



Modelos não-radiais

Enzo Barberio Mariano

Questões

1. Quais as características básicas de um modelo DEA radial?
2. O que são e quais são os modelos DEA híbridos?
3. Como se pode construir matematicamente os modelos híbridos da DEA?
4. Qual é o método para se determinar retornos de escala em que se utiliza os resultados dos modelos híbridos?
5. Quais são as principais características do modelo FDH?
6. Como o FDH é construído a partir do modelo BCC?
7. O que é relação de dominância e como esse conceito se relaciona com o modelo FDH?

Modelos não-radiais

- **Não trata os inputs e outputs de maneira uniforme;**
 - Inputs/outputs tem deslocamentos diferentes até a fronteira
- **Podem ter orientações mistas:**
 - Olha ao mesmo tempo para os inputs e outputs
- **Não estão sujeitos aos problemas das folgas;**
 - As folgas tem um outra interpretação nesses modelos;
- **Modelos não radiais:**
 - Aditivo ou Pareto-Koopmans (PK)
 - Slack Based Measure (SBM)
 - Enhanced Russell Measure (ERM)




Modelo aditivo

- **Origem:**
 - Charnes, Cooper, Golany, Seiford e Stutz (1985)
 - **Título:** “Foundations of data envelopment analysis and Pareto–Koopmans empirical production functions”;
- **Características**
 - Primeiro modelo não-radial proposto;
 - Identifica apenas unidades que são eficientes pela definição de Pareto-Koopmans (sem falsos eficientes)
 - Permite calcular a contribuição de cada variável e as metas e benchmarks para DMUs ineficientes;
 - **Não permite calcular um índice de eficiência;**

Conceito de Folga nos modelos radiais e não-radiais

- **Modelos radiais:**
 - Apenas aparecem quando a projeção radial leva a um ponto ineficiente;
 - São as sobras de inputs ou falta de outputs necessárias para que a projeção se torne eficiente;
 - Pode ser interpretado como um viés no modelo;
- **Modelo aditivo;**
 - Não tem projeção radial e as folgas aparecem sempre;
 - A folga é a distância de cada output ou input até a fronteira;
 - A folga é utilizada para a determinação da eficiência;

Folgas e orientação no modelo aditivo





Modelo aditivo na forma do envelope

$$Max \sum_{i=1}^m Si + \sum_{j=1}^n Sj$$

Sujeito a:


$$\sum_{k=1}^z y_{ik} \cdot \lambda_k - Si = y_{i0} , \text{ para todo } i$$

$$\sum_{k=1}^z x_{jk} \cdot \lambda_k + Sj = x_{j0} , \text{ para todo } j$$

$$\sum_{k=1}^z \lambda_k = 1$$

$$\lambda_k, Sj \text{ e } Si \geq 0$$

Pode ser adaptado para retornos de escala constantes, variáveis ou híbridos



Modelo aditivo na forma dos multiplicadores

$$\text{Min} \sum_{i=1}^m v_i \cdot x_{j0} - \sum_{j=1}^n u_j \cdot y_{j0} + w$$

Sujeito a:

$$\sum_{i=1}^m v_i \cdot x_{jk} - \sum_{j=1}^n u_j \cdot y_{jk} + w \geq 0, \text{ para todo } k$$

$$u_i \geq 1 \text{ para } i = 1, 2, \dots, m$$

$$v_j \geq 1 \text{ para } j = 1, 2, \dots, n$$

w sem restrição de sinal

Pode ser adaptado para retornos de escala constantes, variáveis ou híbridos





Modelo aditivo x Radial

- **Toda DMU eficiente no modelo aditivo também será no modelo radial correspondente;**
 - DMUs eficientes nos modelos radiais podem não ser no modelo aditivo;
- **O resultado dos modelos radiais tem um sentido prático:**
 - O resultado do modelo aditivo é a soma de valores (folgas) expressos em unidades diversas;
- **Invariância a unidade de medida:**
 - O resultado dos modelos BCC e CCR são invariantes a unidade de medida das variáveis;
 - O resultado do modelo aditivo depende das unidades de medida;
 - **Ex:** Mudar de “Km” para “m” não muda a eficiência nos modelos radiais, mas muda no aditivo



Metas, benchmarks e contribuição relativa

- **Contribuição relativa:**
 - A partir do peso na forma dos multiplicadores;
 - Divisão da contribuição individual de uma variável pelo output ou input virtual total
- **Benchmarks:**
 - Pelas variáveis lambda da forma do envelope;
 - Se forem 0 ou diferente de 0;



Metas no modelo aditivo

- Procedimento 1:

$$Meta = x_{j0} - S_j$$

$$Meta = y_{i0} + S_i$$

- Procedimento 2:

$$Meta = \sum_{k=1}^z x_{jk} \cdot \lambda_k$$

$$Meta = \sum_{k=1}^z y_{ik} \cdot \lambda_k$$

Exercício

Considere um conjunto de 7 DMUs com dois inputs e um output

DMUs	Input 1	Input 2	Output
A	4	3	1
B	7	3	1
C	8	1	1
D	4	2	1
E	2	4	1
F	10	1	1
G	3	7	1

O modelo Aditivo com retornos constantes de escala foi rodado

Exercício

DMU	FO	S-1	S-2	S+1	λ_1	λ_2	λ_3	λ_4	λ_5	λ_6	λ_7	Status	Meta I1	Meta I2	Meta O
A	1	1	0	0	0	0	0	0,5	0,5	0	0	Ineficiente	3	3	1
B	4	4	0	0	0	0	0	0,5	0,5	0	0	Ineficiente	3	3	1
C	0	0	0	0	0	0	1	0	0	0	0	Eficiente	8	1	1
D	0	0	0	0	0	0	0	1	0	0	0	Eficiente	4	2	1
E	0	0	0	0	0	0	0	0	1	0	0	Eficiente	2	4	1
F	2	2	0	0	0	0	1	0	0	0	0	Ineficiente	8	1	1
G	4	1	3	0	0	0	0	0	1	0	0	Ineficiente	2	4	1

Modelo SBM



- **Slack Based Measure (SBM)**
 - Medida baseada em folgas;
- **Origem:**
 - Desenvolvido por Kaoru Tone em 2001;
 - Artigo publicado no EJOR;
 - “A slacks-based measure of efficiency in data envelopment analysis”
- **Características:**
 - Usa as folgas do modelo aditivo para construir um índice de eficiência;
 - O modelo SBM é invariante a unidade de medida;
- **Pode ser expresso na forma dos multiplicadores ou do envelope;**



Eficiência no modelo SBM

- **É um valor entre 0 e 1:**
 - Representa a redução **média** dos inputs e o aumento **médio** dos outputs necessário para se chegar a fronteira;
 - Os valores não mais equiproporcionais, por isso é uma **média**;
- **Pode ser dividido em dois componentes:**
 - Eficiência relativa aos inputs;
 - Eficiência relativa aos outputs;
- **A eficiência global é a multiplicação dos dois componentes**



Medida baseada em folgas

$$E = \frac{1 - \frac{1}{m} * \sum_{j=1}^m \frac{Sj^-}{x_{j0}}}{1 + \frac{1}{n} * \sum_{i=1}^n \frac{Si^+}{y_{i0}}}$$

Eficiência dos inputs

Eficiência dos outputs

$$1 - \frac{1}{m} * \sum_{j=1}^m \frac{sj^-}{x_{j0}}$$

X

$$\frac{1}{1 + \frac{1}{n} * \sum_{i=1}^n \frac{si^+}{y_{i0}}}$$

Média das folgas relativas

Folga relativa



Modelo SBM fracionário

Sujeito a:

$$\text{Min } FO = \frac{1 - \frac{1}{m} * \sum_{j=1}^m \frac{S_j^-}{x_{j0}}}{1 + \frac{1}{n} * \sum_{i=1}^n \frac{S_i^+}{y_{i0}}}$$

Modelo de programação fracionária

$$\sum_{k=1}^z y_{ik} \cdot \lambda_k - S_i^+ = y_{i0}, \text{ para todo } i$$

$$\sum_{k=1}^z x_{jk} \cdot \lambda_k + S_j^- = x_{j0}, \text{ para todo } j$$

$$\sum_{k=1}^z \lambda_k = 1$$

$$\lambda_k, S_j \text{ e } S_i \geq 0$$

Passível de ajuste



Linearização do modelo SBM

- Usa-se o método desenvolvido por Charnes e Cooper (1973);
- Deve-se acrescentar uma variável de linearização chamada “t”
 - Deve-se multiplicar o numerador e o denominador por t;
 - Deve-se igualar o denominador a 1;
- A variável t deve ser utilizada para ajustar os valores das variáveis obtidas;



Modelo SBM na forma do envelope

$$\text{Min } FO = t - \frac{1}{m} * \sum_{j=1}^m \frac{S_j^-}{x_{j0}}$$

Após a resolução as varáveis novas devem ser divididas por t para se obter as antigas

Sujeito a:

$$t + \frac{1}{n} * \sum_{i=1}^n \frac{S_i^+}{y_{i0}} = 1$$

$$\sum_{k=1}^z y_{ik} \cdot \lambda_k - S_i^+ - t \cdot y_{i0} = 0, \text{ para todo } i$$

$$\sum_{k=1}^z x_{jk} \cdot \lambda_k + S_j^- - t \cdot x_{j0} = 0, \text{ para todo } j$$

$$\sum_{k=1}^z \lambda_k = t$$

$$\lambda_k, S_j \text{ e } S_i \geq 0 \text{ e } t > \varepsilon$$

Passível de ajuste: constante, variável ou híbrido

Metas no modelo SBM

- **Procedimento 1:**

$$Meta = x_{j0} - \frac{S_j}{t}$$

$$Meta = y_{i0} + \frac{S_i}{t}$$

- **Procedimento 2:**

$$Meta = \frac{\sum_{k=1}^z x_{jk} \cdot \lambda_k}{t}$$

$$Meta = \frac{\sum_{k=1}^z y_{ik} \cdot \lambda_k}{t}$$

Exercício

Considere um conjunto de 7 DMUs com dois inputs e um output

DMUs	Input 1	Input 2	Output
A	4	3	1
B	7	3	1
C	8	1	1
D	4	2	1
E	2	4	1
F	10	1	1
G	3	7	1

O modelo SBM com retornos constantes de escala foi rodado

Exercício

DMU	FO	t	S-1	S-2	S+1	λ_1	λ_2	λ_3	λ_4	λ_5	λ_6	λ_7	M I 1	M I 2	M O
A	0,83	1,00	0	1	0	0	0	0	1	0	0	0	4	2	1
B	0,62	0,67	0,67	0	0,33	0	0	0	1	0	0	0	6	3	1,5
C	1,00	1,00	0	0	0	0	0	1	0	0	0	0	8	1	1
D	1,00	1,00	0	0	0	0	0	0	1	0	0	0	4	2	1
E	1,00	1,00	0	0	0	0	0	0	0	1	0	0	2	4	1
F	0,90	1,00	2	0	0	0	0	1	0	0	0	0	8	1	1
G	0,62	0,67	0	0,67	0,33	0	0	0	0	1	0	0	3	6	1,5

Modelo SBM na forma dos multiplicadores

$$\text{Max } \xi$$

Sujeito a:

$$\sum_{i=1}^m v_i \cdot x_{j_0} - \sum_{j=1}^n u_j \cdot y_{j_0} + \xi = 1$$

$$-\sum_{i=1}^m v_i \cdot x_{jk} + \sum_{j=1}^n u_j \cdot y_{jk} \leq 0 \text{ para todo } k$$

$$u_j \geq \frac{\xi}{m \cdot y_{0j}} \text{ para } j = 1, 2, \dots, n$$

$$v_i \geq \frac{1}{n \cdot x_{0i}}, \text{ para } i = 1, 2, \dots, m$$



Modelos SBM orientados

- O modelo SMB pode ser adaptado para as orientações aos inputs ou aos outputs;
- O modelo SBM orientado também está sujeito ao problema dos falsos eficientes;
- Teorema:
 - A eficiência dos SBM orientado será sempre maior que a do SBM sem orientação;
 - Devido ao viés da eficiência das folgas omitidas;

Modelos SBM Orientados

SBM ao Input

$$\text{Min } FO = 1 - \frac{1}{m} * \sum_{j=1}^m S_j^- / x_{j0}$$

Sujeito a:

$$\sum_{k=1}^z y_{ik} \cdot \lambda_k - S_i^+ = y_{i0}, \text{ para todo } i$$

$$\sum_{k=1}^z x_{jk} \cdot \lambda_k + S_j^- = x_{j0}, \text{ para todo } j$$

$$\lambda_k, S_j \text{ e } S_i \geq 0$$

SBM ao output

$$\text{Max } FO = 1 + \frac{1}{n} * \sum_{i=1}^n \frac{S_i^+}{y_{i0}}$$

Sujeito a:

$$\sum_{k=1}^z y_{ik} \cdot \lambda_k - S_i^+ = y_{i0}, \text{ para todo } i$$

$$\sum_{k=1}^z x_{jk} \cdot \lambda_k + S_j^- = x_{j0}, \text{ para todo } j$$

$$\lambda_k, S_j \text{ e } S_i \geq 0$$



SBM ao input

DMU	FO	S-1	S-2	S+1	λ_1	λ_2	λ_3	λ_4	λ_5	λ_6	λ_7
A	0,83	0	1	0	0	0	0	1	0	0	0
B	0,62	3	1	0	0	0	0	1	0	0	0
C	1,00	0	0	0	0	0	1	0	0	0	0
D	1,00	0	0	0	0	0	0	1	0	0	0
E	1,00	0	0	0	0	0	0	0	1	0	0
F	0,90	2	0	0	0	0	1	0	0	0	0
G	0,62	1	3	0	0	0	0	0	1	0	0

SBM ao output

DMU	FO	S-1	S-2	S+1	λ_1	λ_2	λ_3	λ_4	λ_5	λ_6	λ_7
A	0,86	0	0	0,17	0	0	0	0,83	0,33	0	0
B	0,63	0	0	0,58	0	0	0,17	1,42	0	0	0
C	1,00	0	0	0	0	0	1	0	0	0	0
D	1,00	0	0	0	0	0	0	1	0	0	0
E	1,00	0	0	0	0	0	0	0	1	0	0
F	1,00	0	0	0	0	0	0	0	0	1	0
G	0,67	0	1	0,5	0	0	0	0	1,5	0	0

Enhanced Russell Measure (ERM)

- **Desenvolvido por Pastor, Ruiz e Sirvent em 1999;**
 - Artigo também publicado no EJOR;
 - “An enhanced DEA Russell graph efficiency measure”
- **Baseia-se no cálculo de um valor de eficiência para cada input e para cada output:**
 - θ_j – Eficiência relacionada ao input j
 - η_i – Inverso da eficiência relacionada ao output i ;
- **A eficiência total da DMU é uma medida baseada nessas eficiências individuais;**
- **O modelo ERM é equivalente ao SBM**



Enhanced Russell Measure (ERM)

$$\text{Min } FO = \frac{\frac{1}{m} \sum_{j=1}^m \theta_j}{\frac{1}{n} \sum_{i=1}^n \eta_i}$$

Sujeito a:

$$\sum_{k=1}^z y_{ik} \cdot \lambda_k \geq \eta_i \cdot y_{i0} \quad , \text{ para todo } i$$

$$\sum_{k=1}^z x_{jk} \cdot \lambda_k \leq \theta_j \cdot x_{j0} \quad , \text{ para todo } j$$

$$\sum_{k=1}^z \lambda_k = 1$$

$$\lambda_k \geq 0$$

$$\eta_k \geq 1$$

$$0 \geq \theta_k \geq 1$$

A linearização também é feita com o acréscimo de uma variável de linearização “t”

Passível de ajuste

Enhanced Russell Measure (E)

$$\text{Min } FO = \frac{1}{m} \sum_{j=1}^m \theta_j$$

Sujeito a:

$$\frac{1}{n} \sum_{i=1}^n \eta_i = 1$$

$$\sum_{k=1}^z y_{ik} \cdot \lambda_k \geq \eta_i \cdot y_{i0} \quad , \text{ para todo } i$$

$$\sum_{k=1}^z x_{jk} \cdot \lambda_k \leq \theta_j \cdot x_{j0} \quad , \text{ para todo } j$$

$$\eta_i - t \geq 0 \quad , \text{ para todo } i$$

$$\theta_j - t \leq 0 \quad , \text{ para todo } j$$

$$\lambda_k \geq 0 \text{ e } 0 \leq t \leq 1$$

Para voltar as variáveis originais, deve-se dividir o valor das variáveis por t

Pode ser adaptado para outros tipos de retorno de escala:

$$\sum_{k=1}^z \lambda_k = t$$

Metas no modelo ERM

- **Procedimento 1:**

$$Meta = \frac{x_{j0} * \theta}{t}$$

$$Meta = \frac{y_{i0} * \eta}{t}$$

- **Procedimento 2:**

$$Meta = \frac{\sum_{k=1}^z x_{jk} \cdot \lambda_k}{t}$$

$$Meta = \frac{\sum_{k=1}^z y_{ik} \cdot \lambda_k}{t}$$

Exercício

Considere um conjunto de 7 DMUs com dois inputs e um output

DMUs	Input 1	Input 2	Output
A	4	3	1
B	7	3	1
C	8	1	1
D	4	2	1
E	2	4	1
F	10	1	1
G	3	7	1

O modelo SBM com retornos constantes de escala foi rodado



Exercício

DMU	FO	t	θ_1	θ_2	η_1	λ_1	λ_2	λ_3	λ_4	λ_5	λ_6	λ_7	M I 1	M I 2	M O
A	0,83	1	1	0,67	1	0	0	0	1	0	0	0	4	2	1
B	0,62	0,67	0,57	0,67	1	0	0	0	1	0	0	0	6	3	1,5
C	1,00	1	1	1	1	0	0	1	0	0	0	0	8	1	1
D	1,00	1	1	1	1	0	0	0	1	0	0	0	4	2	1
E	1,00	1	1	1	1	0	0	0	0	1	0	0	2	4	1
F	0,90	1	0,8	1	1	0	0	1	0	0	0	0	8	1	1
G	0,62	1	0,67	0,57	1	0	0	0	0	1	0	0	2	4	1