

Facility location problems: A parameterized view

Michael R. Fellows e Henning Fernau (2011)

Resumo para Algoritmos Parametrizados

Marcelo Pinheiro Leite Benedito

13 de dezembro de 2016

Resumo

Neste trabalho, descrevemos brevemente alguns resultados obtidos em *Facility location problems: A parameterized view* [1], por Michael R. Fellows e Henning Fernau, onde são introduzidas as primeiras tentativas de resolução do problema a partir do ponto de vista parametrizado.

1 Introdução

O *Facility Location Problem* (FLP) é amplamente estudado na literatura de diversas áreas da computação e busca modelar o seguinte cenário: uma empresa deseja abrir uma quantidade de instalações para atender seus clientes. Há custo tanto para abrir uma nova instalação quanto para servir um cliente através de uma instalação específica. O objetivo é servir todos os clientes minimizando o custo total. Diversos outros problemas NP-difíceis podem ser modelados como o FLP, o que torna ainda mais útil o estudo de sua complexidade parametrizada. Abaixo temos as principais formas de se tratar um problema NP-difícil:

- A. **heurísticas**: espera-se que produzam boas soluções em pouco tempo, porém não garantem a qualidade dessas soluções;
- B. **algoritmos de aproximação**: executam em tempo polinomial e garantem soluções que possuem valores aproximados do ótimo, mas nem sempre essa aproximação é boa, isso é, com fator pequeno;
- C. **programação linear inteira (PLI)**: não possuem garantia de tempo de execução polinomial, mas se o algoritmo termina, produz solução ótima.

Este trabalho se alinha com a última estratégia, pois o problema é formulado seguindo a estratégia de PLI e é investigado considerando algumas parametrizações naturais, como custo e número de instalações. Por ser o primeiro trabalho que trata o FLP de forma parametrizada, apresentamos resultados “triviais”, mas que são importantes para se dar início ao estudo.

Sobre o ponto de vista de aproximação, o FLP é um dos problemas mais estudados da área, com algoritmos criados a partir de diversas técnicas. Atualmente, o melhor algoritmo de aproximação para este problema, no caso métrico, possui fator 1.488 [3] e limite de aproximabilidade de 1.463 [2].

1.1 Definições

Dado um grafo bipartido $B = (F \cup C, E)$, sendo F o conjunto de instalações, C o de clientes e E o conjunto de arestas do tipo (f, c) , que indica que o cliente c pode ser atendido por uma instalação f ; funções de custo $\omega_F : F \rightarrow \mathbb{N}_{\geq 1}$ e $\omega_E : E \rightarrow \mathbb{N}_{\geq 1}$, representando o custo de abertura de instalações e o custo de atendimento a clientes por instalações, respectivamente. Além disso, é dado um custo máximo $k \in \mathbb{N}$. Devemos determinar um conjunto de instalações a serem abertas $F' \subseteq F$ e arestas $E' \subseteq E$ tal que:

$$A. \forall f \in F (f \in F' \iff \exists e \in E' (f \in e))$$

$$B. \forall c \in C, \exists e \in E' (c \in e)$$

$$C. \sum_{f \in F'} \omega_F(f) + \sum_{e \in E'} \omega_E(e) \leq k$$

Podemos formular o problema em termos da representação de matrizes dos custos de abertura de instalações e custos de atendimento. Dados $M \in \mathbb{N}_{\geq 1}^{(n+1) \times m}$, indexada de forma $M[0 \dots n][1 \dots m]$, e $k \in \mathbb{N}$, existe $F' \subseteq \{1, \dots, m\}$ e função $s : C \rightarrow F'$ tal que $\sum_{f \in F'} M[0, f] + \sum_{c \in C} M[c, s(c)] \leq k$?

Nesta formulação, as colunas são as potenciais instalações e as linhas são os clientes. Na matriz M , a linha de índice 0 possui os custos de abertura de cada instalação, enquanto as restantes indicam o custo de atendimento do cliente (índice da linha) por uma instalação específica (índice da coluna). Eventuais arestas faltantes no grafo de entrada B podem ter valor maior que k na matriz M , indicando inviabilidade.

2 Abordagens iniciais

Existem alguns parâmetros naturais para o problema, que são: o número n de clientes, o número m de potenciais instalações, o limite superior k do custo e o limite superior l de instalações que podem ser abertas. A primeira abordagem, com força bruta, nos fornece o seguinte resultado:

Teorema 1. *Facility Location pode ser resolvido em tempo $\mathcal{O}^*(2^m)$.*

Demonstração. Para cada $F' \subseteq F$, avalia-se o valor obtido (em tempo polinomial) e devolve o subconjunto que leva a uma melhor solução. Observe que, dado F' , podemos encontrar em tempo polinomial o conjunto E' de custo mínimo, bastando conectar cada cliente a uma instalação de F' □

Em relação aos outros parâmetros, as abordagens são menos claras. Neste trabalho, exploraremos o parâmetro k , que é uma escolha natural para problemas de minimização.

2.1 Regras de Redução

Um algoritmo de kernelização transforma uma instância (I, k) em uma (I', k') em tempo polinomial, sendo que o tamanho da nova instância é limitado por uma função de k . Sabe-se que um problema é \mathcal{FPT} se, e somente se, ele admite um algoritmo de kernelização. Esses algoritmos geralmente são baseados em regras de redução, por isso, elas são importantes nesse tipo de estudo.

Regra de Redução 1. Se dada uma instância (M, k) com $M \in \mathbb{N}_{\geq 1}^{(n+1) \times m}$ e vale que $n > k$, então retorne **não**.

Lema 1. A Regra 1 é válida.

Demonstração. Se cada cliente possui custo de atendimento de pelo menos uma unidade e todos devem ser atendidos, então não é possível atender a todos quando $n > k$. \square

Lema 2. Quando não for mais possível a aplicação da Regra 1, então a instância reduzida (M, k) não tem mais que $(k + 1)$ linhas.

Note que este Lema nos dá forte ligação entre os parâmetros k e n . Podemos definir os custos de uma instalação f como o vetor $v_f = M[0 \dots n][f]$; quando aplicamos um operador de comparação entre vetores, entende-se que estão sendo comparados elementos de uma mesma posição.

Regra de Redução 2. Se existem instalações f e g tal que $v_f \leq v_g$, então remova g da instância sem mudança em k .

Lema 3. A Regra 2 é segura.

Demonstração. Se temos uma solução S com instalações f e g e vale que $v_f \leq v_g$, então uma solução S' obtida removendo-se g de F' e adicionando f (consequentemente servindo os clientes antes atendidos por g) não pode ter valor de solução maior do que S . \square

Regra de Redução 3. Em uma instância $((B, \omega_E, \omega_F), k)$, as modificações abaixo não mudam o parâmetro:

Algoritmo 1

```

1: para cada instalação  $f$  faça
2:   se  $\omega_F(f) \geq k$  então remova  $f$ 
3:   fim se
4:   para cada cliente  $c$  faça
5:     se  $\omega_F(f) + \omega_E(c, f) > k + 1$  então  $\omega_E(c, f) := k + 1 - \omega_F(f)$ 
6:     fim se
7:   fim para
8: fim para

```

Lema 4. A Regra 3 é segura.

Demonstração. Uma instalação com custo de abertura k não pode servir nenhum cliente, porque isso implicaria em uma solução de custo pelo menos $k + 1$. Se uma instalação não é tão cara mas somada com o custo de atendimento passa o limite superior do parâmetro, então podemos diminuir este valor para $k + 1$, que ainda é inviável. \square

2.2 Kernelização com Lema de Dickson

Nesta seção, usaremos o Lema de Dickson para limitar o número de instalações que podem existir após a aplicação da regra de redução 3, ou seja, o número de colunas de M .

Lema de Dickson: dada constante n , o conjunto (\mathbb{N}^n, \leq) possui tamanho finito.

Teorema 2. Facility Location é FPT quando parametrizado com o custo k .

Demonstração. Seja (M, k) uma instância já reduzida com as regras 1-3. Pelo Lema 2, M não tem mais que $k + 1$ linhas, logo, cada instalação possui um vetor de custos deste tamanho. Também sabemos que os vetores das instalações não são comparáveis, pela redução 2. Pelo Lema de Dickson, o número de vetores é limitado por uma função $g(k)$, já que usamos a redução 3. Então, a matriz M tem, no máximo, $(k + 1)g(k)$ elementos. \square

Com isso, temos $f(k) = (k + 1)g(k)$, o tamanho do kernel que foi conseguido pelo último Teorema. Mais precisamente, $g(k)$ limita a quantidade de vetores (de tamanho $k + 1$) de números naturais não comparáveis, sendo que cada elemento destes varia de 0 a $k + 1$, pela regra 3. Logo, temos, no máximo, $(k + 2)^{k+1}$ vetores deste tipo. Com o Teorema 2 e a argumentação anterior, chegamos no seguinte resultado:

Corolário 1. *Facility Location pode ser resolvido em tempo $\mathcal{O}^*(2^{(k+2)^{k+1}})$.*

2.3 Refinamentos

Observa-se que uma solução para o FLP pode ser vista como uma partição no conjunto de clientes, onde clientes em um mesmo grupo são atendidos pela mesma instalação. Podemos obter esses grupos polinomialmente dados o conjunto F' de instalações abertas e as conexões ativas entre instalações e clientes. O contrário também é facilmente obtido. Com isso, obtemos o seguinte resultado:

Lema 5. *Dada instância (M, k) , Facility Location pode ser resolvido em tempo $\mathcal{O}(k^k \text{poli}(g(k)) + nm)$, onde $\text{poli}(\cdot)$ é um polinômio e $g(k)$ limita o número de instalações.*

Demonstração. As regras 1 e 2 são executadas em tempo $\mathcal{O}(nm)$. Sabe-se que o número de partições é, no máximo, k^k , que é um limitante do Número de Bell. Para cada partição, assumimos que é servida por uma única instalação, então calculamos o seu custo em tempo polinomial em $\mathcal{O}(\text{poli}(g(k)))$. \square

Lema 6. *Se tivermos instância (M, k) reduzida com as regras 1-3, então $nm \leq (k + 1)^{k+2}$.*

Demonstração. Pela regra 1, temos, no máximo, k clientes; pela regra 3, existem $(k + 1)^{k+1}$ vetores distintos referentes a instalações. Pela regra 2, cada instalação deve possuir vetor diferente, logo é possível a existência de $(k + 1)^{k+1}$ instalações. Como cada vetor de instalação tem $k + 1$ elementos, M tem, no máximo, $(k + 1)^{k+2}$ elementos. \square

Até agora, obtivemos kernels não muito pequenos que podem não ser úteis na prática. Adiante, tentaremos responder se existem kernels menores do que os que obtemos e se há alternativa de algoritmos parametrizados além da força bruta no kernel obtido.

2.4 Algoritmo usando programação dinâmica

A ideia de programação dinâmica em subconjuntos melhora o tempo de execução.

Teorema 3. *Facility Location pode ser resolvido em tempo $\mathcal{O}(2^k m + 3^k)$ em uma instância (M, k) .*

Demonstração. Começamos pré-processando o vetor OS (de tamanho $2^n \leq 2^k$), fixando um subconjunto $X \subseteq C$ de clientes atendidos por uma mesma instalação. A célula $OS(X)$ possui o custo de atender todos os clientes em X e abrir a instalação que resulta no custo mínimo. Então, $OS(X) := \min_{f \in F} (F_X(f))$, onde $F_X(f)$ é o custo de abrir f e servir X através dela. Com isso, podemos calcular o custo $s(X)$ de servir um certo grupo de clientes através de algumas instalações combinando dois subconjuntos, com o uso de programação dinâmica:

$$s(X) := \min_{\emptyset \subseteq Y \subseteq X} (OS(Y) + s(X \setminus Y))$$

Tal fórmula resulta em $\mathcal{O}(3^n) \leq \mathcal{O}(3^k)$ operações. Cada um dos clientes pertence a Y , $X \setminus Y$ ou $C \setminus X$. Note que quando $|X| = 1$, então $Y = X$ e $s(X) = OS(X) + s(\emptyset) = OS(X)$. Pode acontecer de existirem clientes atendidos pela mesma instalação nos conjuntos Y e $X \setminus Y$, seja Y' estes clientes. Mesmo com essa possibilidade, ainda vale a fórmula apresentada, pois:

$$s(X) \leq OS(Y \cup Y') + s(X \setminus (Y \cup Y')) \leq OS(Y) + s(X \setminus Y)$$

O tempo de execução do algoritmo se dá pelo cálculo de cada $OS(X)$ em tempo $\mathcal{O}(|X||F|) \subseteq \mathcal{O}(2^k m)$ e do custo da fórmula da programação dinâmica em si, o que resulta em um algoritmo $\mathcal{O}(2^k m + 3^k)$. Abaixo temos o algoritmo:

Algoritmo 2

```

1: se  $|C| > k$  então retorne não
2: fim se
3:  $s(\emptyset) := 0$ 
4: para cada  $X \subseteq C$  faça
5:   calcule  $OS(X)$  em tempo  $\mathcal{O}(|X||F|)$ 
6: fim para
7: para  $i := 1 \dots |C|$  faça
8:   para cada  $X \subseteq C$  com  $|X| = i$  faça
9:      $s(X) := \min_{\emptyset \subseteq Y \subseteq X} (OS(Y) + s(X \setminus Y))$ 
10:  fim para
11: fim para

```

□

Aplicando-se o Lema 6 antes de executar a programação dinâmica, obtemos um algoritmo que possui melhor tempo de execução, dado por $\mathcal{O}^*(2^k(k+1)^{k+2}) \subseteq \mathcal{O}^*((2k)^k)$.

3 Conclusões

Este trabalho foi o responsável por iniciar o estudo parametrizado do FLP e fornecer alguns pontos importantes sobre o problema. Até hoje, não foi feito outro trabalho parametrizado para o FLP, portanto, temos possibilidades que podem ser exploradas:

- Ainda está em aberto se é possível dar melhores algoritmos e kernels menores para este problema e variantes;

- Talvez existam outros parâmetros que se mostrem mais adequados para serem aplicados em casos específicos do problema, como o que admite clientes não atendidos (*outliers*) ou um problema que já possua um certo número de instalações abertas;
- No caso geral, nem toda instalação estará perto de todos os clientes, então pode-se usar este fato para diminuir ainda mais a complexidade dos algoritmos dando uma noção de vizinhança ou restrição de grau à clientes.

4 Exercício

Durante todo o trabalho, consideramos que os custos de abertura de instalações e de conexão entre clientes e instalações são números naturais. Se esses valores fossem números racionais, explique o motivo das abordagens abaixo funcionarem ou não com essa mudança:

- (a) Kernelização com Lema de Dickson em tempo $\mathcal{O}^*(2^{(k+2)^{k+1}})$;
- (b) Programação dinâmica em tempo $\mathcal{O}(2^k m + 3^k)$.

Referências

- [1] M. R. Fellows and H. Fernau. Facility location problems: A parameterized view. *Discrete Applied Mathematics*, 159(11):1118–1130, 2011.
- [2] S. Guha and S. Khuller. Greedy Strikes Back: Improved Facility Location Algorithms. In *Proc. of the Ninth Annual ACM-SIAM Symposium on Discrete Algorithms*, SODA '98, pages 649–657, Philadelphia, PA, USA, 1998. Society for Industrial and Applied Mathematics.
- [3] S. Li. A 1.488 Approximation Algorithm for the Uncapacitated Facility Location Problem. In L. Aceto, M. Henzinger, and J. Sgall, editors, *Automata, Languages and Programming*, volume 6756 of *Lecture Notes in Computer Science*, pages 77–88. Springer Berlin Heidelberg, 2011.