

Uma Aplicação de Programação Semidefinida Não Linear ao Problema de Identificação de Fatores de Risco

Alfred J. D. Albon¹

Unifesp, São José dos Campos, SP

Daiana O. Santos²

Unifesp, Osasco, SP

Programação Semidefinida Não Linear (PSDNL) é uma área de pesquisa que consiste em minimizar uma função objetivo cujas restrições do problema pertencem ao cone das matrizes semidefinidas positivas. Em PSDNL estamos interessados em resolver o seguinte problema

$$\begin{aligned} & \underset{x \in \mathbb{R}^n}{\text{Minimizar}} && f(x) \\ & \text{sujeito a} && g(x) \in \mathbb{S}_+^m, \end{aligned} \tag{PSDNL}$$

onde as funções $f : \mathbb{R}^n \rightarrow \mathbb{R}$ e $g : \mathbb{R}^n \rightarrow \mathbb{S}^m$ são continuamente diferenciáveis, \mathbb{S}^m é o conjunto das matrizes simétricas e \mathbb{S}_+^m o cone das matrizes semidefinidas positivas. Detalhes da teoria envolvida no problema podem ser vistos em [4]. Um dos motivos do crescente interesse em PSDNL está no fato de este possuir aplicações em diferentes campos de estudo, em [1] os autores introduzem condições de otimalidade para o problema em questão e analisam resultados de convergência para o algoritmo de Lagrangiano aumentado. A seguir, vamos descrever um problema em economia, mais especificamente na identificação de fatores de risco financeiro, que pode ser tratado como um PSDNL, introduzido em [2].

O problema de identificação de fatores de risco envolve a decomposição de uma matriz de covariância em duas matrizes semidefinidas positivas, permitindo assim a obtenção de informações sobre o tipo de risco presente.

Grande parte das ferramentas utilizadas na análise de risco, com o objetivo de obter informações sobre os tipos de risco presentes em uma matriz de covariância, baseiam-se em modelos estatísticos. Dentre esses modelos estatísticos, podemos citar o PCA (Principal Component Analysis). Recentemente, têm-se utilizado métodos de otimização para realizar essa decomposição, fornecendo métodos mais robustos e menos suscetíveis a outliers.

Considerando Σ uma matriz de covariância, gostaríamos de ter $\Sigma = \mathcal{L} + \mathcal{W}$ onde \mathcal{L} é uma matriz semidefinida positiva de posto baixo e \mathcal{W} é uma matriz esparsa e semidefinida positiva. Uma abordagem para este problema, utilizando otimização convexa, requer resolver o seguinte problema de otimização:

$$\begin{aligned} & \underset{(\mathcal{L}, \mathcal{W})}{\text{Minimizar}} && \lambda \|\mathcal{L}\|_* + \gamma \|\mathcal{W}\|_1 + \|\mathcal{L} + \mathcal{W} - \Sigma\|_F^2 \\ & \text{sujeito a} && \mathcal{L}, \mathcal{W} \succeq 0, \end{aligned} \tag{P}$$

onde $\lambda > 0$ e $\gamma > 0$ são parâmetros de regularização que controlam o posto e a esparsidade da solução. A norma $\|\cdot\|_*$ é a norma nuclear, dada pela soma dos valores singulares da matriz em

¹alfred_james_dias@outlook.com

²daiana.santos@unifesp.br

questão, cuja minimização induz posto baixo, enquanto $\|\cdot\|_1$ é a norma ℓ_1 , que induz esparsidade, enquanto $\|\cdot\|_F$ é a norma de Frobenius. Observe que o problema (P) é um problema de otimização semidefinida não linear.

Em trabalhos recentes, nos quais o caso convexo é considerado e essa abordagem utilizando otimização é empregada, o algoritmo ADMM (Alternating Direction Method of Multipliers) tem sido proposto para resolver o problema (P). O ADMM é uma variação do método do Lagrangiano Aumentado que se mostrou altamente eficaz quando a função objetivo pode ser escrita como uma soma de funções [3], por exemplo:

$$\begin{array}{ll} \text{Minimizar} & f(x) + g(x) \\ \text{sujeito a} & (A + B)x = b \end{array}$$

pode ser reformulado como

$$\begin{array}{ll} \text{Minimizar} & f(x) + g(y) \\ \text{sujeito a} & Ax + By = b \\ & x = y \end{array}$$

O propósito deste estudo é duplo: implementar um algoritmo ADMM para abordar o problema (P) e avaliar os resultados obtidos, contrastando-os com os que seriam fornecidos pelo PCA em uma análise de risco de uma carteira de investimentos, por exemplo.

Referências

- [1] R. Andreani, G. Haeser e D. S. Viana. “Optimality conditions and global convergence for non-linear semidefinite programming”. Em: **Mathematical Programming** 180 (2020), pp. 203–235. DOI: 10.1007/s10107-018-1354-5.
- [2] J. R. Bohn, L. R. Goldberg e A. D. Shkolnik. **Identifying broad and narrow financial risk factors with convex optimization**. Available at SSRN: <https://ssrn.com/abstract=2800237>. 2016.
- [3] S. Boyd, N. Parikh, E. Chu et al. “Distributed optimization and statistical learning via the alternating direction method of multipliers”. Em: **Foundations and Trends in Machine Learning** 3.1 (2011), pp. 1–122. DOI: 10.1561/22000000016.
- [4] F. Jarre. “Elementary optimality conditions for nonlinear SDPs”. Em: **Handbook on Semidefinite, Conic and Polynomial Optimization**. Springer, 2012, pp. 455–470.