PREVISÃO DO CONSUMO DE GASES COMBUSTÍVEIS VIA HOLT-WINTERS NA USINA SIDERÚRGICA INTEGRAGADA

Thayron Ribeiro Cremasco
Universidade Federal do Espírito Santo
Av. Fernando Ferrari, 514, Goiabeiras, Vitória - ES, Edifício CT-II, CEP 29075-910
thayron.cremasco@gmail.com

José Leandro Félix Salles
Universidade Federal do Espírito Santo
Av. Fernando Ferrari, 514, Goiabeiras, Vitória - ES, Edifício CT-II, CEP 29075-910
jleandro@ele.ufes.br

João Gustavo Coelho Pena
Universidade Federal do Espírito Santo
Av. Fernando Ferrari, 514, Goiabeiras, Vitória - ES, Edifício CT-II, CEP 29075-910
jgeng_autcon@yahoo.com.br

RESUMO

Os processos de produção de aço em uma usina siderúrgica integrada produzem gases combustíveis que podem ser reaproveitados na própria planta, nos processos de produção ou nas centrais termelétricas. Porém, gerenciar a distribuição destes gases combustíveis é bastante complexo, principalmente devido ao desequilíbrio entre a produção e o consumo destes gases, e a capacidade limitada dos gasômetros e restrições operacionais. Portanto, há a necessidade de utilizar-se algoritmo de otimização integrado a um sistema de previsões capaz de auxiliar os operadores nas tomadas de decisão. O objetivo deste trabalho é fazer a previsão do consumo destes gases através do método de *Holt-Winters* com um e dois ciclos utilizando algoritmo genético para determinar as constantes de amortecimento. Dados reais de uma siderúrgica no estado do Espírito Santo são utilizados para validar o modelo de previsão.

PALAVRAS CHAVE: Previsão, Holt-Winters, Algoritmo Genético.

Tópico: Planejamento Energético, Aplicações na Indústria, Metaheurística.

ABSTRACT

In an integrated steel mill, the byproduct gases of steel production processes can be recovered as fuel for the plant itself and can be used to generate electricity and steam in power plants. However, managing the gas distribution is quite complex, mainly due to the imbalance between production and consumption of these gases, and the limited capacity of the gasometers and operational constraints. Therefore, it is necessary to use an optimization algorithm integrated to a prediction system that can help operators in decision making. The objective of this work is to forecast the consumption of these gases by the *Holt-Winters* method with one and two cycles using genetic algorithm to determine the damping costants. Actual data of a steelmaking industry in the Espírito Santo state are used to validate the predictive model.

KEYWORDS. Forecasting, Holt-Winters, Genetic Algorithm.

Paper topics: Energy Planning, Industry Applications, Methaheuristic.

1. Introdução

O setor siderúrgico brasileiro e mundial passa por uma das piores crises da história. O Instituto Aço Brasil (IABr) calcula que em 2015 a venda de aço no mercado interno brasileiro teve uma queda em torno de 16% em comparação com o ano de 2014, e a previsão para o ano de 2016 é que as vendas internas continuem em queda. De acordo com a Associação Mundial do Aço (WSA), a desaceleração do consumo de aço e a consequente queda de seu preço, tem gerado uma crise mundial no setor. Portanto, as empresas siderúrgicas necessitam mais do que nunca cortar gastos, buscar alternativas que reduzam os custos de produção e aumentar a eficiência nos processos produtivos.

A indústria siderúrgica é um dos maiores consumidores de energia, e também produz uma quantidade significativa de gases residuais, especialmente na indústria siderúrgica integrada, onde se realiza a redução do minério de ferro em coke e se executam todas as etapas necessárias à produção do aço. A utilização dos recursos de forma eficiente contribui para a minimização do impacto ambiental, além de reduzir os custos de produção, tendo em vista que os combustíveis reaproveitados na própria siderúrgica, podem ser utilizados para aquecer o alto-forno, gerando vapor nas caldeiras ou gerando energia elétrica para a fábrica (veja Figura 1).

Figura 1. Fluxograma simplificado da distribuição de combustíveis siderúrgicos

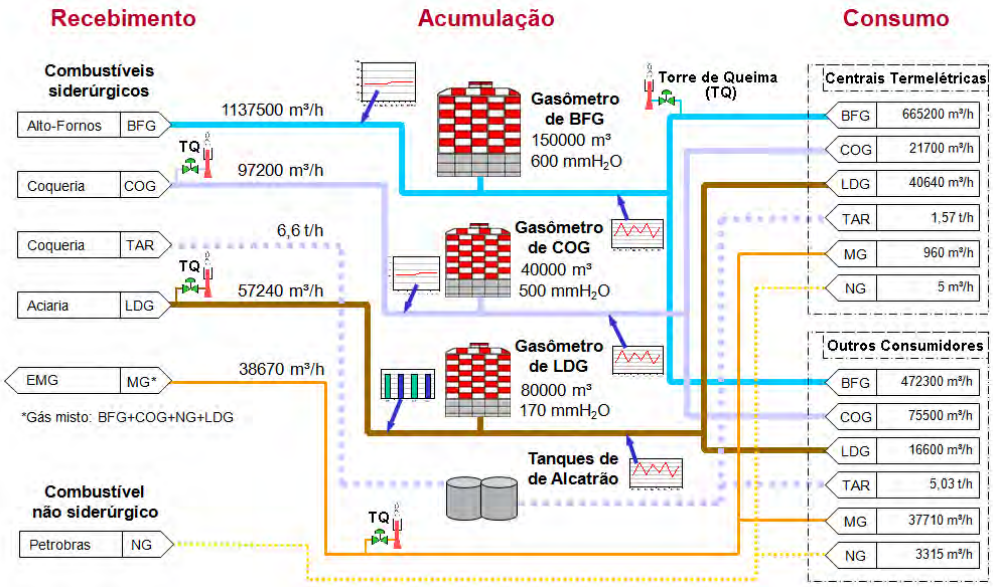

Os quatro tipos de combustíveis gerados durante a produção do aço são: Gás de Alto-Forno (Blast Furnace Gas – BFG), Gás de Coqueria (Coke Oven Gas – COG), Gás de Aciaria (Linz-Dourwitz Gas – LDG) e Alcatrão (TAR). A fábrica comporta uma infraestrutura para a captação, transporte, acumulação, estocagem e distribuição dos combustíveis às unidades consumidoras. Os gases são armazenados em grandes compartimentos conhecidos como gasômetros. A torre de queima é acionada quando o gasômetro atinge um nível considerado alto.

No entanto, nas siderúrgicas integradas, os excedentes dos gases armazenados nos gasômetros são utilizados para gerar vapor na caldeira e eletricidade nas termelétricas. Em geral, a quantidade de energia elétrica gerada é maior do que a utilizada na siderúrgica, de modo que o excedente de energia pode ser vendido para a concessionária.

O gerenciamento e a distribuição desses gases são tarefas complexas, pois os perfis de produção e consumo variam bastante, os acumuladores apresentam capacidade limitada de gases, além de algumas restrições de aproveitamento de gases destinados às centrais termelétrica. Nas últimas décadas, algumas técnicas de gerenciamento da distribuição de gases siderúrgicos têm sido desenvolvidas, destacando-se a programação inteira mista do sistema de distribuição de energia,

veja [Kim et al. 2003], [Kong et al. 2010], [Kong et al. 2015] e [Zhao et al. 2015], e a previsão da produção e consumo de gases [Sun et al. 2013], [Zhao et al. 2012], [Zhao et al. 2014], cujos dados são usados para resolver o problema de otimização.
O software de otimização da distribuição dos combustíveis desenvolvidos em [de Oliveira et al. 2016] a ser implantado numa siderúrgica do estado do Espírito Santo, resolve este problema de forma off-line, ou seja, utiliza dados passados de produção e consumo de combustíveis siderúrgicos para resolver o problema de programação inteira mista da distribuição de gases. Ao ser implantado de fato no gerenciamento dos gases, este software atuará de forma on-line. Para isso é necessário desenvolver algoritmos de previsão confiáveis da produção e consumo de gases. O objetivo deste artigo é desenvolver modelos de previsão do consumo dos gases COG e BFG usando o médodo de Holt-Winters com um e dois ciclos [Taylor, 2013], sendo que as constantes de amortecimento do modelo serão obtidas através do Algoritmo Genético [Holland 1975].

Na seção 2 são descritas a modelagem e a metodologia utilizada na previsão do consumo dos combustíveis gerados durante a produção de aço, na seção 3 são mostrados os resultados obtidos e são feitas suas análises. Para finalizar, na seção 4, é feita a conclusão do artigo.

2. Metodologia

2.1. Holt-Winters

O modelo de amortecimento exponencial de Holt-Winters é aplicado em previsões de séries temporais sazonais [Morettin e Cléilia 2006], sendo um dos modelos mais utilizados na prática. Este método é baseado em equações com diferentes constantes de suavização, associadas ao nível, a tendência e a sazonalidade da série.

A estrutura do modelo para uma sazonalidade [Morettin e Cléilia 2006], é mostrada a seguir:

$$Z_t = (a_1 + a_2.t).p_t,$$

onde a_1, a_2 e p_t são os parâmetros relacionados ao nível, à tendência e ao fator sazonal da série, respectivamente. As equações de atualização desses parâmetros são:

$$\hat{a}_1(T) = \alpha\left[\frac{Z_T}{\rho_{m(T)}(T-1)}\right] + (1-\alpha)[\hat{a}_1(T-1) + \hat{a}_2(T-1)]$$

$$\hat{a}_2(T) = \beta.[\hat{a}_1(T) - \hat{a}_1(T-1)] + (1-\beta).\hat{a}_2(T-1)$$

$$\rho_{m(T)} = \gamma\left[\frac{Z_T}{\hat{a}_1(T)}\right] + (1-\gamma)\rho_{m(T)}(T-1)$$

onde α, β e γ são as constantes de amortecimento do nível, tendência e sazonalidade respectivamente.
A modelagem também pode ser feita para duas sazonalidades como em [Taylor, 2003] a sua estrutura é mostrada a seguir:

$$Z_t = (a_1 + a_2.t).p1_t.p2_t,$$

onde a_1, a_2, $p1_t$ e $p2_t$ são respectivamente os parâmetros do nível, da tendência, do fator sazonal 1 e do fator sazonal 2 da série.
As equações de atualização são as mesmas apresentadas anteriormente para uma sazonalidade, acrescentando apenas uma constante de amortecimento para a segunda sazonalidade.

A maior complexidade deste método está em encontrar valores adequados para constantes de amortecimento que resultem em um erro de previsão satisfatório. Portanto, é utilizado um código baseado em algoritmo genético para auxiliar neste quesito.

2.2. Algoritmo genético

O algoritmo genético é um método de resolução particular das meta-heurísticas existentes. Esse algoritmo utiliza técnicas inspiradas nas leis da seleção natural e da genética, como a hereditariedade, mutação, seleção natural e recombinação para resolver problemas complexos de otimização [Holland 1975].

Inicialmente é gerada uma população, ou seja, um conjunto de indivíduos. Cada indivíduo é representado por um conjunto de constantes de amortecimento (α, β e γ), gerados no começo de forma randômica. Esses indivíduos são submetidos à função objetivo ou função *fitness* e os que apresentarem maior valor de *fitness* serão considerados os mais aptos e irão participar dos processos de cruzamento. Já os indivíduos considerados menos aptos sofrem mutações, desta forma, novos indivíduos são gerados e irão compor uma nova geração. Este ciclo se repete até se esgotar o número de gerações pré-estabelecido. Neste caso, o maior valor de *fitness* será atribuído aos indivíduos que apresentarem o menor erro percentual de previsão, esta função é mostrada a seguir.

$$fitness = \frac{Dados\ previstos - Dados\ reais}{N^{\underline{o}}\ de\ amostras}$$

Escolheu-se utilizar uma meta-heurística, neste caso o algoritmo genético, uma vez que um método exato, apesar de apresentar valores ótimos, demanda um tempo maior de processamento, inviabilizando sua utilização.

O algoritmo genético utilizado neste modelo de previsão baseado em *Holt-Winters* foi desenvolvido por [Almeida 2007].

2.3. Previsão

Os dados utilizados neste artigo se referem às series temporais do consumo a cada um minuto dos gases combustíveis BFG e COG em três diferentes altos-fornos dispostos numa usina siderúrgica integrada.

A partir dos dados contidos na série, parte destes serão utilizados para a estimação de parâmetros (α, β e γ) outra para o teste de aptidão e uma terceira parte para comparar a previsão com dados reais. Após testes realizados, observou-se que os melhores resultados eram obtidos utilizando números de amostras equivalente a oito ciclos sazonais para a estimação de parâmetros, um ciclo sazonal para o teste de aptidão e a previsão de uma hora no futuro. Isto é ilustrado na Figura 2 através de uma parcela da série temporal de consumo de BFG no alto-forno 3.

Figura 2. Aplicação dos dados utilizados para o modelo de previsão

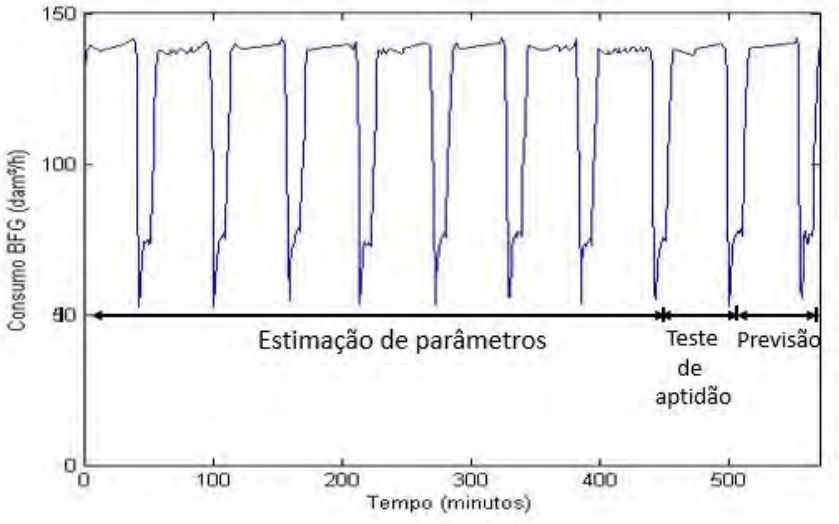

É necessário encontrar a sazonalidade da série temporal apresentada. Este artigo apresenta dois métodos para encontrá-la. O primeiro utiliza a transformada rápida de Fourier (FFT), para encontrar a densidade espectral de potência da série temporal [Moretin e Clélia, 2006], a frequência zero e sua vizinhança é desprezada, uma vez que as frequências muito baixas não devem ser consideradas nessa aplicação. Encontrando a frequência de maior potência que irá representar a sazonalidade dominante da série, deve-se converter o valor obtido em [Hz] para [minutos], determinando-se a sazonalidade do processo. A Figura 3 apresenta a densidade espectral de potência utilizada neste método, aplicada na série temporal referente ao consumo de BFG no alto-forno 3.

Figura 3. Densidade de espectro de potência para encontrar a sazonalidade

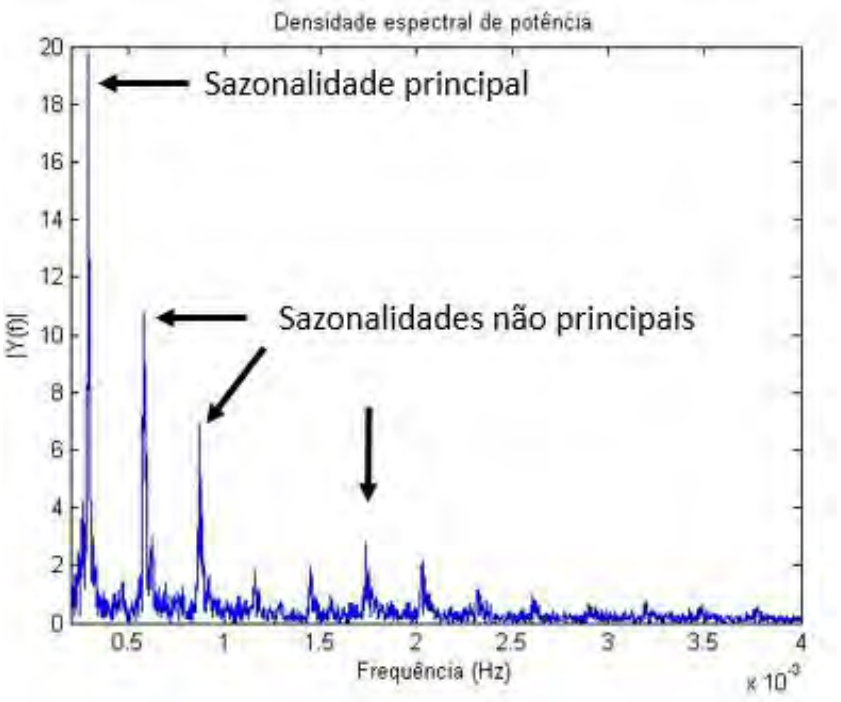

O segundo método implementa a auto-correlação normalizada da série temporal. A Figura 4 mostra uma parcela da auto-correlação normalizada pertencente ao consumo de BFG no alto-forno 3. A sazonalidade da série será o período médio encontrado nesta função, ou seja, a soma de todos os períodos da função dividido pelo número total de períodos.

Figura 4. Função de auto-correlação normalizada para encontrar a sazonalidade

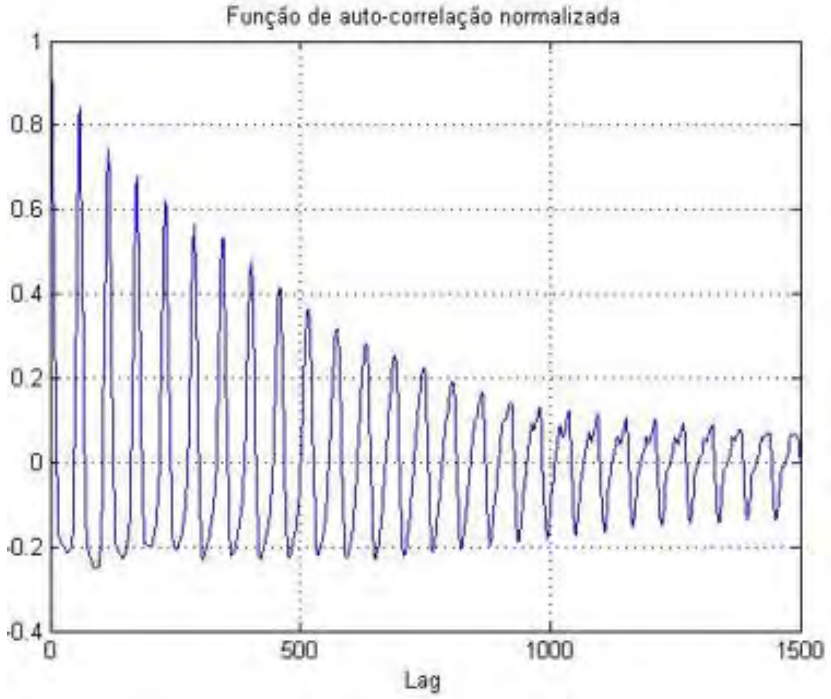

Obteve-se sazonalidade de 57 amostras por ciclo pelo método da função espectral de potência, já pelo método obteve-se sazonalidade de 55 amostras por ciclo. Os resultados são muito parecidos, porém no código será utilizado o primeiro método, pois este é mais preciso.

A seguir, a Figura 5 mostra o fluxograma completo da metodologia apresentada neste trabalho. É possível verificar os passos do método de previsão de *Holt-Winters* e sua interação com o algoritmo genético.

Figura 5. Fluxograma da metodologia

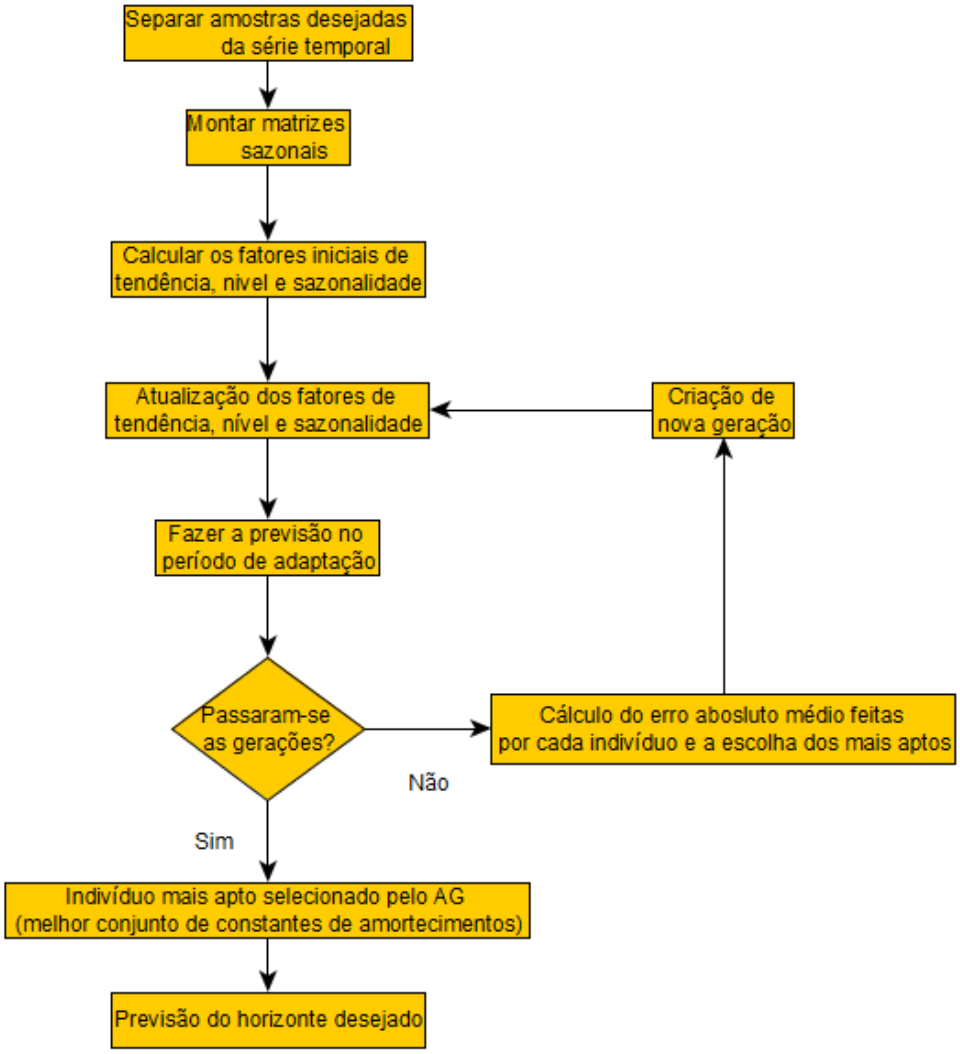

Este código foi desenvolvido para atuar on-line e em conjunto com o algoritmo de otimização do sistema de distribuição de gases na usina siderúrgica integrada apresentado por [de Oliveira et al. 2016]. É gerado um horizonte de previsão de uma hora a cada passo, isto é, a cada minuto, que irá permitir que o algoritmo de otimização de distribuição de gases possa atuar on-line, tomando decisões como o número ótimo de queimadores que devem estar acessos em um determinado instante nas fornalhas das caldeiras.

3. Resultados obtidos

Os testes são feitos utilizando as séries temporais de consumo a cada minuto dos gases combustíveis BFG e COG em três diferentes altos-fornos de uma siderúrgica referentes aos dias 17, 18 e 19 de novembro de 2014, totalizando 4321 amostras para cada uma das seis séries.

Primeiramente é feita uma comparação entre dois métodos utilizados para obter a sazonalidade da série temporal, sendo estes o método da função densidade espectral de potência e o método da função de auto-correlação normalizada. Através do primeiro método é possível obter as sazonalidades não principais, portanto para este método serão apresentados os resultados das sazonalidades secundárias. Os resultados para ambos os métodos são apresentados na Tabela 1.

Tabela 1. Sazonalidade para os diferentes métodos apresentados

Série	Sazonalidade (minutos)		
	Método: Densidade espectral de potência		**Método**: Função de auto-correlação
	Principal	**Secundária**	
BFG AF 1	228	273	225
BFG AF 2	161	234	160
BFG AF 3	57	29	55
COG AF 1	228	273	226
COG AF 2	161	234	168
COG AF 3	57	29	54

Cada um dos três altos-fornos possui sua própria característica de consumo, ou seja, sua própria sazonalidade, independente do combustível que é consumido. Por exemplo, o alto-forno 1 apresenta a sazonalidade de 228 minutos, independente se o gás consumido é o BFG ou o COG, como pode ser visto no método de densidade espectral de potência. Já no método de função de auto-correlação as sazonalidades não são perfeitamente iguais, pois é feita uma aproximação média.

Percebe-se que os resultados para os dois métodos são muito próximos, validando ambos. Escolhe-se utilizar o método de densidade espectral de potência, pois este método é preciso, já o método da auto-correlação é uma aproximação média.

A seguir, são simuladas cinco previsões do consumo de BFG e de COG no alto-forno 3, para os métodos utilizando uma e depois duas sazonalidades, com o horizonte de previsão de uma hora. A sintonia do algoritmo genético foi feita com três geração, uma população com cem indivíduos, taxa de mutação de 1% e taxa de cruzamento de 95%. Os resultados apresentam os coeficientes de amortecimentos obtidos e o erro percentual absoluto médio da previsão.

A Tabela 2 e a Tabela 3 apresentam os resultados obtidos para as previsões de consumo de BFG no alto-forno 3 utilizando o método com uma sazonalidade e duas sazonalidades respectivamente, em um mesmo período da série.

Tabela 2. Resultados das previsões com uma sazonalidade do consumo de BFG no alto-forno 3

	Constante de amortecimento			Erro percentual absoluto médio de previsão (%)
Nº	**α**	**β**	**γ**	
1	0,0659	0,0430	0,7944	3,7222
2	0,0806	0,0183	0,6967	4,1859
3	0,0719	0,0232	0,7042	3,6563
4	0,0178	0,0175	0,5187	4,0855
5	0,7200	0,0177	0,1566	3,6937
			Média	3,8687

Tabela 3. Resultados das previsões com duas sazonalidades do consumo de BFG no alto-forno 3

	Constante de amortecimento				Erro percentual absoluto médio de previsão (%)
Nº	**α**	**β**	**γ**	**δ**	
1	0,0115	0,0007	0,2925	0,2177	4,2917
2	0,0760	0,0315	0,3541	0,8122	4,9625
3	0,0719	0,0437	0,2967	0,3561	4,3598
4	0,0111	0,0241	0,9300	0,4602	4,6653
5	0,0024	0,0761	0,4267	0,1302	4,2871
				Média	4,5133

Observa-se que os erros de previsão são bastante satisfatórios para ambos os casos, uma vez que para todas as simulações de previsão mostradas na Tabela 2 e na Tabela 3 os erros percentuais

absolutos médios da previsão foram abaixo de 5%. As constantes de amortecimento da tendência (β), apresentam valores muito pequenos, próximos de zero, já que a série quase não tem tendência. A seguir, a Figura 6 mostra o gráfico de pior resultado obtidos nas previsões para ambos os casos, ou seja de maior erro.

Figura 6. Pior previsão obtida com 1 e 2 sazonalidades para consumo de BFG no alto-forno 3

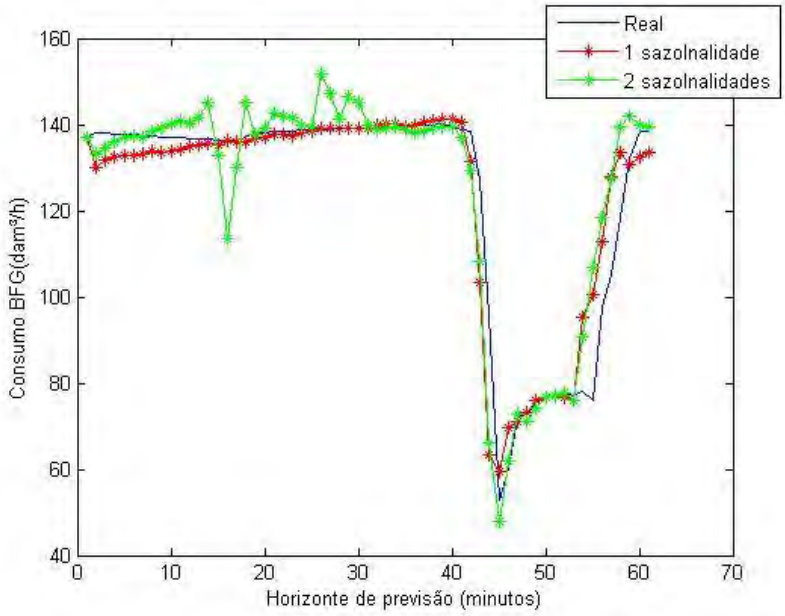

A Tabela 4 e a Tabela 5 apresentam os resultados obtidos para as previsões de consumo de COG no alto-forno 3.

Tabela 4. Resultados das previsões com uma sazonalidade do consumo de COG no alto-forno 3

	Constante de amortecimento			Erro percentual absoluto médio de previsão (%)
Nº	**α**	**β**	**γ**	
1	0,0017	0,0718	0,0656	6,0371
2	0,1517	0,0049	0,0399	6,2790
3	0,1690	0,0054	0,1824	6,3174
4	0,1447	0,0139	0,5367	6,4015
5	0,1713	0,0175	0,4452	6,9108
			Média	6,3892

Tabela 5. Resultados das previsões com duas sazonalidades do consumo de COG no alto-forno 3

	Constante de amortecimento				Erro percentual absoluto médio de previsão (%)
Nº	**α**	**B**	**γ**	**δ**	
1	0,1066	0,0171	0,5398	0,0319	6,3128
2	0,1308	0,0346	0,3386	0,1003	6,7688
3	0,0984	0,0641	0,2672	0,3469	6,8435
4	0,1521	0,0294	0,4692	0,2407	6,7885
5	0,1706	0,0293	0,4482	0,2001	6,7454
				Média	6,6918

Percebe-se que os erros de previsão neste caso são maiores que no caso analisado anteriormente, isto pode ser justificado pelo fato desta série ter um nível menor. Mesmo com este

aumento do erro percentual médio da previsão, estes valores permanecem satisfatórios. Assim como no caso anterior, os valores da constante de amortecimento da tendência (β) têm valores próximos de zero, pois esta série também quase não apresenta tendência. A seguir, a Figura 7 mostra o gráfico de pior resultado obtidos nas previsões de ambos os casos, ou seja de maior erro.

Figura 7. Pior previsão obtida com 1 e 2 sazonalidades para consumo de COG no alto-forno 3

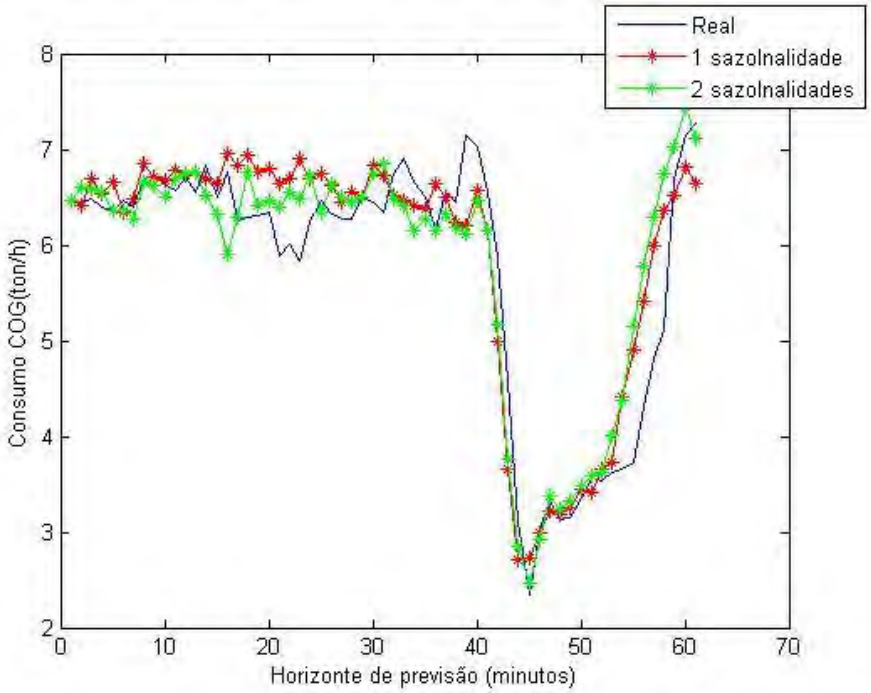

Observa-se que este método de previsão é validado para as séries temporais de consumo de combustíveis BFG e COG, pois apresentam erros de previsão satisfatórios. Constatou-se também que o método de uma sazonalidade e de duas sazonalidades apresentaram erros de previsão muito semelhantes, como pode ser visto nas simulações mostradas acima, percebendo-se até que os resultados com uma sazonalidade foram um pouco melhores, portanto conclui-se que não há a necessidade de incluir uma segunda sazonalidade na metodologia de previsão destas séries.

Para finalizar é feita uma simulação de previsão on-line (cálculo dos fatores de amortecimentos realizados a cada nova amostra de dados) de 15 passos a partir da amostra k = 456, para série de consumo de BFG no alto-forno 3, ou seja, é feita a previsão de uma hora, para cada passo. Os resultados das constantes de amortecimento e erro percentual absoluto médio da previsão obtidos são mostrados na Tabela 6.

Tabela 6. Resultados de previsão online para o consumo de BFG no alto-forno 3

	Constante de amortecimento			Erro percentual absoluto médio de previsão (%)
Passos	**α**	**β**	**γ**	
k	0,0726	0,0191	0,4731	3,8000
k+1	0,0789	0,0058	0,6280	3,9547
k+2	0,0720	0,0018	0,9013	3,6252
k+3	0,0010	0,0074	0,5922	3,6036
k+4	0,0001	0,0472	0,1293	3,5942
k+5	0,0125	0,0101	0,0513	4,0597
k+6	0,0691	0,0440	0,2594	3,8652
k+7	0,0000	0,0490	0,4158	3,3671
k+8	0,0705	0,0333	0,4470	3,6642
k+9	0,0613	0,0282	0,2111	4,1575
k+10	0,0710	0,0086	0,5908	3,6821
k+11	0,0003	0,0167	0,7053	3,8647
k+12	0,0770	0,0482	0,7642	3,8954
k+13	0,0611	0,0126	0,4231	3,9486
k+14	0,0500	0,0771	0,7355	3,5716
k+15	0,0830	0,0022	0,6531	4,0012
			Média	3,7909

Pode-se ver que o código consegue ter previsões satisfatórias para o modelo on-line, gerando uma média de erro percentual absoluto de previsão de aproximadamente 3,79% para 15 passos, e os cálculos dos fatores de amortecimentos usando algoritmos genéticos sendo realizados em menos de 10 segundos, o que possibilita a atuação on-line deste código, uma vez que as amostras são colhidas de um em um minuto.

4. Conclusão

Os resultados obtidos nas simulações mostram que o Método de *Holt-Winters* sintonizado via algoritmo genético é capaz de fazer previsões com o horizonte de uma hora para o consumo de BFG e COG com erros dentro de uma margem satisfatória. Portanto o algoritmo genético conseguiu integrar-se de maneira adequada ao modelo de *Holt-Winters* sintonizando as constantes de amortecimento.

Os resultados das simulações mostram que as previsões utilizando apenas uma sazonalidade foram satisfatórios, pois adicionando uma segunda sazonalidade ao método não ocorrem melhoras nas previsões.

Considerando os resultados obtidos, conclui-se que é viável fazer a integração deste código ao software de otimização apresentado por [de Oliveira, 2016] pois, além das previsões apresentam erros satisfatórios, o tempo de execução do código não passa de dez segundos, viabilizando a sua utilização.

Foram feitas simulações do consumo dos combustíveis BFG e COG utilizando o método de *Holt-Winters*, pois o consumo apresenta sazonalidades. O próximo passo será desenvolver um algoritmo baseado nas técnicas SARIMA para fazer a previsão da produção destes combustíveis, uma vez que não apresenta sazonalidade.

Agradecimentos

Esta pesquisa recebeu apoio do CNPq através do programa RHAE número do processo 458294/2012-8 e da siderúrgica ArcelorMittal Brazil S.A

Referências

Almeida, G. M. (2007). Sintonia de Controladores Preditivos Usando Algoritmos Genéticos. Dissertação de Mestrado, Programa de Pós-Graduação em Eng. Elétrica. Univ. Federal do Espírito Santo.

Holland, J. H. (1975). Adaptation in natural and artificial systems. The University of Michigan Press, An Arbor, Berlim.

Kim, J. H.; Yi, H. S.; Han, C. (2003). A novel MILP model for plantwide multiperiod optimization of byproduct gas supply system in the iron and steel-making process. *Chemical Engineering Research Design*. v. 81, N. 8, 1015–1025.

Kong, H.; Qi, E. Qi; Li H.; Li, G. Zhang,X. (2010). An MILP model for optimization of byproduct gases in the integrated iron and steel plant. *Applied Energy*. V. 87, N. 7, p. 2156–2163.

Kong, H. (2015). A green mixed integer linear programming model for optimization of byproduct gases in iron and steel industry. *International Journal of Iron and Steel Research*. v. 22, N.8, p. 681–685.

Moretin, P. A. e Clélia M. C. Toloi (2006). Análise de Séries Temporais. Edgard Blücher, São Paulo.

de Oliveira J. V. B; Pena, J. G. C. Pena; Salles, J. L. F.. (2016). An improved plant-wide multiperiod optimization model of a byproduct gas supply system into the iron and steel-making process, *Applied Energy*, V. 164, p 462-474l.

Taylor J. W. (2003). Short-Term Electricity Demand Forecasting Using Double Seasonal Exponencial Smoothing. In: *The Journal of Operational Research Society*, V. 54, 799-805.

Sun, W.; Cai, J.; Song, J (2013). Plant-wide supply-demand forecast and optimization of byproduct gas system in steel plant. *International Journal of Iron and Steel Research*. V. 20, p. 1–7.

Zhao, J.; Liu, Q.; Wang, W.; Pedricz, W.; Cong, L. (2012) Hybrid neural prediction and optimized adjustment for coke oven gas system in steel industry. *IEEE Transactions on Neural Networks and Learning Systems*. V. 23, N. 3, p. 439–449.

Zhao, J.; Wang, W.; Sun, K.; Liu, Y. (2014) A bayesian networks structure learning and reasoning-based byproduct gas scheduling in steel industry. *IEEE Transactions on Automation Science and Engineering*, v. 11.

Zhao, X.;Bai, H.; Lu, X.;Shi, Q;Han, J. (2015). A MILP model concerning the optimization of penalty factors for the short-term distribution of byproduct gases produced in the iron and steel making process. *Applied Energy*. V 148, p. 142–158.