

## MÉTODOS DE PESQUISA OPERACIONAL NA DEFINIÇÃO DE METAS PARA INDICADORES DE SUSTENTABILIDADE EM UMA EMPRESA DO SETOR ELÉTRICO BRASILEIRO NO CONTEXTO DA AGENDA 2030

### **Katia Cristina Garcia**

Cepel - Centro de Pesquisas de Energia Elétrica  
Av. Horácio Macedo, 354 - Cidade Universitária, Ilha do Fundão - Rio de Janeiro – RJ  
garciak@cepel.br

### **Rodrigo Gomes Távora Maia**

UFRJ - Universidade Federal do Rio de Janeiro  
Av. Athos da Silveira Ramos, 149 - Ilha do Fundão - Rio de Janeiro – RJ  
rgtmaia@gmail.com

### **José Francisco Moreira Pessanha**

Cepel - Centro de Pesquisas de Energia Elétrica  
Av. Horácio Macedo, 354 - Cidade Universitária, Ilha do Fundão - Rio de Janeiro – RJ  
francisc@cepel.br

## RESUMO

O trabalho discute o uso de métodos estatísticos de previsão e o uso da análise envoltória de dados como auxílio na definição de metas para indicadores de sustentabilidade no contexto da Agenda 2030. A metodologia proposta consiste no tratamento das séries temporais com a identificação e remoção de *outliers* a partir da aplicação do método Loess, na realização das previsões de acordo com os modelos de suavização exponencial, na definição do *benchmark* a partir da Análise Envoltória de Dados (DEA) e posterior definição da meta global e, por último, na distribuição da meta pelo método de mínimos quadrados aliando o *benchmark* com as previsões. A metodologia foi aplicada em uma empresa do setor elétrico brasileiro para os indicadores de consumo de energia elétrica e consumo de água da rede de abastecimento das atividades administrativas.

**Palavra-chave:** Sustentabilidade Empresarial; Métodos de Previsão; Análise Envoltória de Dados; Indicadores de Sustentabilidade; Agenda 2030; Objetivos de Desenvolvimento Sustentável.

## ABSTRACT

The present paper discusses the use of statistics methods of forecasting and the use of data envelopment analysis to assist in the definition of goals for sustainability index in the context of Agenda 2030. The proposed methodology consists in the time series analysis using Loess method for identification and removal of outliers, forecasting the time series using exponential smoothing, in the definition of the benchmark using the Data Envelopment Analysis (DEA) and posterior definition of global goal and finally, in the distribution of global goal by the least squares method, combining the benchmark and the forecasting. For

practical example, this methodology was applied to a company of the Brazilian electric sector, using the electric energy consumption index and the water consumption index from administrative activities.

**Keywords:** Corporate Sustainability; Prediction Models; Data Envelopment Analysis (DEA); Sustainability Index; Agenda 2030; Sustainable Development Goals.

**Como Citar:**

GARCIA, Katia Cristina; MAIA, Rodrigo Gomes Távora; PESSANHA, José Francisco Moreira. Métodos de Pesquisa Operacional na Definição de Metas para Indicadores de Sustentabilidade em uma Empresa do Setor Elétrico Brasileiro no Contexto da Agenda 2030. *In: SIMPÓSIO DE PESQUISA OPERACIONAL E LOGÍSTICA DA MARINHA*, 19., 2019, Rio de Janeiro, RJ. **Anais** [...]. Rio de Janeiro: Centro de Análises de Sistemas Navais, 2019.

## 1. INTRODUÇÃO

Ao final de 2015, como uma continuação e ampliação dos chamados Objetivos de Desenvolvimento do Milênio (ODM), foram lançados os Objetivos de Desenvolvimento Sustentável (ODS), durante a Cúpula das Nações Unidas para o Desenvolvimento Sustentável, em Nova York. As negociações começaram em 2013, seguindo mandato emanado pelo país sede da Conferência Rio+20, o Brasil. Na prática, os chamados ODS serão responsáveis por orientar as políticas públicas e as atividades de cooperação internacional nos próximos anos, compondo a chamada Agenda 2030, com indicativos do “futuro que queremos”.

Diferente dos ODM, os ODS são aplicáveis a todas as nações do mundo, e mais do que isso, não apenas pelos governos, mas também com responsabilidades compartilhadas com a indústria, empresas privadas e sociedade. Pode-se arriscar dizer que o papel das empresas é chave para o alcance dos ODS, principalmente nos países onde os recursos financeiros são limitados.

Considerando a importância estratégica do setor elétrico para o alcance de vários dos ODS como, por exemplo, o ODS 7 (Energia Limpa e Sustentável) e o ODS 13 (Ação contra a Mudança Global do Clima), discutir a contribuição do setor para a Agenda 2030 torna-se imperativo.

As empresas do setor vêm de uma forma geral, trabalhando a questão da Sustentabilidade Empresarial de maneira crescente nos últimos dez anos. A internalização dos conceitos de Desenvolvimento Sustentável e do *triple bottom line* (ELKINGTON, 1994 *apud* SARTORI, 2016, p. 37), a identificação das questões de sustentabilidade materiais no contexto da empresa, o mapeamento de possíveis ações para incremento da sustentabilidade ambiental, econômica e social, a definição de indicadores de sustentabilidade para monitoramento das ações e a comunicação às partes interessadas são algumas das etapas que exemplificam esta busca das empresas.

Porém, no novo contexto mundial, estas etapas não são mais suficientes para garantir uma boa gestão em sustentabilidade. Os ODS apontam objetivos específicos que precisam ser monitorados com indicadores a partir da definição de metas claras, que viabilizem o atendimento até o ano de 2030. Esta necessidade impõe às empresas o estudo de metodologias que auxiliem na definição de metas, de forma a atender às demandas externas e internas dos diferentes *stakeholders*, ao mesmo tempo em que vislumbram o atendimento aos ODS no que tange a responsabilidade assumida frente ao seu país. Ainda que esse movimento ocorra de forma voluntária, o mercado passa a exigir um posicionamento formal das empresas, como uma forma de diferenciação. Uma prova disto é que ações e indicadores para monitoramento dos ODS já estão sendo apresentados nos Relatórios de Sustentabilidade de diversas empresas do setor nos últimos dois anos, normalmente seguindo a metodologia SDG Compass (CEBDS, 2018).

Esta metodologia foi elaborada pela GRI (Global Reporting Initiative) em conjunto com Pacto Global, WBCSD (World Business Council for Sustainable Development) e a ONU, a fim de orientar a ação das empresas para implantação dos ODS em suas estratégias de negócios. A metodologia tem cinco passos. O primeiro passo definido pela metodologia é o mapeamento dos impactos atuais, potenciais, positivos e negativos de suas atividades nos ODS, em toda cadeia de valor. O segundo passo é selecionar os indicadores e definir uma forma de coleta. No passo 3, são estabelecidas prioridades para planos de ação e melhoria, com estabelecimento de metas. Para isto deve-se selecionar os indicadores ou KPIs (*key performance indicators*) adequados de forma a garantir uma boa condução, monitoramento e comunicação dos resultados. No passo 4, as metas de sustentabilidade são integradas às estratégias de negócio, e no passo 5, todo o processo e progresso deve ser relatado e

comunicado às partes interessadas.

O presente artigo discute o uso de métodos de pesquisa operacional em uma metodologia para definição de metas de sustentabilidade no contexto da Agenda 2030 para uma empresa *holding* e suas unidades de negócios. Mais especificamente, a metodologia proposta baseia-se no emprego de métodos de previsão de séries temporais e na Análise Envoltória de Dados (Data Envelopment Analysis - DEA) para a definição de metas para os consumos de água e energia na *holding* e suas unidades de negócios.

A utilização de métodos de previsão é útil na definição de metas factíveis, mas que consigam impulsionar planos de ação que garantam uma contribuição efetiva da empresa para o alcance dos ODS. Assim, as previsões do consumo de energia e água para a *holding* são obtidas a partir da soma das previsões calculadas separadamente para cada uma de suas unidades de negócios, portanto, uma abordagem *bottom-up*. Já a definição das metas para os consumos de água e energia segue uma estratégia *top-down*, em que, inicialmente definem-se metas globais para a empresa *holding* por meio de modelos DEA e, na sequência, as metas globais são decompostas em metas locais para cada unidade de negócio com o auxílio de um modelo de mínimos quadrados restritos, cujas restrições incluem os limites mínimos e máximos para as metas locais em cada unidade de negócio, limites definidos pelos intervalos de previsão, e uma restrição de compatibilização das metas locais com a meta global para a *holding*.

Este trabalho apresenta, além da discussão teórica, um caso prático, construído a partir de uma análise com base em séries mensais históricas de diferentes indicadores de sustentabilidade ambiental, como por exemplo, indicadores de consumo de energia elétrica e de consumo de água, que vem sendo utilizados por mais de uma década por uma empresa do Setor Elétrico Brasileiro no monitoramento de seu desempenho em sustentabilidade.

## 2. METODOLOGIA PROPOSTA

A aplicação da metodologia proposta inicia-se com a obtenção de séries temporais mensais de consumo de recursos, e.g., água e energia, coletadas em uma empresa. Conforme ilustrado na Figura 1, a metodologia possui três etapas: tratamento de dados, previsão e *benchmarking*.



Figura 1. Estrutura da metodologia proposta

**2.1. ETAPA 1: TRATAMENTO DE DADOS**

As séries temporais podem conter *outliers*, i.e., dados discrepantes das demais observações. Os *outliers* são provocados por erros de preenchimentos dos formulários de dados ou por externalidades, e.g., vazamento de água e acidentes. A presença de *outliers* compromete a qualidade dos modelos de previsão e, portanto, a especificação dos modelos de previsão deve ser precedida por uma etapa de tratamento de dados.

Na metodologia proposta, o tratamento das séries temporais é realizado com o auxílio do método de regressão não paramétrica Loess (CLEVELAND, 1979 *apud* MARQUETTI; VIALI, 2004, p. 254), por ser um método de tratamento automático, facilitando a sua aplicação para várias empresas.

O método Loess fornece versões suavizadas das séries temporais, acompanhadas de intervalos de confiança. O tratamento de dados consiste em identificar, em cada série analisada, as observações localizadas fora dos limites dos intervalos de confiança e a substituição das mesmas pelos respectivos valores suavizados. Ao final, as séries temporais tratadas estão livres de *outliers* e podem ser utilizadas no ajuste dos modelos de previsão.

**2.2. ETAPA 2: PREVISÃO**

A previsão de séries temporais baseia-se na premissa segundo a qual os fatores que influenciaram o comportamento dos dados no passado continuam influenciando seus movimentos futuros. Assim, analisando o comportamento passado da série temporal podem ser obtidos os elementos para prever o seu comportamento futuro. O propósito dos métodos de previsão é distinguir o padrão de evolução da série (o sinal) de qualquer ruído que possa estar contido nas observações e então usar este padrão (o sinal) para prever valores futuros da série. Conforme ilustrado na Figura 2, uma série temporal pode ser decomposta em três componentes não observáveis: tendência (*trend*), sazonalidade (*seasonal*) e irregular (*remainder*).

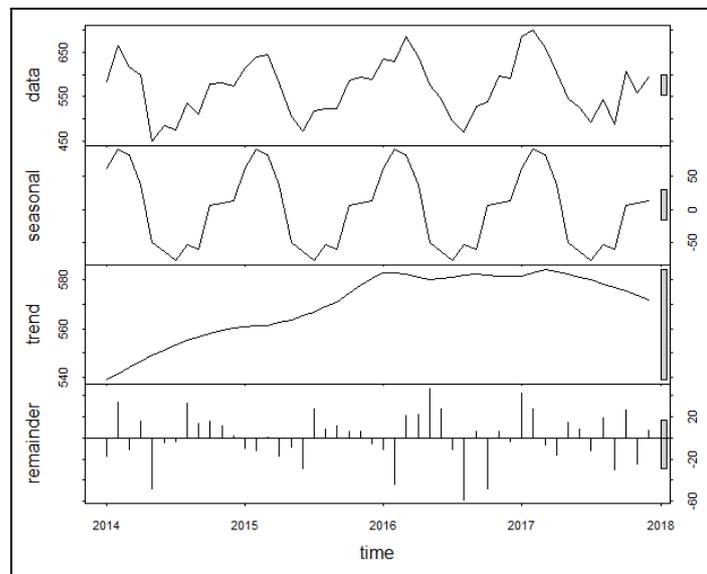


Figura 2. Decomposição de uma série temporal

A componente de tendência aponta para movimentos de longo prazo que indicam o crescimento ou decrescimento da série temporal. Já a componente sazonal descreve as variações periódicas da série temporal com períodos que duram até um ano, como por exemplo, as estações do ano. Por fim, a componente irregular captura as variações de curta

duração decorrentes, por exemplo, de greves e outros eventos não gerenciáveis. A combinação das componentes supracitadas pode seguir o modelo aditivo, em que a amplitude da variação sazonal é constante ao longo do tempo, i.e., é realizada a soma das componentes, ou o modelo multiplicativo, i.e., a amplitude da variação sazonal aumenta ou diminui como função do tempo, sendo realizada a multiplicação das componentes.

Os métodos escolhidos para a realização da previsão na metodologia foram os métodos clássicos de previsão (MUN, 2010 *apud* BERTOLO, 2013, p. 5), i.e., os métodos de alisamento exponencial, pelo fato de obter melhores resultados se comparados a outros métodos (MAKRIDAKIS *et al.*, 2018) em séries mensais. Outro fator que auxiliou na escolha desses métodos foi a praticidade de aplicação, já que para o presente estudo foram previstas várias séries temporais.

As componentes tendência, sazonalidade e erro podem ser combinadas de diferentes maneiras, originando um modelo de previsão diferente para cada combinação, em que cada componente compõe parte do acrônimo dado a cada modelo, conforme indicado pelos 19 modelos na Tabela 1.

Tabela 1. Modelos de alisamento exponencial

		Tendência	Sazonalidade		
			Sem	Aditiv a	Multiplicativa
Err o	Aditivo	Sem	ANN	ANA	-
	Multiplicativo		MNN	MNA	MNM
	Aditivo	Aditiva	AAN	AAA	-
	Multiplicativo		MAN	MAA	MAM
	Aditivo	Aditiva Amortecida	AAdN	AAdA	-
	Multiplicativo		MAdN	MAdA	MAdM
Aditivo	Multiplicativa	-	-	-	
Multiplicativo		MMN	-	MMM	
Aditivo	Multiplicativa Amortecida	-	-	-	
Multiplicativo		MMdN	-	MMdM	

Nos acrônimos apresentados na Tabela 1, a componente erro fornece a primeira letra do nome do modelo, podendo ser “A” (erro aditivo) ou “M” (erro multiplicativo). Já a componente tendência fornece a segunda e, em alguns casos, a terceira letra do nome do modelo, podendo ser “N” (sem tendência), “A” (tendência aditiva), “Ad” (tendência aditiva amortecida), “M” (tendência multiplicativa) ou “Md” (tendência multiplicativa amortecida). A componente sazonalidade fornece a última letra, podendo ser “N” (sem sazonalidade), “A” (sazonalidade aditiva) ou “M” (tendência multiplicativa).

Há algumas restrições de combinações de componentes, por exemplo, uma tendência ou sazonalidade multiplicativa não pode ter o erro aditivo. Adicionalmente vale citar a presença de alguns métodos amplamente conhecidos e aplicados no estudo de previsões de séries temporais como o Holt-Winters Aditivo (AAA e MAA), Holt-Winters Multiplicativo (MAM) e Holt (AAN e MAN).

**2.3. ETAPA 3: BENCHMARKING**

A última etapa consiste na definição das metas globais para a *holding*, a partir do *benchmarking* realizado pela Análise Envolvória de Dados (DEA), e na desagregação das metas globais entre as unidades de negócio da *holding* por meio do método dos mínimos

quadrados, tendo como restrição os limites inferior e superior dos intervalos de previsão para cada mês do horizonte de estudo (o uso de metas mensais permite monitorar melhor o desempenho das unidades).

Introduzida por Charnes, Cooper e Rhodes (1978), a DEA é uma técnica não-paramétrica utilizada na avaliação da eficiência de unidades produtivas (Decision Making Units - DMU) comparáveis, i.e., unidades que empregam processos tecnológicos semelhantes na transformação de múltiplos insumos (*inputs*) em múltiplos produtos (*outputs*). A abordagem DEA utiliza programação linear para construir uma fronteira de produção, a partir das observações das quantidades de insumos e produtos das DMU avaliadas, sem a necessidade de conhecer a priori qualquer relação de importância (pesos) entre as variáveis consideradas. A fronteira de produção funciona como um *benchmark* contra o qual podem ser comparados os desempenhos das DMU, as DMU tecnicamente eficientes (eficiência igual a 1) localizam-se na fronteira de produção, enquanto as DMU ineficientes localizam-se abaixo da fronteira. Os desvios das DMU em relação a fronteira quantificam as respectivas ineficiências. Portanto, a fronteira de produção pode ser usada como referência para o estabelecimento de metas para cada DMU.

Há dois modelos DEA clássicos: CCR ou CRS (*Constant Return of Scale*), proposto por Charnes, Cooper e Rhodes (1978) e BCC ou VRS (*Variable Return of Scale*), proposto por Banker, Charnes e Cooper (1984). Ambos podem ser orientados ao insumo, caso o objetivo seja fornecer metas para a conservação de recursos (uso eficiente dos insumos), ou orientados ao produto, caso o produto seja definir metas para expansão da produção.

Os modelos CCR (CRS) na Tabela 2 admitem retornos constantes de escala, i.e., qualquer variação nos insumos leva a uma variação proporcional nos produtos. Os modelos CRS fornecem uma medida global da eficiência técnica.

Tabela 2. Modelos CCR (CRS) (adaptado de CASA NOVA; SANTOS, 2008)

Modelo CCR (CRS) – Orientado ao Insumo	Modelo CCR (CRS) – Orientado ao Produto
Maximizar $h_k$ (Eficiência) $h_k = \sum_{r=1}^m u_r * y_{rk}$	Minimizar $h_k$ (Eficiência) $h_k = \sum_{i=1}^n v_i * x_{ik}$
Com as restrições: 1. $\sum_{r=1}^m u_r * y_{rj} - \sum_{i=1}^n v_i * x_{ij} \leq 0$ 2. $\sum_{i=1}^n v_i * x_{ik} = 1$ 3. $u_r, v_i \geq 0$	Com as restrições: 1. $\sum_{r=1}^m u_r * y_{rj} - \sum_{i=1}^n v_i * x_{ij} \leq 0$ 2. $\sum_{r=1}^m u_r * y_{rk} = 1$ 3. $u_r, v_i \geq 0$
Sendo: $y_r$ = quantidade de produto $r$ ; $x_i$ = quantidade de insumo $i$ ; $u, v$ = pesos de produtos e insumos; e $r=1$ até $m$ ; $i=1$ até $n$ ; $j=1$ até $N$	Sendo: $y_r$ = quantidade de produto $r$ ; $x_i$ = quantidade de insumo $i$ ; $u, v$ = pesos de produtos e insumos; e $r=1$ até $m$ ; $i=1$ até $n$ ; $j=1$ até $N$

Já os modelos BCC (VRS) na Tabela 3 admitem a premissa de retorno variável de escala, i.e., qualquer incremento nos insumos pode levar a um acréscimo, não necessariamente proporcional, aos produtos. Esse modelo faz uma avaliação da eficiência técnica (ET) e da eficiência da escala (EE), estimando a eficiência técnica pura, a uma dada

escala de operações, e identificando se existem ganhos de escala crescentes, decrescentes ou constantes.

Tabela 3. Modelos BCC (VRS) (adaptado de CASA NOVA; SANTOS, 2008)

Modelo BCC (VRS) – Orientado ao Insumo	Modelo BCC (VRS) – Orientado ao Produto
<p>Maximizar</p> $\sum_{r=1}^m u_r * y_{rk} - u_k$	<p>Minimizar</p> $\sum_{i=1}^n v_i * x_{ik} + v_k$
<p>Com as restrições:</p> <ol style="list-style-type: none"> <li><math>\sum_{r=1}^m u_r * y_{rj} - \sum_{i=1}^n v_i * x_{ij} - u_k \leq 0</math></li> <li><math>\sum_{i=1}^n v_i * x_{ik} = 1</math></li> <li><math>u_r, v_i \geq 0</math></li> </ol>	<p>Com as restrições:</p> <ol style="list-style-type: none"> <li><math>\sum_{r=1}^m u_r * y_{rj} - \sum_{i=1}^n v_i * x_{ij} - v_k \leq 0</math></li> <li><math>\sum_{r=1}^m u_r * y_{rk} = 1</math></li> <li><math>u_r, v_i \geq 0</math></li> </ol>
<p>Sendo:</p> <p><math>y_r =</math> quantidade de produto <math>r</math>;</p> <p><math>x_i =</math> quantidade de insumo <math>i</math>;</p> <p><math>u, v =</math> pesos de produtos e insumos; e</p> <p><math>r=1</math> até <math>m</math>; <math>i=1</math> até <math>n</math>; <math>j=1</math> até <math>N</math></p>	<p>Sendo:</p> <p><math>y_r =</math> quantidade de produto <math>r</math>;</p> <p><math>x_i =</math> quantidade de insumo <math>i</math>;</p> <p><math>u, v =</math> pesos de produtos e insumos; e</p> <p><math>r=1</math> até <math>m</math>; <math>i=1</math> até <math>n</math>; <math>j=1</math> até <math>N</math></p>

Em respeito às eficiências, pode ser observada a seguinte relação:

$$EE(x_k, y_k) = \frac{EP(x_k, y_k)}{ET(x_k, y_k)} \tag{1}$$

Sendo:

$$EE(x_k, y_k) = \text{Eficiência de Escala}$$

$$EP(x_k, y_k) = \text{Eficiência Produtiva}$$

$$ET(x_k, y_k) = \text{Eficiência Técnica}$$

Para definir metas globais de redução de consumo de recursos para a *holding* como um todo, propõe-se um conjunto de dois modelos DEA, todos orientados ao insumo. A opção por dois modelos e não apenas um deve-se ao limitado conjunto de DMU e a percepção de que a redução proporcional de todos os insumos pode não ser factível. Na Tabela 4 apresentam-se as variáveis insumos e produtos em cada dos modelos. Os modelos foram avaliados apenas na formulação VRS, devido a grande heterogeneidade de escala das DMU analisadas.

Tabela 4. Modelos DEA responsáveis pela definição das metas

Modelo	Insumos	Produtos
1	Consumo de energia	Valor adicionado distribuído
		Energia gerada
2	Consumo de água	Valor adicionado distribuído
		Energia gerada

Para a aplicação dos modelos DEA e consequente definição de benchmark, foram levantadas informações dos inputs e outputs, acima mencionados, de acordo com os

*Relatórios de Sustentabilidade de 2017, preenchidos no formato GRI (GRI-G4 ou GRI-Standard), de empresas do setor elétrico brasileiro que atuam como geradoras e transmissoras. Ao todo, foram levantadas 12 empresas (incluída a empresa do estudo). Porém, duas empresas tiveram uma qualidade de preenchimento muito abaixo das outras, sendo descartadas para não influenciarem no estudo. Portanto, foram inseridas no modelo nove empresas, mais a holding.*

Para desagregar as metas globais entre as unidades de negócio da *holding* e, conseqüentemente, compatibilizar as metas individuais com a meta global definida pelo DEA, propõem-se a aplicação do método dos mínimos quadrados, tendo como restrição os limites inferior e superior dos intervalos de previsão para cada mês do horizonte de estudo. No caso de unidades com previsão de crescimento em relação ao ano anterior, a restrição passa a ser a própria previsão, e não o seu limite superior. A formulação matemática do modelo de desagregação das metas globais, obtidas pelo modelo DEA, nas metas locais para as unidades de negócios é apresentada a seguir, em que  $M_i$  denota a meta (variável de decisão) para a unidade de negócio  $i \forall i=1,N$  e  $V_i$  o respectivo consumo verificado no último ano:

$$\text{Min} \sum_{i=1}^N \frac{1}{V_i} (M_i - V_i)^2 \quad (2)$$

s.a.

$$\alpha_i \leq M_i \leq \beta_i \forall i=1, N \quad (3)$$

$$\sum_{i=1}^N M_i = \theta V_{\text{Holding}} \quad (4)$$

$$M_i \geq 0 \forall i=1, N \quad (5)$$

A função objetivo em (2) busca minimizar os desvios entre as metas  $M_i$  e os respectivos níveis correntes dos consumos  $V_i$  no último ano. A restrição em (3) restringe as metas  $M_i$  para o intervalo definido pelos limites do intervalo de previsão  $[\alpha_i, \beta_i]$  para a  $i$ -ésima unidade de negócio. Na restrição (4)  $\theta$  é a eficiência da *holding* determinada pelo modelo DEA e  $V_{\text{holding}}$  é o valor verificado do consumo da *holding* no último ano. Assim, o produto  $\theta V_{\text{holding}}$  é a meta global a ser alcançada pela *holding*. A restrição em (4) garante que a soma das metas locais para as unidades de negócios deve coincidir com a meta global para a *holding*. Já a restrição (5) é típica dos modelos de otimização e indica a não negatividade das variáveis de decisão.

### 3. APLICAÇÃO E RESULTADOS

A aplicação da metodologia proposta é ilustrada por meio de um estudo de caso com dados provenientes de uma *holding* com nove unidades de negócios atuantes no setor elétrico. Sem perda de generalidade, no estudo de caso apresentado consideram-se apenas as análises realizadas na definição das metas para dois indicadores: consumo de energia elétrica e consumo de água.

Adicionalmente, considera-se que o horizonte de planejamento do estudo de caso abrange apenas o ano de 2018. Assim, primeiramente foi realizado o levantamento de séries temporais mensais das nove unidades de uma *holding* no período 2014-2017, portanto, cada série temporal possui 48 observações mensais. Na sequência, o método Loess foi aplicado em todas as séries temporais obtidas com o objetivo de corrigir eventuais *outliers* presentes nos dados. Em seguida, as séries tratadas foram analisadas pelo programa “NNQ-Estatística” (<http://qualimetria.ufsc.br/publicacoes/software/previsao/>), desenvolvido pela Universidade Federal de Santa Catarina (UFSC), com o objetivo de identificar o melhor modelo de

alisamento exponencial para cada série, em cada unidade de negócio. Os melhores modelos para as séries de consumo de água e consumo de energia são apresentados na Tabela 5.

Os modelos ajustados foram utilizados para gerar previsões mensais de janeiro até dezembro de 2018, portanto, um horizonte de previsão de 12 meses. Seguindo a abordagem *bottom-up*, a soma das previsões mensais para 2018, em cada unidade, resultou na previsão total da *holding*.

As previsões dos consumos de energia e água para a *holding* no ano de 2018 são apresentadas na Tabela 6 e Figuras 2 e 3, juntamente como os valores verificados para 2018. Ainda nas Figuras 2 e 3, as linhas tracejadas correspondem ao intervalo de confiança de previsão de 95%, os pontos os dados reais de 2018 e a reta a previsão para 2018.

Consumo de Energia		Consumo de Água	
Empresa	Método	Empresa	Método
Unidade 1	ANA	Unidade 1	MNM
Unidade 2	MNA	Unidade 2	MNA
Unidade 3	ANA	Unidade 3	MNA
Unidade 4	ANA	Unidade 4	MNA
Unidade 5	MNA	Unidade 5	MNA
Unidade 6	ANA	Unidade 6	MNM
Unidade 7	ANA	Unidade 7	ANA
Unidade 8	MNA	Unidade 8	MNM
Unidade 9	ANA	Unidade 9	MAA

(a) Melhores métodos para os indicadores de consumo de energia

(b) Melhores métodos para os indicadores de consumo de água

Tabela 5. Métodos de previsões que melhor se ajustaram aos dados de cada unidade

Comparação Mensal 2018: Real x Previsão			
em MWh	Real	Previsão	Variação Mensal
jan	6.399	6.429	0%
fev	5.711	6.179	8%
mar	6.625	6.307	-5%
abr	6.154	5.960	-3%
mai	5.878	5.504	-6%
jun	5.190	5.186	0%
jul	5.248	5.166	-2%
ago	5.525	5.264	-5%
set	5.528	5.325	-4%
out	5.723	5.659	-1%
nov	5.736	5.782	1%
dez	5.912	6.036	2%
<b>total anual</b>	<b>69.630</b>	<b>68.797</b>	<b>-1%</b>

(a) Consumo de energia

Comparação Mensal 2018: Real x Previsão			
em m³	Real	Previsão	Variação Mensal
jan	44.458	47.420	7%
fev	42.318	45.126	7%
mar	48.757	45.419	-7%
abr	46.360	43.959	-5%
mai	44.478	41.049	-8%
jun	37.935	39.318	4%
jul	33.340	40.109	20%
ago	37.193	41.494	12%
set	36.037	42.515	18%
out	39.184	40.544	3%
nov	38.405	42.295	10%
dez	38.038	42.287	11%
<b>total anual</b>	<b>486.503</b>	<b>511.535</b>	<b>5%</b>

(b) Consumo de água

Tabela 6. Valores mensais previstos e verificados dos consumos de energia e de água

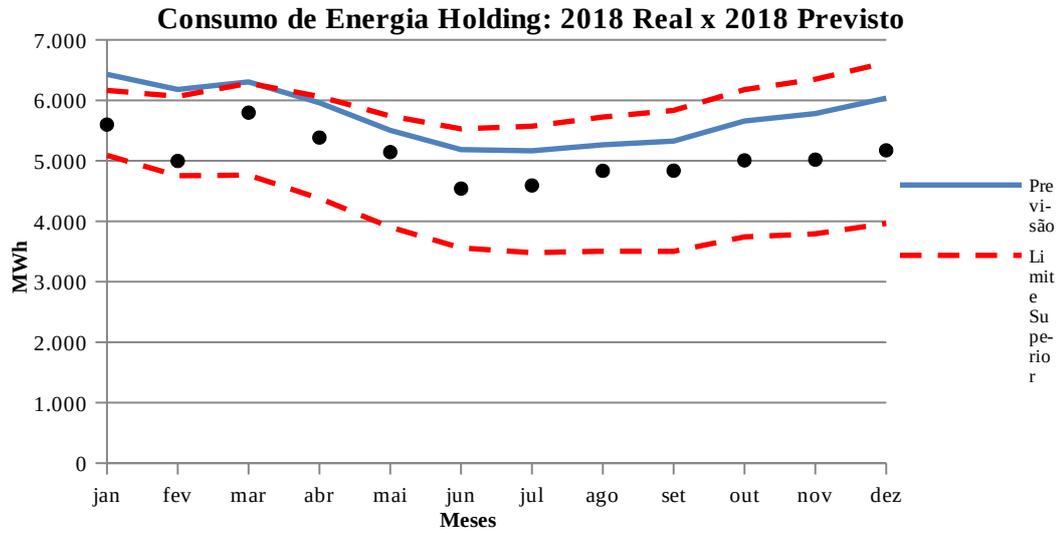


Figura 2. Comparação entre o consumo de energia previsto e real em 2018

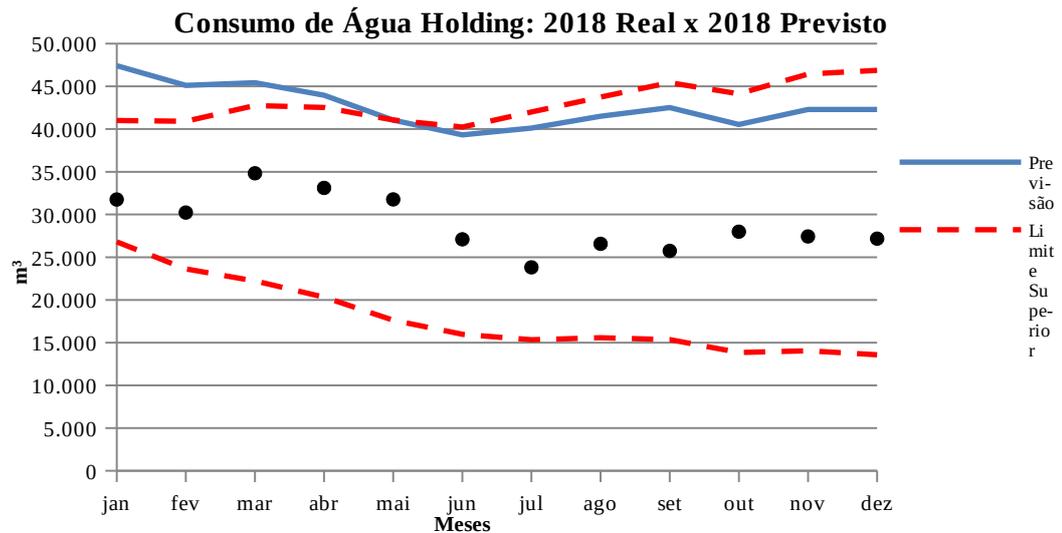


Figura 3. Comparação entre o consumo de água previsto e real em 2018

### 3.1. METAS PARA O CONSUMO DE ENERGIA

Os resultados dos modelos DEA (VRS, orientado ao insumo), com o consumo de energia como único insumo, são apresentados na Tabela 7 abaixo. Observa-se que a *holding* é eficiente no modelo VRS. Portanto, no modelo VRS, a *holding* é o próprio *benchmarking*.

Tabela 7. Eficiências VRS em relação ao consumo de energia (Modelo 1)

Empresa	Eficiência VRS
Empresa 1	0,001617675
Holding	1
Empresa 2	0,23284908
Empresa 3	0,006364428
Empresa 4	0,567805187
Empresa 5	0,454286347
Empresa 6	1
Empresa 7	0,110313978
Empresa 8	1
Empresa 9	1

Como a *holding* já é eficiente, não há um percentual de redução como meta. Então, será definida uma meta global de manutenção, ou seja, manter o consumo de energia igual ao ano anterior. O resultado se encontra na Tabela 8 abaixo.

Tabela 8. Distribuição da meta de manutenção para o consumo de energia

Unidades	Consumo Real 2017 (MWh)	Previsão 2018 (MWh)	Meta 2018 Distribuída (MWh)	Meta % (2017-2018)	Consumo Real 2018 (MWh)	Meta seria atingida?
Unidade 1	1.026	538	965	-6,0%	517	Sim
Unidade 2	1.149	1.107	1.150	0,1%	1.025	Sim
Unidade 3	3.732	3.642	3.735	0,1%	4.611	Não
Unidade 4	3.332	3.722	3.335	0,1%	3.217	Sim
Unidade 5	5.553	5.355	5.558	0,1%	5.571	Não
Unidade 6	6.822	6.296	6.828	0,1%	6.284	Sim
Unidade 7	7.008	6.890	7.014	0,1%	6.691	Sim
Unidade 8	16.939	16.008	16.954	0,1%	16.248	Sim
Unidade 9	26.593	25.239	26.616	0,1%	25.167	Sim
Holding	72.154	68.797	72.154	0,0%	69.331	Sim

### 3.2. METAS PARA O CONSUMO DE ÁGUA

Os resultados do modelo DEA (VRS, orientado ao consumo) para o *input* de consumo de água estão presentes na Tabela 9 a seguir. Observa-se que, novamente, a *holding* é eficiente no modelo VRS. Portanto, no modelo VRS, a *holding* é o próprio *benchmarking*.

Tabela 9. Eficiências VRS em relação ao consumo de água (Modelo 2)

Empresa	Eficiência VRS
Empresa 1	0,035049959
<i> Holding </i>	1
Empresa 2	0,000318208
Empresa 3	0,007425765
Empresa 4	0,000797606
Empresa 5	1
Empresa 6	1
Empresa 7	1
Empresa 8	0,430790507
Empresa 9	0,526713245

Como no caso a *holding* já é eficiente, não há um percentual de redução como meta. Então, será definida uma meta global de manutenção, ou seja, manter o consumo de água igual ao ano anterior. O resultado da desagregação da meta global da *holding* entre as suas unidades, pelo método de mínimos quadrados, se encontra na Tabela 10 abaixo.

Tabela 10. Distribuição da meta de manutenção para o consumo de água

Unidades	Consumo Real 2017 (m³)	Previsão 2018 (m³)	Meta 2018 Distribuída (m³)	Meta % (2017-2018)	Consumo Real 2018 (m³)	Meta seria atingida?
Unidade 1	1.577	959	1.804	14,4%	3.080	Não
Unidade 2	50.932	40.933	55.432	8,8%	55.623	Não
Unidade 3	23.528	21.782	24.938	6,0%	27.604	Não
Unidade 4	112.920	129.586	111.685	-1,1%	113.335	Não
Unidade 5	33.404	29.582	34.157	2,3%	27.073	Sim
Unidade 6	38.693	40.980	44.522	15,1%	45.602	Não
Unidade 7	30.562	28.621	32.888	7,6%	42.253	Não
Unidade 8	178.840	208.375	164.421	-8,1%	160.351	Sim
Unidade 9	11.703	10.717	12.312	5,2%	11.240	Sim
<i> Holding </i>	482.159	511.535	482.159	0,0%	486.161	Não

#### 4. CONCLUSÕES

Conclui-se que a definição de metas de sustentabilidade a partir de previsões mensais calculadas pelos métodos de alisamento exponencial, considerando o intervalo de confiança identificado a partir da análise histórica de séries temporais de indicadores, pode auxiliar as empresas no alcance dos ODS identificados como prioritários. A definição do percentual de variação da meta em relação ao intervalo de confiança pode variar de acordo com o interesse, a política da empresa ou com sua capacidade de definir planos de ação mais ou menos desafiadores em relação aos temas tratados, como por exemplo, em relação à redução no consumo de energia, água e geração de resíduos. O uso de um *benchmarking* também pode ser um apoio para definição de metas, combinando o objetivo de atingir a eficiência do mercado com o intervalo de confiança de previsão da empresa.

Nota-se que é sempre importante a identificação de *outliers*, não só utilizando métodos de tratamento de dados, como o Loess, por exemplo, mas também com a realização de análise qualitativa da série temporal com a finalidade de identificar erros de preenchimento ou situação e eventos não fortuitos.

Assim, observa-se que a definição de metas de sustentabilidade utilizando métodos de previsão como os de alisamento exponencial, associados à análise de discrepância de dados, análise da fonte da série de dados, identificação de *outliers* e definição de *benchmarking*, podem garantir definições de metas desafiadoras mais adequadas à realidade das empresas do setor, considerando o contexto dos países onde possuem suas atividades de geração, transmissão ou distribuição. Além disso, este tipo de metodologia pode tornar o processo de definição de metas algo dinâmico, parte integrante da gestão de sustentabilidade, mas que precisa ser constantemente avaliado e melhorado para melhor apoiar as decisões gerenciais estratégicas. Algumas sugestões de melhorias são o uso de outros métodos de previsão e utilizar o DEA para comparar a *holding* com empresas internacionais.

Portanto, a metodologia proposta é promissora e pode ser adaptada para ser aplicada em outras áreas além da sustentabilidade e por outras empresas, não apenas para o setor elétrico.

#### 5. REFERÊNCIAS BIBLIOGRÁFICAS

- [1] BERTOLO, Luiz Antonio. **Métodos básicos de previsão no Excel**. Catanduva-SP, 2013. Disponível em: <http://www.bertolo.pro.br/MetodosQuantitativos/Simulacao/MetodosBasicosDePrevisaoDeSeriesTemporaisNoExcel.pdf>. Acesso em: 5 out. 2018. Primeira referência. Primeira referência.
- [2] CASA NOVA, Silvia Pereira de Castro; SANTOS, Ariovaldo. Aplicação da análise por envoltória de dados utilizando variáveis contábeis. **Revista de Contabilidade e Organizações**, São Paulo, 2008. Disponível em: <http://www.revistas.usp.br/rco/article/view/34717>. Acesso em: 23 mar. 2019.
- [3] CEBDS, 2018. Guia de ODS para empresas. Disponível em: <https://cebds.org/publicacoes/guia-dos-ods/#.XPBHG4hKjIU>. Acesso em: 29 mar. 2019.
- [4] COSTA, Sayonara Fernandes; BOENTE, Diego Rodrigues. Avaliação da eficiência econômico-financeira das empresas integrantes do índice de sustentabilidade empresarial por meio da análise envoltória de dados. **Revista Ambiente Contábil**, Natal, 2011. Disponível em: <https://periodicos.ufrn.br/ambiente/article/view/1358>. Acesso em: 21 mar. 2019.

- [5] MAKRIDAKIS, Spyros; SPILIOTIS, Evangelos; ASSIMAKOPOULOS, Vassilios. Statistical and Machine Learning forecasting methods: Concerns and ways forward. **PLOS ONE**, [S. l.], 2018. Disponível em: <https://journals.plos.org/plosone/article/file?id=10.1371/journal.pone.0194889&type=printable>. Acesso em: 21 ago. 2019.
- [6] MARQUETTI, Adalmir; VIALI, Lori. Princípios e aplicações de regressão local. **Análise Econômica**, Porto Alegre, v. 22, n. 42, p. 253-277, 2004. Disponível em: <https://seer.ufrgs.br/AnaliseEconomica/article/view/10808/6418>. Acesso em: 16 abr. 2019.
- [7] PESSANHA, José Francisco Moreira *et al.* Implementando modelos DEA no R. In: SIMPÓSIO DE EXCELÊNCIA EM GESTÃO E TECNOLOGIA, 2013, Rio de Janeiro. **Anais [...]**. Rio de Janeiro: Associação Educacional Dom Bosco, 2013. Disponível em: <https://www.aedb.br/seget/arquivos/artigos13/44218525.pdf>. Acesso em: 21 mar. 2019.
- [8] R CORE TEAM. **R: A language and environment for statistical computing**. R Foundation for Statistical Computing, Vienna, Áustria, 2019. Disponível em: <https://www.R-project.org/>. Acesso em: 5 fev. 2019
- [9] RESENDE, Marcelo. Relative efficiency measurement and prospects for yardstick competition in brazilian electricity distribution. **Energy Policy**, [S. l.], 2002. Disponível em: <https://www.sciencedirect.com/science/article/pii/S030142150100132X>. Acesso em: 28 mar. 2019.
- [10] SARTORI, Simone. **Proposta de método de avaliação integrada de sustentabilidade com uso da análise envoltória de dados**. 2016. 251 p. Tese (Doutorado em Engenharia de Produção) - Universidade Federal de Santa Catarina, Florianópolis, 2016. Disponível em: <https://repositorio.ufsc.br/xmlui/handle/123456789/168099>. Acesso em: 15 mar. 2019.
- [11] SOUZA, Matheus Alves Madeira; RODRIGUES, Lásara Fabrícia; FARIA, Gilson Ataliba. Análise envoltória de dados aplicada ao setor elétrico de transmissão brasileiro. In: SIMPÓSIO BRASILEIRO DE PESQUISA OPERACIONAL, 2016, Vitória. **Anais [...]**. [S. l.]: Sociedade Brasileira de Pesquisa Operacional, 2016. Disponível em: <http://www.din.uem.br/sbpo/sbpo2016/pdf/155893.pdf>. Acesso em: 29 mar. 2019.
- [12] UFSC. **NNQ - Estatística**. Florianópolis, 2008. Disponível em: <http://qualimetria.ufsc.br/publicacoes/software/previsao/>. Acesso em: 23 jan. 2019.
- [13] VERÍSSIMO, Andrey Jonas et al. Métodos estatísticos de suavização exponencial Holt-Winters para previsão de demanda em uma empresa do setor metal mecânico. **Revista Gestão Industrial**, Paraná, v. 8, n. 4, p. 154-171, 2012. DOI 10.3895/S1808-044820120004. Disponível em: <https://periodicos.utfpr.edu.br/revistagi/article/view/1378>. Acesso em: 4 out. 2018.
- [14] ZHOU, Haibo et al. Data envelopment analysis application in sustainability: The origins, development and future directions. **European Journal of Operational Research**, [S. l.], v. 264, 2017. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0377221717305623>. Acesso em: 28 mar. 2019.