



São Paulo - Brazil - May - 22nd to 24th - 2013

Acc4emic INTERNATIONAL WORKSHOP ADVANCES IN CLEANER PRODUCTION

“INTEGRATING CLEANER PRODUCTION INTO SUSTAINABILITY STRATEGIES”

Combinando Sustentabilidade e Modelos Quantitativos - Uma Análise para os Países do BRICS

SARTORI, S. ^{a,*}, CAMPOS, L.M.S. ^a; SAMOHYL, R. ^a

a. Universidade Federal de Santa Catarina, Florianópolis

**Corresponding author, simone.sartori@posgrad.ufsc.br*

Resumo

O interesse no desenvolvimento de indicadores para medir a sustentabilidade é crescente, mas são poucos os estudos sobre as mudanças desses indicadores ao longo do tempo. Neste contexto, este artigo apresenta uma análise temporal das emissões de CO₂ para os países do BRICS (Brasil, Rússia, Índia, China e África do Sul) no período de 1980 à 2010, exceto para Rússia (1992 à 2010). A análise das emissões de CO₂ aqui tratado como indicador de sustentabilidade, apresenta de forma preliminar a atual situação destes países e emissões futuras num horizonte de 10 anos. Embora a série temporal analisada e estimada seja curta, revelou algumas informações importantes. A estimação por meio dos modelos ARIMA e Suavização Exponencial apresentaram coeficientes estatisticamente significativos. Do ponto de vista prático, o modelo ARIMA apresenta melhor aderência à série, uma vez que possui menor Critério de Informação Akaike (AIC). A estimativa de crescimento das emissões de CO₂ confirma a insustentabilidade futura do BRICS. Por fim, a experiência deste trabalho sugere o uso de modelos de previsão para análise quantitativa da sustentabilidade.

Palavras-chave: Sustentabilidade, Emissão de CO₂, ARIMA, Suavização Exponencial.

1. Introdução

A sustentabilidade, operacionalmente e conceitualmente, é um dos temas mais complexos que a ciência moderna tem enfrentado (Cabezas e Fath, 2002). Desde então, no início dos anos 90, muitas iniciativas vem acontecendo na busca pela avaliação da sustentabilidade por meio de indicadores (UNCED, 1992; Hammond *et al.*, 1995; Keeble *et al.*, 2003; Bohringer e Jochem, 2007; Niemeijer e Groot, 2008; Heink e Kowarik, 2010; Global Reporting Initiative, 2011; Munier, 2011; Dahl, 2012; Índice Dow Jones de Sustentabilidade, 2012).

A possibilidade de comparações, muitas vezes, é a principal meta das avaliações da sustentabilidade. Comparar o desempenho atual com os anos anteriores, comparar o progresso em certas metas de desempenho ou comparar empresas, regiões e países. A principal tendência está em desenvolver e avaliar um conjunto de indicadores organizados dentro de uma estrutura que pode eventualmente agregar os resultados dos indicadores separados (Ronchi *et al.*, 2002).

Um conjunto de indicadores de sustentabilidade desempenha um papel importante na representação da realidade ao permitir a medição e cálculo, porém, são estáticos e não têm a profundidade de conceituação e explicação dos fenômenos que representam (Todorov e Marinova, 2009), sem apresentar conhecimento de situações futuras. Cabe portanto a adição da dimensão tempo, o que

“INTEGRATING CLEANER PRODUCTION INTO SUSTAINABILITY STRATEGIES”

São Paulo - Brazil - May 22nd to 24th - 2013

realça a perspectiva de longo prazo das várias dimensões de sustentabilidade (ambiental, econômico e social).

Na perspectiva de longo prazo, a avaliação da sustentabilidade tornou-se parte dos modelos de base temporal, econométricos, dinâmicos, por exemplo: Geographical Information Systems (Costanza *et al.*, 1997); SUE model (Bockermann *et al.*, 2005); NEMESIS (2006); Panta Rhei (Lehr *et al.*, 2008); EcoSTEP Tool (JISC, 2012), entre outros. Descrever um estado de sustentabilidade estático fornece uma representação simplificada da realidade.

Sendo assim, os indicadores de sustentabilidade, representados por meio de modelos, devem ser utilizados para extrapolar o tempo para a série passada ou atual no futuro (Zhang, 2003). Por sua vez, o tempo é uma consideração crucial. Qualquer modelo para avaliar e prever cenários futuros devem ser capazes de captar as mudanças que estão acontecendo dentro de um horizonte de tempo adequado, avaliando e estimando consequências futuras das interações dinâmicas entre a sociedade e a natureza. Os modelos de séries temporais são uma área importante de previsão de que observações passadas da mesma variável são recolhidas e analisadas para desenvolver um modelo que descreve uma relação subjacente. Assim, pode-se afirmar que os valores futuros das séries em análise são funções matemáticas dos valores presentes e passados.

Uma previsão é fundamental para as tomadas de decisão, ajudando a planejar o futuro e tornar decisões mais racionais (Armstrong, 1988). Previsão é prever o futuro com a maior acurácia, dando todas as informações disponíveis, incluindo dados históricos e conhecimento de eventos futuros que possam afetar as previsões (Hyndman, 2009). A sociedade moderna necessita de previsões de curto, médio e longo prazo, dependendo da aplicação específica.

De modo geral, a sustentabilidade consiste em dois elementos principais: o *Triple Bottom Line* e o tempo, isto é, considera-se a equidade nas dimensões ambiental, econômica e social ao longo do tempo. Neste contexto, este trabalho tem por objetivo contribuir com os estudos ambientais visando construir e analisar uma previsão de 10 anos a partir de um indicador de sustentabilidade - emissões de CO₂ para os países do BRICS (Brasil, Rússia, Índia, China e África do Sul). Para tanto, utilizou-se dos métodos de previsão Auto-Regressivo Integrado de Médias Móveis (ARIMA) e Suavização Exponencial, que fazem parte da classe de modelos univariados.

Para efeitos deste trabalho: i) o indicador quantificável para medir o progresso (ou regresso) são as emissões de CO₂; ii) os dados estão sendo considerados para os países do BRICS, isto é, limites do sistema; iii) os resultados permitem a análise sobre os impactos ambientais para os países em questão; iv) o PIB é usado apenas para análise de correlação entre o crescimento (diminuição) do PIB frente ao crescimento (diminuição) das emissões de CO₂; v) refere-se a modelos temporais no qual permite prever a sustentabilidade para 10 anos à frente.

2. Métodos

Nos atuais métodos de previsão, os modelos podem ser divididos em três categorias: análise multivariada, análise de séries temporais univariadas e modelos inteligentes não-lineares (Pao *et al.*, 2012). Entre os modelos, citam-se os: Redes Neurais Artificiais, Monte Carlo, Data Mining, Fuzzy, ARIMA, Holt-Winters, Modelo não linear de Bernoulli (NGBM), entre outros. Não há nenhum método que é melhor em todas as situações (Maia *et al.*, 2008), mas o uso de métodos simples é importante quando a incerteza é elevada e poucos dados estão disponíveis (Armstrong, 2001).

2.1 Dados

A emissão de Co₂ a partir do consumo de combustíveis fósseis (milhões de toneladas) foi obtida do site do departamento de Energia dos Estados Unidos da América, produzido pela Administração de Informação de Energia (EIA). Para chegar às emissões totais de todos os combustíveis fósseis, foram agregadas as emissões dos três combustíveis envolvidos - carvão, petróleo e gás natural - em unidades comuns. Os dados para análise do PIB para os países do BRICS foram obtidos no site do Banco Mundial. O PIB é medido em milhões de dólares. Os dados correspondem ao período de 1980 à 2010, totalizando 32 observações, exceto para Rússia, analisada no período de 1992 à 2010. Para

analisar o comportamento da série, serão utilizados dois métodos de previsão univariados: Suavização Exponencial e ARIMA. Para analisar o melhor método serão utilizados os critérios de medidas dos erros de previsão como o erro absoluto percentual médio (MAPE) e Critério de Informação de AKaike (AIC).

O erro absoluto percentual médio (MAPE) é a média calculada pelo somatório da razão do erro (diferença do valor previsto e do observado) e o valor observado, tudo em termos absolutos, conforme representado na Eq. 1.

$$MAPE = \frac{1}{n} \sum_{t=1}^n |previsto_t - observado_t / observado_t| \quad (1)$$

O AIC permite que a decisão seja feita baseando-se entre a redução na soma do quadrado dos resíduos estimados e um modelo mais parcimonioso. Este critério é dado por:

$$AIC = T \ln(\text{soma dos quadrados dos resíduos}) + 2n \quad (2)$$

O T indica o número de observações utilizadas e o n indica o número de parâmetros estimados.

A situação ideal é quanto menor o AIC melhor o ajustamento do modelo. Entretanto, cabe comparar o AIC dos modelos para saber qual o modelo que melhor explica a dinâmica das séries temporal analisadas.

Na aplicação do Modelo ARIMA e Suavização Exponencial, utilizou-se do software R studio, utilizando o pacote *forecast* que permitem a escolha de um modelo de forma automática (*auto.arima* e *ets*).

2.2 Modelo ARIMA

O modelo de Box-Jenkins (Box e Jenkins, 1976), popularmente conhecido por ARIMA (Auto-regressivos Integrados de Médias Móveis) é um modelo univariado que visa captar o comportamento da autocorrelação entre os valores da série temporal, e com base nesse comportamento, realizar previsões futuras.

Os passos básicos do modelo ARIMA são: i) considerar a sequência de dados do alvo ao longo do tempo de predição como uma sequência aleatória; ii) usar um modelo matemático para descrever ou simular a sequência de dados; e iii) prever os valores futuros da série temporal, dados os valores passados e os valores presentes (Jia *et al.*, 2010), bem como os erros do passado (Pao *et al.*, 2012)

Os modelos ARIMA resultam da combinação de três componentes denominados filtros ou processos: o componente auto-regressivo AR(p), o filtro de integração I (d) e o componente de médias móveis MA(q) e AR combinado com MA (ARMA). Uma série pode ser modelada pelos três filtros (processos) ou apenas um subconjunto deles, resultando em vários modelos (Fava, 2000).

Em suma, quando se faz referência a modelos ARIMA esses modelos estão sendo ajustados à série original. Já ao fazer-se referência a modelos ARMA, considera-se que a série é uma série diferenciada. A transformação mais comum consiste em tomar diferenças sucessivas da série original até obter uma série estacionária, onde uma diferença significa subtrair Y_t por Y_{t-1} . Em situações normais, será suficiente tomar uma ou duas diferenças para que a série se torne estacionária. O número d de diferenças necessárias para tornar a série estacionária é denominado ordem de integração. Um modelo ARIMA (pdq) é dado pela Eq. 3 (Morretin e Toloi, 1987).

$$Y_t = \delta + \theta_1 Y_{t-1} + \dots + \theta_p Y_{t-p} + e_t - a_1 e_{t-1} - \dots - a_q e_{t-q} \quad (3)$$

Onde δ é um parâmetro intercepto relacionado com a média de Y_t , os θ são os parâmetros auto-regressivos desconhecidos, os a são constantes desconhecidas que descrevem a relação existente entre os ruídos e Y_t , e e_t são os ruídos aleatórios não correlacionados, com média zero e variância constante.

Os parâmetros p e q representam o número de parâmetros relativos aos comprimentos de defasagem em que se observam valores significativos das autocorrelações e que correspondem a particularidades

do sistema de geração das séries que devem ser explicadas pelo modelo (pois correspondem a um padrão de geração). O processo gerador dos dados da série é dito aleatório linear se o modelo ajustado Y_t pode ser descrito como uma combinação linear de valores defasados de Y_t e ε_t .

Destaca-se que as previsões usando o modelo ARIMA são realizadas sob as observações da própria série de dados, não dependendo de nenhuma variável externa. O modelo univariado ARIMA tem sido amplamente utilizado para a modelagem e previsão nas áreas ambiental, financeira, engenharia, energia e outras aplicações (Bowden e Payne, 2008; Pappas *et al.*, 2008).

2.2 Suavização Exponencial

O método de suavização exponencial tornou-se muito popular devido à sua simplicidade e desempenho. Este método consiste em decompor a série em componentes (tendência e sazonalidade) e suavizar seus valores passados, isto é, dar pesos diferenciados cujos valores decaem exponencialmente para zero quanto mais antigo for o dado, portanto, valorizando os dados mais recentes (Souza *et al.*, 2008).

O método de suavização exponencial trabalha com a série original sem exigência de nenhuma manipulação que comprove estacionariedade ou normalidade nos dados. A seleção e utilização deste método de previsão pode parecer *ad-hoc*. A escolha do método é geralmente baseada no reconhecimento de componente-chave da série de tempo (tendência e sazonalidade) e como estes entram no método de suavização (modo aditivo ou multiplicativo) (Hyndman e Athanasopoulos, 2012).

A suavização exponencial simples foi o primeiro método a ser desenvolvido para dados que não possuem tendência e nem sazonalidade (Hyndman e Athanasopoulos, 2012), conforme representado na Eq. 4.

$$P_{t+1} = \alpha O_{t-1} + (1-\alpha)P_t \quad (4)$$

Onde P_t representa o valor que foi previsto para o período t , O_t o valor observado no mesmo período t e α é o parâmetro de suavização do método, que pode variar de 0 à 1. Isto é, o valor previsto para o próximo período P_{t+1} é uma combinação do valor previsto para hoje P_t e o valor observado de hoje.

Para dado com tendência e sem sazonalidade, tem-se o Método de Holt, representado pelas Eq. 5, Eq. 6 e Eq. 7.

$$n_t = \alpha + (1-\alpha)(n_{t-1} + c_{t-1}) \quad (5)$$

$$c_t = \beta(n_t - n_{t-1}) + (1-\beta)c_{t-1} \quad (6)$$

$$P_{t+k} = n_t + kc_t \quad (7)$$

A Eq. 5 representa o nível (n_t) e é uma combinação entre o observado e o previsto no período t .

A Eq. 6 representa o crescimento (c_t) que é diferença entre os níveis sequenciais, e para fazer previsões são necessárias duas constantes de suavização, α para o nível e β para o crescimento, que variam entre 0,01 e 0,99.

A Eq. 7 representa a previsão para k períodos à frente.

Para dado com tendência e sazonalidade, tem-se o Método de Holt-Winters, representado pelas Eq.8, Eq.9 e Eq. 10.

$$n_t = \alpha (O_t - s_{t-n}) + (1-\alpha)(n_{t-1} + c_{t-1}) \quad (8)$$

$$c_t = \beta(n_t - n_{t-1}) + (1-\beta)c_{t-1} \quad (9)$$

$$s_t = \gamma(O_t + n_{t-1} - c_{t-1}) + (1-\gamma)s_{t-m} \quad (10)$$

$$P_{t+k} = n_t + kc_t + s_{t+m+k} \quad (11)$$

Neste método, para fazer previsões, são necessárias três constantes de suavização: α para nível, β para o crescimento e γ para a sazonalidade, e variam de 0,01 e 0,99. A Eq. 11 representa a previsão para k períodos à frente, onde m é o ciclo sazonal.

3. Resultados

O roteiro básico para estimação e análise dos modelos envolve os passos: i) análise descritiva dos dados; ii) identificação dos modelos, escolha do melhor modelo com base nos critérios AIC e MAPE, e estimação e apresentação das previsões para 10 passos à frente.

3.1 Apresentação Descritiva dos Dados

O crescimento das emissões de CO₂ ao longo do tempo apresenta uma variação substancial entre os países em análise, podendo estar associado ao crescimento econômico dos países (Fig.1b). Conforme Fig. 1a e 1b, o país com maior peso nas emissões de CO₂ e maior PIB é a China.

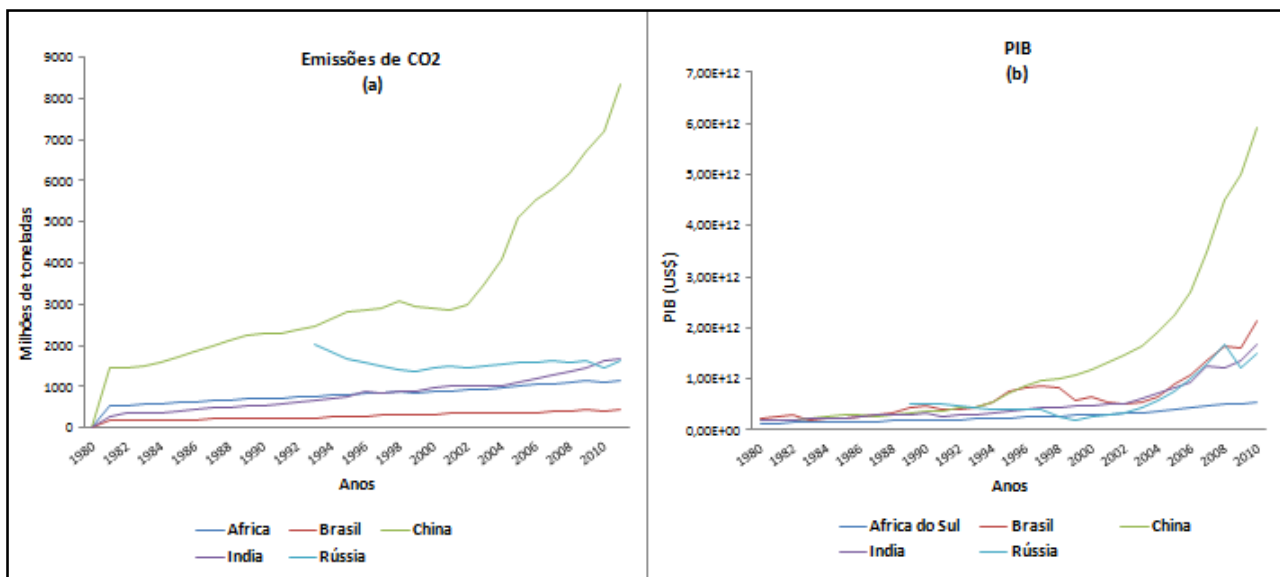


Fig.1: Emissão de CO₂ (a) e Produto Interno Bruto (b). Fonte: elaborada pelos autores.

A Tab.1 apresenta o percentual de crescimento para cada série dos países do BRICS, calculados como crescimento ocorrido em 20 anos (período de 1980 à 2000) e nos últimos 10 anos (período de 2000 à 2010) para as séries das emissões de CO₂ (Painel A) e PIB (Painel B), exceto para a Rússia (período inicial em 1989 e final em 2010).

Tab. 1: Taxas de crescimento (%) para as emissões de CO₂ e do PIB. Fonte: elaborada pelos autores.

	África	Brasil	China	Índia	Rússia
Painel A - emissão de CO₂ em milhões de toneladas métricas					
Crescimento 1980-2000	65,18%	85,47%	96,74%	244,39%	-25,81%
Crescimento 2000-2010	29,06%	31,08%	191,98%	69,06%	9%
Painel B - Produto Interno Bruto em milhões de dólares					
Crescimento 1980-2000	158,29%	174,31%	532,77%	150,37%	-48,72%
Crescimento 2000-2010	76,84%	232,41%	394,84%	254,82%	472,76%

Nos últimos 20 anos, a Índia apresentou maior taxa de crescimento de CO₂ (244,39%) e a China apresentou maior taxa de crescimento do PIB (532,77%). Desde a adoção de uma estratégia de reforma e abertura comercial em 1978, a China tem mantido uma taxa elevada de crescimento

econômico (Yu *et al.*, 2013). E nos últimos 10 anos, a China apresentou maior taxa de crescimento das emissões de CO₂ (191,98%), e a Rússia apresentou maior taxa de crescimento do PIB (472,76%).

Em termos exploratórios, a análise de correlação (Tab. 2) apresenta um coeficiente de Pearson forte para os países África do Sul, Brasil, China e Índia. Isto é, o PIB e emissão de CO₂ estão positivamente correlacionadas e caminham no mesmo sentido de crescimento. Entretanto, esta correlação não implica, necessariamente, a relação de causa e efeito, mas serve como elemento auxiliar na análise deste estudo.

Tab. 2: Coeficiente de correlação de Pearson. Fonte: elaborada pelos autores.

Países	África do Sul	Brasil	China	Índia	Rússia
Coeficiente de Correlação	0,98	0,87	0,97	0,93	0,12

3.2 Identificação do modelo Box-Jenkins (ARIMA) e Suavização Exponencial

Na fase de identificação do modelo Box-Jenkins, busca-se identificar se este foi gerada por um processo AR, MA, ARMA ou ARIMA. Bem como, busca-se determinar quais são as suas ordens. Conforme Gujarati (2000), as principais ferramentas a serem utilizadas na etapa de identificação dos modelos ARIMA são a ACF, PACF e respectivos correlogramas.

A Fig.2 apresenta o correlograma da série original (superior) e o gráfico de autocorrelação parcial da série (inferior). Para os países como a África, Brasil, China e Índia o correlograma ACF apresenta padrão de decaimento exponencial sem oscilações e o PACF apresenta 1 truncamento, onde caracteriza a série como auto-regressiva (dados correlacionados ao longo do tempo), exigindo uma transformação na série; a Rússia diferencia-se dos demais países, apresentando um correlograma vazio e decaimento rápido para zero, indicando série estacionária. Se o processo é não estacionário, é necessário diferenciar a série original "d" vezes até obter a série estacionária.

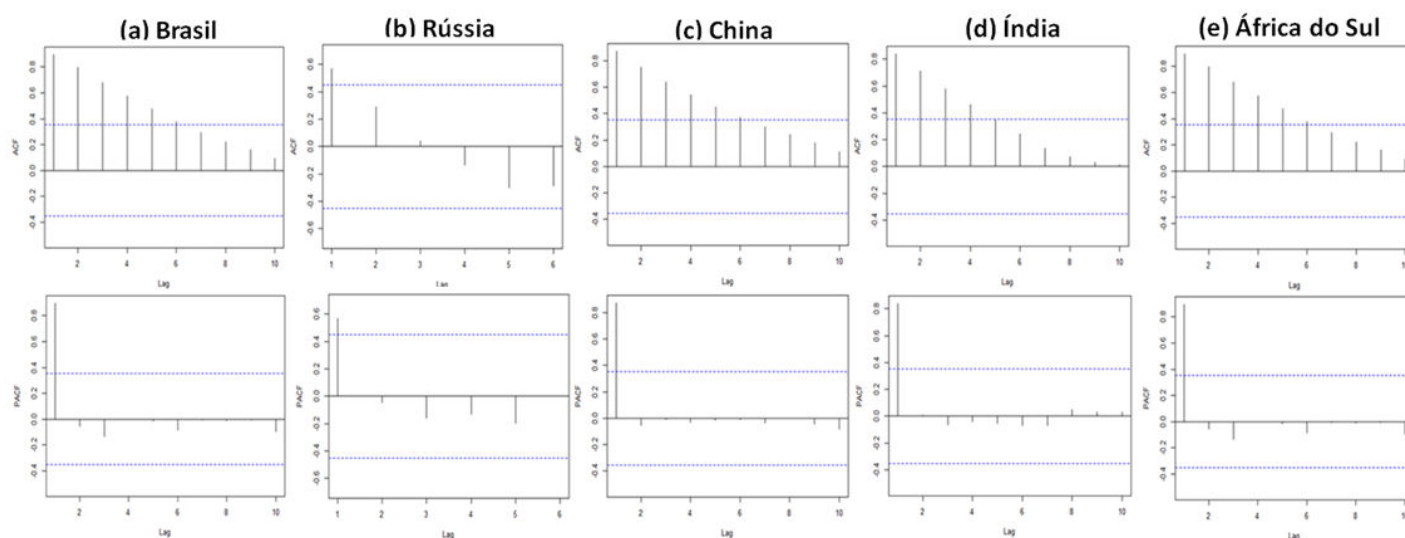


Fig. 2: Correlograma ACF e PACF. Fonte: elaborada pelos autores.

Conforme Tabela 3, observa-se que África do Sul e Brasil possuem características parecidas quando da necessidade de estacionar a série, isto é, o modelo ARIMA é um modelo auto regressivo de ordem 1 e uma diferença foi o suficiente para estacionar a série. A Índia e a China apresentaram auto regressivo de ordem 2. Já a Rússia apresenta-se como série estacionária, com tipo de modelo SARIMA, isto é, tem uma defasagem (p), não há diferenças sazonais (d), não há erros defasados no lado direito da equação (q) e possui ciclo sazonal(s).

Tab. 3: Resumo da Identificação dos modelos ARIMA (p,d,q)

Países	África do Sul	Brasil	China	Índia	Rússia
ARIMA	(0,1,0)	(0,1,0)	(0,2,0)	(0,2,1)	(1,0,0)
Tipo de modelo	MA (q)	MA (q)	MA (q)	ARIMA (d,q)	SARIMA

Na identificação dos modelos de suavização exponencial, os dados analisados para os países do BRICS compreendem as três componentes de suavização exponencial: alfa (nível), beta (tendência) e gama (sazonalidade), conforme Tab. 4. Os países África do Sul e China possuem tendência aditiva e sem sazonalidade. O Brasil e a Rússia não possuem tendência e nem sazonalidade, portanto, a previsão por Suavização Exponencial Simples é adequada. A Índia apresenta comportamento multiplicativo suavizado e sem sazonalidade.

Tab. 4: Resumo da Identificação dos modelos Suavização Exponencial

	África do Sul	Brasil	China	Índia	Rússia
α (nível)	0,73	0,99	0,99	0,78	0,97
B (tendência)	0,01	0,00	0,99	0,01	0,00
γ (sazonalidade)	0,00	0,00	0,00	0,00	0,00
Tipo de modelo	MAN	MNN	MAN	MMdN	MNN

Na análise do melhor método, a Tab.5 apresenta os critérios de medidas dos erros de previsão como o erro absoluto percentual médio (MAPE) e Critério de Informação de Akaike (AIC). A situação ideal é quanto menor o AIC melhor o ajustamento do modelo. Portanto, o modelo ARIMA melhor explica a dinâmica das séries temporais analisadas uma vez que permite fazer o “trade-off” entre uma redução na soma do quadrado dos resíduos estimados e um modelo mais parcimonioso.

Tab. 5: Erro absoluto percentual médio (MAPE) e Critério de Informação de Akaike (AIC).

	Brasil		Rússia		Índia		China		África do Sul	
	MAPE	AIC	MAPE	AIC	MAPE	AIC	MAPE	AIC	MAPE	AIC
ARIMA	3.25%	235.38	5.03%	235.28	2.88%	298.73	3.34%	396.16	1.55%	266.64
Suavização Exponencial	4.11%	264.77	5.09%	232.14	2.91%	326.59	4.75%	419.83	1.55%	285.21

O modelo ARIMA é excelente na previsão de curto prazo (Granger e Newbold, 1977), portanto as previsões foram feitas para 10 passos à frente (até o ano de 2020). As Figs. 3, 4, 5, 6 e 7 mostram os dados reais no período de 1980 a 2010 e os dados previstos dentro dos intervalos de confiança de 80% (cor laranja) e 95% (cor amarela). O valor mínimo (Lo) e o valor máximo (Hi) estabelecido permitem afirmar que o verdadeiro valor estimado está contido dentro deste intervalo.


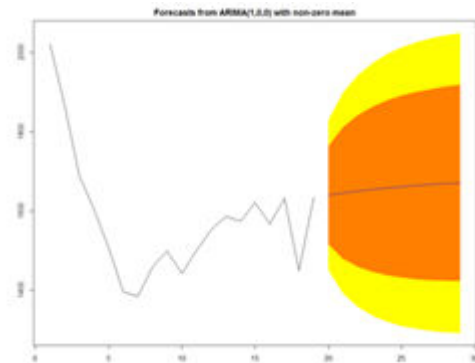

Fig. 3: Previsão para o Brasil - Modelo ARIMA

Fig. 4: Previsão para a Rússia - Modelo ARIMA


Rússia						
> prev	Point	Forecast	Lo 80	Hi 80	Lo 95	Hi 95
20	1640.004	1515.460	1764.548	1449.531	1830.477	
21	1645.427	1479.964	1810.890	1392.373	1898.481	
22	1650.170	1459.233	1841.107	1358.158	1942.182	
23	1654.319	1445.986	1862.652	1335.701	1972.936	
24	1657.948	1437.230	1878.666	1320.388	1995.507	
25	1661.122	1431.379	1890.865	1309.760	2012.483	
26	1663.898	1427.483	1900.313	1302.332	2025.463	
27	1666.326	1424.931	1907.721	1297.144	2035.508	
28	1668.450	1423.313	1913.587	1293.546	2043.354	
29	1670.308	1422.346	1918.269	1291.084	2049.532	

**Fig. 5:** Previsão para a Índia - Modelo ARIMA


Índia						
> prev	Point	Forecast	Lo 80	Hi 80	Lo 95	Hi 95
32	1786.337	1737.041	1835.634	1710.945	1861.730	
33	1877.052	1797.152	1956.951	1754.856	1999.247	
34	1967.766	1857.176	2078.356	1798.633	2136.899	
35	2058.481	1915.870	2201.092	1840.376	2276.585	
36	2149.195	1972.911	2325.479	1879.592	2418.798	
37	2239.910	2028.217	2451.602	1916.154	2563.665	
38	2330.624	2081.788	2579.461	1950.062	2711.187	
39	2421.339	2133.653	2709.024	1981.362	2861.315	
40	2512.053	2183.858	2840.249	2010.122	3013.985	
41	2602.768	2232.448	2973.088	2036.412	3169.123	

**Fig. 6:** Previsão para a China - Modelo ARIMA

China						
>	Point	Forecast	Lo 80	Hi 80	Lo 95	Hi 95
32	9437.04	9160.500	9713.58	9014.108	9859.972	
33	10553.12	9934.754	11171.48	9607.413	11498.821	
34	11669.19	10634.476	12703.91	10086.729	13251.660	
35	12785.27	11270.599	14299.94	10468.779	15101.764	
36	13901.35	11850.472	15952.23	10764.803	17037.894	
37	15017.43	12379.401	17655.45	10982.914	19051.937	
38	16133.50	12861.435	19405.57	11129.307	21137.699	
39	17249.58	13299.796	21199.36	11208.907	23290.254	
40	18365.66	13697.122	23034.19	11225.748	25505.567	
41	19481.73	14055.624	24907.84	11183.215	27780.254	

**Fig. 7:** Previsão para a África do Sul - Modelo ARIMA

África do Sul						
>	Point	Forecast	Lo 80	Hi 80	Lo 95	Hi 95
32	1165.428	1140.737	1190.119	1127.667	1203.189	
33	1185.696	1150.778	1220.614	1132.293	1239.098	
34	1205.964	1163.198	1248.729	1140.559	1271.368	
35	1226.231	1176.850	1275.613	1150.709	1301.754	
36	1246.499	1191.289	1301.709	1162.063	1330.936	
37	1266.767	1206.287	1327.247	1174.271	1359.263	
38	1287.035	1221.709	1352.360	1187.128	1386.942	
39	1307.303	1237.467	1377.139	1200.498	1414.107	
40	1327.571	1253.498	1401.643	1214.287	1440.854	
41	1347.838	1269.760	1425.917	1228.427	1467.250	



Embora a série analisada seja de curto prazo, revela alguns padrões interessantes. Analisando os dados históricos e conforme estimativa para os países do BRICS, as emissões de CO₂ tendem a subir ainda mais nos próximos anos, o que pode estar associado ao forte desempenho econômico que atualmente está ocorrendo nos países analisados. Em termos absolutos, a China, a Rússia e a Índia são os países que mais contribuem nas emissões de CO₂. Em 2010, os BRICS representaram cerca de um quarto do PIB mundial, e estes cinco países representaram 33% do uso global de energia e 37% de emissões de CO₂ provenientes da queima de combustível (IEA, 2012). Além disso, os intervalos de

confiança ampliam-se com o passar dos anos, entretanto, as variáveis estimadas são bem comportadas e com variações extremamente suaves, o que gera estimativas confiáveis.

4. Considerações finais

Este trabalho consistiu de uma análise temporal das emissões de Dióxido de Carbono (CO₂) para os países do BRICS. Considerando as mudanças ao longo do tempo, a série histórica dos níveis de emissões de CO₂ tem aumentado ao longo do século passado em comparação com o nível estável durante a era pré-industrial, e esta pesquisa corrobora ao evidenciar o contínuo crescimento para os próximos 10 anos. Evidencia-se que a avaliação da sustentabilidade contribui ao identificar as questões que podem ser revertidas ou melhoradas, especialmente quando os indicadores podem ser estimados e comparados, e são capazes de mostrar alterações à longo prazo. Neste trabalho, deve-se ter em conta a limitação em reunir os dados para um período mais longo, especialmente para a Rússia. Para trabalhos futuros, sugerem-se abordagens alternativas para a análise da sustentabilidade por meio do uso de outros métodos para fazer previsões como Correlação, Regressão Simples, Regressão Linear Múltipla, entre outros métodos quantitativos.

Agradecimentos

Os autores gostariam de agradecer a Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPQ) pelo apoio financeiro, bem como aos revisores anônimos por seus comentários e sugestões.

Referências

- Armstrong, J.S. 1988. Research needs in forecasting. *International Journal of Forecasting*, n.4, p.449-465.
- Armstrong, J.S. 2001. Standards and Practices for Forecasting. *Principles of Forecasting: A Handbook for Researchers and Practitioners*, Norwell, MA: Kluwer Academic Publishers.
- Bockermann, A.; Meyer, B.; Omann, I.; Spangenberg, J.H. 2005. Modelling sustainability: Comparing an econometric (PANTA RHEI) and a systems dynamics model (SuE). *Journal of Policy Modeling*, v.27, n.2, p.189-210.
- Bohringer, C.; Jochem, P.E.P. 2007. Measuring the immeasurable - A survey of sustainability indices. *Ecological Economics*, v.63, n.1, p.1-8.
- Bowden, N.; Payne, J.E. 2008. Short term forecasting of electricity prices for MISO hubs: evidence from ARIMA-EGARCH models. *Energy Economics*, v.30, n.6, p.3186-3197.
- Box, G.E.P.; Jenkins, G.M. (Eds.2), 1976. *Time Series Analysis Forecasting and Control*. San Francisco: Holden-Day.
- Cabezas, H.; Fath, B.D. 2002. Towards a theory of sustainable systems. *Fluid Phase Equilibria*, v.194-197, p.3-14.
- Costanza, R.; D'Arge, R.; De Groot, R.; Farber, S.; Grasso, M.; Hannon, B.; Limburg, K.; Naeem, S.; O'Neill, R.V.; Paruelo, J.; Raskin, R.G.; Sutton, P.; Van Den Belt, M. 1997. The value of the world's ecosystem services and natural capital. *Nature*, v.387, n.6630, p.253-260.
- Dahl, A.L. 2012. Achievements and gaps in indicators for sustainability. *Ecological Indicators*, v.17, p.4-19.
- JISC. 2012. Essential Reading: The EcoSTEP™ Tool for Measuring Sustainability. <http://www.ecospheres.com/ecostep.html> acessado em Fevereiro/2013.
- Fava, V.L. 2000. Manual de econometria. In: Vasconcelos, M.A.S.; Alves, D. São Paulo: Editora Atlas.
- GRI - Global Reporting Initiative. 2011. A new phase: the growth of sustainability reporting. GRI's Year in Review. <https://www.globalreporting.org/resource/library/GRI-Year-In-Review-2010-2011.pdf> acessado em Novembro/2012.
- Granger, C.W.J.; Newbold, P. 1977. *Forecasting economic time series*. Academic Press.

- Hammond, A.; Adriaanse, A.; Rodenburg, E.; Bryant, D.; Woodward, R. Environmental Indicators: A Systematic Approach to Measuring and Reporting on Environmental Policy Performance in the Context of Sustainable Development. World Resources Institute, 1995.
- Heink, U.; Kowarik, I. What are indicators? On the definition of indicators in ecology and environmental planning. *Ecological Indicators*, v.10, n.3, p.584-593, 2010.
- Hyndman, R.J. 2009. Business forecasting methods. <http://www.robjhyndman.com/papers/businessforecasting.pdf> acessado em Setembro/2012
- Hyndman, R.J.; Athanasopoulos, G. 2012. Forecasting: principles and practice. <http://otexts.com/fpp/> acessado em Janeiro/2013.
- IEA Statistics. 2012. CO₂ emissions from fuel combustion. International Energy Agency. <http://www.iea.org/co2highlights/co2highlights.pdf> acessado em janeiro/2012.
- Índice Dow Jones de Sustentabilidade. 2012. <http://www.sustainability-index.com/dow-jones-sustainability-indexes/index.jsp> acessado em Novembro/2012.
- Jia, J.S.; Zhao, J.Z.; Deng, H.B.; Duan, J. 2010. Ecological footprint simulation and prediction by ARIMA model - A case study in Henan Province of China. *Ecological Indicators*, v.10, n.2, p.538-544.
- Keeble, J.J.; Topiol, S.; Berkeley, S. 2003. Using Indicators to Measure Sustainability Performance at a Corporate and Project Level. *Journal of Business Ethics*, v.44, n.2-3, p.149-158.
- Lehr, U.; Nitsch, J.; Kratzat, M.; Lutz, C.; Edler, D. 2008. Renewable energy and employment in Germany. *Energy Policy*, v.36, n.1, p.108-117.
- Maia, A.L.S.; Carvalho, F.A.T.; Ludermir, T.B. 2008. Forecasting models for interval-valued time series. *Neurocomputing*, v.71, n.16-18, p.3344-3352.
- Morretin, P. A.; Toloí, C.M.C. (Eds.2), 1987. *Previsão de Séries Temporais*. São Paulo: Atual Editora.
- Munier, N. 2011. Methodology to select a set of urban sustainability indicators to measure the state of the city, and performance assessment. *Ecological Indicators*, v.11, n.5, p.1020-1026.
- NEMESIS. 2006. New Econometric Model for Environmental and Sustainable development and Implementation Strategies. <http://www.nemesis-model.net/Desc.php?lang=en&TM=41&IS=57> acessado em Fevereiro/2013.
- Niemeijer, D.; Groot, R. 2008. A conceptual framework for selecting environmental indicator sets. *Ecological indicators*, v.8, n.1, p.14-25, 2008.
- Pao, H.T.; Fu, H.C.; Tseng, C.L. 2012. Forecasting of CO₂ emissions, energy consumption and economic growth in China using an improved grey model. *Energy*, v.40, n.1, p.400-409.
- Pappas, S.S.; Ekonomou, L.; Karamousantas, DC.; Chatzarakis, G.E.; Katsikas, S.K.; Liatsis, P. 2008. Electricity demand loads modeling using Auto Regressive moving average (ARMA) models. *Energy*, v.33, n.9, p.1353-1360.
- Ronchi, E.; Federico, A.; Musmeci, F. 2002. A system oriented integrated indicator for sustainable development in Italy. *Ecological Indicators*, v.2, n.1, p.197-210.
- Souza, G.P.; Samohyl, R.W.; Miranda, R.G. (Eds.1), 2008. *Métodos Simplificados de Previsão Empresarial*. Editora Ciência Moderna.
- Todorov, V.I.; Marinova, D. 2009. *Sustainometrics: Measuring sustainability*. World IMACS / MODSIM Congress, Cairns, Australia, July, p.13-17.
- UNCED, 1992. Agenda 21, Programme of Action for Sustainable Development, adopted at the United Nations Conference on Environment and Development, Rio de Janeiro, Brazil, 1992. http://www.un.org/esa/dsd/agenda21/res_agenda21_40.html acessado em Novembro/2012.
- Yua, Y.; Chena, D.; Zhua, B.; Hua, S. 2013. Eco-efficiency trends in China, 1978–2010: Decoupling environmental pressure from economic growth. *Ecological Indicators*, v.24, n.1, p.177–184
- Zhang, G.P. 2003. Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, v.50, n.1, 158-175.