

PREVISÕES COM SÉRIES TEMPORAIS: CÁLCULO DE COEFICIENTES SAZONAIS COM REGRESSÃO LINEAR

Tânia Regina Sordi Relvas

Resumo:

A controladoria precisa estar atenta, pois os contextos produtivo e competitivo atuais, de certa forma, impõem às empresas a necessidade de suas estruturas de controle serem mais rápidas e ágeis que as estruturas controladas, ou seja, impuseram a instantaneidade. E, para que se possa lidar com a instantaneidade, só mesmo a antecipação. Assim, o aumento da complexidade no ambiente empresarial requer da área de Controladoria um sistema de gestão de custos melhor capacitado em aspectos de mensuração, alocação e principalmente de predição, objetivando melhorar a qualidade das decisões frente às escolhas estratégicas. Através da análise estratégica de custos e do adequado emprego de técnicas quantitativas, pode-se alavancar o poder informativo do sistema de gestão de custos, o que requer o tratamento tanto de dados financeiros, quanto não financeiros. A aplicação de técnicas quantitativas como a análise de regressão e de séries temporais são capazes de melhorar a análise de custos e seus direcionadores, promovendo melhores bases para a tomada de decisão. Isso, permite, considerando um tempo de resposta adequado, interagir nos acontecimentos presentes para moldar o futuro, numa postura pró-ativa.

Área temática: Educação: Ensino e Prática da Gestão de Custos numa Ótica Interdisciplinar

14.1. PREVISÕES COM SÉRIES TEMPORAIS: CÁLCULO DE COEFICIENTES SAZONAIS COM REGRESSÃO LINEAR

Tânia Regina Sordi Relvas

Rua Ana de Barros, 225 – apto. 62B, Jardim Santa Inês, São Paulo, São Paulo, Cep: 02423-020, fone/fax: (011) 203.4204

Mestranda em Contabilidade e Controladoria da Faculdade de Economia, Administração e Contabilidade da Universidade de São Paulo – USP, Av. Prof. Luciano Gualberto, 908 – FEA III, cep 05508-900, São Paulo – SP.

RESUMO

A controladoria precisa estar atenta, pois os contextos produtivo e competitivo atuais, de certa forma, impõem às empresas a necessidade de suas estruturas de controle serem mais rápidas e ágeis que as estruturas controladas, ou seja, impuseram a instantaneidade. E, para que se possa lidar com a instantaneidade, só mesmo a antecipação. Assim, o aumento da complexidade no ambiente empresarial requer da área de Controladoria um sistema de gestão de custos melhor capacitado em aspectos de mensuração, alocação e principalmente de predição, objetivando melhorar a qualidade das decisões frente às escolhas estratégicas. Através da análise estratégica de custos e do adequado emprego de técnicas quantitativas, pode-se alavancar o poder informativo do sistema de gestão de custos, o que requer o tratamento tanto de dados financeiros, quanto não financeiros. A aplicação de técnicas quantitativas como a análise de regressão e de séries temporais são capazes de melhorar a análise de custos e seus direcionadores, promovendo melhores bases para a tomada de decisão. Isso, permite, considerando um tempo de resposta adequado, interagir nos acontecimentos presentes para moldar o futuro, numa postura pró-ativa.

Unitermos: *gestão de custos; previsão; séries temporais; sazonalidade; regressão linear;*

1. Introdução

Desde a introdução da administração científica na condução das empresas que os gestores, cada vez mais, preocupam-se em utilizar técnicas científicas de administração e previsão dos eventos econômicos relevantes para a continuidade e sobrevivência da organização.

Apesar disso, por mais avançadas e sofisticadas que sejam as ferramentas disponíveis, a eliminação das incertezas e riscos é simplesmente impossível, pois uma previsão nada mais é do que a estimativa de um resultado provável baseada num conjunto de premissas e suposições acerca de um determinado período futuro.

A contabilidade, como uma ciência que objetiva, segundo Iudícibus¹, o fornecimento de informações econômicas para os vários usuários de forma a propiciarem decisões racionais, pode e deve fornecer, também, informações sobre eventos ou tendências futuras, auxiliando o processo de tomada de decisões.

Iudícibus² há muito já reconheceu uma tendência crescente para o emprego de técnicas quantitativas que facilitem a explicitação e o tratamento de problemas empresariais, enfatizando o descaso da maioria dos contadores, muito mais por questões de insegurança, fraca formação, e pouco conhecimento do assunto do que por pura convicção de tal postura.

A utilização de técnicas estatísticas para a construção de modelos de previsão de custos tem como vantagens uma melhor capacidade de prognosticar o comportamento dos custos e o aumento da objetividade e acurácia na geração das informações. Objetividade e acurácia são importantes pois, considerando, por exemplo, um processo de orçamentação, é muito comum os gestores se protegerem através da subestimação de receitas e da superestimação de despesas e investimentos, provocando desvios não normais em relação às premissas macroeconômicas emanadas da alta direção para toda a organização.

O objetivo é entender e controlar melhor os fatores críticos de sucesso da empresa e capacitar os gestores à se anteciparem aos concorrentes e aproveitar oportunidades para construir vantagens competitivas sustentáveis, lembrando sempre que, o bom senso e a experiência sempre devem estar presentes e contribuir para impedir uma possível confiança cega nos prognósticos resultantes.

O modelos estatísticos são representados por equações derivadas diretamente dos dados disponíveis, sem recorrer a qualquer teoria, exceto no caso da escolha dos dados a serem utilizados. Já os modelos econométricos, levam em conta uma dada teoria econômica, a qual quase sempre não pode ser convenientemente modelada matematicamente.³

¹ Iudícibus, Sergio de, *Teoria da Contabilidade*. 3ª ed. São Paulo: Atlas, 1993. p. 21

² Ibid. p. 339

³ AMARANTE, Luiz Antonio Martins. *Previsão em Economia: Aplicação de Dois Métodos Univariados de Análise de Séries Temporais*. São Paulo, 1986. Dissertação (Mestrado em Economia) - Faculdade de Economia, Administração e Contabilidade - Universidade de São Paulo. p. 4

Considerando os objetivos do presente trabalho, modelo deve ser entendido como uma descrição matemática da relação entre determinadas variáveis ou do comportamento de uma ou mais variáveis num dado período de tempo. Assim, as previsões abordadas no presente trabalho fundamentam-se nos modelos do tipo dinâmicos, probabilísticos, lineares, não-lineares, recursivos, univariados, de função de transferência e de intervenção.

2. Previsão

A previsão, de um modo geral é um termo usado para descrever o que acontecerá em um determinado conjunto de circunstâncias e decisões num dado momento, provendo uma idéia dos resultados futuros se os gestores não promoverem mudanças no estado de coisas.

Todavia, para os fins do presente trabalho, previsão deve ser entendida como uma forma de medir uma ou mais variáveis observadas num dado período de tempo para poder, com isso, modelar matematicamente uma série temporal ou uma relação causal com outras variáveis que não o tempo. Essa definição permite visualizar as duas abordagens que fundamentam as técnicas quantitativas de previsão: análise de dados históricos no tempo (relações temporais) e análise de eventos ligados ou vinculados à ocorrência de outros (relações causais):

Estudo das relações temporais:

$$\boxed{Y_{t-d}, \dots, Y_{t-2}, Y_{t-1}, Y_t} \Rightarrow \boxed{Y_{t+h}}$$

Estudo das relações causais:

$$\begin{array}{ccc} \boxed{X_{t-d}, \dots, X_{t-2}, X_{t-1}, X_t} & \Rightarrow & \boxed{X_{t+h}} \\ \downarrow (b) & & \downarrow (b_h) \\ \boxed{Y_{t-d}, \dots, Y_{t-2}, Y_{t-1}, Y_t} & \Rightarrow & \boxed{Y_{t+h}} \end{array}$$

onde:

Y = variável a ser prognosticada

X = variáveis causais

d = número de períodos dos dados históricos

h = números de períodos no horizonte da previsão

t = período presente (ano, mês, trimestre etc.)

b = coeficiente angular da relação causal nos dados históricos

b_n = coeficiente angular da relação causal no horizonte previsto

Miranda⁴ assim explica essas relações:

- as relações temporais (essencialmente estatística) buscam descobrir o processo formador (gerador) das séries, suas tendências, sazonalidades, etc., para poder reproduzi-lo no futuro.
- as relações causais (levando em conta um referencial dado pela teoria econômica) buscam a explicação do comportamento das séries, a partir de outras séries.

Nas previsões modeladas através de séries temporais, a predição é baseada numa análise intrínseca que estuda os dados históricos da variável de interesse, ou seja, baseiam-se no estudo do comportamento de uma variável num dado período de tempo. Um modelo de séries temporais sempre assume que algum padrão ou combinação de padrões é recorrente através do tempo, ou seja, volta a ocorrer. Esse tipo de previsão, cuja regra básica é a avaliação orientada em períodos de tempo sequenciais, é adequado ao estudo de variáveis cujo comportamento é característico ao longo do tempo.

Já, as previsões modeladas através de relações causais, assumem que os padrões da variável de interesse estão relacionados com variáveis extrínsecas, ou seja, podem ser explicadas em termos de outras variáveis (exibe uma relação de causa e efeito com uma ou mais variáveis independentes). Esse tipo de modelo objetiva descobrir a forma da relação entre as variáveis e usá-la para prever os valores futuros das variáveis dependentes.

Contudo, quando usado para referir-se às abordagens que fundamentam as técnicas de previsão, o termo “causal”, é geralmente reservado para modelos com variáveis extrínsecas e não os períodos de tempo sequenciais, o que será assumido no presente trabalho.

O estudo de séries temporais para efeito de previsão tem por finalidade identificar e descrever os padrões de comportamento a partir da relação causal com o tempo, que exerce influência sobre os dados. Já o estudo das relações causais tem por finalidade explicar os padrões históricos dos dados, a partir da relação causal com outras variáveis correlacionadas.

Os modelos baseados em relações causais e séries temporais formam a categoria quantitativa dos modelos de previsão. Contudo o modelo objeto de estudo no presente trabalho é aquele baseado em séries temporais.

3. Séries Temporais

Uma série temporal, como já comentado, nada mais é do que um conjunto de observações ordenados no tempo e, seu estudo tem por finalidade determinar se o comportamento das observações apresenta algum padrão não-aleatório, ou seja se há ou não

⁴ MIRANDA, Luiz Carlos. *Modelos de Simulação Empresarial*. São Paulo, 1985. Dissertação (Mestrado em Contabilidade) – Faculdade de Economia, Administração e Contabilidade – Universidade de São Paulo. p. 94

relacionamento histórico entre as observações.

O objetivo de se identificar e entender esses padrões de comportamento, ou seja, determinar qual o relacionamento histórico entre as observações para que se possa estimar o comportamento futuro da variável observada.

Uma série temporal, de certa forma, reflete uma relação causal, cuja variável dependente é a que se deseja prever e a variável independente é o tempo, que pode ser horas, dias, semanas, meses, trimestres, anos e décadas, dependendo do caso em estudo.

Num conceito mais amplo, dado por Morettin & Tolo⁵, série temporal é um conjunto de observações ordenadas no tempo, como valores diários do preço das ações de uma empresa na Bolsa de Valores, valores mensais de temperatura de uma cidade, o registro de um eletrocardiograma de uma pessoa etc.

Considerando que,

- processos estocásticos são processos controlados por leis probabilísticas, podendo ser pensado como um conjunto de todas as possíveis trajetórias que se poderiam observar de uma variável;
- trajetória são as diversas posições de uma dada variável no tempo de um processo físico;
- o processo estocástico, visto como uma família de trajetórias, é uma população e cada trajetória observada, corresponde à amostra;

portanto, pode-se dizer que uma série temporal é uma trajetória ou parte de uma trajetória, dentre as muitas que poderiam ter sido observadas, podendo ser vista, também, como uma amostra de um processo estocástico e pode ser assim representada (matematicamente):

$$Y = f(t)$$

onde: y = variável em estudo (dependente);

t = variável tempo (independente);

f = função temporal que condiciona o valor de y ;

O objetivo da análise de séries temporais é descobrir os padrões e modelos de comportamento (crescimento e mudança) das variáveis estudadas para que possam ser usados para efeito de previsibilidade de valores futuros da série sob consideração. Esse tipo de análise não indicará todas as respostas válidas para explicar o futuro, mas certamente será extremamente útil para o processo de previsão e para ajudar a reduzir os próprios erros de previsão.

Para isso, é preciso um esforço em se identificar os fatores que influenciam cada um dos valores periódicos nas séries, ou seja, as variáveis a serem previstas apresentam padrões de comportamento distintos e característicos. Esse procedimento de identificação é chamado

⁵ MORETTIN, Pedro A. e TOLOI, Clélia M. *Séries Temporais*. 2ª ed. São Paulo: Atual, 1987. p. 1

de decomposição das séries temporais e quatro tipos de padrões de comportamento podem ser distinguidos: tendência, sazonal, cíclico e irregular.

Torna-se evidente, portanto, a necessidade de tratamento estatístico dos dados, ou seja, a construção de gráficos, histogramas e diagramas de dispersão para a verificar, previamente, a existência de tendências, ciclos e variações sazonais. O quadro abaixo resume as características de cada componente de uma série temporal:

Componentes:	Descrição:	Exemplos:
1. Tendência	Existe quando há um aumento ou diminuição no valor da variável no tempo, ou seja, indica a direção geral dos valores (tendência de longo prazo de queda ou alta).	Crescimento populacional de algumas cidades, alguns indicadores econômicos, produto nacional bruto, preços de ações etc. (vide figura nº 1)
2. Sazonal	Existe quando uma série é influenciada por fatores sazonais. Variação sazonal refere-se a padrões de mudança que ocorrem regularmente no tempo. (curto prazo)	Vendas de produtos para estações de tempo específicas (verão/inverno), temperatura da cidade de São Paulo ao longo dos últimos cinco anos etc. (vide figura nº 2)
3. Cíclico	Existe quando uma série é influenciada por flutuações de longo prazo (oscilações regulares no longo prazo - acima de um ano- em torno da tendência).	Venda de bens de capital, as fases de expansão-recessão-recuperação-expansão de um ciclo de negócios etc. (vide figura nº 3)
4. Irregular	Existe quando há flutuações randômicas, causadas por eventos imprevisíveis e não periódicos. Esse componente é também conhecido como ruído.	Normalmente decorrem de causas naturais ou sociais como secas, greves, enchentes, guerras etc. (vide figura nº 4)

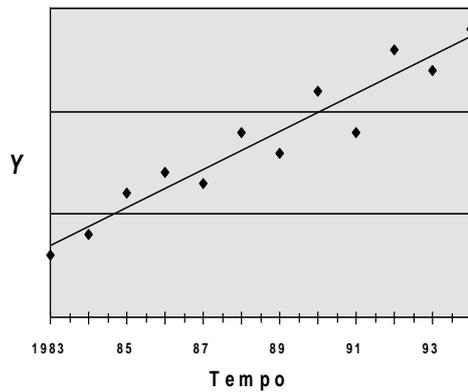


Figura nº1: Padrão com Tendência

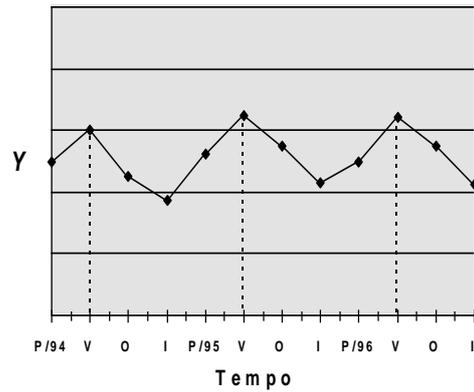


Figura nº 2: Padrão Sazonal

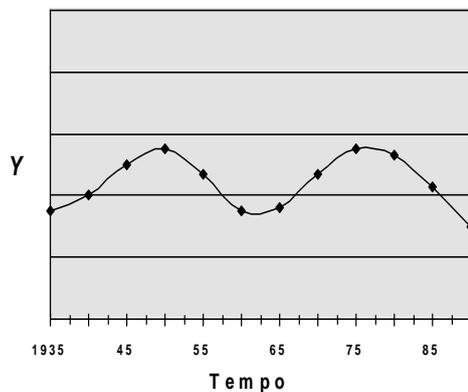


Figura nº 3: Padrão Cíclico

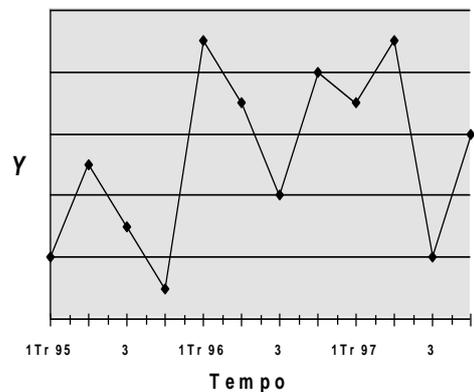


Figura nº 4: Padrão Irregular

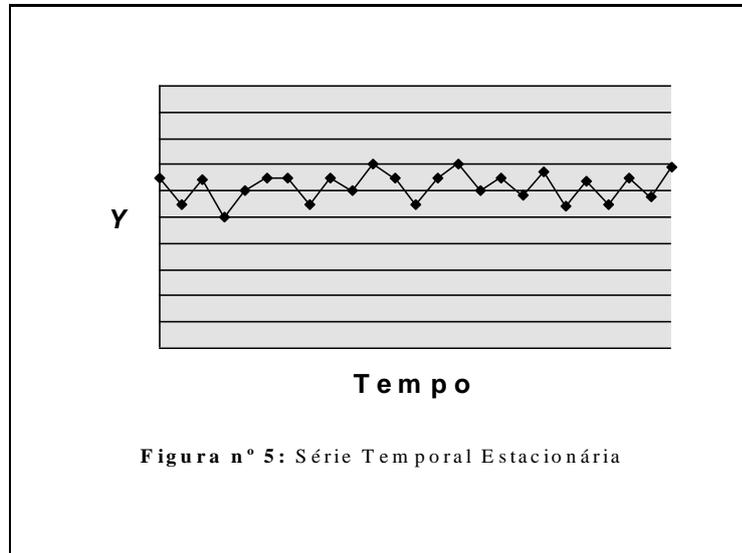
É importante, a essa altura, diferenciar um padrão cíclico de um sazonal. O primeiro tem padrões de mudança com extensão (tempo entre os picos inferiores e superiores) e recorrência variáveis, e o segundo tem extensão e recorrência regular. Além disso, os ciclos comportam-se como grandes contrações e expansões ao longo dos anos e não dentro de cada ano como num padrão sazonal.

O caráter cíclico de uma série temporal não é fácil de distinguir, mas ele surge, de modo que sua trajetória no gráfico inicialmente move-se para baixo, antes de ascender.⁶

Vale ressaltar que, a ausência de tendência numa série temporal caracteriza um padrão estacionário, ou seja, os valores da variável estudada flutuam ao redor de uma média constante e, conseqüentemente, os valores da variável não aumentam ou diminuem de forma significativa ao longo do tempo, como na figura nº 5. Exemplo de uma série estacionária é uma

⁶ FARNUM, Nicholas R. e STANTON, LaVerne W. Quantitative Forecasting Methods. Boston: PWS-Kent, 1989. p. 34

situação de controle de qualidade envolvendo amostragem para um processo de produção contínua com número de defeitos estáveis. Para séries estacionárias o tempo é um elemento muito importante, visto que no curto prazo uma variável pode apresentar tal comportamento, mas se considerado o longo prazo, pode-se verificar uma tendência.



As flutuações irregulares em torno da média (ou valor esperado de y_t) representam a variável aleatória, o erro ou desvio, também chamados de ruído branco ou elemento irregular. Quando os erros não são correlacionados entre si, ou seja, são independentes, eles flutuam em torno da média da série. Contudo, quando são correlacionados (existe correlação entre erros sucessivos) e, portanto, dependentes, a série resultante tende a se alternar rapidamente acima e abaixo da média (auto-correlação negativa) ou de forma mais lenta, flutuando acima e abaixo por longos períodos de tempo (auto-correlação positiva).

A determinação dos componentes básicos de uma série temporal é feita através de análise das séries, que visa decompor a série em cada um de seus elementos e depois recompô-la para estudar as variações observadas. Assim, conhecendo seus componentes e pressupondo-se a existência de algum padrão geral e não aleatório de comportamento esses componentes poderão ser descritos por funções matemáticas e com elas poder predizer o comportamento futuro da variável estudada.

Considerando, portanto, que uma série temporal (Y_t) é resultante da combinação de fatores como tendência, sazonalidade, cíclico e irregular; o processo de combinação desses componentes pode ser aditivo ou multiplicativo, como segue:

$$Y_t = \hat{T}_t + \hat{S}_t + \hat{C}_t + \hat{I}_t$$

$$Y_t = \hat{T}_t \times \hat{S}_t \times \hat{C}_t \times \hat{I}_t$$

O modelo aditivo, que considera uma série temporal como resultante da soma de seus componentes, deve ser adotado quando os componentes da série atuam isoladamente, ou

seja, de modo absoluto e independente entre si. Já o modelo multiplicativo, que considera uma série temporal como resultante do produto de seus componentes, deve ser adotado quando os componentes da série atuem de modo proporcional às suas respectivas forças. A escolha entre um e outro é fundamentada, basicamente, na sensibilidade das variações sazonais em relação ao próprio fenômeno e, sendo apurada uma regularidade aritmética, deve-se adotar o modelo aditivo e caso contrário, o multiplicativo.

No modelo aditivo, cada componente é uma quantidade na mesma unidade de medida da variável de interesse, já no modelo multiplicativo, somente a tendência é expressa na mesma unidade da variável em estudo, sendo os demais componentes expressos em índices ou porcentagens da tendência.

Há, também, autores que admitem a possibilidade de um modelo híbrido, ou seja, um misto entre o aditivo e o multiplicativo, sendo esse o caso. Dessa forma, existem várias possibilidades de combinação.

Segundo Hanke & Reitsch⁷, a abordagem mais freqüentemente usada é o processo de combinação multiplicativo, esta é, também, a opinião de Milone & Angelini⁸, ao afirmarem que, em termos práticos, o modelo multiplicativo é o mais adequado em cerca de 75% dos casos.

A seguir abordam-se os principais processos que possibilitam a decomposição de uma série temporal em cada um de seus componentes, permitindo analisar cada uma separadamente. O objetivo não se resume na simples decomposição. Após a remoção sistemática de cada componente, a começar pela tendência, eles são analisados isoladamente e, depois, a série é recomposta para que se possa apurar os desvios entre a série histórica e a série calculada, para fins de entendimento das variações passadas, previsão dos movimentos futuros, testes e controle do processo para fins de melhoria.

Vale ressaltar que, para efeito de recomposição, os valores de tendência serão os mesmos, independente se o modelo é aditivo ou multiplicativo, mas o valor dos demais componentes, conforme já apontado, serão diferentes e, conseqüentemente, os valores teóricos preditos da série.

Considerando a impossibilidade de tratar num único artigo todos os componentes, bem como seu objetivo que restringe-se ao cálculo de coeficientes sazonais através da regressão linear, abordam-se a seguir, somente os componentes tendência e sazonalidade. Quanto aos métodos de isolamento dos componentes, será dada maior ênfase ao método dos mínimos quadrados, em razão da facilidade de utilização desses modelos em programas de planilhas de cálculo para microcomputadores, bem como pelas limitações dos métodos de médias móveis, principalmente pelo baixo poder de inferências estatísticas e pouca acurácia.

3.1. Tendência

⁷ HANKE, John E. e REITSCH, Arthur. *Business Forecasting*. Boston: Allyn and Bacon Inc., 1981. p.148

⁸ MILONE, Giuseppe e ANGELINI, Flávio. *Estatística Aplicada*. São Paulo: Atlas, 1995. p.260

A tendência de uma série são variações de longo prazo que aumentam ou diminuem os valores das variáveis no tempo. Em termos econômicos, as forças básicas que produzem ou afetam a tendência de uma série são, por exemplo: crescimento populacional, mudanças nos preços relativos, mudanças nas preferências das pessoas, escassez de matérias-primas, mudanças na legislação, mudanças tecnológicas, aumentos de produtividade, entre outros.

O objetivo, considerando que esse é o elemento mais importante da série, é remover a tendência para fins de ajudar o processo decisório (previsões) e, também, estudar os demais componentes.

Os processos mais conhecidos para decompor a tendência são os seguintes:

- **Assentimento:** Consiste em obter a melhor curva de ajustamento a partir de inspeção visual de gráficos e diagramas de dispersão.
- **Mínimos Quadrados:** Consiste em obter a melhor curva de ajustamento mediante a aplicação da análise de regressão que considera o tempo como a variável independente e os valores da série como a variável dependente. Pressupõe-se que o sistema causal que influencia a série seja uma função do tempo. Os coeficientes de regressão são calculados a partir do método dos mínimos quadrados, abordado em detalhes no tópico 6.1.4.
- **Médias Móveis:** Também conhecido como suavização, consiste na média aritmética dos últimos k (número de elementos que compõem o conjunto para se calcular a média) valores da série, de forma que, à medida que se considera um novo valor para se incluir na média, despreza-se o mais antigo. Como o objetivo é suavizar as variações da variável, quanto maior k , maior a suavização obtida e sem a necessidade de ajustamento a uma determinada curva. Os efeitos dos demais elementos (cíclicos e sazonais) são eliminados da série se as médias móveis forem de ordem igual ou maior que o período do ciclo ou maior que 12 meses para eliminar a sazonalidade.

A tendência pode ser linear ou curvilínea, cuja reta ou curva deve ser encontrada para que se possa remover a tendência. O processo depende, também, do modelo que está sendo usado (aditivo ou multiplicativo).

No modelo aditivo, a tendência é removida subtraindo-se cada observação da série do correspondente valor teórico da tendência (calculado por uma equação de regressão ou uma média móvel), resultando numa série de desvios, conforme abaixo demonstrado:

$$Y = T + S + C + I \quad \rightarrow \quad Y = T + S + C + I - T \quad \rightarrow$$

$$Y = S + C + I$$

No modelo multiplicativo, os dados originais da série devem ser divididos (ao invés de subtraídos) pelo valor calculado da tendência naquele momento, resultando num índice que, multiplicado por 100 apresenta-se como percentagem.

$$Y = T S C I \quad \rightarrow \quad \frac{Y}{T} = \frac{T S C I}{T} \quad \rightarrow \quad \frac{Y}{T} = S C I$$

O processo mais utilizado é o que se baseia na análise de regressão para ajustar a tendência a uma função polinomial, onde o grau m do polinômio é bem menor que o número de observações N , conforme modelo abaixo:

$$\hat{T}_t = \beta_0 + \beta_1 t + \dots + \beta_m t^m$$

Considerando $m=1$, tem-se uma tendência linear (polinômio de grau 1).

No processo de médias, à medida que se acrescentam novos valores na série e se abandonam os mais antigos, as médias de k elementos se “movem” para outros patamares. As vantagens desse processo são a facilidade, simplicidade, e a possibilidade de ser aplicado em tendências lineares e não lineares. Contudo, tem grandes desvantagens, das quais destacam-se:

- a redução do tamanho original da série, o impedimento de sua aplicação no estudo do que acontece fora do intervalo considerado;
- a possibilidade de gerar movimentos cíclicos inexistentes nos dados originais e sua suscetibilidade a valores extremos, podendo gerar distorções; e
- inexistência de correspondentes na média para os primeiros e últimos valores da série, embora tenham tendência linear;
- baixo poder para inferências estatísticas, uma vez que não se baseia num modelo probabilístico;
- não permite um meio acurado de fazer previsões;

Outro grande problema a ser considerado é que, num processo de isolamento da tendência através de médias móveis, é preciso escolher um período de tempo bastante longo pois, caso contrário, o processo não será eficaz em remover variações sazonais, cíclicas e algumas irregulares. Só que, com isso, à medida que a média é calculada com um grande número de elementos, menos sensível ela se torna aos elementos mais recentes. Alguns autores sugerem, nesses casos, usar um esquema de ponderação, atribuindo um peso maior aos dados mais recentes.

3.2. Sazonalidade

Como já abordado, fatores sazonais são aqueles que provocam o retorno regular e sucessivo do fenômeno nas mesmas épocas. Em geral, são considerados como variações regulares dentro do período de um ano.

Segundo afirma Morettin & Toloi⁹, “... as flutuações sazonais tendem a “perturbar”as outras componentes presentes na série”, daí a importância da remoção da sazonalidade de uma série temporal. O isolamento e estudo desse componente facilita a identificação e interpretação dos demais componentes, bem como provê informações úteis ao processo decisório, na medida em que fatores sazonais sejam relevantes para o planejamento de curto e médio prazos e para a execução e controle das operações.

Um fator importante quando se estuda esse componente é analisar dois tipos de relações sazonais: as relações entre observações para meses sucessivos em um ano particular (ciclos dentro do ano), e as relações entre observações para o mesmo mês em anos sucessivos.

Segundo Milone & Angelini¹⁰, as principais formas para o isolamento desse componente numa série temporal são:

- **Porcentagem da Média:** o índice sazonal de um sub-período é definido como a média das razões entre os dados dos sub-períodos e as médias anuais do período analisado, ou seja consiste em expressar os dados em porcentagem das médias (ou medianas) anuais. Em um conjunto de 12 médias anuais, o somatório dos índices de sazonalidade deve ser igual a 1.200, com média igual a 100. Para isolar as variações sazonais deve-se dividir o valor da variável pelo índice sazonal correspondente a seu período;
- **Porcentagem da Tendência:** semelhante ao anterior, o índice sazonal é dado pela média das relações entre os dados dos sub-períodos e os respectivos valores da tendência e, novamente, os dados expressos em porcentagens das tendências anuais devem somar 1.200 e ter média 100. Para isolar as variações sazonais deve-se dividir o valor da variável pelo índice sazonal correspondente a seu período;
- **Porcentagem das Médias Móveis:** semelhante aos anteriores, obtém um índice sazonal pela média das relações entre os dados dos sub-períodos e as respectivas médias móveis e, depois dividindo-se os dados originais pelos respectivos índices sazonais;
- **Série de Elos Relativos:** consiste em dividir o valor da variável num dado mês pelo valor correspondente ao mês imediatamente anterior e, em seguida, considera-se um dos meses como base e ajusta-se os demais valores a essa base (100) e os índices de sazonalidade são obtidos pela divisão do índice dos demais meses do ano pelo índice do mês base);

Além desses, outro método muito utilizado é o método de regressão, indicados “... para séries que apresentam sazonalidade determinística, ou seja, esta pode ser prevista perfeitamente a partir de meses anteriores.”¹¹

Assim, considerando a seqüência:

⁹ MORETTIN, Pedro A. e TOLOI, Clélia M. op. cit. p. 32

¹⁰ MILONE, Giuseppe e ANGELINI, Flávio. op. cit. p.264

¹¹ MORETTIN, Pedro A. e TOLOI, Clélia M. op. cit. p.35

$$Y_{ij} = T_{ij} + S_j + a_{ij} \rightarrow i = 1, \dots, p \rightarrow j = 1, \dots, 12 .$$

$$T_t = \sum_{j=0}^m \beta_j t^j \rightarrow t = 1, \dots, N$$

$$S_t = \sum_{j=1}^{12} \alpha_j d_{jt} \rightarrow t = 1, \dots, N$$

E, também, considerando:¹²:

- \bar{d}_{jt} são variáveis periódicas (senos, cossenos ou variáveis sazonais *dummies*);
- \bar{s}_j indica uma sazonalidade constante (não varia de ano para ano) e pode ser representada por 12 constantes;
- \bar{a}_t é o ruído branco, com média zero e variância constante;
- $\bar{d}_{jt} = 1$ se o período t corresponde ao mês j ($j = 1, \dots, 12$) e 0 caso contrário;
- o modelo submete-se à restrição: $\sum_{j=1}^{12} \alpha_j = 0$;
- o modelo pode ser reescrito na seguinte forma: $S_t = \sum_{j=1}^{11} \alpha_j D_{jt}$;
- $\bar{D}_{jt} = 1$ se o período t corresponde ao mês j ($j = 1, \dots, 11$), -1 se o período t corresponde ao mês 12 e 0 caso contrário;
- uma tendência linear;

pode-se reescrever o modelo na forma abaixo e solucioná-lo com regressão múltipla:

$$\hat{Y}_t = \beta_0 + \beta_1 t + \sum_{j=1}^{11} \alpha_j D_{jt} + a_t$$

¹² MORETTIN, Pedro A. e TOLOI, Clélia M. op. cit. p.35

Após determinados os coeficientes de sazonalidade, esta deve ser removida da série, obtendo-se o isolamento dos demais componentes, como segue:

No modelo aditivo:

$$Y = T + S + C + I \quad \rightarrow \quad Y = T + S + C + I - S \quad \rightarrow \\ Y = T + C + I$$

No modelo multiplicativo:

$$Y = T S C I \quad \rightarrow \quad \frac{Y}{S} = \frac{T S C I}{S} \quad \rightarrow \quad \frac{Y}{S} = T C I$$

Se o objetivo é estudar os movimentos cíclicos e irregulares, o uso de dados anuais (soma de 12 sub-períodos mensais) ou o cálculo da média móvel de longo prazo (sub-períodos igual ou superior a 12 meses), já revela uma série (calculada) livre dos efeitos sazonais

4. Cálculo dos Coeficientes Sazonais

No quadro a seguir figura uma série de custo relativo ao período de jan/85 a dez/89, para a qual aplicou-se o método de decomposição baseado em regressão múltipla descrito no tópico anterior. Para tanto, atribuiu-se uma variável *dummy* positiva para cada período mensal, com exceção de dezembro, em respeito à restrição de que a soma dos coeficientes sazonais deve ser zero (motivo pelo qual o mês de dezembro é representado em todas as variáveis *dummies* com o número (-1)).

Mês/ano	Custo	período	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov
Jan/85	18.371	1	1	0	0	0	0	0	0	0	0	0	0
Fev/85	17.272	2	0	1	0	0	0	0	0	0	0	0	0
Mar/85	18.750	3	0	0	1	0	0	0	0	0	0	0	0
Abr/85	19.649	4	0	0	0	1	0	0	0	0	0	0	0
Mai/85	19.636	5	0	0	0	0	1	0	0	0	0	0	0
Jun/85	20.404	6	0	0	0	0	0	1	0	0	0	0	0
Jul/85	21.446	7	0	0	0	0	0	0	1	0	0	0	0
Ago/85	20.980	8	0	0	0	0	0	0	0	1	0	0	0
Set/85	21.290	9	0	0	0	0	0	0	0	0	1	0	0
Out/85	22.106	10	0	0	0	0	0	0	0	0	0	1	0
Nov/85	20.771	11	0	0	0	0	0	0	0	0	0	0	1
Dez/85	20.151	12	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
Jan/86	20.019	13	1	0	0	0	0	0	0	0	0	0	0
Fev/86	20.651	14	0	1	0	0	0	0	0	0	0	0	0
Mar/86	22.046	15	0	0	1	0	0	0	0	0	0	0	0
Abr/86	21.339	16	0	0	0	1	0	0	0	0	0	0	0
Mai/86	22.441	17	0	0	0	0	1	0	0	0	0	0	0
Jun/86	23.215	18	0	0	0	0	0	1	0	0	0	0	0
Jul/86	23.883	19	0	0	0	0	0	0	1	0	0	0	0
Ago/86	24.316	20	0	0	0	0	0	0	0	1	0	0	0
Set/86	23.794	21	0	0	0	0	0	0	0	0	1	0	0
Out/86	24.629	22	0	0	0	0	0	0	0	0	0	1	0
Nov/86	23.088	23	0	0	0	0	0	0	0	0	0	0	1
Dez/86	22.604	24	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
Jan/87	20.770	25	1	0	0	0	0	0	0	0	0	0	0
Fev/87	20.334	26	0	1	0	0	0	0	0	0	0	0	0
Mar/87	24.160	27	0	0	1	0	0	0	0	0	0	0	0
Abr/87	21.954	28	0	0	0	1	0	0	0	0	0	0	0
Mai/87	24.057	29	0	0	0	0	1	0	0	0	0	0	0
Jun/87	24.180	30	0	0	0	0	0	1	0	0	0	0	0
Jul/87	24.054	31	0	0	0	0	0	0	1	0	0	0	0
Ago/87	24.854	32	0	0	0	0	0	0	0	1	0	0	0
Set/87	23.838	33	0	0	0	0	0	0	0	0	1	0	0
Out/87	24.669	34	0	0	0	0	0	0	0	0	0	1	0
Nov/87	24.195	35	0	0	0	0	0	0	0	0	0	0	1
Dez/87	22.932	36	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
Jan/88	22.519	37	1	0	0	0	0	0	0	0	0	0	0
Fev/88	21.446	38	0	1	0	0	0	0	0	0	0	0	0
Mar/88	24.679	39	0	0	1	0	0	0	0	0	0	0	0
Abr/88	23.595	40	0	0	0	1	0	0	0	0	0	0	0
Mai/88	24.856	41	0	0	0	0	1	0	0	0	0	0	0
Jun/88	25.446	42	0	0	0	0	0	1	0	0	0	0	0
Jul/88	25.681	43	0	0	0	0	0	0	1	0	0	0	0
Ago/88	27.502	44	0	0	0	0	0	0	0	1	0	0	0
Set/88	26.004	45	0	0	0	0	0	0	0	0	1	0	0
Out/88	27.770	46	0	0	0	0	0	0	0	0	0	1	0
Nov/88	26.060	47	0	0	0	0	0	0	0	0	0	0	1
Dez/88	24.849	48	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
Jan/89	25.155	49	1	0	0	0	0	0	0	0	0	0	0
Fev/89	23.621	50	0	1	0	0	0	0	0	0	0	0	0
Mar/89	26.285	51	0	0	1	0	0	0	0	0	0	0	0
Abr/89	25.493	52	0	0	0	1	0	0	0	0	0	0	0
Mai/89	27.416	53	0	0	0	0	1	0	0	0	0	0	0
Jun/89	27.197	54	0	0	0	0	0	1	0	0	0	0	0
Jul/89	27.348	55	0	0	0	0	0	0	1	0	0	0	0
Ago/89	29.179	56	0	0	0	0	0	0	0	1	0	0	0
Set/89	26.618	57	0	0	0	0	0	0	0	0	1	0	0
Out/89	29.880	58	0	0	0	0	0	0	0	0	0	1	0
Nov/89	27.679	59	0	0	0	0	0	0	0	0	0	0	1
Dez/89	25.380	60	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1

Agora, aplicando-se a regressão múltipla tendo por variável dependente o custo e como variáveis independentes o período e os onze períodos sazonais, através do programa excel obteve-se os seguintes resultados:

RESUMO DOS RESULTADOS								
Estatística de regressão								
R m múltiplo	0,975533582							
R-Quadrado	0,951665771							
R-quadradoaju	0,939325116							
Erro padrão	678,3121898							
Observações	60							
ANOVA								
	gl	SQ	MQ	F	F de significação			
Regressão	12	425781463,6	35481788,63	77,11631364	1,02535E-26			
Resíduo	47	21625049,06	460107,4268					
Total	59	447406512,7						
	Coeficientes	Erro padrão	Stat t	valor-P	95% inferiores	95% superiores	Inferior 95,0%	Superior 95,0%
Interseção	19.567,08	180,10508	108,64258	0,00000	19.204,76	19.929,40	19.204,76	19.929,40
período	131,41	5,16010	25,46664	0,00000	121,03	141,79	121,03	141,79
jan	-1.485,62	291,81926	-5,09088	0,00001	-2.072,68	-898,55	-2.072,68	-898,55
fev	-2.319,03	291,36269	-7,95925	0,00000	-2.905,17	-1.732,88	-2.905,17	-1.732,88
mar	68,66	290,99691	0,23595	0,08145	-516,75	654,07	-516,75	654,07
abr	-840,35	290,72228	-2,89056	0,00580	-1.425,21	-255,49	-1.425,21	-255,49
mai	303,18	290,53905	1,04351	0,30205	-281,31	887,67	-281,31	887,67
jun	578,93	290,44739	1,99324	0,05206	-5,37	1.163,23	-5,37	1.163,23
jul	841,72	290,44739	2,89801	0,00569	257,42	1.426,02	257,42	1.426,02
ago	1.594,02	290,53905	5,48642	0,00000	1.009,53	2.178,51	1.009,53	2.178,51
set	405,02	290,72228	1,39315	0,17013	-179,84	989,88	-179,84	989,88
out	1.775,62	290,99691	6,10185	0,00000	1.190,21	2.361,03	1.190,21	2.361,03
nov	192,15	291,36269	0,65948	0,51280	-394,00	778,29	-394,00	778,29

Assim, admitindo-se o tempo como fator preditivo e a existência de sazonalidade em subperíodos mensais num modelo aditivo, obteve-se um poder de explicação ajustado (coeficiente de determinação ajustado) de 93,9%. Esse coeficiente de determinação é melhor que o obtido se aplicar-se apenas a regressão simples entre o custo e o tempo (76,8%). Vale ressaltar que tanto a equação e coeficientes angulares foram validados estatisticamente ($F > F$ de significação; $Stat t > valor-P$).

Vale ressaltar que, para aplicação do modelo respeitando a restrição de que a soma dos coeficientes sazonais seja zero, utilizou-se somente 11 períodos sazonais. Dessa forma, para o cálculo do coeficiente sazonal de dezembro basta somar os onze coeficientes calculados e inverter seu sinal: R\$ -1.114,30. Assim, as previsões para os próximos períodos foram obtidas a partir dos coeficientes de regressão calculados:

PREVISÕES		
Observação	per.sazonal	Custo Previsto
61	jan	26.097,49
62	fev	25.395,49
63	mar	27.914,59
64	abr	27.136,99
65	mai	28.411,93
66	jun	28.819,09
67	jul	29.213,29
68	ago	30.097,00
69	set	29.039,41
70	out	30.541,42
71	nov	29.089,36
72	dez	29.028,62

5. Conclusões

Conclui-se que as técnicas quantitativas e modelos de previsão podem alavancar as possibilidades da análise estratégica de custos, melhorando o poder de explicação da posição atual da estrutura de custos em relação às variáveis que a provocam ou influenciam e, ainda, permitindo que, de forma mais objetiva e científica, se possa prever ou estimar o comportamento futuro dos mesmos, alavancando as possibilidades de antecipação da empresa frente às oportunidades e ameaças.

Justifica-se tal pensamento em razão de que, o contexto produtivo e competitivo atual provocaram nas empresas a necessidade de que suas estruturas de controle serem mais rápidas e ágeis que as estruturas controladas, ou seja, impuseram a instantaneidade. E, para que se possa lidar com a instantaneidade, só mesmo a antecipação.

O objetivo é possibilitar que as áreas de gestão de custos tenha um tempo de resposta adequado às novas demandas informativas dos gestores, permitindo a eles interagir nos acontecimentos presentes para moldar os futuros, numa postura pró-ativa.

6. Bibliografia

- AMARANTE, Luiz Antonio Martins. *Previsão em Economia: Aplicação de Dois Métodos Univariados de Análise de Séries Temporais*. São Paulo, 1986. Dissertação (Mestrado em Economia) - Faculdade de Economia, Administração e Contabilidade - Universidade de São Paulo.
- FARNUM, Nicholas R. e STANTON, LaVerne W. *Quantitative Forecasting Methods*. Boston: PWS-Kent, 1989.
- HANKE, John E. e REITSCH, Arthur. *Business Forecasting*. Boston: Allyn and Bacon Inc., 1981.
- HOFFMANN, Rodolfo. *Estatística para Economistas*. 2ª ed. São Paulo: Livraria Pioneira Editora, 1991.
- IUDÍCIBUS, Sergio de, *Teoria da Contabilidade*. 3ª ed. São Paulo: Atlas, 1993.
- _____. *Análise de Custos*. 2ª ed. São Paulo: Atlas, 1989.
- KAZMIER, Leonard J. Ph.D. *Estatística Aplicada a Economia e Administração*. do original *Schaum's Outline of Theory and Problems of Business Statistics* Tradução por: Carlos Augusto Crusius. Revisão técnica: Jandyra M. Fachel - Instituto de Matemática da UFRGS Depto. Estatística - São Paulo:- McGraw-Hill do Brasil, 1982.
- MAKRIDAKIS, Spyros, WHEELWRIGHT, Steven C. e MCGEE, Victor E. *Forecasting: Methods and Applications*. 2ª ed. New York: John Wiley & Sons, 1983.
- MILONE, Giuseppe & ANGELINI, Flávio. *Estatística Aplicada*. São Paulo: Atlas, 1995.
- MIRANDA, Luiz Carlos. *Modelos de Simulação Empresarial*. São Paulo, 1985. Dissertação (Mestrado em Contabilidade) - Faculdade de Economia, Administração e Contabilidade - Universidade de São Paulo.
- MORETTIN, Pedro A. e TOLOI, Clélia M. *Previsão de Séries Temporais*. 2ª ed. São Paulo: Atual, 1987.
- MORETTIN, Pedro A. e TOLOI, Clélia M. *Séries Temporais*. 2ª ed. São Paulo: Atual, 1987.
- PINDYCK, Robert S. & RUBINFELD Daniel L. *Econometric Models and Economic Forecasts*. Boston: Irwin/McGraw-Hill, 1998.
- STEVENSON, William. *Estatística Aplicada à Administração*. São Paulo: HARBRA, 1986.
- WHEELWRIGHT, Steven C. e MAKRIDAKIS, Spyros. *Forecasting Methods for Management*. New York: John Wiley & Sons, 1973.