

Eine Heuristik basierend auf der MILP-8
A heuristic based on the Lagrange Relaxation
für das Index Fonds Problem

$$Z := \max \sum_{i=1}^m \sum_{j=1}^n f_{ij} x_{ij}$$

und Nb

$$\sum_{j=1}^n y_j = 9$$

(Anmerkung:
ursprünglich
 $\sum_{j=1}^n y_j \leq 9$)

(P)

$$x_{ij} \leq y_j \quad \forall i, j \in \overline{1, n}$$

relaxiert

$$\rightarrow \sum_{j=1}^n x_{ij} = 1 \quad \forall i \in \overline{1, n}$$

$$x_{ij}, y_j \in \{0, 1\} \quad \forall i, j \in \overline{1, n}$$

Anmerkung: Das Problem lässt sich mit
allgemeinen Solvern (Excel, Matlab ~~CVX~~) oder
mit kommerziellen Solvern (CPLEX, GUROBI)

new für relativ kleine Werte von n

Hauptschwierigkeit: Hohe Anzahl an binären Variablen

$n^2 + n$ sowie Restriktionen $n^2 + n + 1$.

Standard Solver haben schon Probleme für $N=100$!

In praktischen Instanzen des Problems, die in Clustering-Anwen-
dungen in Datenanalyse vorkommen, gilt oft $N \approx 10^5$

Bei solche Dimensionen des Problems gibt man sich auch
mit heuristischen Lösungen zufrieden.

die Lagrange-Relaxation des Problems MILP-9 ~~(P)~~
 mit Lagrange-Multiplikatoren $u \in \mathbb{R}^n$:

$$L(u) := \max_{x,y} \sum_{i=1}^m \sum_{j=1}^m s_{ij} x_{ij} + \sum_{i=1}^m u_i \left(1 - \sum_{j=1}^n x_{ij}\right)$$

ndNb
 (\bar{P})

$$\sum_{j=1}^m y_j = 9$$

$$x_{ij} \leq y_j \quad \forall i,j \in \overline{1,n}$$

$$x_{ij}, y_j \in \{0,1\}, \quad \forall i,j \in \overline{1,n}$$

Eigenschaft 1
 Aus Proposition 4.3 folgt $L(u) \geq Z$ (Achtung
 mit maximieren!)

Eigenschaft 2 Für ein fixes $u \in \mathbb{R}^n$ lässt sich
 \bar{P} leicht lösen, wie folgt.

Reformuliere die Zielfunktion als $\rightarrow \circ \Rightarrow x_{ij} = y_j$

$$L(u) := \max \sum_{i=1}^m \sum_{j=1}^m (s_{ij} - u_i) x_{ij} + \sum_{i=1}^m u_i$$

Für ein gegebenes $y \in \mathbb{R}^m$ x_{ij} sollte entweder
 auf die obere Schraube y_j oder auf die untere
 Schraube 0 fixiert werden, je nach dem ob
 $s_{ij} - u_i > 0$ oder $s_{ij} - u_i \leq 0$ (ke breaking arbitrary).

Also lässt sich das Problem \bar{P} erneut reformulieren:

$(\bar{\bar{P}})$

$$\max \sum_{j=1}^m c_j y_j + \sum_{i=1}^m u_i$$

ndNb

$$\sum_{j=1}^m y_j = 9$$

$$y_j \in \{0,1\} \quad \forall j \in \overline{1,m}$$

gleich
geblieben

wobei $c_j := \sum_{i=1}^m \max\{0, s_{ij} - u_i\}$

Beobachtung (\bar{P}) ist trivial lösbar:

Sortiere $(c_j)_{j \in \{1, \dots, n\}}$ absteigend, d.h. $c_{j_1} \geq c_{j_2} \geq \dots \geq c_{j_n}$

und setze $y_{j_1}^* = y_{j_2}^* = \dots = y_{j_k}^* = 1$ und $y_j^* = 0, \forall j \neq j_\ell$
 $\ell \in \{1, \dots, k\}$

Dann gilt $L(u) = \sum_{j=1}^n c_{j_\ell} + \sum_{i=1}^m u_i$

Eigenschaft 3 Für Opt. Lösung von \bar{P} setze $x_{ij} = y_j \iff \begin{cases} s_{ij} - u_i > 0 \\ \text{sonst} \\ u_i = 0 \end{cases}$

Basierend auf der Optimallösung y^* von \bar{P} kann eine heuristische Lösung (x^*, y^*) von P konstruiert werden. Darüber hinaus lässt sich auch eine Abschätzung für die Qualität dieser Lösung ermitteln:

$\forall i \in \{1, \dots, m\}$, sei $j(i) \leftarrow \operatorname{argmax}_{j \in \{1, \dots, n\} : y_j = 1} s_{ij}$.

Für jedes i wird also genau ein Fonds eingewichtet. Asset $j(i)$ das die größte Ähnlichkeit zum i -ten Asset hat.

Setze dann $\forall i, j \in \{1, \dots, m\}, x_{ij}^* = \begin{cases} 1 & \text{für } j = j(i) \\ 0 & \text{sonst} \end{cases}$

(x^*, y^*) ist somit eine zulässige Lösung für P mit Ziel funktionswert $z^* = \sum_{i,j=1}^m s_{ij} x_{ij}^*$.

Für diese Lösung gilt $z^* \leq z \leq L(u) \leq L(u) - z^*$ (für jede andere zulässige Lösung von P).

D.h. Wenn $L(u) - z^*$ "klein", so ist auch $z - z^*$ klein.

In diesem Sinne kann man mit Hilfe von $L(u)$ die Güte der Lösung (x^*, y^*) bewerten.

Eigenschaft 4

Um die beste obere Schranke $L(u)$ und die dazugehörige heuristische Lösung (ermittelt wie in Eigenschaft 3) zu berechnen wird

$$\min_{u \in \mathbb{R}^n} L(u) \quad \text{gelöst.}$$

Das ist ein unrestrictiertes Minimierungsproblem mit einer konvexen, i.o. nicht differenzierbaren, Zielfunktion.

So ein Problem lässt sich mit Hilfe eines Subgradienten-Verfahrens, eine Verallgemeinerung des Newton-Verfahrens für die unrestrictierte Optimierung mit differenzierbarer Zielfunktion

Betrachten wir nun allgemein ein $f: \mathbb{R}^n \rightarrow \mathbb{R}$ konvex und ein Optimierungsproblem (unrestrictiert)

$$\min_{x \in \mathbb{R}^n} f(x)$$

Def: Ein $g \in \mathbb{R}^n$ heißt Subgradient von f in $x_0 \in \mathbb{R}^n$ falls $\forall y \in \mathbb{R}^n$

$$f(y) - f(x_0) \geq g^t (y - x_0) \quad \text{gilt.}$$

Das Subdifferential von f in x_0 , bezeichnet mit $\partial f(x_0)$, ist die Menge aller Subgradienten von f in x_0 :


$$\partial f(x_0) := \{ g \in \mathbb{R}^n : g \text{ ist Subgradient von } f \text{ in } x_0 \}$$

Das Subdifferential einer konvexen Funktion ist nicht leer in jedem Punkt $x_0 \in \mathbb{R}^n$, d.h. $\partial f(x_0) \neq \emptyset$.

Beispiel

$$f(x) = |x|, \quad f: \mathbb{R} \rightarrow \mathbb{R}$$

$$\partial f(x_0) = \begin{cases} 1 & x_0 > 0 \\ -1 & x_0 < 0 \\ [-1, 1] & x_0 = 0 \end{cases}$$



$\partial f(0)$ besteht aus den Steigungen der grünen strichierten Geraden

$x_0 = 0$

$\forall x \in \mathbb{R} \quad |x| \geq g \cdot x \Rightarrow g \in [-1, 1]$

$x_0 = 1 \quad |x| - 1 \geq g(x-1) \Rightarrow g \in \mathbb{R}$

Anmerkung:
denn gilt

falls f in x_0 differenzierbar, $\frac{df}{dx} = ?$
 $\partial f(x_0) = \{ \nabla f(x_0) \}$
 \rightarrow Gradient for f in x_0

In diesem Sinne sind Subgradienten eine Verallgemeinerung der Gradienten.

Algorithmus: Subgradienten-Verfahren (generisch)

Input: $f: \mathbb{R}^n \rightarrow \mathbb{R}$, convex

Output: eine heuristische Lösung (approximative Lösung) für $\min_{x \in \mathbb{R}^n} f(x)$

(1) Wähle $x_0 \in \mathbb{R}^n$

(2) for $i = 1, 2, \dots$ do /* bis ein Stoppkriterium erfüllt wird */

wähle $g_i \in \partial f(x_i)$

wähle $\alpha_i > 0$

/* Schrittweite */

setze $x_{i+1} = x_i - \alpha_i g_i$

end for

(3) Output the current x_i

Es gibt einige Fragen bzgl. der Implementierung dieses Algorithmus.

z.B. Wahl der Startlösung x_0

b) Wahl der Schrittweite d_i in jeder Iteration.
 Ad b) Betrachtung Ansätze wie etwa der Armijo-Goldstein Ansatz für den Algorithmus des steilsten Abstiegs funktionieren nicht im Fall von nicht differenzierbaren Funktionen.

Es gibt viele andere Ansätze in der Literatur zB ein sehr einfacher Ansatz wäre $d_i = \alpha > 0 \quad \forall i$


Ein weiterer einfacher Ansatz: wähle d_i ∞
 monoton fallend und so, dass $\sum_{i=0}^{\infty} d_i^2 < \infty$ und $\sum_{i=0}^{\infty} d_i = \infty$

Exakte Algorithmen zur Lösung gemischt-ganzzahliger linearer Optimierungsprobleme

- Branch and Bound (B&B) (Land and Doig 1960)
- Cutting Planes (CP) (Dantzig 1954 für das Rundreiseproblem)
(Gomory 1958, 1960 für allgemeine MILP)
- Kombiniertes Verfahren: Branch and Cut (Padberg and Rinvaldi 1987) (B&C)

Example

$$\begin{array}{ll}
 \max & x_1 + x_2 \\
 \text{u.d. NB} & \\
 \text{(P)} & - x_1 + x_2 \leq 2 \\
 & 8x_1 + 2x_2 \leq 19 \\
 & x_1, x_2 \geq 0 \\
 & x_1, x_2 \in \mathbb{Z}
 \end{array}$$



Die lineare Relaxation

Das

$$\begin{aligned} \max & x_1 + x_2 \\ \text{u.d.NB} & -x_1 + x_2 \leq 2 \\ & 8x_1 + 2x_2 \leq 19 \\ & x_1, x_2 \geq 0 \end{aligned}$$

(LP)

hat Opt. Lösung $\bar{x} := (1.5, 3.5)$ mit Zielfunktionswert 5.
Es gilt also $\text{Opt}_P \leq 5$.

\bar{x} ist nicht zulässig für P.

Wie können wir diese nicht-ganzzahlige Lösung des Problems ausschließen ohne ganzzahlige Lösungen, also zulässige Lösungen zu verlieren?

Branch! Erzeuge 2 neue LPs mit zusätzlichen

Restriktionen $x_1 \leq 1$ bzw. $x_1 \geq 2$.

Jede zul. Lösung von P muss eine zulässige Lösung für eines der 2 LPs LP1 und LP2.

<p>(LP1)</p> $\begin{aligned} \max & x_1 + x_2 \\ \text{u.d.NB} & -x_1 + x_2 \leq 2 \\ & 8x_1 + 2x_2 \leq 19 \\ & x_1 \leq 1 \\ & x_1, x_2 \in \mathbb{R}_+ \end{aligned}$	$\left\{ \begin{array}{l} \\ \\ \\ \\ \end{array} \right.$	<p>(LP2)</p> $\begin{aligned} \max & x_1 + x_2 \\ \text{u.d.NB} & -x_1 + x_2 \leq 2 \\ & 8x_1 + 2x_2 \leq 19 \\ & x_1 \geq 2 \\ & x_1, x_2 \in \mathbb{R}_+ \end{aligned}$
--	--	--

Opt. Lösung von LP1 : $\bar{x} = (1; 3)$ mit Zielfunkt.wert 4

Diese Lösung ist auch zulässig für P.

D.h. jetzt haben wir auch eine untere Schranke für Opt_P : $LB := 4 \leq \text{Opt}_P \leq 5 =: UB$

Opt. Lösung von LP2 : $\bar{x} = (2; 1, 5)$ mit Zielfunkt.wert = 3,5

Achtung: 3,5 ist kleiner als die vorhandene untere Schranke $LB = 4$ für Opt_P, und im zulässigen Bereich des LP2 können keine Lösungen von P mit einem besseren Zielfunkt.wert

als 3,5 vorkommen. Also braucht man nicht weiter

nach der Opt. Lösung von P im zulässigen Bereich

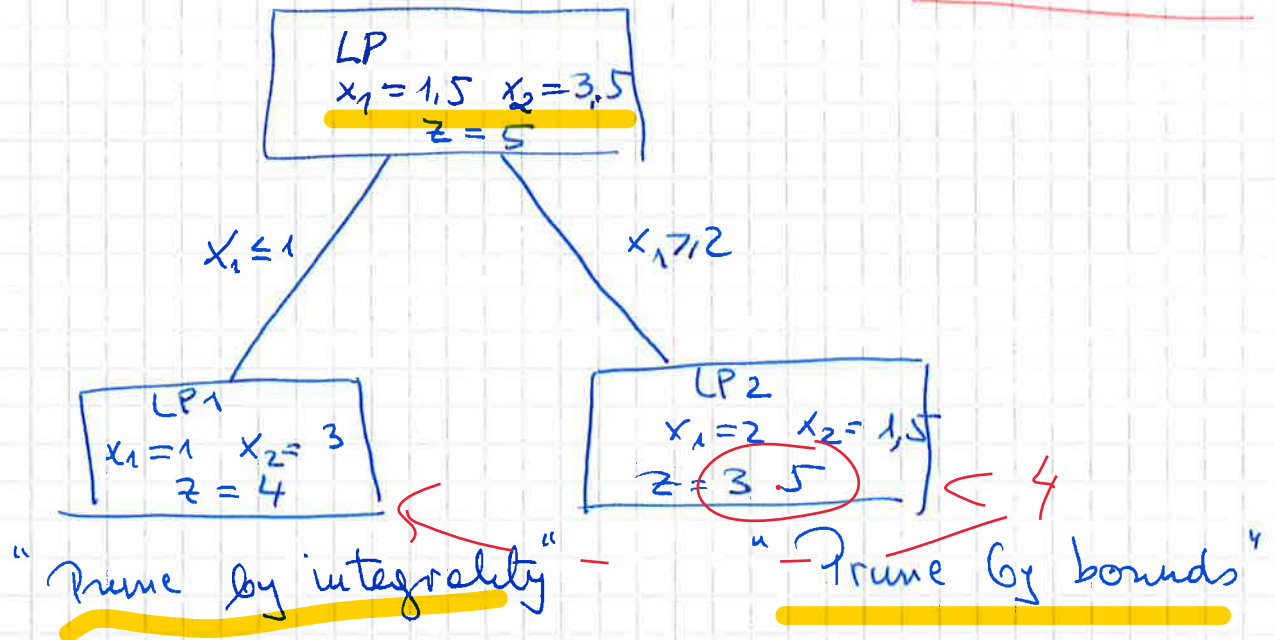
von LP1 zu suchen. (LP2) kann eliminiert werden

("fathom LP2" oder "prune LP2")

Im zulässigen Bereich von LP1 kann auch keine bessere Lösung als (1,3) gefunden werden

⇒ (1,3) ist eine Opt. Lösung von P.

Wir mussten 3 LPs lösen; diese lassen sich in einem sogenannten Branch and Bound Baum (B2B-Baum) organisieren, in dem jeder Knoten einem dieser gelösten LPs entspricht.



Die Suche nach Lösungen in einem Knoten des B&B-Baum kann aus 3 Gründen unterbrochen werden

(i) Ganzzahligkeit der Optimallösung der LP-Relaxation in diesem Knoten
 (prune by integrality)

(ii) Der optimale Zielfunktionswert der LP-Relax. in diesem Knoten ist schlechter als ~~der~~ Zielfunktionswert einer bekannten zulässigen Lösung des ursprünglichen Problems P
 (prune by bound)

(iii) Die lineare Relaxation in diesem Knoten ist unzulässig
 (Prune by infeasibility)