

Um estudo de caso comparativo de métodos de previsão de demanda baseados em séries temporais no consumo de gás cloro em uma empresa de saneamento

Antônio Sérgio Neves de Azevedo (antonio22yy@hotmail.com)

Guilherme Ernani Vieira (UFSC / g.vieira@ufsc.br)

Resumo:

Este artigo descreve um estudo prático feito há algum tempo atrás em uma empresa de saneamento da região metropolitana de Curitiba/Paraná, o qual visava comparar a aplicação de alguns modelos matemáticos básicos de previsão de demanda (média móvel simples, suavização exponencial simples e suavização exponencial de *Holt*) para estimar o consumo de gás cloro (Cl_2) numa estação de tratamento de água. Neste trabalho, são descritos as etapas que envolvem um processo convencional de tratamento de água, especialmente a fase de desinfecção, onde é utilizado o gás cloro. Uma análise comparativa baseada em medidas de erros de previsão mostrou qual dos modelos matemáticos considerados tem a melhor aplicabilidade para o cenário da empresa. Foi realizado ainda uma análise dos dados históricos do produto consumido (Cl_2), indicando que sua demanda apresentava tendência, mas não possuía comportamento sazonal.

Palavras-chave: Previsão de demanda, modelos matemáticos, séries temporais, erros de previsão, análise comparativa.

A comparative case study of forecasting methods based on time series in the consumption of chloride gas in a water treatment company

Abstract:

This paper describes a practical study performed some time ago in a water treatment company in the metropolitan area of Curitiba/Paraná, which aimed at comparing the use of some basic mathematical models applied to demand forecasting (simple moving average, simple exponential smoothing and Holt's exponential smoothing) to estimate the consumption of chlorine gas (Cl_2) in a water treatment station. In this work, the phases involved in a conventional water treatment process are described, especially the disinfection phase, where the chlorine gas is used. A comparative analysis based on forecast error measures showed which of the mathematical models considered has the best applicability for the company's scenario. Yet, another analysis was made considering the historical data for the product consumed (Cl_2), indicating that its demand showed tendency but no seasonal behavior.

Key-words: Demand forecast, mathematical models, time series, forecasting errors, comparative analysis.

1. Introdução

O consumo de gás cloro (Cl_2) numa estação de tratamento de água (ETA) representa um fator crítico no processo de fornecimento de água potável (isto é, isenta de germes nocivos à saúde) para a população e é uma variável sujeita a problemas operacionais de diversas naturezas, como falhas no fornecimento de energia elétrica, defeitos das válvulas dos cilindros, peças gerais e equipamentos, falhas humanas na operação etc. Por estes motivos, a boa previsão do consumo desta substância contribui para o planejamento gerencial do processo de tratamento da água, ajudando a diminuir os efeitos das incertezas na produção, manutenção e controle da disponibilidade de água tratada distribuída de maneira contínua para a população.

Para transformar a água captada na natureza em água potável, praticamente sem nenhuma contaminação, cheiro e cristalina, o processo de tratamento envolve várias etapas e alguns critérios de desempenho desejados, como produzir água: (a) livre de bactérias, protozoários, vírus e outros microorganismos; (b) ter baixo teor de compostos orgânicos; (c) correção eficaz da cor, sabor, odor; (d) reduzido índice de turbidez, ferro etc.

Um sistema de tratamento de água convencional é composto de adutoras, floculadores, decantadores, filtros e reservatórios e é denominado convencional por ser comumente encontrado na maioria das estações de tratamento de água, conforme esquema ilustrativo da Figura 1.



Figura 1 – Processo convencional de tratamento de água (Fonte: SAAE, 2006)

As etapas do tratamento de água podem ser assim resumidas:

- *Captação*: É a fonte abastecedora de água com vazão capaz de abastecer a comunidade.
- *Oxidação*: É oxidar os metais presentes na água, principalmente o ferro e o manganês, que estão dissolvidos na água bruta, através da injeção de cloro ou produto similar para tornar os metais insolúveis na água para posterior remoção.
- *Coagulação*: É a adição de sulfato de alumínio ou cloreto férrico para a remoção das partículas de sujeiras através da formação de flocos (partículas maiores) para posterior remoção. Para otimizar este processo adiciona-se cal, que mantém o pH da água no nível adequado para atuação mais efetiva do coagulante.
- *Decantação*: É o processo de separação de partículas sólidas da água, pela ação da gravidade, propiciando a sedimentação dessas partículas no fundo dos tanques.

- *Filtração*: Como a água ainda contém impurezas que não foram totalmente sedimentadas no processo de decantação. Ela é encaminhada às unidades filtrantes, passando por filtros constituídos de camadas de areia suportadas por cascalho de diversos tamanhos que retêm a sujeira ainda restante.
- *Desinfecção*: é injetado o cloro para eliminar os germes nocivos à saúde, garantindo também a segurança e a qualidade da água quando ela for escoada nas redes de distribuição e reservatórios. Numa unidade de tratamento de água há dois pontos de dosagens, classificados como pré-cloração e cloração final. A pré-cloração ocorre no início do tratamento e tem por objetivo principal auxiliar a eficiência da coagulação, realizar o controle de algas e microorganismo e reduzir a produção de certos gostos e odores. A cloração final visa garantir total desinfecção e qualidade biológica da água a ser distribuída. Detalhe: além do cloro (Cl_2), há a possibilidade de utilização de outros agentes desinfetantes, por exemplo, o ozônio, o ácido peracético, a luz ultravioleta, íons de prata, dióxido de cloro (ClO_2).
- *Tanque de Contato*: É o recipiente onde se processa a desinfecção final. Muito mais do que ser um ponto de dosagem de cloro, o tanque de contato tem a função de homogeneizar a ação do cloro na água. Suas dimensões e características permitem que todas as parcelas de água no sistema possuam total desinfecção.
- *Correção de pH*: É efetuada através da adição de produtos químicos para que a água não se torne excessivamente ácida. A acidez possibilita a corrosão de tubulações e equipamentos. No entanto, água excessivamente alcalina pode provocar incrustações na parede da tubulação da rede de distribuição. Para ajuste do pH, utilizam-se dois produtos distintos, que variam suas utilizações de acordo com as características da água a serem dosadas, é o carbonato de sódio (Barrilha) e cal hidratada.
- *Fluoretação*: Finalmente a água é fluoretada através de compostos à base de flúor (fluossilicato de sódio). A aplicação destes compostos na água de abastecimento público contribui para a redução da incidência de cárie dentária, especialmente no período de formação dos dentes.

Neste contexto, o presente artigo tem como objetivo prever a demanda mensal do consumo de gás cloro numa estação de tratamento de água, pertencente a uma empresa de saneamento da região metropolitana de Curitiba, através da aplicação de alguns métodos de previsão baseados em séries temporais. Podendo servir dessa forma, como uma ferramenta de apoio aos gerentes desses sistemas de tratamento de água, como forma de facilitar o planejamento, operação e controle da aquisição desse produto, a fim de diminuir custos e produzir serviços com qualidade em termos de produção e disponibilidade na forma de distribuição de água contínua para a população.

Os dados utilizados neste trabalho foram obtidos de relatórios de consumo de produtos químicos de uma estação de tratamento de água pertencente a uma empresa de saneamento da região, que atende a Capital e região metropolitana do Estado do Paraná, durante o período de janeiro a dezembro de 2007. Porém, para poder determinar se o produto em questão tinha ou não sazonalidade, foram analisados ainda em conjunto os dados históricos dos anos de 2005 a 2007.

Este artigo encontra-se organizado em quatro seções, incluindo a introdução. Na seção seguinte, faz-se um resumo de alguns modelos básicos de previsão baseados em séries temporais

e uma rápida descrição de medidas de erros de previsão (importantes para comparação da qualidade da previsão gerada pelo método). Na terceira seção, trata-se dos modelos implementados e dos resultados das análises feitas. A última seção faz algumas considerações finais.

2. Modelos de Previsão baseados em Séries Temporais

O objetivo de qualquer modelo de previsão é prever o componente de demanda futura, pois são essenciais para os processos de decisão e planejamento da cadeia de suprimento conduzidos pelos tomadores de decisão (Chopra e Meindl, 2004). Neste contexto, é comum uma empresa ter dados históricos referentes à demanda ou vendas (as quais serão iguais caso a empresa tenha conseguido atender a 100% da demanda, caso contrário, vendas será de fato menor que a demanda real.) É geralmente com base neste histórico, representado na forma de uma série temporal, que a empresa consegue fazer sua previsão de demanda.

Para Heizer e Render (2001), uma série temporal é qualquer conjunto de observações ordenadas no tempo (semanalmente, mensalmente, trimestralmente, etc). Os modelos de séries temporais são não causais, já que a previsão futura é baseada exclusivamente no padrão de comportamento de dados históricos em série (Pelligrini e Fogliatto, 2000).

De acordo com Trautwein Jr. (2004), existem vários métodos de previsão de demanda e podem ser agrupados em métodos quantitativos (são métodos analíticos baseados em um modelo matemático) e métodos qualitativos (são métodos não analíticos, baseados em julgamento, intuição, entrevistas com especialistas, experiência dos envolvidos, pesquisa de mercado entre outros). A Figura 2 relaciona alguns dos inúmeros modelos existentes na literatura para a previsão de demanda.

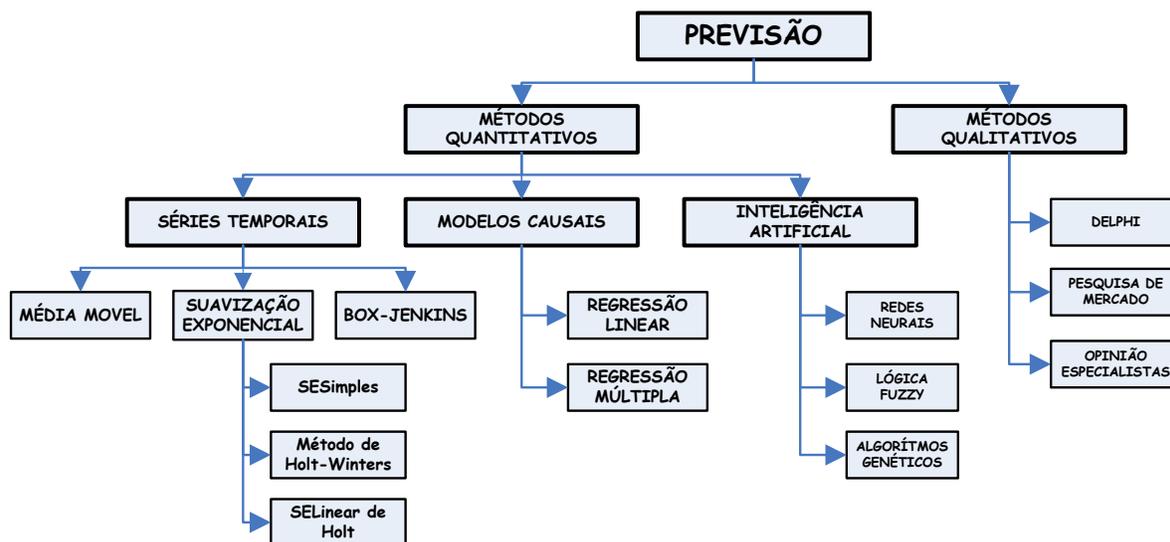


Figura 2 – Alguns métodos para previsão de demanda

Para Ballou (2006), uma série de tempo (ou temporal) tem seu fundamento numa estrutura que pode ser decomposta em quatro categorias:

1. Tendência: verifica o sentido de deslocamento da série ao longo de vários anos.

2. Sazonalidade: diz respeito aos altos e baixos normais na série de tempo que se repetem de tempos em tempos por períodos inferiores há um ano. Associada, na maioria dos casos, a mudanças climáticas.
3. Ciclos: movimento ondulatório que ao longo de vários anos tende a ser periódico.
4. Variação Residual (Ruído aleatório ou Erro): compreende a variabilidade intrínseca aos dados e não pode ser modelado.

Métodos com diferentes níveis de complexidade abordam mais profundamente essas categorias. Métodos mais simples, como o Suavizamento (ou ajuste) Exponencial Simples, não consegue tratar bem dados com tendência, sazonalidade e/ou ciclos. Neste estudo

2.1. Modelo de Média Móvel Simples (MMS)

O método da Média Móvel Simples (MMS) é amplamente usado pela sua facilidade de implementação e manutenção, e pela necessidade de poucos dados históricos para a sua aplicação (Lemos, 2006). Porém, esse método é indicado apenas para previsões de curto prazo e dados históricos irregulares, onde a demanda não apresenta tendência e nem sazonalidade, pois a previsão para um novo período envolve sempre a adição de novos dados e desconsidera os dados anteriores. Uma alternativa é a graduação ponderada dentro da média (Média Móvel Ponderada).

Nesse modelo, segundo Chopra e Meindl (2004), estima-se o nível no período t (L_t) pela média das demandas (D_t) durante os N períodos mais recentes:

$$L_t = (D_t + D_{t-1} + \dots + D_{t-N+1}) / N \quad (1)$$

A previsão para o próximo período de tempo (F_{t+1}) e para todos os demais períodos futuros (F_{t+n}) é a mesma e baseia-se na estimativa de nível atual (pois este modelo não considera sazonalidade):

$$F_{t+1} = L_t \text{ e } F_{t+n} = L_t \quad (2)$$

Logo, para computar a próxima previsão por MMS, simplesmente adiciona-se a mais recente observação e descarta-se a mais antiga. A Média Móvel revisada serve como a próxima previsão.

$$L_{t+1} = (D_{t+1} + D_t + \dots + D_{t-N+2}) / N \quad \text{e}$$

$$F_{t+2} = L_{t+1}$$

2.2. Modelo de Suavização Exponencial Simples (SES)

Segundo Lemos (2006), a Suavização Exponencial é o modelo de previsão mais popular e com o melhor custo/benefício entre os métodos de extrapolação. A SES é uma média ponderada que dá pesos (ou importância) menores à valores antigos (isto é informações antigas têm menos importância do que informações mais recentes), eliminando uma das desvantagens da MMS (Baco, Lima e Paiva/2006). Porém, como MMS, é um modelo adequado somente quando a série histórica não apresenta tendência nem sazonalidade.

Neste caso, a estimativa inicial de nível L_0 é feita com a média de todos os dados históricos, porque se supõem que a demanda não apresenta tendência ou sazonalidade (Chopra e Meindl, 2004):

$$L_0 = \frac{1}{n} \sum_{t=1}^n D_t \quad (3)$$

A previsão atual para todos os períodos futuros é igual à estimativa atual do nível:

$$F_{t+1} = L_t \text{ e } F_{t+n} = L_t \quad (4)$$

Após a observação da demanda para o período $t+1$ (D_{t+1}), revisa-se a estimativa do nível para:

$$L_{t+1} = \alpha \cdot D_{t+1} + (1-\alpha)L_t \quad (5)$$

Onde, α é a constante de suavização, sendo que $0 < \alpha < 1$. Quanto mais o valor de α se aproximar de 1, maior será o ajuste do erro na previsão anterior, ou seja, valoriza demandas recentes e portanto, é mais sensível a mudanças. Quanto mais próximo de 0 o valor de α , menor será o ajuste. Dessa forma, o modelo aborda as demandas históricas mais uniformemente, gerando previsões mais estáveis (Lemos, 2006).

2.3. Suavização Exponencial de Holt (SEH)

A metodologia de Suavização Exponencial Linear de *Holt* é também conhecida como método de Suavização Exponencial Dupla, porque a estimativa da média e a estimativa da tendência são ambas amortecidas (Geigher e Frazier, 2002). Este método expande o método de Suavização Exponencial Simples para previsões com dados que apresentam tendência linear, mas que não apresentam sazonalidade (Lemos, 2006).

Segundo Baco, Lima e Paiva (2006), a única diferença desse modelo com os anteriores, é a presença da componente T_t que representa a tendência dos dados, para evitar que os valores reais sejam subestimados ou super estimados.

Neste caso, a estimativa inicial de nível e de tendência pode ser obtida por regressão linear, utilizando ferramenta de análise do Excel, entre a demanda (D) e o período de tempo (t), de acordo com Chopra e Meindl (2004):

$$D_t = a_t + b \quad (6)$$

A constante b mede a estimativa de demanda no período $t=0$ e é uma estimativa do nível inicial L_0 . A inclinação a mede a taxa de mudança na demanda por período e é a estimativa inicial de tendência T_0 . Logo, a previsão para todos os períodos futuros é:

$$F_{t+1} = L_t + T_t \text{ e } F_{t+n} = L_t + nT_t \quad (7)$$

A previsão (F_t) é obtida com o uso de duas constantes de suavização, α (constante de suavização para o nível, $0 < \alpha < 1$) e β (constante de suavização para a tendência, $0 < \beta < 1$). Portanto, as estimativas de nível e de tendência para o este modelo são:

$$L_{t+1} = \alpha \cdot D_{t+1} + (1-\alpha) \cdot (L_t + T_t) \quad (8)$$

$$T_{t+1} = \beta \cdot (L_{t+1} - L_t) + (1-\beta) \cdot T_t \quad (9)$$

2.4. Medidas de Erros de Previsão

Os erros possuem informações valiosas e devem ser analisadas com cuidado, pois se a análise de um erro indicar que ele está além das estimativas históricas, essa descoberta pode indicar que o modelo adotado deixou de ser adequado (Ballou, 2006). Por exemplo, o erro quadrático médio (EQM), o desvio absoluto médio (DAM) e o erro absoluto médio percentual (EAMP) são amplamente usados para estimar tamanho de erros na previsão. Já o viés da previsão (VP) e a razão de viés (TS – do inglês, *tracking signal*) são muito usados para estimar se a previsão consistentemente superestima ou subestima a demanda (Lemos, 2006). Neste trabalho, foram utilizadas os seguintes modelos para esses indicadores (Chopra e Meindl, 2004):

- Erro de previsão para o período t é dado por E_t :

$$E_t = F_t - D_t \quad (10)$$

Onde: F_t e D_t são a previsão feita/utilizada e a demanda real para o período t , respectivamente.

- Erro Quadrático Médio (EQM_n) - até um período de tempo n :

$$EQM_n = \frac{1}{n} \sum_{t=1}^n (E_t^2) \quad (11)$$

- Desvio Absoluto (A_t) - valor absoluto do erro no período t :

$$A_t = |E_t| \quad (12)$$

- Desvio Absoluto Médio (DAM_n) - até um período de tempo n :

$$DAM_n = \frac{1}{n} \sum_{t=1}^n (A_t) \quad (13)$$

Segundo Alvim (2005), o erro da previsão deve ser mensurado antes de poder ser utilizado para revisar a previsão, ou para auxiliar no planejamento. Há várias maneiras de mensurar o erro, mas uma frequentemente utilizada é o desvio absoluto médio (DAM), o qual é a média do desvio absoluto em todos os períodos. Este pode ser usado para estimar o desvio-padrão do componente aleatório (σ), supondo que o componente aleatório seja distribuído normalmente. Nesse caso, o desvio-padrão do componente aleatório é (Chopra e Meindl, 2004):

$$\sigma = 1,25 \cdot DAM \quad (14)$$

A partir daí, estima-se que a média do componente aleatório é zero e que o desvio-padrão do componente aleatório da demanda é então σ .

- Erro Absoluto Médio Percentual (EAMP_n) - o erro absoluto médio como porcentagem de demanda, até um período de tempo n :

$$EAMP_n = \frac{100}{n} \sum_{t=1}^n \frac{|E_t|}{D_t} \quad (15)$$

- Viés de Previsão (*VP* ou, simplesmente, *viés*) – utilizado para se determinar se o modelo de previsão consistentemente superestima ou subestima a demanda, podemos utilizar a soma dos erros de previsão para avaliar o viés da previsão até um período de tempo n :

$$viés_n = \sum_{t=1}^n E_t \quad (16)$$

O viés da previsão oscilará em torno de zero se o erro for verdadeiramente aleatório e não enviesado de uma forma ou de outra. O ideal é que, ao se plotar todos os erros, a inclinação da reta seja de fato, zero.

- Razão de viés (*TS* ou *RV*): É a razão entre o viés da previsão e o *DAM* e é formulada da seguinte forma, para um determinado período de tempo t :

$$TS_t = \frac{viés_t}{DAM_t} \quad (17)$$

De acordo com Chopra e Meindl (2004), se o *TS* em qualquer período estiver fora da faixa ± 6 , isso significa que a previsão está enviesada e que pode estar sub (razão de viés abaixo de -6) ou superestimada (razão de viés acima de +6). Uma razão de viés negativa acontece quando a demanda tem uma tendência de crescimento e o gerente está usando um modelo de previsão como a *MMS*: uma vez que a tendência não está incluída, a média da demanda histórica será sempre menor que a demanda futura. A razão de viés negativa detectará que o modelo de previsão está consistentemente subestimando a demanda e alertará o gerente.

3. Modelos implementados e resultados das análises comparativas realizadas

A primeira análise feita neste estudo diz respeito à verificação da sazonalidade. A sazonalidade refere-se aos picos e vales regulares que se repetem anualmente. Foram analisados os dados históricos dos últimos três anos (2005 a 2007) para determinar se o produto em questão tinha ou não sazonalidade. Os resultados obtidos estão ilustrados no gráfico da Figura 1. Pode-se verificar que o consumo do produto em questão não possui sazonalidade. Portanto, o padrão de consumo do produto em questão não se repete todo ano.

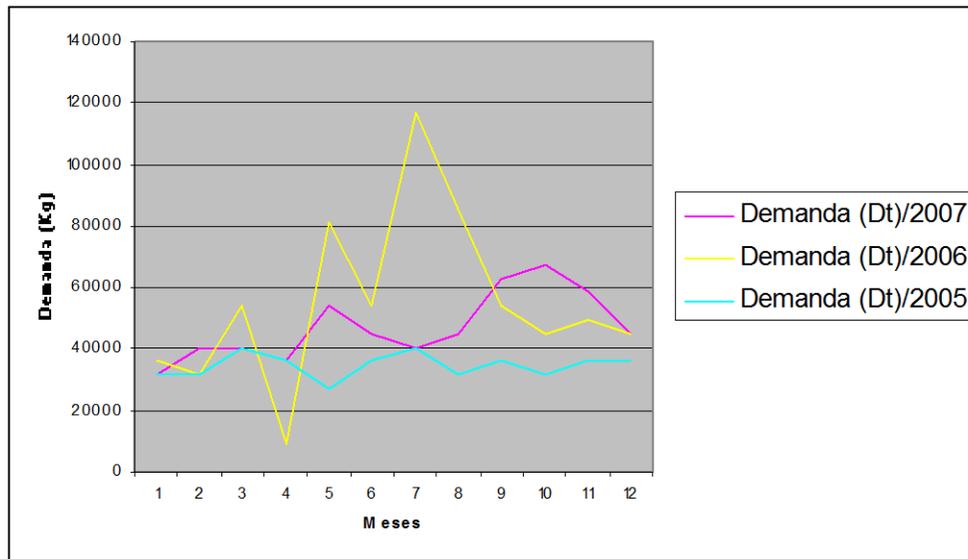


Figura 3 – Identificação da sazonalidade

A segunda análise do estudo teve por objetivo verificar a se o consumo do produto tinha ou não tendência. O efeito de tendência confere a demanda uma tendência de crescer ou decrescer com o tempo. Logo, os resultados obtidos indicaram que o padrão de consumo do produto tinha tendência, conforme gráfico da Figura 2, mas não sazonalidade.

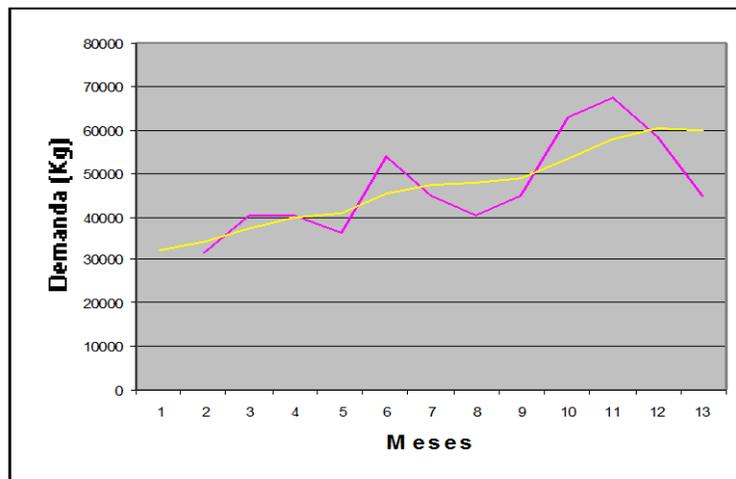


Figura 4 – Identificação de tendência (2007)

A terceira análise deste estudo, foi à implementação dos modelos utilizando a ferramenta de análise do Excel. O primeiro modelo ser implementado foi a MMS, os valores obtidos estão descritos na Tabela 1. O método da MMS é amplamente utilizado pela sua facilidade de implementação e pela pouca necessidade de dados históricos para a sua aplicação. Porém, este método não correspondeu muito bem, por exemplo, o valor do $EAMP=23,34\%$ foi o maior dos três métodos considerados, além de ter apresentado um $DAM=12515,63$ consideravelmente grande em relação ao tamanho da previsão. E, ter apresentado valores de TS que indicam que a previsão estava enviesada.

Tabela 1 – Valores obtidos com MMS.

MODELO DE MÉDIA MÓVEL											
(t)	(Dt)	(Lt)	(Ft)	(Et)	(At)	(EQM)	(DAM)	(EP)	(EAMP)	(TS)	(DP)
1	31500										
2	40500										
3	40500										
4	36000	37125									
5	54000	42750	37125	-36000	36000	1296000000	36000,00	66,67	66,67	-1,00	45000,00
6	45000	43875	42750	-16875	16875	790382812,5	26437,50	37,50	52,08	-2,00	33046,88
7	40500	43875	43875	-2250	2250	528609375	18375,00	5,56	36,57	-3,00	22968,75
8	45000	46125	43875	3375	3375	399304687,5	14625,00	7,50	29,31	-3,54	18281,25
9	63000	48375	46125	-1125	1125	319696875	11925,00	1,79	23,80	-4,43	14906,25
10	67500	54000	48375	-16875	16875	313875000	12750,00	25,00	24,00	-5,47	15937,50
11	58500	58500	54000	-19125	19125	321287946,4	13660,71	32,69	25,24	-6,51	17075,89
12	45000	58500	58500	-4500	4500	283658203,1	12515,63	10,00	23,34	-7,46	15644,53

O segundo método implementado foi a Suavização Exponencial Simples e os valores obtidos estão descritos na Tabela 2. Através dos valores obtidos, pode-se verificar que o método de SES teve um desempenho melhor que a MMS, porém, apresentou um DAM de 7667,90 e um $EAMP$ de 16,16%. Logo, a estimativa de desvio-padrão de erro de previsão usando-se o método de SES é $1,25 \times 7667,90 = 9584,87$. Um valor de desvio-padrão de erro de previsão consideravelmente grande em relação ao tamanho da previsão.

Tabela 2 – Modelo de SES.

MODELO DE SUAUIZÇÃO EXPONENCIAL SIMPLS											
(t)	(Dt)	(Lt)	(Ft)	(Et)	(At)	(EQM)	(DAM)	(EP)	(EAMP)	(TS)	(DP)
		47250,00									
1	31500	40162,50	47250,00	15750,00	15750,00	496125000,00	15750,00	50,00	50,00	1,00	19687,50
2	40500	40314,38	40162,50	-337,50	337,50	248176406,25	8043,75	0,83	25,42	1,92	10054,69
3	40500	40397,91	40314,38	-185,63	185,63	165473908,59	5424,38	0,46	17,10	2,81	6780,47
4	36000	38418,85	40397,91	4397,91	4397,91	133776221,14	5167,76	12,22	15,88	3,80	6459,70
5	54000	45430,37	38418,85	-15581,15	15581,15	204129890,52	7250,44	28,85	18,47	0,56	9063,05
6	45000	45236,70	45430,37	430,37	430,37	170169980,58	6113,76	0,96	15,55	0,73	7642,20
7	40500	43105,19	45236,70	4736,70	4736,70	152270366,94	5917,04	11,70	15,00	1,56	7396,29
8	45000	43957,85	43105,19	-1894,81	1894,81	134134151,18	5414,26	4,21	13,65	1,35	6767,82
9	63000	52526,82	43957,85	-19042,15	19042,15	199808887,92	6928,47	30,23	15,49	-1,69	8660,59
10	67500	59264,75	52526,82	-14973,18	14973,18	224667230,56	7732,94	22,18	16,16	-3,45	9666,17
11	58500	58920,61	59264,75	764,75	764,75	204349271,97	7099,47	1,31	14,81	-3,65	8874,33
12	45000	52656,34	58920,61	13920,61	13920,61	219617408,81	7667,90	30,93	16,16	-1,57	9584,87
Alfa	0,45										

O último método matemático a ser implementado foi a SEH. Os valores obtidos (Tabela 3) demonstraram que este método apresentou o melhor desempenho comparado com os anteriores. Por exemplo, apresentou valores da razão de viés (TS_t) que indicaram que a previsão não estava enviesada. Além do mais, os valores do DAM de 6626,89 e o $EAMP$ de 13,85% são mais baixos que os outros modelos analisados. Além do mais, a estimativa do desvio-padrão de erro de previsão para o modelo de *Holt* foi de 8283,62, menor que os modelos anteriormente analisados. Ou seja, foi o modelo que apresentou o melhor desempenho.

Tabela 3 – Modelo de *Holt*.

MODELO DE SUAUIZACÃO EXPONENCIAL LINEAR DE HOLT												
(t)	(Dt)	(Lt)	(Tt)	(Ft)	(Et)	(At)	(EQM)	(DAM)	(EP)	(EAMP)	(TS)	(DP)
		32727,28	2234,27									
1	31500	34615,40	2216,96	34961,55	3461,55	3461,55	11982328,40	3461,55	10,99	10,99	1,00	4326,94
2	40500	37199,12	2235,30	36832,36	-3667,64	3667,64	12716965,87	3564,60	9,06	10,02	-0,06	4455,75
3	40500	39540,98	2240,63	39434,42	-1065,58	1065,58	8856462,75	2731,59	2,63	7,56	-0,47	3414,49
4	36000	41203,45	2211,72	41781,61	5781,61	5781,61	14999095,24	3494,09	16,06	9,68	1,29	4367,62
5	54000	44473,65	2264,64	43415,17	-10584,83	10584,83	34407011,40	4912,24	19,60	11,67	-1,24	6140,30
6	45000	46564,47	2255,95	46738,30	1738,30	1738,30	29176121,29	4383,25	3,86	10,37	-0,99	5479,06
7	40500	47988,38	2214,35	48820,42	8320,42	8320,42	34898013,86	4945,70	20,54	11,82	0,81	6182,13
8	45000	49682,46	2188,34	50202,73	5202,73	5202,73	33919309,25	4977,83	11,56	11,79	1,85	6222,29
9	63000	52983,71	2243,98	51870,79	-11129,21	11129,21	43912637,51	5661,32	17,67	12,44	-0,34	7076,65
10	67500	56454,93	2305,34	55227,70	-12272,30	12272,30	54582317,35	6322,42	18,18	13,02	-2,25	7903,02
11	58500	58734,24	2304,04	58760,27	260,27	260,27	49626446,80	5771,31	0,44	11,87	-2,42	7214,14
12	45000	59434,46	2223,85	61038,29	16038,29	16038,29	66926466,07	6626,89	35,64	13,85	0,31	8283,62
Alfa	0,1											
Beta	0,05											

Recapitulando os acrônimos usados nessa tabela:

t = Período	Et=Erro	EAMP=Erro Absoluto Médio Percentual
Dt = Demanda	At=Erro Absoluto	TS=Razão de Viés
Lt=Nível	EQM=Erro Quadrático Médio	DP=Desvio-Padrão
Tt=Tendência	DAM=Desvio Absoluto Médio	
Ft=Previsão	EP=Erro Percentual	

Dessa forma, através das metodologias implementadas, chegou-se aos seguintes valores previstos para a previsão do gás cloro:

1. MMS:

$$F_{13} = F_{14} = F_{15} = 58500$$

2. SES:

$$F_{13} = F_{14} = F_{15} = 52656,34$$

3. SEH:

$$F_{13} = L_{12} + T_{12} = 59690,97 + (1) \times 2682,14 = 61658,31$$

$$F_{14} = L_{12} + T_{12} = 59690,97 + (2) \times 2682,14 = 63882,16$$

$$F_{15} = L_{12} + T_{12} = 59690,97 + (3) \times 2682,14 = 66106,02$$

4. Comentários Finais

Com base nas informações sobre os erros obtidos dos métodos implementados, o modelo matemático que apresentou melhor desempenho para a previsão de demanda do produto em análise foi o modelo de *Holt*. Isto já era de se imaginar, uma vez que, conforme descrito anteriormente, a série analisada mostrava que existia uma tendência de crescimento no consumo do gás cloro e, portanto, tanto a MMS quanto a SES não seriam métodos adequados para este tipo de cenário. Mesmo assim, é importante frisar que esses métodos (MMS e SES) são amplamente usados no dia-a-dia de várias empresas, por serem métodos extremamente fáceis, especialmente o média móvel. Entretanto, conforme está sendo demonstrado, a empresa deve escolher cuidadosamente seu método de previsão.

Além disso, os valores obtidos para a razão de viés para o SEH indicou que a previsão ficou dentro da faixa de ± 6 , portanto não está nem super e nem subestimando o consumo (isto é, não está tendencioso). Para os valores obtidos da MMS, houve uma ruptura na razão de viés, subestimando a previsão para este modelo. O que não causou surpresa, já que a análise dos dados históricos indicou que a demanda possui tendência, mas não tem sazonalidade.

Por fim, é razoável sugerir para trabalhos futuros a aplicação de outros modelos matemáticos com o auxílio de softwares específicos, ou métodos mais sofisticados, como uso de redes neurais, por exemplo, para se avançar nas comparações e buscas por melhores métodos de previsão.

Referências

- GAITHER, Norman; FRAZIER, Greg. Administração da Produção e Operações. São Paulo, Editora Pioneira Thomson Learning, 2002.
- HEIZER, Jay; RENDER, Barry. Administração de Operações: Bens e Serviços. 5 Edição, Trad. Dalton Alencar, LTC Editora, Rio de Janeiro, 2001.
- BACO, Samuel B.; LIMA, Renato S.; PAIVA, Anderson P.. Comparação de modelos de séries temporais para a previsão de demanda de matéria prima na fabricação de anéis de pistão. XXVI ENEGEP, Fortaleza, CE, Brasil, Out/2006.
- BALLOU, Ronald H.. Gerenciamento da Cadeia de Suprimentos/Logística Empresarial. Editora Bookman, 5 Edição, Porto Alegre, 2006.
- CHOPRA, Sunil; MEINDL, Peter. Gerenciamento da Cadeia de Suprimentos: Estratégia, Planejamento e Operações. Editora Pearson Education, 1 Edição, São Paulo, 2004.
- PELLEGRINI, Fernando R. Metodologia para implementação de Sistemas de Previsão de Demanda. Dissertação. 2000 (Mestrado em Engenharia de Produção) Programa de pós-graduação em Engenharia de Produção, Ufrgs, Porto Alegre.
- SAAE-Serviço Autônomo de Água e Esgoto. Sistemas de Tratamento de Água, Aracruz, 2006.
- PELLIGRINI, Fernando R.; FOGLIATTO, F. Estudo comparativo entre modelos de Winters e de Box-Jenkins para a previsão de demanda sazonal. Revista Produto & Produção, v.4, número especial, p. 72-85, abril 2000.
- LEMOS, Fernando O. Metodologia para seleção de métodos de previsão de demanda. Dissertação. 2006 (Mestrado em Engenharia de Produção) Programa de pós-graduação em Engenharia de Produção, Ufrgs, Porto Alegre.
- WERNER, Liane; RIBEIRO, José L.D. Previsão de demanda: uma aplicação dos modelos box-jenkins na área de assistência técnica de computadores pessoais. Revista Gestão & Produção, v.10, n.1, p. 47-67, abril 2003.
- TRAUTWEIN JR., Breno. Métodos para previsão de consumo de água para curtíssimo prazo: um estudo de caso em empresa de saneamento. 2004 (Mestrado em Engenharia de Produção e Sistemas) Programa de pós-graduação em Engenharia de Produção, PucPR, Curitiba.
- ALVIN, Silvio Luiz. O efeito da propagação de erros da previsão de demanda na cadeia de suprimentos globalizada: estudo de caso de uma indústria eletroeletrônica. 2005 (Mestrado em Engenharia Civil) Programa de pós-graduação em Engenharia Civil, Unicamp, Campinas.