models*, Chapman & Hall/CRC Texts in Statistical Science, 2010.
- [14] Bhatti M.A., *Practical Optimization Methods with Mathematica Applications*. Springer-Verlag Inc., 2000.
- [15] Calamai P.H., Moré J.J., „Projected Gradient Methods for Linearly Constrained Problems”, *Mathematical Programming*, Vol. 39, Issue 1, 93–116 (1987).
- [16] Box G.E.P., Norman R.D., *Response Surfaces, Mixtures, and Ridge Analyses*, Wiley Series in Probability and Statistics, Wiley-Blackwell, 2007.
- [17] Eiman J. Alenezzy, *Models and Algorithms for the Capacitated Facility Location Problem: Basics. Concepts. Methods*, LAP LAMBERT Academic Publishing, 2014.
- [18] Vijeyamurthy Ch.N., *Genetic Algorithm for Facility Location Problem*, LAP LAMBERT Academic Publishing, 2013.
- [19] Martin R., *Facility Location and Related Problems*, Südwestdeutscher Verlag für Hochschulschriften, 2009.