

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

DOI: 10.19177/rgsa.v9e32020586-606

**Katia Cristina Garcia<sup>1</sup>**  
**Rodrigo Gomes Távora Maia<sup>2</sup>**  
**José Francisco Moreira Pessanha<sup>3</sup>**

### RESUMO

O trabalho discute o uso de métodos estatísticos de previsão e de Análise Envoltória de Dados (DEA) como auxílio na definição de metas para indicadores de sustentabilidade no contexto da Agenda 2030 para uma empresa do setor elétrico brasileiro e suas unidades de negócios. A metodologia proposta consiste no tratamento das séries temporais de um indicador, na realização das previsões com modelos de alisamento exponencial, na definição de benchmark e definição de uma meta global por meio da DEA e, por último, na aplicação de uma abordagem *top-down* baseada em programação quadrática para definição de metas individuais para as unidades de negócios, compatíveis com a meta global definida para a empresa. A metodologia foi aplicada em uma empresa do setor elétrico brasileiro (*holding*) para os indicadores de consumo de energia elétrica e consumo de água da rede de abastecimento das atividades administrativas. As previsões foram acuradas e a *holding* demonstrou-se eficiente para os dois indicadores, sendo definidas metas de manutenção do desempenho atual.

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

<sup>1</sup> Pós-Doutorado em Adaptação à Mudança Climática Global pela Université Grenoble Alpes (IEPG-UJF-UPMF) em 2015, Doutora em Planejamento Energético e Ambiental pelo Instituto Alberto Luiz Coimbra de Pós-Graduação e Pesquisa de Engenharia (PPE/COPPE/UFRJ, 2007), Mestre em Engenharia de Produção (PEP/COPPE/UFRJ, 2001) e Engenheira Química pela Pontifícia Universidade Católica do Rio de Janeiro (1998). Atualmente é pesquisadora do Centro de Pesquisas de Energia Elétrica (CEPEL/ELETROBRÁS). E-mail: [garciak@cepel.br](mailto:garciak@cepel.br)

<sup>2</sup> Graduando em Engenharia Ambiental pela Universidade Federal do Rio de Janeiro (UFRJ). E-mail: [rqtmaia@gmail.com](mailto:rqtmaia@gmail.com)

<sup>3</sup> Estatístico (ENCE, 1992) e engenheiro eletricista (UERJ, 1994). É mestre (COPPE/UFRJ, 1999) e doutor (PUC-Rio, 2006) em engenharia elétrica. Atualmente é professor adjunto da Universidade do Estado do Rio de Janeiro (UERJ) e pesquisador do Centro de Pesquisas de Energia Elétrica (CEPEL). E-mail: [francisc@cepel.br](mailto:francisc@cepel.br)

# OPERATIONAL RESEARCH METHODS IN THE DEFINITION OF GOALS FOR SUSTAINABILITY INDEX IN A COMPANY OF THE BRAZILIAN ELECTRIC SECTOR IN THE CONTEXT OF AGENDA 2030

## ABSTRACT

The present paper discusses the use of statistics methods of forecasting and the use of Data Envelopment Analysis (DEA) 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 and global goal using DEA 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. Predictions were close to reality and the company proved to be efficient and maintenance goals were set.

**Keywords:** Corporate Sustainability Prediction Models. Data Envelopment Analysis (DEA). Sustainability Index. Agenda 2030. SDG.



## 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.

Olhando especificamente para a relevância dos ODS no setor elétrico, nota-se que este, além de ter um caráter estratégico para a economia brasileira e para a sociedade como um todo, também é um dos setores considerados chave no âmbito das discussões sobre mudanças do clima, seja no que se refere à mitigação e necessidade de redução das emissões de gases de efeito estufa e ampliação de fontes renováveis na matriz elétrica, seja em relação às questões de adaptação. Tal afirmação corrobora as conclusões do estudo da Rede Brasil do Pacto Global, sobre integração dos ODS no Setor Elétrico Brasileiro, que menciona a ligação importante e direta do setor com diversos ODS, como o ODS 7 (Energia Limpa e Acessível) e ODS 13 (Ação Climática).

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).

A metodologia SDG Compass foi elaborada pela GRI (Global Reporting Initiative) em conjunto com Pacto Global, WBCSD (World Business Council for Sustainable Development) e a Organização das Nações Unidas (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 corresponde ao mapeamento dos impactos atuais, potenciais, positivos e negativos de suas atividades nos ODS, em toda cadeia de valor. O segundo passo consiste em 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. Já no passo 4 as metas de sustentabilidade são integradas às estratégias de negócio, e no passo 5, todo o processo e progresso devem ser relatados e comunicados às partes interessadas.

O presente artigo discute como o uso de métodos de Pesquisa Operacional (RAGSDALE, 2008) pode auxiliar no desenvolvimento de uma metodologia robusta para definição de metas de sustentabilidade relacionadas aos ODS priorizados por uma empresa do setor elétrico brasileiro, no contexto da Agenda 2030. Mais especificamente, a metodologia proposta baseia-se no emprego de métodos de previsão de séries temporais (SAMOHYL; SOUZA; MIRANDA, 2008 e VERISSIMO *et al.*, 2012) e na Análise Envoltória de Dados (*Data Envelopment Analysis - DEA*) (CHARNES; COOPER; RHODES, 1978) 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, baseadas no desempenho histórico, mas que consigam impulsionar planos de ação de melhoria contínua, que garantam uma contribuição efetiva da empresa para o alcance dos ODS priorizados. No caso apresentado 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

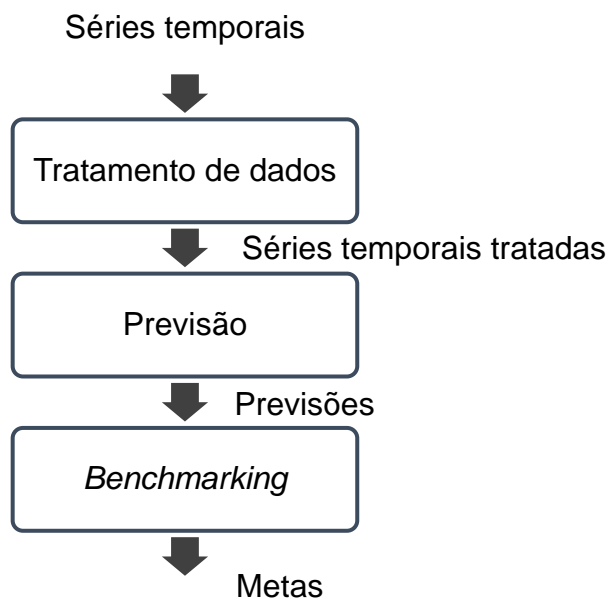
a *holding* por meio de modelos DEA e, na sequência, as metas globais são desagregadas em metas individuais para cada unidade de negócio com o auxílio de um modelo de programação quadrática (RAGSDALE, 2008). Para isso, usam-se como restrições dos limites mínimos e máximos para as metas locais em cada unidade de negócio os limites definidos pelos intervalos de previsão e uma restrição de compatibilização das metas locais com a meta global para a *holding*.

Portanto, 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 do setor elétrico brasileiro. Conforme ilustrado na Figura 1, a metodologia possui três etapas principais: tratamento de dados, previsão e *benchmarking*.

Figura 1 - Estrutura da metodologia proposta.



Fonte: Elaboração Própria.

## 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). 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 mostrado 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.



Fonte: Elaboração Própria.

A componente de tendência aponta para movimentos de longo prazo que indicam o crescimento ou decréscimo 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 de 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	Aditiva	Multiplicativa
Erro	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

Fonte: Elaboração Própria.

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 sazonal 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 da meta global para a empresa, a partir do *benchmarking*, visando garantir que esta caminhe para um desempenho em sustentabilidade compatível com as melhores práticas das empresas do mesmo setor.



Esta etapa é realizada utilizando DEA, e a desagregação da meta entre as unidades de negócio por meio de programação quadrática, tendo como restrição os limites inferior e superior dos intervalos de previsão para cada mês do horizonte de estudo.

Introduzida por Charnes, Cooper e Rhodes (1978), a DEA é uma técnica não-paramétrica utilizada na avaliação da eficiência de unidades produtivas comparáveis (*decision making units* - DMU), i.e., unidades que empregam processos tecnológicos semelhantes na transformação de múltiplos insumos (*inputs*) em múltiplos produtos (*outputs*).

A abordagem DEA foi escolhida para essa etapa com base em aplicações correlatas de Costa e Boente (2011), Sartori (2016) e Zhou *et al.* (2017) em avaliações de sustentabilidade empresarial. A implementação da DEA também pode ser vista em Resende (2002), Pessanha *et al.* (2010) e Souza, Rodrigues e Faria (2016) em empresas do setor elétrico brasileiro.

Essa análise 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 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. 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 objetivo 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. Esses modelos fornecem uma medida global da eficiência técnica.

Tabela 2 - Modelos CCR (CRS).

Modelo CCR (CRS) – Orientado ao Insumo	Modelo CCR (CRS) – Orientado ao Produto
Maximizar $h_k$ (Eficiência)	Minimizar $h_k$ (Eficiência)
$h_k = \sum_{r=1}^m u_r * y_{rk}$	$h_k = \sum_{i=1}^n v_i * x_{ik}$
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 $N$

Fonte: Adaptado de CASA NOVA; SANTOS, 2008.

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 ganhos de escala crescentes, decrescentes ou constantes.

Tabela 3 - Modelos BCC (VRS).

Modelo BCC (VRS) – Orientado ao Insumo	Modelo BCC (VRS) – Orientado ao Produto
Maximizar	Minimizar
$\sum_{r=1}^m u_r * y_{rk} - u_k$	$\sum_{i=1}^n v_i * x_{ik} + v_k$
Com as restrições: 1. $\sum_{r=1}^m u_r * y_{rj} - \sum_{i=1}^n v_i * x_{ij} - u_k \leq 0$ 2. $\sum_{i=1}^n v_i * x_{ik} = 1$ 3. $u_r, v_i \geq 0$	Com as restrições: 1. $\sum_{r=1}^m u_r * y_{rj} - \sum_{i=1}^n v_i * x_{ij} - v_k \leq 0$ 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 $N$

Fonte: Adaptado de CASA NOVA; SANTOS, 2008.

Para desagregar as metas globais entre as unidades de negócio da empresa e, conseqüentemente, compatibilizar as metas individuais com a meta global definida pelo DEA, propõem-se a aplicação da programação quadrática, 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 da meta global, obtidas pelo modelo DEA, em metas individuais 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:

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

s.a.:

$$\alpha_i \leq M_i \leq \beta_i \forall i = 1, N \quad (2)$$

$$\sum_{i=1}^N M_i = \theta V_{\text{empresa}} \quad (3)$$


$$M_i \geq 0 \forall i = 1, N \quad (4)$$

A função objetivo em (1) busca minimizar os desvios entre as metas  $M_i$  e os respectivos níveis correntes dos consumos  $V_i$  no último ano. A restrição em (2) 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 (3)  $\theta$  é a eficiência da empresa determinada pelo modelo DEA e  $V_{\text{empresa}}$  é o valor verificado do consumo da empresa no último ano. Assim, o produto  $\theta V_{\text{empresa}}$  é a meta global a ser alcançada pela empresa. A restrição em (3) garante que a soma das metas locais para as unidades de negócios deve coincidir com a meta global para a empresa. Já a restrição (4) 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 empresa do setor elétrico com nove unidades de negócio. Sem perda de generalidade, no estudo de caso apresentado consideram-se apenas as análises realizadas na definição das metas para dois indicadores relacionados ao ODS 9 (Indústria, inovação e infraestrutura): consumo de energia elétrica e consumo de água.

#### 3.1 Tratamento de dados e previsão

No estudo apresentado considerou-se que o horizonte de planejamento abrange o ano de 2018. Primeiramente foi realizado o levantamento de séries temporais mensais das nove unidades de uma *holding* no período 2014-2017 e, portanto, cada série temporal possui 48 observações mensais. Na sequência, o método Loess, com o uso do R (R CORE TEAM, 2019), foi aplicado em todas as séries temporais, com o objetivo de corrigir eventuais *outliers*.

As séries tratadas foram analisadas pelo NINQ-Estatística (UFSC, 2008) com o objetivo de identificar o melhor modelo de alisamento exponencial para cada série temporal, em cada unidade. Os modelos de melhor ajuste, segundo o *Akaike Information Criterion* (AIC) (AKAIKE, 1981), estão na Tabela 4.

Tabela 4 - Métodos de previsões de melhor ajuste aos dados de cada unidade.

Consumo de energia		Consumo de água	
Unidade	Método	Unidade	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	

Fonte: Elaboração Própria.

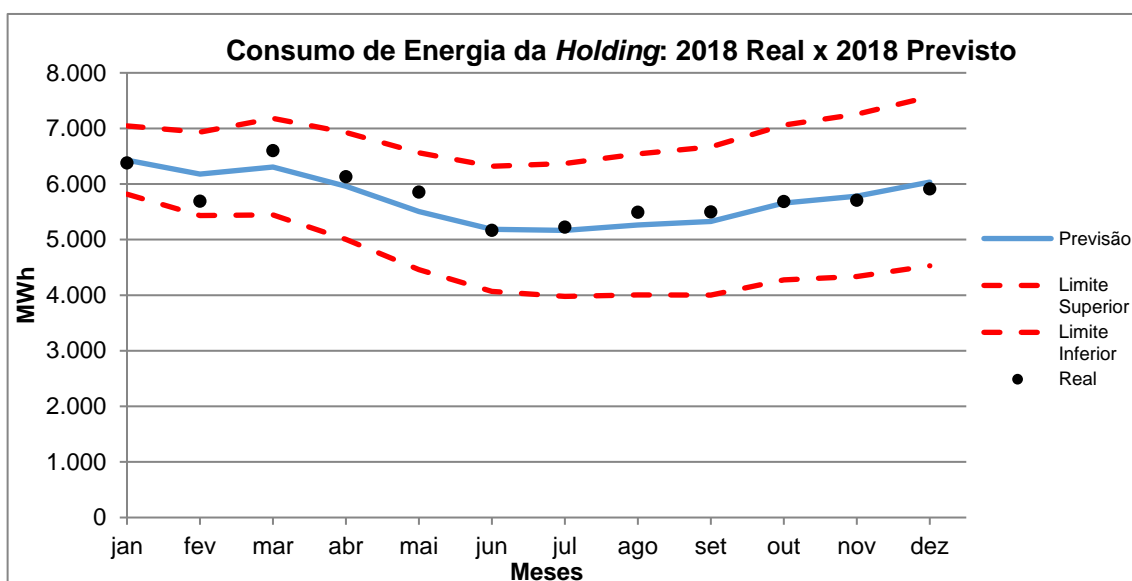
Os modelos ajustados foram utilizados para gerar previsões mensais de 2018, portanto, um horizonte de previsão de 12 meses. Seguindo a abordagem *bottom-up*, a soma das previsões mensais para 2018, em cada unidade, resultou na previsão total da *holding*. As previsões e os valores verificados dos consumos de energia e água para a *holding* são apresentadas na Tabela 5 e Figuras 2 e 3.

Tabela 5 - Valores previstos e verificados dos consumos de energia e de água.

Comparação mensal 2018: Real x Previsão [MWh]				Comparação mensal 2018: Real x Previsão [m³]			
Meses	Real	Previsão	Variação mensal	Meses	Real	Previsão	Variação mensal
jan	6.377	6.429	-1%	jan	44.393	47.420	-6%
fev	5.690	6.179	-8%	fev	42.305	45.126	-6%
mar	6.601	6.307	5%	mar	48.739	45.419	7%
abr	6.131	5.960	3%	abr	46.290	43.959	5%
mai	5.855	5.504	6%	mai	44.459	41.049	8%
jun	5.166	5.186	0%	jun	37.918	39.318	-4%
jul	5.222	5.166	1%	jul	33.322	40.109	-17%
ago	5.491	5.264	4%	ago	37.172	41.494	-10%
set	5.497	5.325	3%	set	36.010	42.515	-15%
out	5.683	5.659	0%	out	39.162	40.544	-3%
nov	5.706	5.782	-1%	nov	38.387	42.295	-9%
dez	5.912	6.036	-2%	dez	38.004	42.287	-10%
<b>total anual</b>	<b>69.331</b>	<b>68.797</b>	<b>1%</b>	<b>total anual</b>	<b>486.161</b>	<b>511.535</b>	<b>-5%</b>
(a) Consumo de energia				(b) Consumo de água			

Fonte: Elaboração Própria.

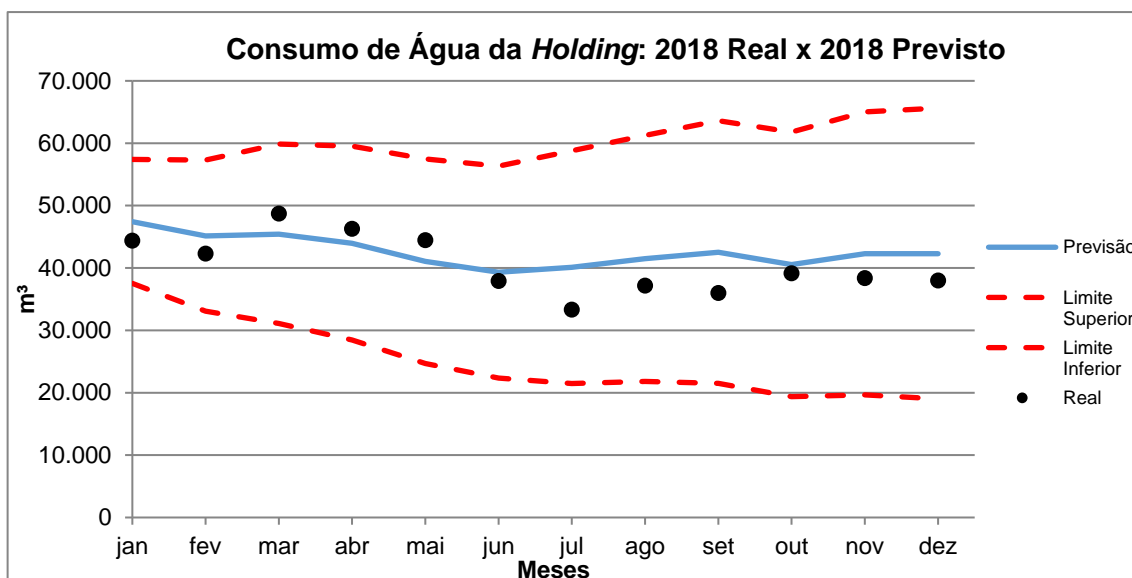
Figura 2 - Comparação entre o consumo de energia previsto e real em 2018.



Fonte: Elaboração Própria.



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



Fonte: Elaboração Própria.

Nas Figuras 2 e 3, os pontos correspondem aos valores mensais observados ao longo de 2018 e a linha contínua indica as respectivas estimativas. As linhas tracejadas indicam os limites inferiores e superiores dos intervalos de previsão de 95%. Percebe-se que as previsões mensais e anuais para os dois indicadores foram acuradas, dentro do intervalo preditivo.

### 3.2 Definição de metas

Para definir metas globais de redução de consumo para esses dois indicadores, propõe-se um conjunto de dois modelos DEA, orientados ao insumo. Essa opção 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 6 apresentam-se os insumos e produtos utilizados em cada modelo, avaliados na formulação VRS, devido à heterogeneidade no porte das DMU.

Tabela 6 - 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

**Revista Gestão & Sustentabilidade Ambiental**

Fonte: Elaboração Própria.

*Para a aplicação dos modelos DEA e conseqüente 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. Portanto, foram inseridas no modelo nove empresas, mais a holding.*

#### 3.2.1 Metas para o consumo de energia elétrica

Os resultados dos modelos DEA (VRS, orientado ao insumo), tendo o consumo de energia como único insumo, são apresentados na Tabela 7. Observa-se que a

*holding* é eficiente no modelo VRS. Portanto, no modelo VRS, a *holding* é o próprio *benchmark*.

Tabela 4 - Eficiências VRS em relação ao consumo de energia (Modelo 1).

DMU	Eficiência VRS
Empresa 1	1
Empresa 2	1
Empresa 3	1
Empresa 4	0,03749
Empresa 5	0,40209
<i> Holding </i>	1
Empresa 6	0,52022
Empresa 7	1
Empresa 8	0,02844
Empresa 9	0,75186

Fonte: Elaboração Própria.

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 da distribuição da meta das unidades pela programação quadrática se encontra na Tabela 8.



Tabela 5 - Metas para o consumo de energia nas unidades de negócio.

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

Fonte: Elaboração Própria.

Apesar da eficiência da *holding* demonstrada na Tabela 7, na Tabela 8 percebe-se que duas unidades não alcançaram suas metas individuais. Porém, isso não impediu que a *holding* atingisse a meta global de manutenção.

R. gest. sust. ambient., Florianópolis, v. 9, n. 3, p. 586-606, jul/set. 2020.



### 3.2.2 Metas para o consumo de água

Os resultados do modelo DEA (VRS, orientado ao consumo), tendo o consumo de água como único insumo, estão presentes na Tabela 9. Observa-se que, novamente, a *holding* é eficiente no modelo VRS.

Tabela 6 - Eficiências VRS em relação ao consumo de água (Modelo 2).

DMU	Eficiência VRS
Empresa 1	1
Empresa 2	0,93328
Empresa 3	1
Empresa 4	1
Empresa 5	0,53637
Holding	1
Empresa 6	0,05341
Empresa 7	0,09738
Empresa 8	0,67618
Empresa 9	1

Fonte: Elaboração Própria.



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. A seguir, na Tabela 10, tem-se o resultado da desagregação da meta global da holding entre as suas unidades, pela programação quadrática.

Tabela 7 - Metas para o consumo de água nas unidades de negócio.

Unidades	Consumo real 2017 [m³]	Previsão 2018 [m³]	Meta 2018 distribuída [m³]	Meta % (2017-2018)	Consumo real 2018 [m³]	Meta seria atingida?
Unidade 1	30.562	28.898	32.888	7,6%	42.253	Não
Unidade 2	1.577	856	1.804	14,4%	3.080	Não
Unidade 3	112.920	148.597	111.685	-1,1%	113.335	Não
Unidade 4	38.693	41.135	44.522	15,1%	45.602	Não
Unidade 5	23.528	21.566	24.938	6,0%	27.604	Não
Unidade 6	178.840	173.728	164.421	-8,1%	160.351	Sim
Unidade 7	33.404	29.318	34.157	2,3%	27.073	Sim
Unidade 8	50.932	46.046	55.432	8,8%	55.623	Não
Unidade 9	11.703	11.892	12.312	5,2%	11.240	Sim
<b> Holding</b>	<b>482.159</b>	<b>502.036</b>	<b>482.159</b>	<b>0,0%</b>	<b>486.161</b>	<b>Não</b>

Fonte: Elaboração Própria.

Vale ressaltar que, apesar da eficiência da *holding* demonstrada na Tabela 9, na Tabela 10 percebe-se que algumas unidades não alcançaram suas metas individuais e, conseqüentemente, a meta global de manutenção da *holding* também não foi atingida.

#### 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 contribuir para o alcance dos ODS identificados como prioritários. O uso de uma análise de *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, identificação de *outliers* e definição de *benchmark*, podem contribuir para a definição de metas mais adequadas à realidade das empresas do setor, considerando seu desempenho histórico e também as melhores práticas de mercado, no setor onde a empresa atua. 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 apoiar as decisões gerenciais estratégicas.

## REFERÊNCIAS

- AKAIKE, H. Likelihood of a model and information criteria. **Journal of Econometrics**, [S. l.], v. 16, n. 1, p. 3-14, 1981. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/0304407681900713>. Acesso em: 28 mar. 2019.
- BANKER, R. D.; CHARNES, A.; COOPER, W. W. Some models for estimating technical and scale inefficiencies in Data Envelopment Analysis. **Management Science**, [S.l.], v. 30, n. 9, p. 1078-1092, 1984. Disponível em: <https://www.jstor.org/stable/2631725?origin=JSTOR-pdf>. Acesso em: 07 abr. 2019.
- 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
- 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.
- CEBDS, 2018. **Guia de ODS para empresas**. Disponível em: <https://cebds.org/publicacoes/guia-dos-ods/#.XPBHG4hKjIU>. Acesso em: 29 mar. 2019.
- CHARNES, A.; COOPER, W. W.; RHODES, E. Measuring the efficiency of decision making units. **European Journal of Operational Research**, [S.l.], 1978. Disponível em: <https://personal.utdallas.edu/~ryoung/phdseminar/CCR1978.pdf>. Acesso em: 07 abr. 2019.
- 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.
- 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.
- 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.

PESSANHA, José Francisco Moreira *et al.* Avaliação dos custos operacionais eficientes das empresas de transmissão do setor elétrico brasileiro: Uma proposta de adaptação do modelo DEA adotado pela ANEEL. **Pesquisa Operacional**. 2010, v. 30, n. 3, p. 521-545. Disponível em: [https://www.scielo.br/scielo.php?pid=S0101-74382010000300002&script=sci\\_abstract&tlng=pt](https://www.scielo.br/scielo.php?pid=S0101-74382010000300002&script=sci_abstract&tlng=pt). Acesso em: 21 mar. 2019.

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

RAGSDALE, Cliff T. **Spreadsheet modeling & decision analysis**. 5. ed. rev. [S. l.: s. n.], 2008. 842 p.

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.

SAMOHYL, R. W.; SOUZA, G. P.; MIRANDA, R. G. **Métodos simplificados de previsão empresarial**. Rio de Janeiro: Editora Ciência Moderna Ltda., 2008.



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.

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.

UFSC. **NNQ - Estatística**. Florianópolis, 2008. Disponível em: <http://qualimetria.ufsc.br/publicacoes/software/previsao/>. Acesso em: 23 jan. 2019.

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.

R. gest. sust. ambient., Florianópolis, v. 9, n. 3, p. 586-606, jul/set. 2020.

DOI 10.3895/S1808-044820120004. Disponível em:  
<https://periodicos.utfpr.edu.br/revistagi/article/view/1378>. Acesso em: 4 out.  
2018.

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.

