

MÉTODOS DE ANÁLISE EM SÉRIES TEMPORAIS E O PLANEJAMENTO DE POLÍTICAS PÚBLICAS EM SAÚDE

Marco Aurélio Kasmin¹
Lirane Elize Defante Ferreto de Almeida²
Mariana Aparecida Euflausino³
Nézio José da Silva⁴
Claudelir Clein⁵

Área de conhecimento: Medicina

Eixo Temático: Ensino e pesquisa na área da saúde

RESUMO

Este trabalho tem como objetivo, evidenciar a potencialidade do uso de modelos estatístico de análise de séries temporais com capacidade preditiva na elaboração do planejamento na área da saúde pública. São abordadas as principais características das séries temporais e as possíveis contribuições desta forma de dados no planejamento da saúde pública, com ênfase nas variáveis: tendência e sazonalidade. Na sequência são apresentados alguns modelos estatísticos com capacidade preditiva, suas características e usualidades. Na última parte deste artigo mostra-se como estes modelos estão sendo, ainda que de forma incipiente, utilizados na área de planejamento e saúde.

Palavras-chave: Planejamento. Saúde Pública. Séries Temporais. Análise de Fourier.

1 INTRODUÇÃO

Ao se trabalhar com séries temporais lida-se com um conjunto de dados que difere dos demais por ser ordenado no tempo, ou seja, todos os valores são referentes ao mesmo fato, no entanto, em períodos distintos. Esse fato muda a natureza dos dados, dá-nos a capacidade de analisar a evolução de determinado fato ao longo do tempo. Os métodos de análise para séries temporais auxiliam tanto na análise para a compreensão do objeto de estudo como fornecem instrumentais matemático-metodológicos para fazer projeções.

¹ Mestrando do Programa de Gestão e Desenvolvimento Regional – UNIOESTE – Campus de Francisco Beltrão. marcokasmin@hotmail.com

² Doutora em Saúde Coletiva(UNICAMP/SP) - Professora do Mestrado em Gestão e Desenvolvimento Regional – UNIOESTE – Campus de Francisco Beltrão. liraneferreto@uol.com

³ Mestrando do Programa de Gestão e Desenvolvimento Regional – UNIOESTE – Campus de Francisco Beltrão. marcokasmin@hotmail.com

⁴ Mestrando do Programa de Gestão e Desenvolvimento Regional – UNIOESTE – Campus de Francisco Beltrão. marcokasmin@hotmail.com

⁵ Mestrando do Programa de Mestrado em Gestão e Desenvolvimento Regional da UNIOESTE – Campus Francisco Beltrão-PR. Email: claudeliradm@gmail.com



Diversos trabalhos que usam das metodologias aqui descritas têm como objetivo a compreensão da natureza do fato objeto de estudo, compreender de que forma a evolução de um quadro de morbidade interfere na vida da população pode auxiliar na tomada de decisões estratégicas, elaboração de planos de combate a uma epidemia, na avaliação da eficácia de uma política pública e na previsão de recursos necessários no campo da saúde. Pode-se entender a área da saúde como um campo multiparadigmático composto de diferentes variáveis que definem a presença da doença ou não e sua manutenção depende de fatores relacionados ao indivíduo, ao governo e a coletividade. Neste trabalho pretende-se tratar da capacidade preditiva desses modelos matemáticos, para que essas estimativas sejam utilizadas no planejamento de políticas públicas, com enfoque na área da saúde.

2 REFERENCIAL TEÓRICO

Entende-se como política de saúde a resposta social (ação ou omissão) de uma organização (como o Estado) diante das condições de saúde dos indivíduos e das populações e seus determinantes, bem como em relação à produção, distribuição, gestão e regulação de bens e serviços que afetam a saúde humana e o ambiente (Paim e Teixeira, 2006).

Ainda segundo Paim e Teixeira (2006) o planejamento de políticas públicas na área da saúde se limitou por um longo período de tempo aos setores financeiros e a legislação orçamentária. Somente na década de 1970 com o desenvolvimento das ciências sociais em saúde que esse quadro começa a mudar. E é somente no final da década de 1980 que se passa a elaborar propostas de reforma na gestão, no planejamento e na organização dos serviços. Pode se atribuir esse fato as grandes discussões que precederam a Constituinte de 1988, que veio a estabelecer a saúde pública como direito universal.

Após 1999, há um aumento do número de pesquisas que abordam o tema do planejamento em saúde com ênfase a gestão descentralizada do Sistema Único de Saúde (SUS), essas políticas de descentralização se intensificam e evoluem até os dias de hoje.



Nessa perspectiva, a redefinição das funções e competências das três esferas de governo do SUS ganha transcendência, constituindo-se um espaço de reflexão e experimentação política-organizacional em torno da nova "missão" do Ministério da Saúde, das Secretarias Estaduais de Saúde e das Secretarias Municipais de Saúde (Teixeira, 1999).

2.1 SÉRIES TEMPORAIS

“Uma série temporal é qualquer conjunto de observações ordenadas no tempo” (Morettin e Tolo, 2006, p:) Assim constitui uma série temporal um conjunto de dados, relativos a um único fato, observados a um intervalo regular de tempo.

Uma característica relevante das séries temporais é a dependência serial, ou seja, ao observar o mesmo fato em períodos diferentes, ou seja, período após período cria-se uma interdependência entre os dados, pois a conjuntura na primeira observação irá interferir nos resultados observados posteriormente. Tal dependência serial pode ser observada por um número indefinido de períodos, a intensidade e duração da dependência serial é característica única da série analisada e reflete a natureza do fato observado.

Ao observar se uma série temporal observa se na verdade uma trajetória, que descreve o comportamento de um determinado fato, essa trajetória pode ser composta pela frequência com que o fato se repete em um intervalo de tempo, assim como pode ser composta por variáveis métricas, ao auferir se e registrar tais variáveis a intervalos regulares.

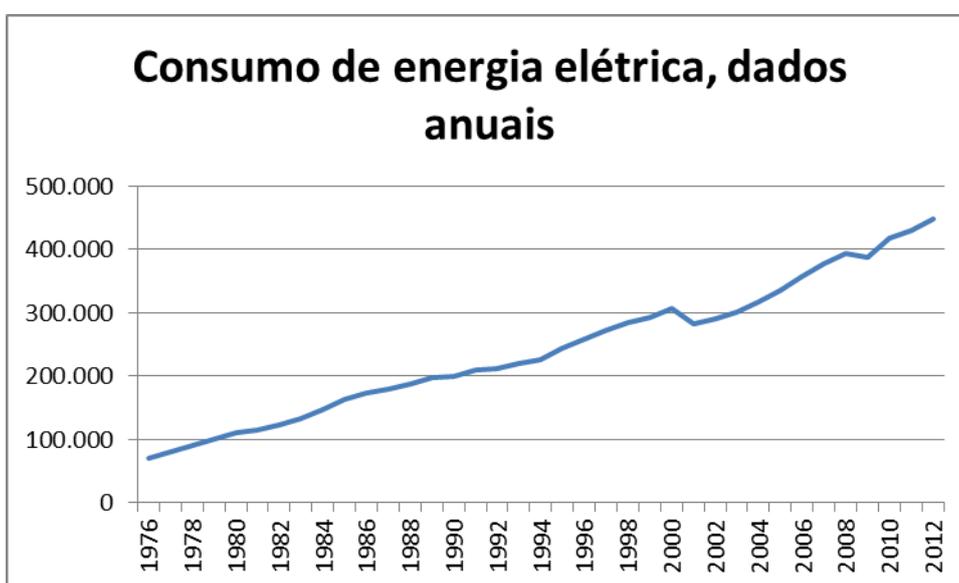
Quando trabalha se com séries temporais é preferível obtê-las com o menor intervalo possível, visto que a frequência das observações pode interferir significativamente na série temporal, alterando assim os resultados da análise.

É comum em qualquer levantamento de dados que as diferentes formas de agregá-los conduzem a perda de determinadas informações preteridas em prol das que são consideradas mais relevantes pelo pesquisador, o mesmo se dá com as séries temporais, mas pode ser amenizado utilizando-se o menor período possível entre as observações.

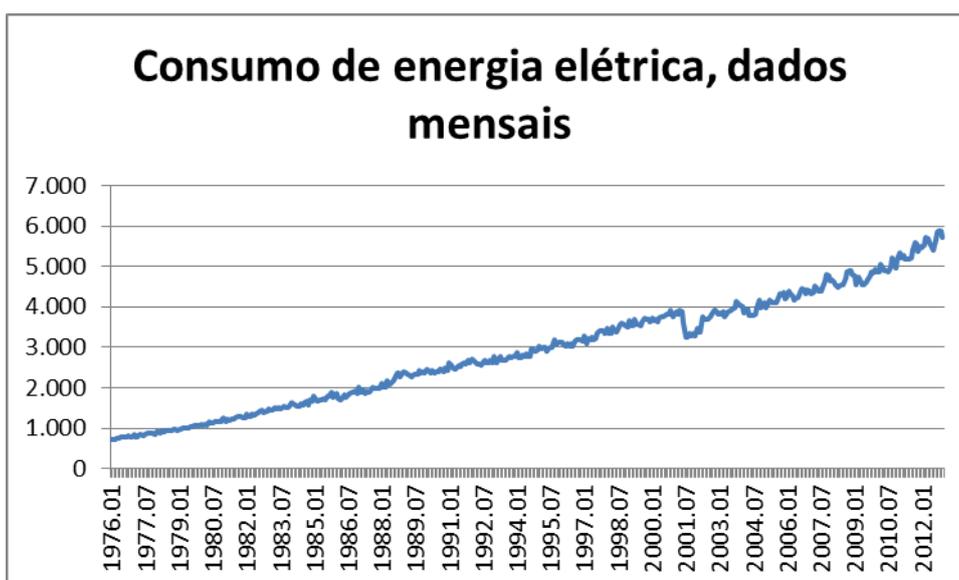


Pode-se afirmar que afirma que a agregação nos dados sempre conduz a perda de informação e que sempre que seja possível se deve construir modelos sobre séries temporais com a maior profundidade de desagregação.

Uma série temporal será mais rica em informações e detalhes quanto menor o período entre as observações, esse fato pode ser observado na figura abaixo, onde foram gerados diferentes gráficos sobre a mesma série de dados - consumo de energia elétrica no Brasil -, porém coletadas com intervalos diferentes, no primeiro grafico observa-se o consumo anual e no segundo o consumo mensal.



Fonte: Elaborado pelo autor. Dados: Ipeadata.



Fonte: Elaborado pelo autor. Dados: Ipeadata.



Observa-se que quanto maior se utiliza um período longo entre as observações, tende-se a suavização da curva do gráfico, predominando assim a tendência de longo prazo.

Ao observar os mesmos dados, em períodos menores, dados mensais e semanais, capta-se as variações cíclicas e sazonais da série temporal, sem de prejuízo algum na análise de tendência.

Nos gráficos acima é possível perceber as componentes descritas pela abordagem dos componentes não observáveis de uma série temporal.

A abordagem dos componentes não observáveis descreve uma série temporal como sendo composta por componentes além dos dados e que regem o comportamento desses.

Segundo a abordagem de componentes não observáveis, as séries temporais podem ser representadas como a combinação de quatro componentes: Tendência, Cíclica, Sazonal e Erro (Mendenhall, 1993).

Assim a série temporal pode ser descrita como: $Z_t = T_t + S_t + a_t$

Há ainda os modelos multiplicativos, que são descritos como: $Z_t = T_t \cdot S_t \cdot a_t$

A componente tendência é aquela que promove alterações unidirecionais e graduais ao longo do tempo em toda a série, comumente de caráter linear. A componente cíclica é aquela que promove alterações senoidais. Ou seja, rege períodos de crescimento e decréscimo de longo prazo. A componente sazonal é aquela que promove alterações recorrentes observáveis a intervalos regulares. A componente de erro é a responsável pelo comportamento aleatório da série. São movimentos de curto prazo com deslocamento inexplicável.

É preciso uma ampla série temporal para diferir a tendência de uma componente cíclica, essa tende a promover alterações em longos períodos de tempo ao longo da componente tendência. Quando a série temporal não é longa o suficiente, corre-se o risco de confundir parte de um ciclo com a tendência. A única forma de evitar esse problema é adotando uma série tão longa quanto o possível. Um exemplo, de como a componente cíclica pode ser confundida com a tendência, acontecem discussões sobre o aquecimento global, onde pesquisadores renomados divergem sobre se há um aquecimento de nível global ou se é um ciclo



natural do planeta, para a derradeira solução desde problema seria preciso uma série temporal de milhões de anos descrevendo a trajetória do clima, não disponível a discussão se mantém.

É preciso também compreender as diferenças entre ciclos e sazonalidade, movimentos sazonais não são necessariamente senoidais, não ocorrem em longos períodos de tempo e sim a intervalos regulares curtos, a própria definição de sazonal segundo o dicionário Priberan remete a um curto espaço de tempo: relativo a sação; próprio de uma estação do ano; que tem a duração de uma estação; Que tem duração limitada durante o ano.

Podemos classificar as séries temporais como: estacionárias, não estacionárias e ergódicas. Séries estacionárias são aquelas que se desenvolvem no tempo aleatoriamente ao redor de uma média constante, refletindo alguma forma de equilíbrio estável. (Morettin e Tolo, 2006), ou seja, é aquela que possui uma tendência horizontal, não tem variações cíclicas ou sazonais, e o componente de erro desenvolve assim uma variância constante.

Séries não estacionárias são aquelas em que se observa uma alteração na média se calculada para diferentes períodos da serie temporal.

Séries ergódicas são aquelas na qual apenas uma realização do processo estocástico é suficiente para se obter todas as estatísticas do mesmo (Morettin e Tolo, 2006).

2.2 MODELOS PARA ANALISE E PREDIÇÃO EM SÉRIES TEMPORAIS

A maioria dos métodos de previsão baseia-se na ideia de que as observações passadas contêm informações sobre o padrão de comportamento da série temporal. O propósito dos métodos é distinguir o padrão de qualquer ruído que possa estar contido nas observações e então usar esse padrão para prever valores futuros da série.

Segundo Morettin e Tolo (2004) uma série pode ser utilizada para: a) Investigar o mecanismo gerador da série temporal; b) Fazer previsões de valores futuros da série; sendo que as previsões podem ser a curto e longo prazo; c) Descrever apenas o comportamento da série, neste caso a construção de histogramas e diagramas de dispersão, entre outros, podem ser ferramentas úteis;



d) Verificar a existência de tendências, ciclos e variações sazonais; e) Procurar periodicidades relevantes nos dados; neste caso, a análise espectral, pode ser de grande utilidade.

Os modelos para análise de séries temporais podem ser classificados segundo seu número de parâmetros. Os modelos paramétricos são aqueles que possuem um número de parâmetros finitos e conhecidos. Os modelos não-paramétricos são aqueles que possuem um número de parâmetros infinitos.

(...) os modelos mais frequentemente usados estão os modelos de erro, modelos auto-regressivos e de médias móveis (ARMA), os modelos auto-regressivos integrados de médias móveis (ARIMA), modelos de memória longa (AFIRMA), modelos estruturais e modelos não lineares. Os modelos não paramétricos mais utilizados são a função de autocovariância e sua transformada de Fourier, o espectro. (Morettin e Tolo, 2006, p. 33)

2.2.1 MODELO ARMA (Modelo auto-regressivo de médias móveis)

Esse modelo foi desenvolvido para ajustar uma função que melhor descreve o comportamento da série, tal modelo combina um processo autoregressivo a um processo de médias móveis (fulano tal) para isso ele utiliza como base os valores passados e a média móvel da série.

Tal modelo pode ser descrito:

$$\left(1 - \sum_{i=1}^p \phi_i L^i\right) X_t = \left(1 + \sum_{i=1}^q \theta_i L^i\right) \varepsilon_t$$

Para estimarmos um modelo ARMA precisamos que este descreva um processo estável, e, portanto há restrições quanto a aplicabilidade de seus coeficientes.

2.2.2 MODELO ARIMA (modelo auto-regressivo integrado de média móvel)

Conhecida também como abordagem Box e Jenkins (1970) é uma análise de modelos paramétricos. “Em geral os modelos postulados são parcimoniosos, contêm um número reduzido de parâmetros e as previsões obtidas são bastante precisas.” (Morettin e Tolo 2006, p:)

O modelo ARIMA (p,d,q) é dado pela equação:



$$\left(1 - \sum_{i=1}^p \phi L^i\right) (1-L)^d X_t = \left(1 + \sum_{i=1}^q \theta_i L^i\right) \varepsilon_t$$

em que d é um inteiro positivo que determina o número de diferenças (no caso $d = 0$, esta equação é equivalente ao modelo ARMA(p, q)), e L é o operador defasagem:

$$LX_t = X_{t-1}$$

2.2.3 MODELO SARIMA (sazonal autoregressivo integrado de médias móveis)

“O processo sazonal autorregressivo integrado de médias móveis trata séries que não têm estacionariedade, mas possuem periodicidade cíclica, com picos e declínios no decorrer de sua evolução temporal” (Lizzi, 2012, p: 48)

O modelo SARIMA se aplica quando há sazonalidade determinística. Ou seja, se pode de antemão dizer o período de sazonalidade observado na série. Os modelos de previsão podem ser univariados, se consideram para a previsão somente os valores passados da série, ou causais, quando agregam outras variáveis relevantes para a previsão.

O modelo pode ser descrito matematicamente como:

$$Z_t = \mu + A \sin(\omega t) + B \cos(\omega t) + \alpha_t$$

Onde μ é uma constante.

$\omega = \frac{2\pi}{T}$ e T é a frequência sazonal determinado pelo pesquisador.

α é a componente de erro aleatório.

2.2.4 MODELO ARMA ANÁLISE DE FOURIER

A análise de Fourier ou análise harmônica é um procedimento alternativo para séries que não possuem sazonalidade determinística. E serve justamente para descobrir a periodicidade em séries temporais (Morettin e Tolo, 2006).

O modelo pode ser descrito como:



$$Z_t = a_0 + \sum_{j=1}^{\frac{n}{2}-1} \left(a_j \cos \frac{2\pi jt}{N} + b_j \sin \frac{2\pi jt}{N} \right)$$

A expressão a cima demonstra a decomposição da série Z_t em componentes periódicas (Morettin e Tolo, 2006) onde a inclusão dos vetores seno e cosseno fornecem a componente cíclica, criando uma curva senoidal.

O modelo será melhor quanto melhor a curva se adequar a distribuição dos dados, observa-se essa adequação através da análise do erro, a soma dos erros será melhor quanto melhor o ajustamento do modelo. O erro devera ainda ser estacionário, assim reduzido se ao componente aleatório.

2.3 APLICAÇÃO DOS MODELOS SÉRIES TEMPORAIS NA SAÚDE

Os modelos acima apresentados possuem capacidade preditiva, ou seja, podem ser usadas para gerar projeções, essas por sua vez seriam de grande valia se incluídas no planejamento de políticas na área da saúde, sobretudo no campo epidemiológico.

Silva, Araújo e Filho (2010) desenvolveram trabalhos cujo objetivo era comparar diferentes modelos estatísticos - *Holt-Wintes*, decomposição aditivo e multiplicativo – para verificar qual melhor se adequa aos dados referentes a pacientes com HIV do Hospital Universitário João de Barros Barreto. Este trabalho oferece grande contribuição ao tema ao explorar as características dos modelos e suas especificidades. E mostram a evolução desta situação nos pacientes de sua amostra.

Lizzi (2012) usou modelos de análise de séries temporais com ênfase no componente sazonal, estudando o numero de casos de Dengue nos municípios de Campinas/SP e Ribeirão Preto/SP. Em seu trabalho Lizzi (2012) comprovou que o modelo tem capacidade preditiva e significancia, tal informação poderia ser utilizada pelos governos municipais para desenvolvimento de planos no combate a Dengue.

Otero (2011) usa modelos de análise de séries temporais para investigar o índice de mortalidade por desnutrição em idosos, verificando que há um componente sazonal associado ao índice, ele atribui, entre outras relações causais, que a



sazonalidade do índice se deve a questão climática associada a debilidade dos idosos em risco nutricional.

Tais trabalhos demonstram que a capacidade preditiva dos modelos pode ser utilizada no planejamento de ações pontuais, que reduziriam o índice de mortalidade dos problemas estudados pelos autores.

Filho e Rissin (2003) usaram séries temporais para traçar e compreender os cenários epidemiológicos no Brasil, fazendo assim uma análise da evolução da situação nutricional brasileira, que obteve grandes avanços nas últimas décadas, mas que já demonstram indícios de problemas relacionados ao estilo de vida moderno, como obesidade.

Por fim temos o exemplo de um trabalho que usando a análise de séries temporais, contribui para a compreensão da evolução da situação nutricional no Brasil, este é de grande valia para a compreensão dos efeitos das diversas políticas desenvolvidas ao longo das últimas décadas. Mesmo sem significância estatística para ser utilizado para predição o modelo analisa de tal maneira a evolução destas variáveis que já levantam questões sobre o futuro dessas variáveis.

3 CONSIDERAÇÕES FINAIS

O objetivo da pesquisa foi de evidenciar a possibilidade de integração de modelos de análise de séries temporais na área da saúde, com ênfase no planejamento, descrevendo alguns dos principais modelos e suas características a partir de um conjunto de trabalhos que usaram esses métodos aplicados à saúde. Evidenciou-se que os métodos de análise de séries temporais podem com sucesso serem aplicados a área da saúde, tanto na análise dos efeitos de políticas como direcionador para o planejamento, desde que o pesquisador observe as especificidade de cada modelo.

REFERÊNCIAS

LIZZI, E. A. (2012). **Predição do número mensal de casos de dengue por modelos de séries temporais**. Dissertação – Faculdade de Medicina de Ribeirão Preto, Universidade de São Paulo – USP. Ribeirão Preto 22 de junho de 2012



MORETTIN, P. A. e TOLOI C. M. (2006). **Análise de séries temporais**. São Paulo: Egard Blücher.

OTERO, U. B. (2011). **Óbitos por desnutrição em idosos, São Paulo e Rio de Janeiro. Análise de séries temporais. 1980-1996**. Revista Brasileira de Epidemiologia vol. 4, num.3, 191-205.

PAIM, J. S. e Teixeira, C. F. (2006). **Política, planejamento e gestão em saúde: balanço do estado da arte**. Rev Saúde Pública, 73-78.

Teixeira, C. F. (1999). **Epidemiologia e planejamento de saúde**. Ciênc. saúde coletiva vol.4 no.2 Rio de Janeiro.

Mendenhall, W. (1993) **A Second Course in Statistics: regression analysis**. Editora Pearson.

SILVA, G.M; ARAÚJO, A. R.; FILHO, G.G.C.(2010) **Análise de Séries Temporais de Pacientes com HIV/AIDS Internados no Hospital Universitário João de Barros Barreto (HUJBB), da Região Metropolitana de Belém, Estado do Pará**. 19º SINAPE. 26 a 30 de julho de 2010, São Pedro-SP

FILHO, M. B; RISSIN, A. (2003) **A transição nutricional no Brasil: tendências regionais e temporais**. Cad. Saúde Pública, Rio de Janeiro, 19(Sup. 1):S181-S191

