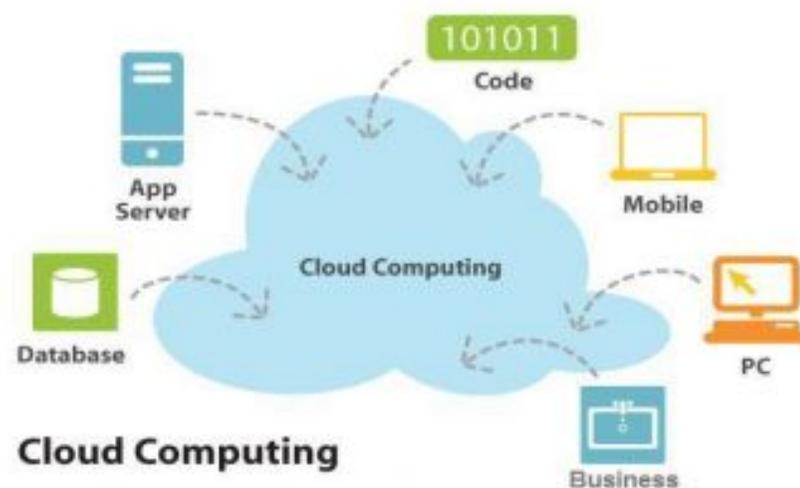


Estratégias para análise do impacto ambiental causado por centros de dados, considerando consumo de energia, eficiência energética e previsões com RNA.

Aluno: João Ferreira
Orientador: Paulo Maciel

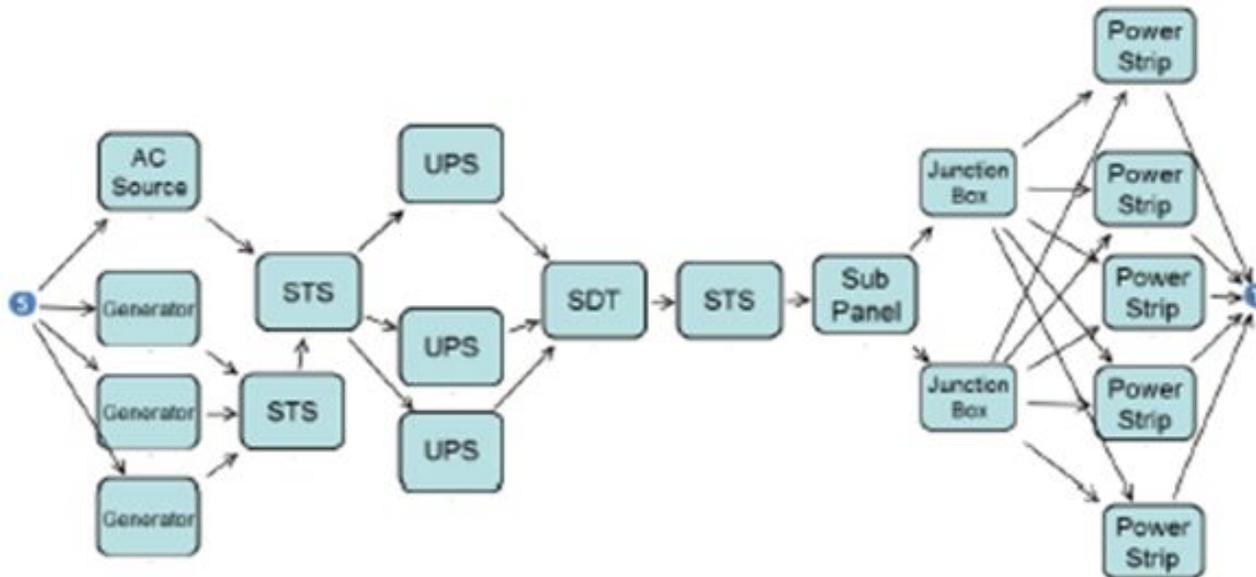
- Data center estão crescendo...
- Fato (Considerando EUA)
 - Centros de dados consomem quase 2% da energia produzida
 - Custo de 4,5 bilhões de dólares
- Preocupações Globais
 - Consumo de energia
 - Ambientes sustentáveis
- Centros de dados sustentáveis
 - Menor quantidade de materiais
 - Menor consumo de energia
- Disponibilidade



Data center

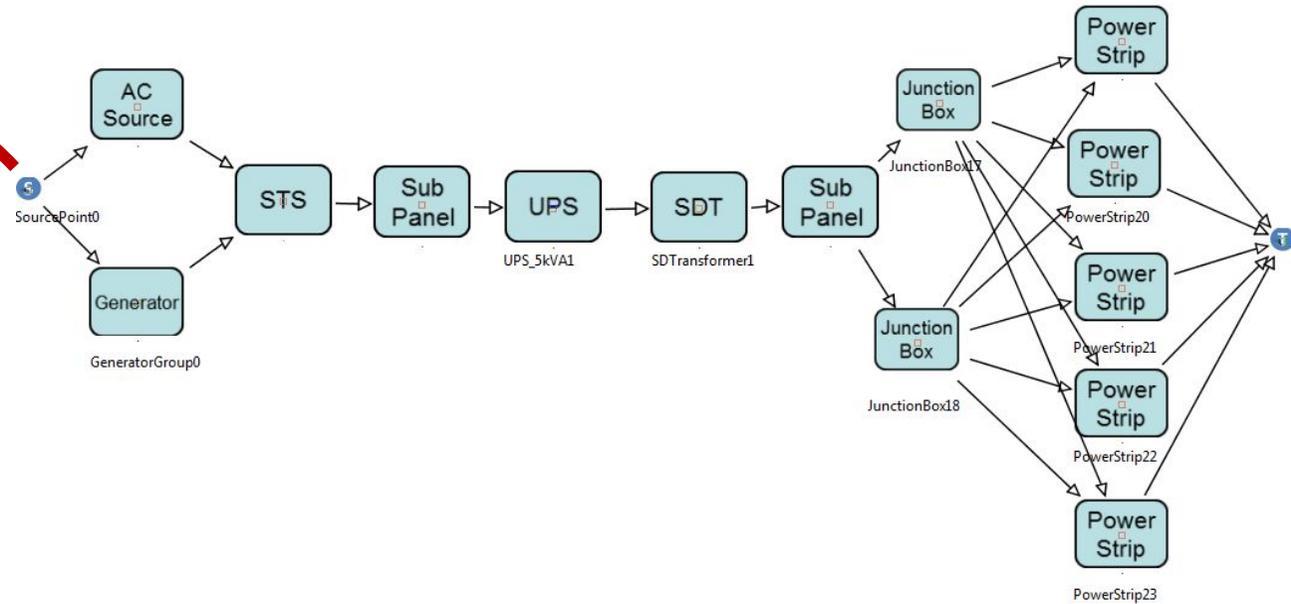
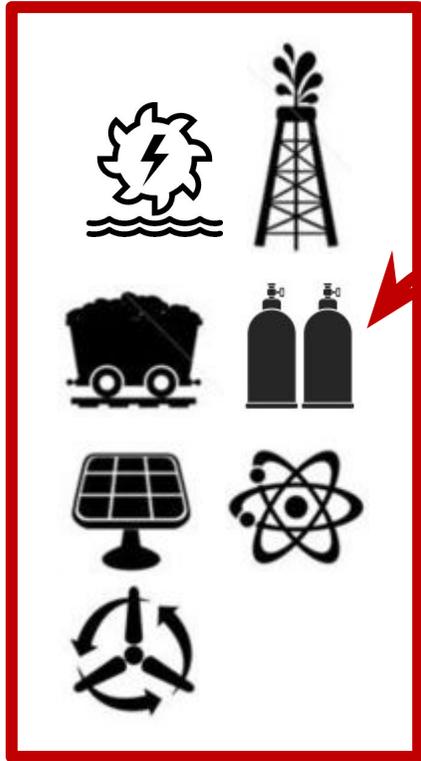
- Infraestrutura de Resfriamento
- **Infraestrutura Elétrica**
- Infraestrutura de TI

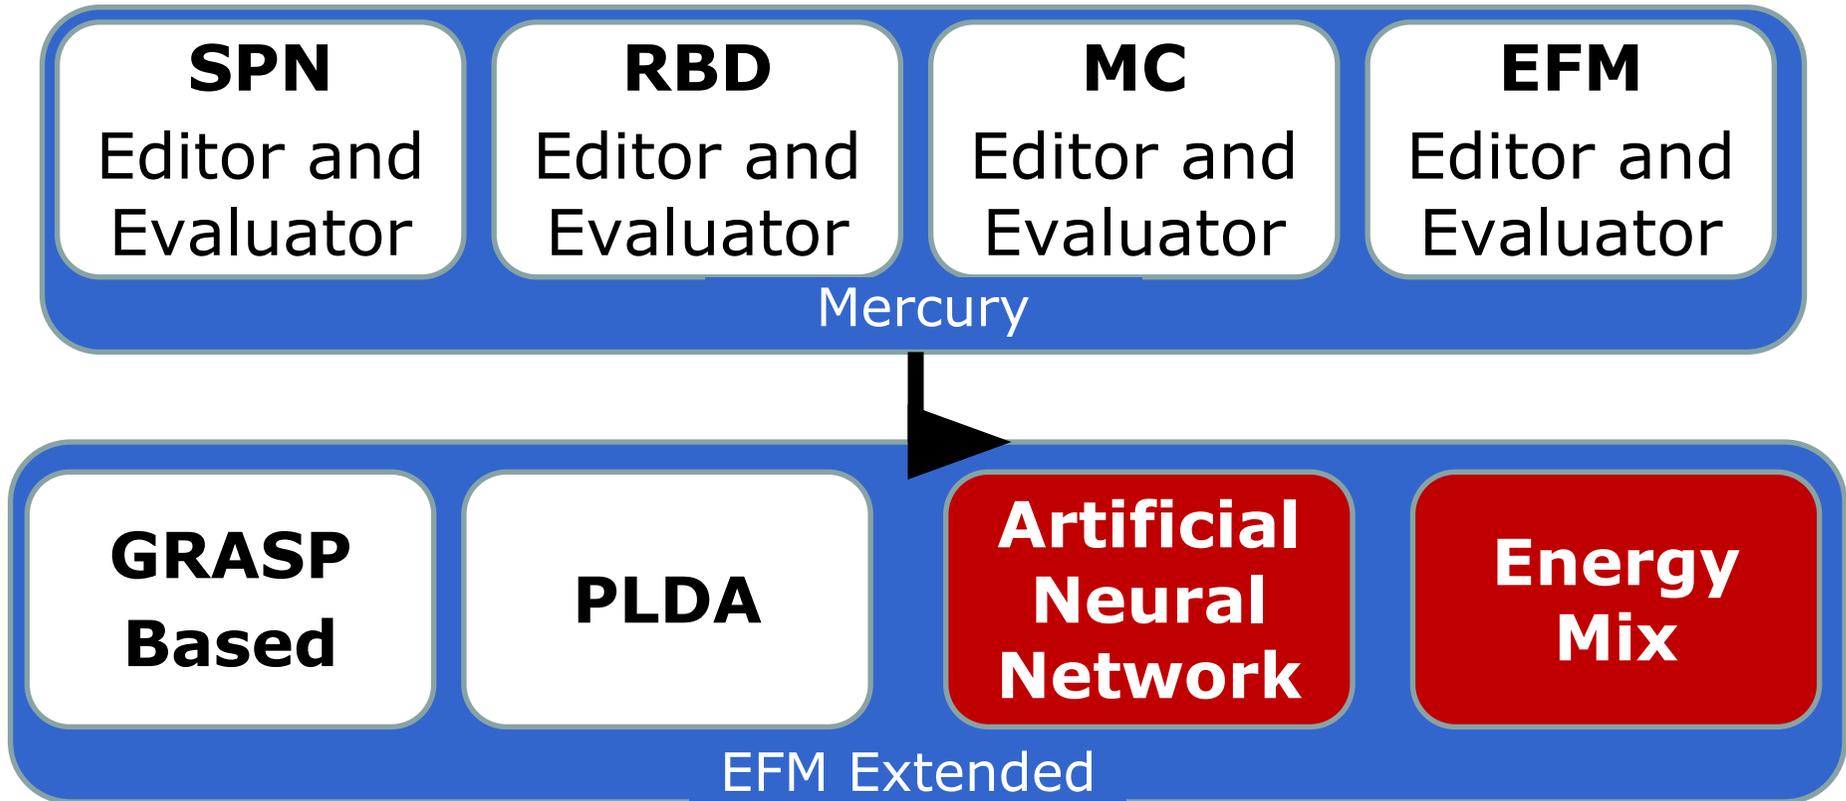
O EFM é utilizado para avaliar o **custo**, **sustentabilidade** e **disponibilidade** de infraestruturas de **energia e refrigeração** de centros de dados, respeitando as restrições de potência de cada dispositivo.

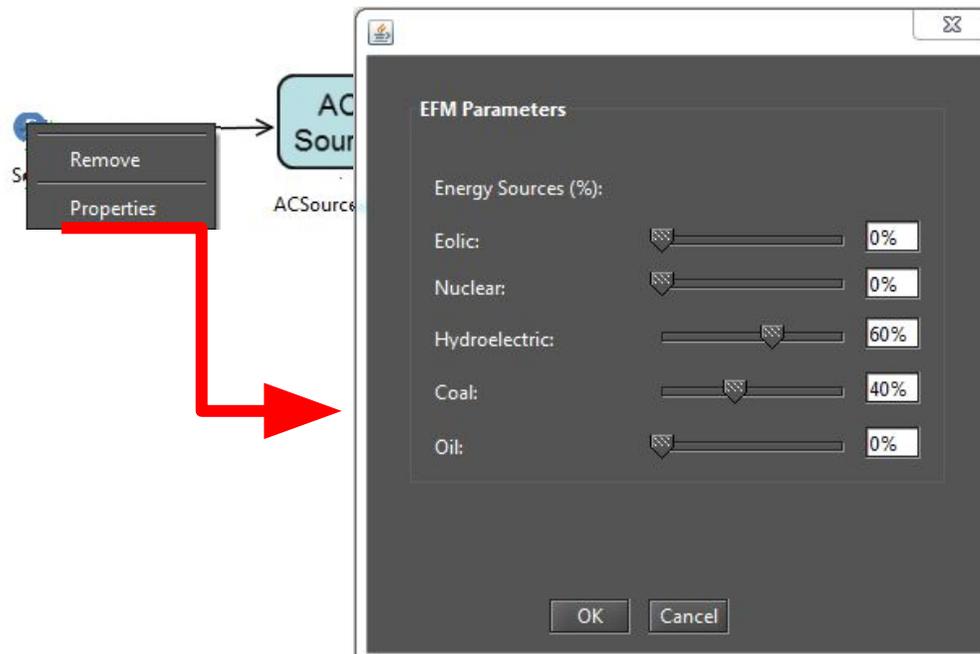


- 1 - Propor algoritmos para distribuição do consumo elétrico em componentes da infraestrutura de produção e energia elétrica dos centros de dados;
- 2 - Considerar o impacto ambiental e energética devido a diferentes fontes de energia elétrica de produção;
- 3 - Estimar as emissões de fontes energéticas;
- 4 - Aplicar modelos de consumo para estimar consumo de energia do centro de dados.

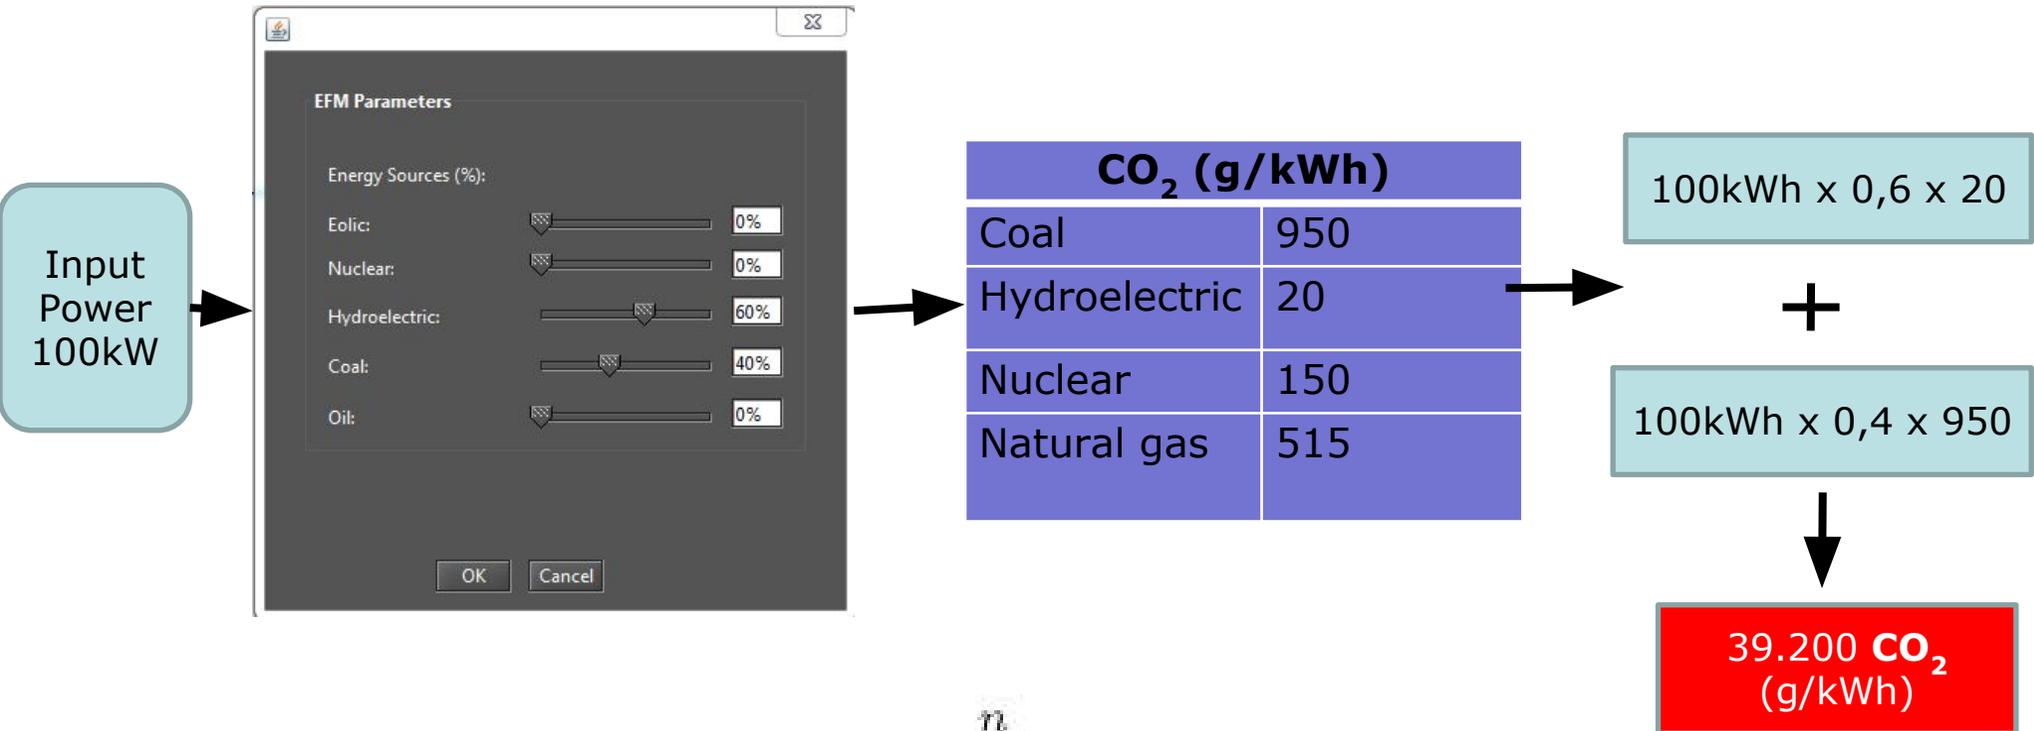
JOB DONE!







Exemplo:



$$CO_2Emissions = \sum_{i=1}^n (P_i \times F_i)$$

$$OperationalCost = \left(\sum_{i=1}^n (P_{Input-i} \times C_{Energy-i}) \right) \times T \times (A + \alpha(1 - A))$$

- Verificar o custo operacional e o impacto ambiental do consumo de energia dos centros de dados dos EUA.
- Utilizar o histórico do consumo de energia dos centro de dados ao longo de 14 anos (2000 - 2014).
- Qual o impacto ambiental e o custo, caso esses centros de dados estivessem instalados no Brasil, China ou Alemanha?
- Qual a previsão de consumo para o futuro?

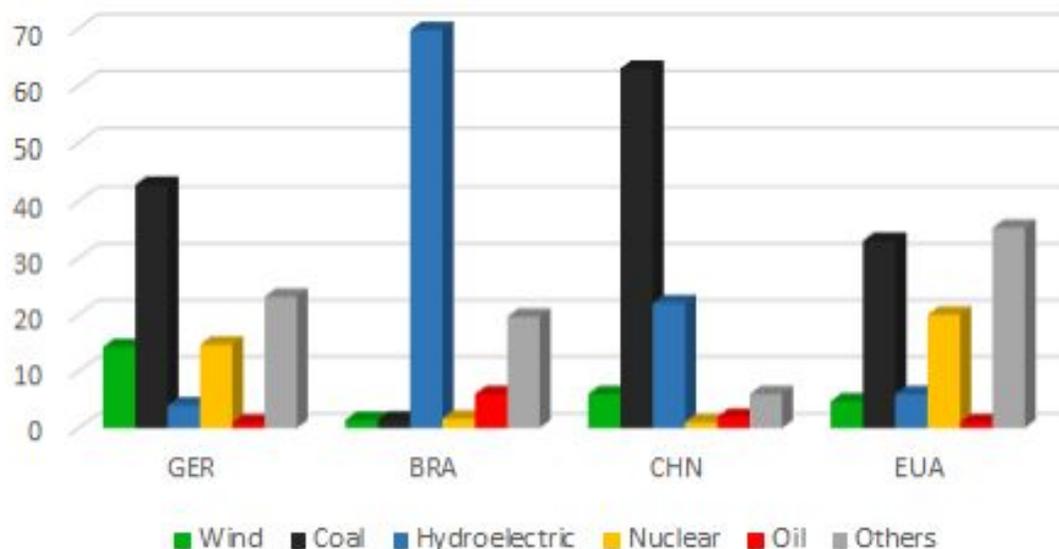
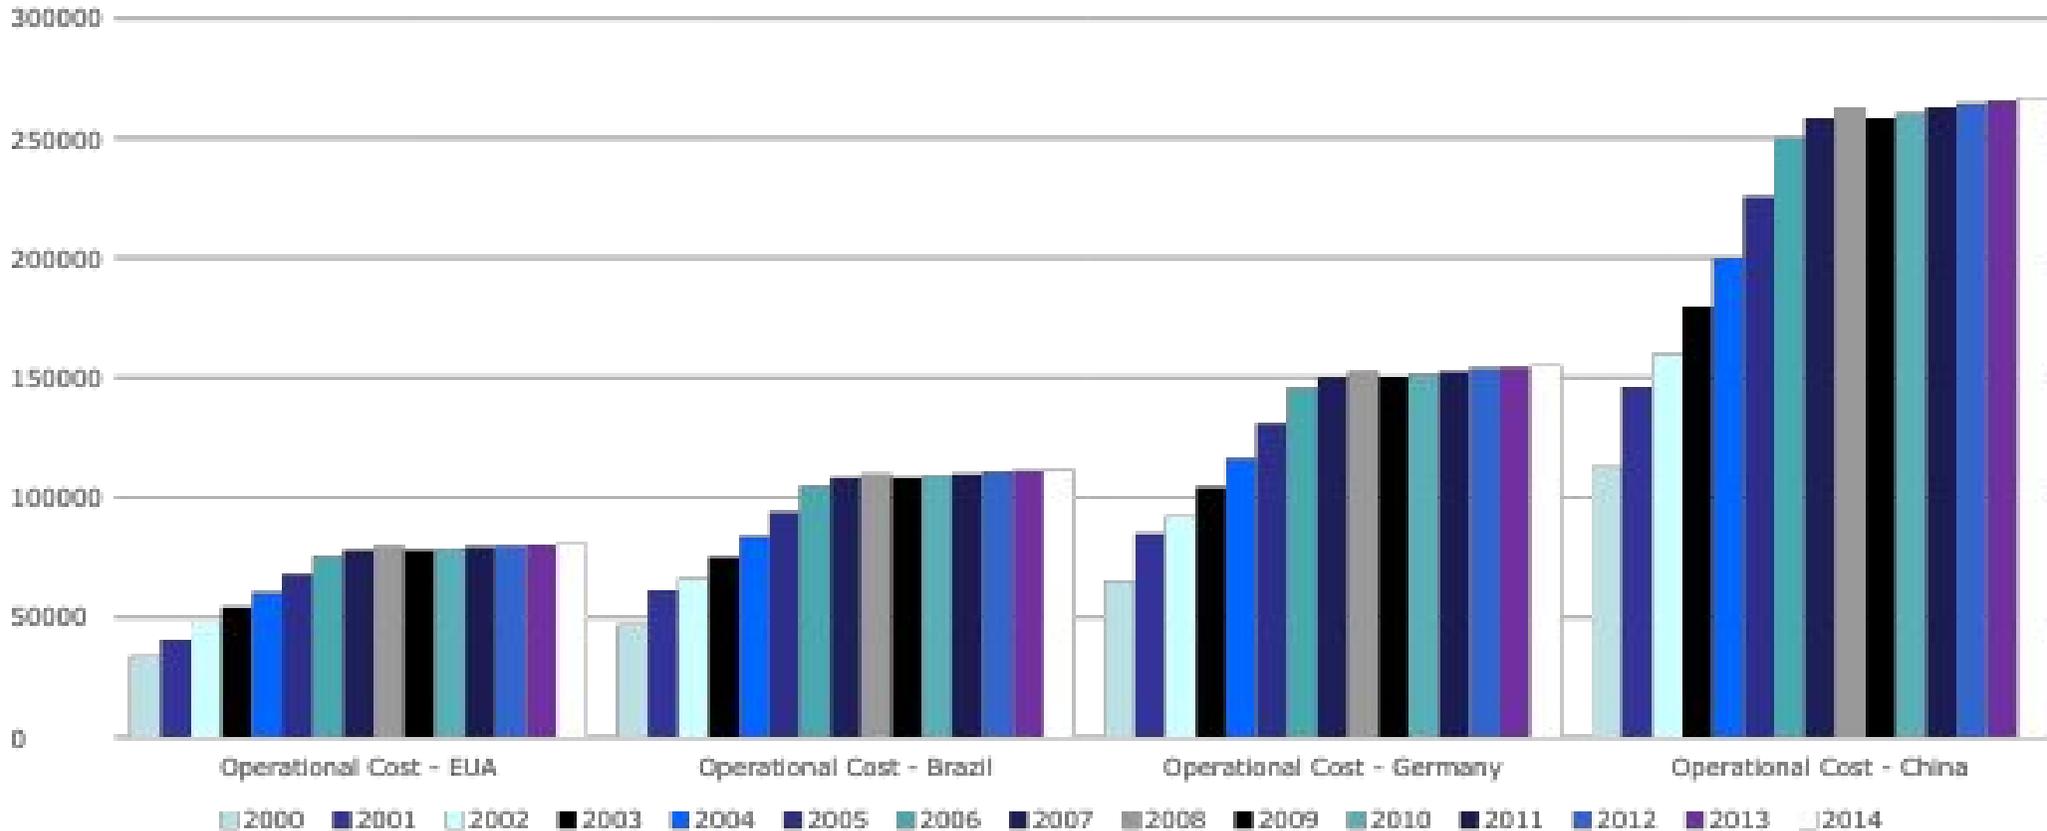


Fig. 10: Germany, Brazil, China and USA energy mixes

Table 2: Energy mixes, Energy cost and CO₂ emissions

| Energy Source | GER | BRA | CHN | EUA | CO ₂ (g/kWh) |
|----------------|-------|-------|------|------|-------------------------|
| Cost kWh (USD) | 0.25 | 0.18 | 0.43 | 0.12 | - |
| Wind | 14.3 | 1.44 | 6 | 4.7 | 10 |
| Coal | 42.9 | 1.5 | 63 | 33 | 950 |
| Hydroelectric | 4 | 69.76 | 22 | 6 | 20 |
| Nuclear | 14.7 | 1.68 | 1 | 20 | 150 |
| Oil | 0.94 | 6 | 2 | 1 | 510 |
| Others | 23.16 | 19.62 | 6 | 35.3 | - |

Operational Cost



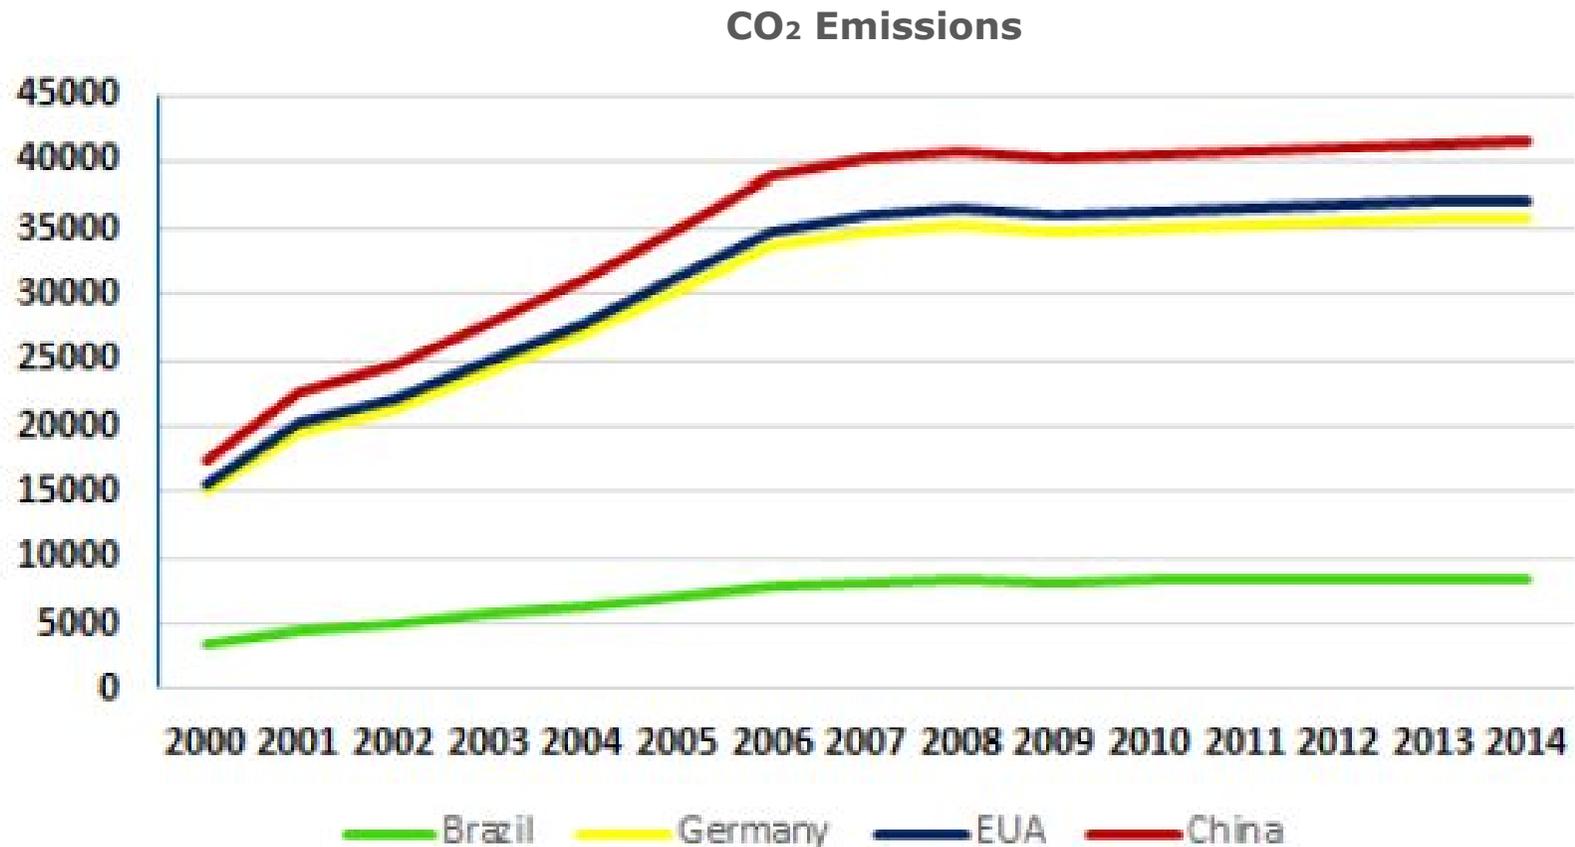


Fig. 11: CO₂ emissions for one year in tons

- 1 - Propor algoritmos para distribuição do fluxo elétrico em componentes da infraestrutura de provimento de energia elétrica dos centros de dados;
- 2 - Considerar o impacto ambiental e eficiência energética devido a diferentes fontes energéticas para o provimento de energia elétrica dos centros de dados.
- 3 - Extensão do EFM para suportar composições de fontes energéticas;
- 4 - Aplicar métodos de previsão para estimar consumo de energia do centro de dados.

2 – Prever o consumo de energia de um centro de dados.

Como?

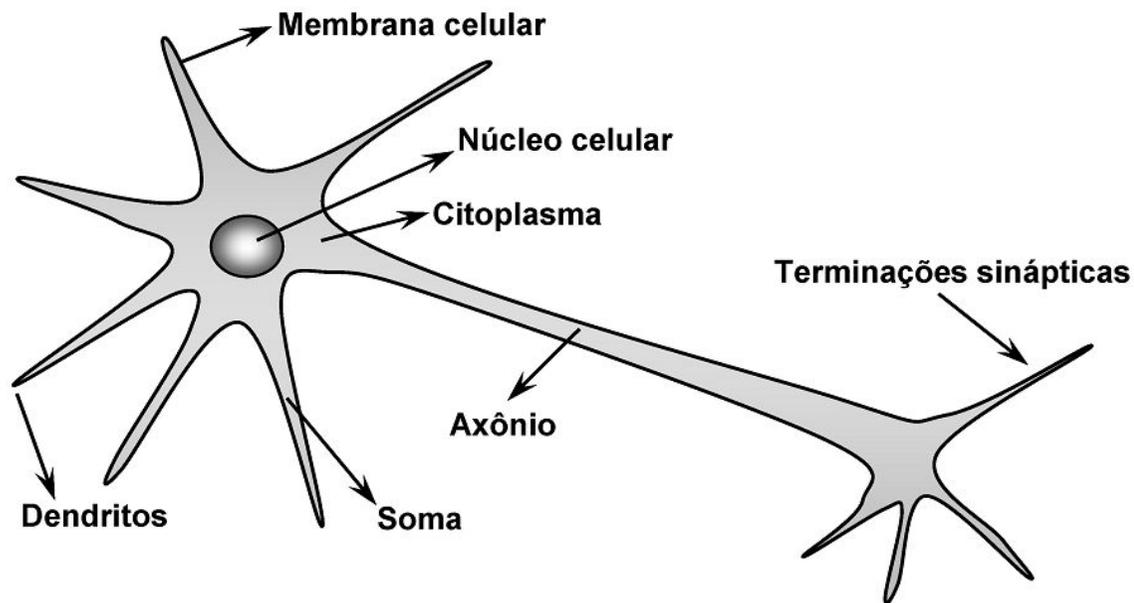
Redes Neurais Artificiais

REDES NEURAIS ARTIFICIAIS (RNA)

1. Técnica inspirada no funcionamento do cérebro, onde neurônios artificiais, conectados em rede, são capazes de aprender e de generalizar.
2. A característica mais significativa de redes neurais está em sua habilidade de aproximar qualquer função contínua ou não contínua com um grau de correção desejado. Esta habilidade das redes neurais as tem tornado útil para modelar sistemas não lineares.

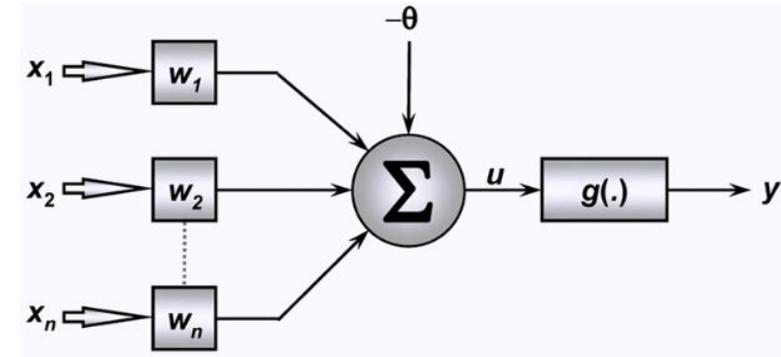
REDES NEURAIS ARTIFICIAIS (RNA) - Introdução

1. Redes Neurais são baseadas na biologia



Neurônio

- Sinais de Entrada $\{ X_1, X_2, \dots, X_n \}$
- Pesos sinápticos $\{ W_1, W_2, \dots, W_n \}$
- Função Agregadora $\{ \Sigma \}$
- Limiar de Ativação $\{ \Theta \}$



- Potencial de Ativação $\{u\} \rightarrow$

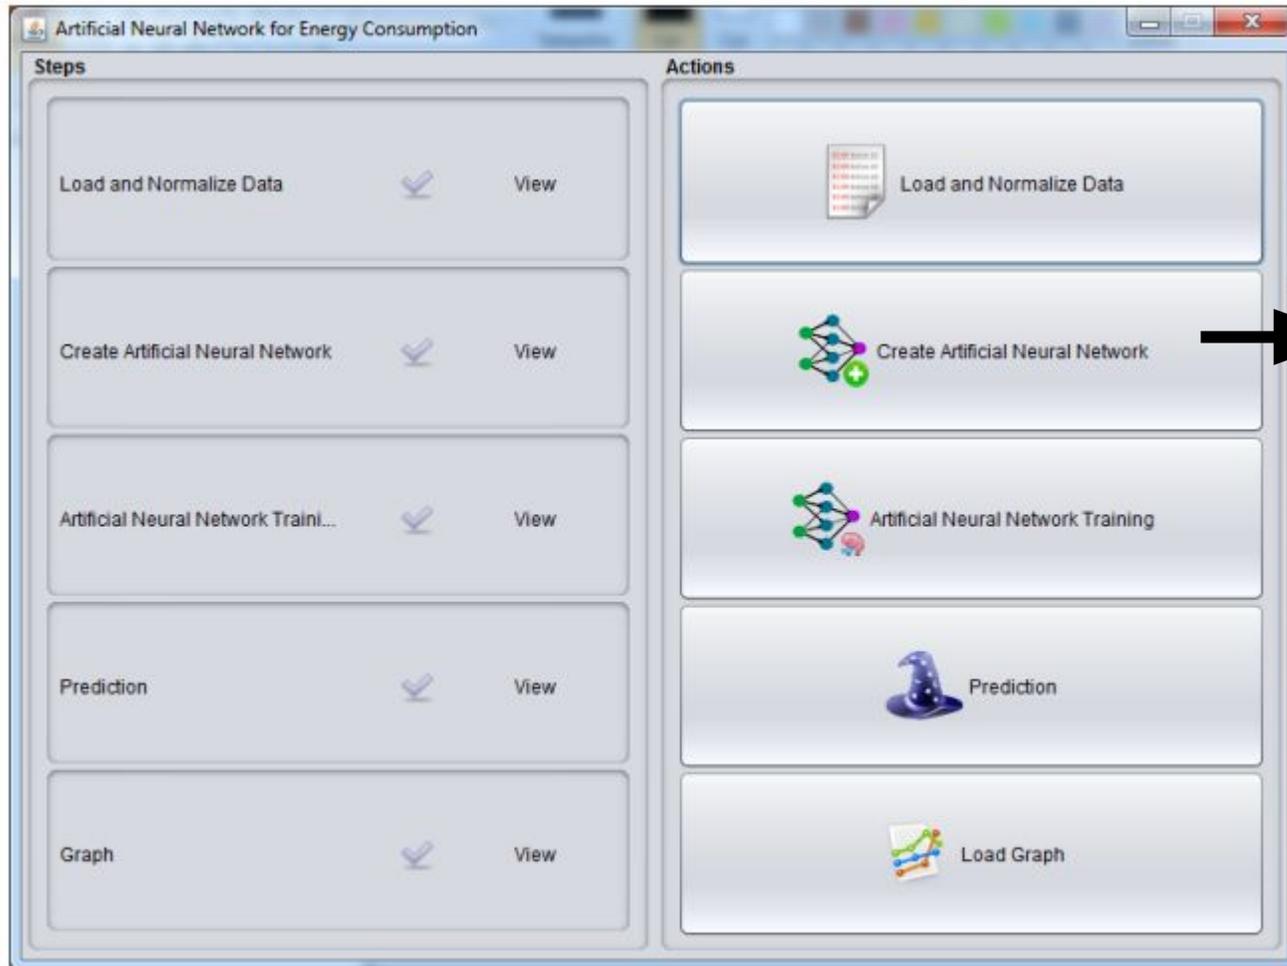
$$u = \sum_{i=1}^n w_i * x_i - \theta$$

- Função de Ativação $\{g\} \rightarrow$

- Sinal de Saída $\{ y \} \rightarrow$

$$y = g(u)$$

MLP Implementado no EFM



taxa de aprendizado: 0.001
momento: 0.99
máximo de épocas: 100.000
erro máximo: 10^{-4}
Camadas ocultas: 1
Neurônios na camada: 30

Fig. 9: ANN view in Mercury Tool

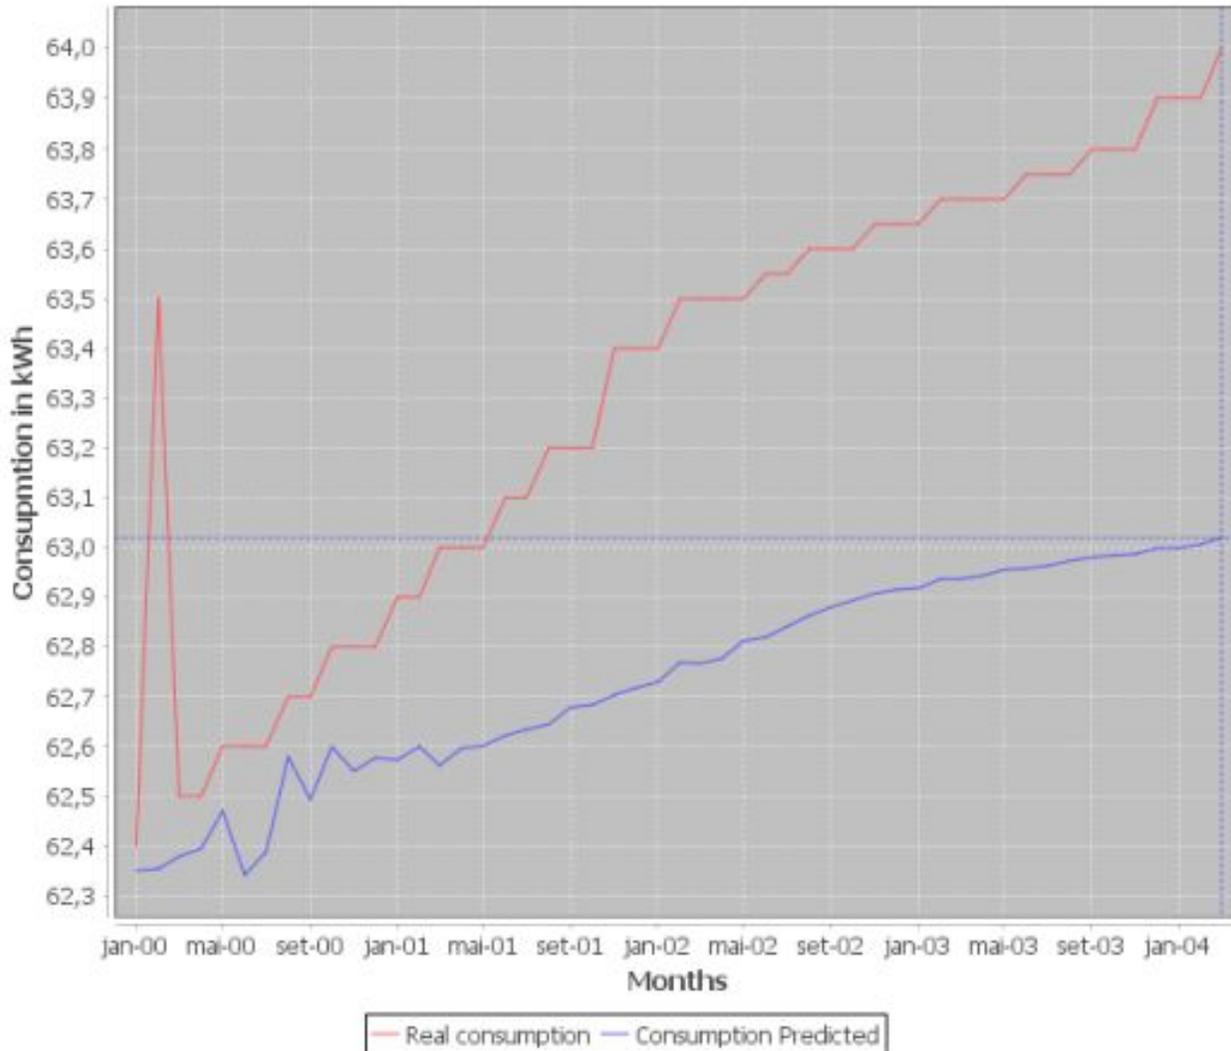


Fig. 14: Real Consumption x Consumption Predicted

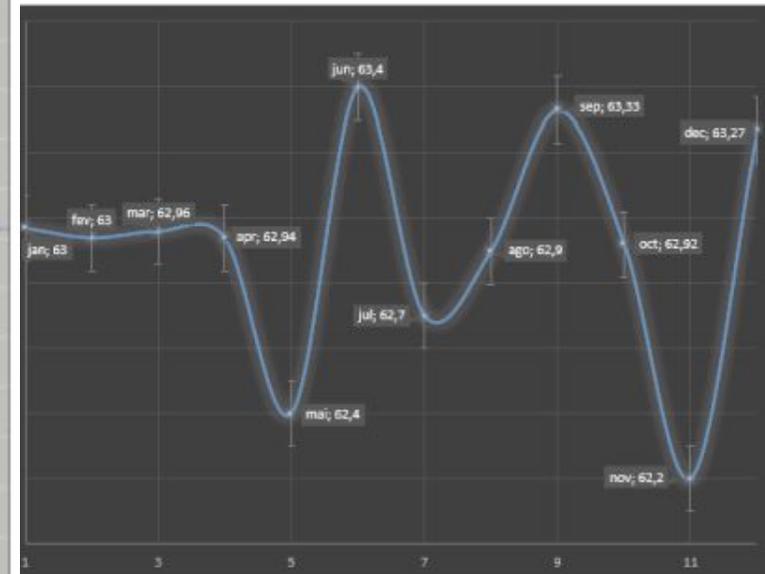


Fig. 15: Predictions to 12 months using MLP

Previsão de consumo para os próximos 12 meses

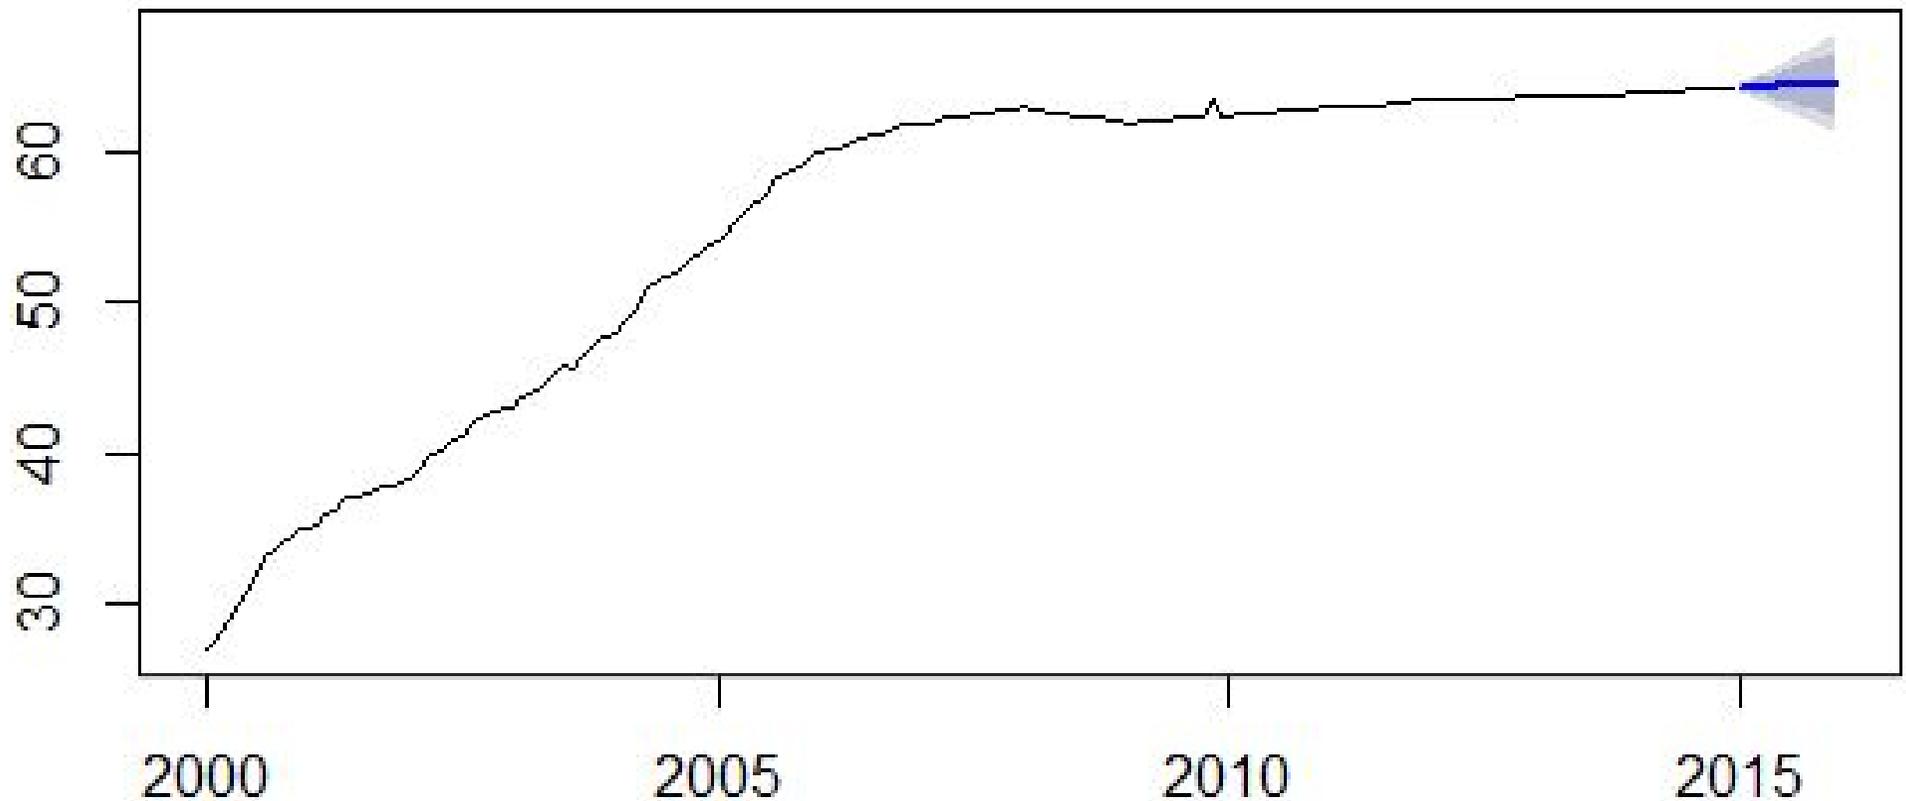


Fig. 13: Forecast from ARIMA(3,2,2)

Table 3: ARIMA and MLP predictions for next 12 months

| | ARIMA | | MLP | |
|-----|-------|-------|-------|-------|
| | Lower | Upper | Lower | Upper |
| Jan | 64,07 | 64,59 | 62,87 | 63,07 |
| Feb | 63,95 | 64,75 | 62,84 | 63,04 |
| Mar | 63,82 | 64,92 | 62,86 | 63,06 |
| Apr | 63,69 | 65,10 | 62,84 | 63,04 |
| May | 63,56 | 65,28 | 62,30 | 62,50 |
| Jun | 63,42 | 65,47 | 63,30 | 63,50 |
| Jul | 63,27 | 65,66 | 62,60 | 62,80 |
| Aug | 63,12 | 65,85 | 62,80 | 63,00 |
| Sep | 62,97 | 66,05 | 63,23 | 63,43 |
| Oct | 62,81 | 66,26 | 62,82 | 63,02 |
| Nov | 62,65 | 66,47 | 62,10 | 62,30 |
| Dec | 62,49 | 66,68 | 63,17 | 63,37 |

As previsões com o MLP indicam um aumento do consumo de energia, custo operacional e emissões de CO₂ na atmosfera entre **1,79 e 2,21%** ao ano.

