

1 Zrewidowany algorytm sympleks

Rozważmy zadanie programowania liniowego w postaci standardowej

$$\mathbb{X} = \begin{cases} \min \mathbf{c}^T \mathbf{x} \\ \mathbf{A}\mathbf{x} = \mathbf{b} \\ \mathbf{x} \geq \mathbf{0}, \end{cases} \quad (1)$$

gdzie $\mathbf{c} \in \mathbb{R}^n$, $\mathbf{A} \in \mathbb{R}^{m \times n}$, $m \leq n$, $\mathbf{b} \in \mathbb{R}^m$, $\mathbf{b} \geq \mathbf{0}$ a $\mathbf{x} \in \mathbb{R}^n$ wektorem zmiennych decyzyjnych.

Przypomnijmy szkic (prymalnego) algorytmu sympleks. Niech \mathbf{B} będzie bazą, $\mathbf{x}^{\mathbf{B}} = \mathbf{B}^{-1}\mathbf{b}$ a $\mathbf{x}^T = [\mathbf{x}^{\mathbf{B}}, \mathbf{0}]$ będzie rozwiązaniem bazowym zadania prymalnego (1). Takie rozwiązanie może być, np. wyznaczone za pomocą metody dwóch faz. Niech $J_{\mathbf{B}}$ będzie zbiorem indeksów kolumn (zmiennych) bazowych. Załóżmy, że $J_{\mathbf{B}}$ jest uporządkowany (zapewnienie, że algorytm sympleks skończy działanie - nie wpadnie w cykl, zob. twierdzenie 3, wykłady nr 4 i 5).

Krok 0 Oblicz \mathbf{y}^j przedstawienia kolumn \mathbf{A}_j w bazie \mathbf{B} , $\mathbf{y}^j = \mathbf{B}^{-1}\mathbf{A}_j$.

Krok 1 Sprawdź kryterium optymalności, tj. $(\forall j \notin J_{\mathbf{B}})(c_j - (\mathbf{c}^{\mathbf{B}})^T \mathbf{y}^j \geq 0)$. Jeśli kryterium jest spełnione, to STOP \mathbf{x} jest rozwiązaniem optymalnym.

W przeciwnym przypadku wybierz kolumnę \mathbf{A}_j taką, że $k \notin J_{\mathbf{B}}$ i $c_k - (\mathbf{c}^{\mathbf{B}})^T \mathbf{y}^k < 0$, która wchodzi i do bazy (lub zmienna x_k).

Krok 2 Wybierz kolumnę \mathbf{B}_{i^*} (zmienną x_{i^*}) wychodzącą z bazy \mathbf{B} ,

$$\frac{x_{i^*}^{\mathbf{B}}}{y_{i^*}^k} = \min \left\{ \frac{x_i^{\mathbf{B}}}{y_i^k} : y_i^k > 0, i \in J_{\mathbf{B}} \right\}.$$

Jeśli $\mathbf{y}^k \leq \mathbf{0}$, wówczas nie ma rozwiązania optymalnego skończonego, STOP.

Krok 3 Uaktualnij: $J_{\mathbf{B}}$, rozwiązanie bazowe $\bar{\mathbf{x}}$, bazę $\bar{\mathbf{B}}$ i $\bar{\mathbf{y}}^j$ przedstawienia kolumn macierzy w bazie $\bar{\mathbf{B}}$

$\mathbf{B} := \bar{\mathbf{B}}$, $\mathbf{x} := \bar{\mathbf{x}}$, $\mathbf{y}^j := \bar{\mathbf{y}}^j$. Idź do Krok 1.

W powyższym algorytmie wymagane jest uaktualnienie $(m+1) \times (n+1)$ elementów tablicy sympleksowej. Główny wysiłek obliczeniowy jest w Kroku 1 i Kroku 3. Okazuje się, że

- możemy uaktualniać tylko $(m+1) \times (m+1)$ elementów tablicy sympleksowej - kluczem jest posiadanie informacji o \mathbf{B}^{-1} . Mając informacje o odwrotności macierzy bazowej możemy wyznaczyć $\mathbf{x}^{\mathbf{B}}$, \mathbf{y}^j przedstawienia kolumn macierzy \mathbf{A} w bazie \mathbf{B} , wskaźniki optymalności:

$$c_j - z_j = c_j - (\mathbf{c}^{\mathbf{B}})^T \mathbf{y}^j = c_j - (\mathbf{c}^{\mathbf{B}})^T \mathbf{B}^{-1} \mathbf{A}_j = c_j - \boldsymbol{\pi}^T \mathbf{A}_j;$$

- możemy wyznaczać wskaźniki optymalności (Krok 1) tak długo aż znajdziemy pierwszą kolumnę $k \notin J_{\mathbf{B}}$, dla której $c_j - (\mathbf{c}^{\mathbf{B}})^T \mathbf{y}^j < 0$ i przerwac przeszukiwanie - wiemy wtedy, że aktualne rozwiązanie nie jest optymalne.

Zatem możemy wyznaczać wskaźniki optymalności i \mathbf{y}^j tylko wtedy kiedy potrzeba.

Biorąc pod uwagę powyższe spostrzeżenia nowy, *zrewidowany*, algorytm sympleks w każdej iteracji będzie tylko pamiętał \mathbf{B}^{-1} , $\mathbf{x}^{\mathbf{B}}$, $\boldsymbol{\pi}$ i wartość funkcji celu $(\mathbf{c}^{\mathbf{B}})^T \mathbf{x}^{\mathbf{B}}$.

Założmy, że pierwsza tablica simpleksowa zawiera macierz jednostkową \mathbf{I} , która znajduje się po lewej stronie (w pierwszych m kolumnach). Zatem mamy początkową bazę $\mathbf{B} = \mathbf{I}$ i $\mathbf{x}^{\mathbf{B}} = \mathbf{b}$. Ponadto zakładamy, że współczynniki funkcji celu zmiennych odpowiadającym kolumnom macierzy jednostkowej są równe zero. W dalszej części tego wykładu pokażemy jak spełnić ten warunek. Tę lewą część tablicy sympleksowej, z macierzą \mathbf{I} , nazwiemy $\text{CARRY}^{(0)}$ (początkowa tablica), która zawiera $(m+1) \times (m+1)$ elementów (zob. tabela 1). W kolejnych iteracjach zrewidowany algorytm będzie uaktualniał tylko tablicę CARRY . Tablica w iteracji r , $\text{CARRY}^{(r)}$, jest przedstawiona w tabeli 1.

Tabela 1: Początkowa tablica $\text{CARRY}^{(0)}$ i tablica $\text{CARRY}^{(r)}$ w iteracji r algorytmu zrewidowanego.

$\text{CARRY}^{(0)}$		\longrightarrow	$\text{CARRY}^{(r)}$	
$\mathbf{x}^{\mathbf{B}}$	\mathbf{I}		$\mathbf{x}^{\mathbf{B}}$	\mathbf{B}^{-1}
$(\mathbf{c}^{\mathbf{B}})^T \mathbf{x}^{\mathbf{B}}$	0 0 ... 0 0		$(\mathbf{c}^{\mathbf{B}})^T \mathbf{x}^{\mathbf{B}}$	$-\boldsymbol{\pi}$

Szkic

Przedstawimy teraz kluczowy fragment zrewidowanego algorytmu sympleks. Okazuje się, że zrewidowany algorytm potrzebuje następujących informacji: tablicę zawierającą oryginalną macierz \mathbf{A} , informację o kolumnach bazowych $J_{\mathbf{B}}$ oraz aktualną tablicę $\text{CARRY}^{(r)}$.

Krok 1 (Pricing operation) Obliczaj wskaźniki optymalności $c_j - \boldsymbol{\pi}^T \mathbf{A}_j$ dla kolumn niebazowych $j \notin J_{\mathbf{B}}$ aż znajdzie się kolumna $k \notin J_{\mathbf{B}}$, dla której $c_k - \boldsymbol{\pi}^T \mathbf{A}_k < 0$ (kolumna \mathbf{A}_k wchodzi do bazy, rozwiązanie nie jest optymalne). Jeśli $(\forall j \notin J_{\mathbf{B}})(c_j - (\mathbf{c}^{\mathbf{B}})^T \mathbf{y}^j \geq 0)$, to aktualne rozwiązanie jest optymalne, STOP.

Krok 2 (Column generation) Oblicz przestawienie $\mathbf{y}^k = \mathbf{B}^{-1}\mathbf{A}_k$ kolumny \mathbf{A}_k w bazie. Jeśli $k \in [m]$, to przedstawienie jest już obliczone i jest zapamiętane w $\text{CARRY}^{(r)}$.

Wybierz kolumnę \mathbf{B}_{i^*} (zmienną x_{i^*}) wychodzącą z bazy \mathbf{B} ,

$$\frac{x_{i^*}^{\mathbf{B}}}{y_{i^*}^k} = \min \left\{ \frac{x_i^{\mathbf{B}}}{y_i^k} : y_i^k > 0, i \in J_{\mathbf{B}} \right\}.$$

Jeśli $\mathbf{y}^k \leq \mathbf{0}$, wówczas nie ma rozwiązania optymalnego skończonego, STOP.

Krok 3 Uaktualnij $\text{CARRY}^{(r)}$ aby otrzymać $\text{CARRY}^{(r+1)}$. Uaktualnienie dokonujemy tak jak dla algorytmu sympleks korzystając z policzonego już przedstawienia \mathbf{y}^k .

Krok 4 (Update basis) Uaktualnij indeksy kolumn należących do bazy $J_{\mathbf{B}}$ (indeksy są uporządkowane).

Kluczowym krokiem jest Krok 2: mając \mathbf{B}^{-1} mamy wystarczającą ilość informacji, aby wygenerować każdy element tablicy sympleksowej.

Główne zalety zrewidowanej wersji algorytmu

- Nie obliczamy wszystkich wskaźników optymalności odpowiadającym kolumnom niebazowym. Wybieramy pierwszą, dla której wskaźnik jest ujemny. Ponieważ $J_{\mathbf{B}}$ jest uporządkowany spełniamy założenie twierdzenia 3 (zob. wykłady nr 4 i 5), które zapewnia, że algorytm sympleks wykonuje skończoną liczbę kroków.
- Krok 1, czyli obliczanie wskaźników, korzysta z oryginalnych kolumn macierzy \mathbf{A} . W wielu przypadkach macierz ograniczeń jest macierzą rzadką (zawiera dużo elementów zerowych), np. w zagadnieniach sieciowych (problem najkrótszej ścieżki, problem maksymalnego przepływu). W tym przypadku możliwa jest redukcja złożoności obliczeniowej i pamięciowej.

Metoda dwóch faz dla zrewidowanego algorytmu

Jak już wiemy metoda dwóch faz służy do wyznaczenia początkowego rozwiązania bazowego dopuszczalnego i polega na rozwiązaniu w pierwszej fazie, za pomocą algorytmu sympleks, następującego problemu programowania liniowego:

$$\begin{aligned} \min \quad & \sum_{i \in [m]} 1 x_i^A \\ \left\{ \begin{array}{l} \mathbf{I} \mathbf{x}^A + \mathbf{A} \mathbf{x} = \mathbf{b} \\ \mathbf{x} \geq \mathbf{0} \\ \mathbf{x}^A \geq \mathbf{0}, \end{array} \right. & \quad (2) \end{aligned}$$

gdzie $\mathbf{x}^A \in \mathbb{R}^m$ jest wektorem sztucznych zmiennych. Aby zastosować zrewidowany algorytm sympleks do zadania (2) musimy zmodyfikować to zadanie i skonstruować równoważne. Zauważ, że współczynniki funkcji celu odpowiadające kolumnom macierzy jednostkowej (przy zmiennych sztucznych) są równe 1, a powinny być równe 0. Wystarczy od funkcji celu (wiersza zerowego) odjąć wszystkie wiersze macierzy $\mathbf{I}\mathbf{x}^A + \mathbf{A}\mathbf{x}$. Otrzymujemy następujące zadanie programowania liniowego:

$$\begin{cases} \min \sum_{i \in [m]} 0 x_i^A - \sum_{i \in [m]} a_{i1} x_1 - \cdots - \sum_{i \in [m]} a_{in} x_n \\ \mathbf{I}\mathbf{x}^A + \mathbf{A}\mathbf{x} = \mathbf{b} \\ \mathbf{x} \geq \mathbf{0} \\ \mathbf{x}^A \geq \mathbf{0}, \end{cases} \quad (3)$$

gdzie $d_j = -\sum_{i \in [m]} a_{ij}$ są współczynnikami funkcji celu oryginalnych zmiennych decyzyjnych x_j , $j \in [n]$, rozwiązywanego w pierwszej fazie zadania (3) za pomocą zrewidowanego algorytmu sympleks a wskaźniki optymalności odpowiadające kolumnom oryginalnych zmiennych są postaci: $d_j - \boldsymbol{\pi}^T \mathbf{A}_j$, $j \in [n]$.

W drugiej fazie wracamy do oryginalnych współczynników c_j zmiennych x_j oraz generujemy $-\boldsymbol{\pi}^T = -(\mathbf{c}^B)^T \mathbf{B}^{-1}$ (współczynniki funkcji celu zmiennych sztucznych są zerowe). Zauważ, że $-\boldsymbol{\pi}^T$ jest wskaźnikiem optymalności kolumn odpowiadających macierzy jednostkowej (zmiennych sztucznych), $-\pi_j = 0 - (\mathbf{c}^B)^T \mathbf{B}^{-1} \mathbf{e}_j$.

Postać iloczynowa macierzy odwrotnej \mathbf{B}^{-1}

Wspomniemy jeszcze o jednym udoskonaleniu algorytmu sympleks, czyli sposobie pamiętania informacji o macierzy \mathbf{B}^{-1} w kolejnych iteracjach. Zauważmy, że macierz bazowa \mathbf{B} różni się tylko jedną kolumną od macierzy bazowej w kolejnej iteracji $\bar{\mathbf{B}}$. Zatem niewielkie modyfikacje macierzy odwrotnych w kolejnych iteracjach algorytmu wykonuje się za pomocą przekształceń elementarnych zastosowanych do \mathbf{B}^{-1} . Mianowicie, jeśli \mathbf{B}^{-1} jest aktualną odwrotnością macierzy bazowej, to odwrotność $\bar{\mathbf{B}}^{-1}$ w kolejnej iteracji wyznaczana jest następująco:

$$\bar{\mathbf{B}}^{-1} = \mathbf{E}\mathbf{B}^{-1},$$

gdzie \mathbf{E} jest macierzą przekształcenia (kolumna \mathbf{A}_k wchodzi do bazy, kolumna \mathbf{A}_{i^*} wychodzi z bazy) jest postaci:

$$\mathbf{E} = \begin{bmatrix} 1 & & \eta_1 & 0 & \cdots & 0 \\ & \ddots & & & & \\ & & \eta_{i^*} & 0 & & \\ & & \eta_{i^*+1} & 1 & & \\ & & \vdots & & \ddots & \\ 0 & \cdots & \eta_m & 0 & & 1 \end{bmatrix}$$

a

$$\boldsymbol{\eta}^T = \left[-\frac{y_1^k}{y_{i^*}^k}, \dots, -\frac{y_{i^*-1}^k}{y_{i^*}^k}, \frac{1}{y_{i^*}^k}, -\frac{y_{i^*+1}^k}{y_{i^*}^k}, \dots, -\frac{y_m^k}{y_{i^*}^k} \right].$$

Zatem informacja o przejściu z \mathbf{B}^{-1} do $\overline{\mathbf{B}}^{-1}$ pamiętana jest za pomocą \mathbf{E} lub oszczędniej za pomocą wektora $\boldsymbol{\eta}$. Jeśli założymy, że macierz bazowa w pierwszej iteracji jest równa \mathbf{I} , wówczas macierz \mathbf{B}^{-1} po r -tej iteracji możemy obliczyć

$$\mathbf{B}^{-1} = \mathbf{E}_r \mathbf{E}_{r-1} \cdots \mathbf{E}_1.$$

Jest to *postać iloczynowa macierzy odwrotnej* \mathbf{B}^{-1} . Podobnie obliczamy

$$\begin{aligned} \boldsymbol{\pi}^T &= (\cdots (((\mathbf{c}^B)^T \mathbf{E}_r) \mathbf{E}_{r-1}) \cdots) \mathbf{E}_1, \\ \mathbf{y}^k &= \mathbf{E}_r (\cdots (\mathbf{E}_2 (\mathbf{E}_1 \mathbf{A}_k)) \cdots). \end{aligned}$$

Powyższa metoda ma zastosowanie do dużych problemów z macierzami rzadkimi.

Od czasu do czasu ciąg przekształceń elementarnych może być zbyt długi, wtedy dokonuje się *reinvertacji*, jest to podyktowane względami pamięciowymi i własnościami numerycznymi (błędy numeryczne), czyli oblicza się macierz \mathbf{B}^{-1} (również \mathbf{x}^B) korzystając z oryginalnych kolumn macierzy \mathbf{A} . Następnie zastępuje się aktualny dłuższy ciąg przekształceń elementarnych krótszym, który prowadzi do macierzy \mathbf{B}^{-1} .

Uwagi na temat treści wykładu

Część wykładu została przygotowana na podstawie książek [2, 1].

Literatura

- [1] Narsingh Deo, Janusz S. Kowalik, Maciej M. Sysło. *Algorytmy optymalizacji dyskretnej z programami w języku PASCAL*. Wydawnictwa Naukowego PWN, 1999.
- [2] Christos H. Papadimitriou, Kenneth Steiglitz. *Combinatorial optimization: algorithms and complexity*. Dover Publications Inc., 1998.