

3 Técnicas de Previsão de Séries Temporais

3.1. Introdução

A previsão de séries temporais é um problema prático de extrema importância, presente em diversas áreas: economia, indústria, serviços, previsão de fenômenos naturais, processamento de sinais, controle entre outros[41].

Praticamente todos os tipos de organizações empresariais, sejam do setor de serviços ou do setor industrial, de pequeno ou grande porte, privada ou estatal, necessitam planejar seus mais variados recursos de forma a atender, ao menor custo possível, a demanda do mercado alvo, maximizando a rentabilidade do negócio[42].

No setor elétrico, a principal aplicação de previsão de séries se dá na previsão de carga elétrica [43][44][45][46][47][48][49][50]. As previsões de carga são indispensáveis para a tomada de decisões referentes à compra e geração de energia elétrica e investimentos em infraestrutura e capacidade, sendo importantes para todas as empresas atuantes no setor elétrico (geração, transmissão, distribuição, financiamento, entre outras)[51]. Outras aplicações de previsão de séries também são encontradas no setor elétrico: previsão de vazão[52][53][54][55][56][57], previsão dos preços da energia elétrica[58][59][60][61], entre outras.

A previsão de séries temporais está também presente no setor financeiro, principalmente no mercado de ações [62][63][64][65][66]. Prever a série do valor de ações é de extrema relevância não só para os investidores, mas também para os pesquisadores acadêmicos que buscam entender o comportamento do mercado de ações[67]. Calcular uma previsão de uma série de preços de ações é bastante desafiador, pois estas são afetadas por diversas variáveis econômicas, sociais e políticas, que muitas vezes estão inter-relacionadas de uma forma significativamente complexa. O conceito central para uma previsão de alto desempenho está em obter os melhores resultados utilizando o mínimo de dados de entrada, desenvolvendo o modelo menos complexo possível[68].

Na economia, previsões de inflação são extremamente importantes para

os agentes econômicos e políticos. Os bancos centrais são os principais usuários dessas previsões, dado que precisam ter uma perspectiva da inflação futura para controlar os instrumentos que afetam o comportamento da economia. No caso específico de bancos centrais que trabalham com política de inflação alvo, a obtenção de previsões de inflação de qualidade é de grande importância. Uma fundamentação sólida para as decisões sobre política monetária necessita de informações sobre diversos aspectos, tais como: o processo gerador da inflação futura; o mecanismo de transmissão dos juros de curto prazo para os juros de longo prazo; as taxas de câmbio; a atividade econômica real e a inflação em si [69]. Prever a inflação futura ainda é uma tarefa desafiadora, e altos investimentos são feitos para desenvolver modelos que resultem em exatidões aceitáveis. Esse é o motivo para se encontrar inúmeras técnicas econométricas na literatura[70] [71][72][73][74].

Realizar previsões de demanda é vital a qualquer empresa do setor industrial, pois fornece dados de entrada básicos para o planejamento de todas as áreas funcionais, incluindo marketing, logística, produção e finanças. Os níveis de demanda afetam profundamente os níveis de capacidade, as necessidades financeiras e a estrutura geral dos negócios [75]. Sabe-se que a previsão sempre está sujeita a erros, já que se trabalha em um ambiente instável na maioria das vezes. Entretanto, diante de um cenário extremamente competitivo, o mais importante é obter previsões mais exatas do que o concorrente. Com isso, a empresa conseguirá se sustentar no mercado com um custo inferior ao da concorrência [76]. Assim, a previsão de séries está presente no planejamento da demanda de indústrias dos mais diversos mercados[77][78] [79][80][81].

A previsão no setor de fornecimento de água é de grande importância, principalmente em países de grande densidade populacional. Como exemplo, o processo de urbanização da China tem avançado rapidamente, chegando a uma população urbana atual maior que 600 milhões de pessoas [82]. O gerenciamento eficiente dos recursos hídricos e do fornecimento e distribuição da água tem se tornado grande preocupação para os gestores. Para isso, uma questão chave é o balanceamento do suprimento e da demanda de água, o que requer uma previsão acurada desta demanda. O grau de exatidão desta previsão tem impacto direto na confiabilidade, na segurança e na economicidade do sistema de suprimento de água. Assim, de forma semelhante à previsão de carga, muitas pesquisas vêm sendo desenvolvidas nesta área [83][84][85][86], incluindo modelos para previsões de curto, médio e longo prazo.

Além dos setores mencionados anteriormente, em outras áreas a previsão de séries temporais também tem papel fundamental. É possível encontrar aplicações na medicina, como, por exemplo, a previsão da taxa de incidência de hipertensão, uma das doenças cardiovasculares mais comuns[87]. Também há aplicação de previsão de séries temporais em sistemas de transporte, nos quais o gerenciamento de tráfego e o controle de congestionamento necessitam de previsões precisas do tráfego futuro [88][89] [90][91][92].

As seções seguintes abordarão técnicas quantitativas de previsão de séries temporais, mencionando brevemente as técnicas estatísticas e as técnicas de inteligência computacional, dando maior ênfase na aplicação de sistemas de inferência fuzzy, base da ferramenta desenvolvida neste estudo.

3.2. Técnicas Estatísticas de Previsão de Séries Temporais

Há inúmeras técnicas estatísticas para previsão de séries temporais. Em sua maioria se baseiam na identificação de uma ou mais componentes da série temporal[93]:

- **Nível:** representa o comportamento da série caso não existisse nenhuma outra componente. Geralmente, o nível é simplesmente o ponto inicial de uma série histórica.
- **Tendência:** componente que representa o crescimento ou declínio de uma série no médio ou longo prazo.
- **Sazonalidade:** componente que representa um comportamento periódico de curto ou médio prazo. Por exemplo, sabe-se que as vendas de sorvete são mais elevadas nos meses do verão e menores no inverno, comportamento este que se repete ano a ano.
- **Ciclo:** semelhante à sazonalidade, mas reflete as flutuações ocorridas no longo prazo, sendo repetidas a cada três, quatro ou mais anos. Geralmente, esta componente é afetada pelas variações econômicas das nações.
- **Aleatoriedade:** as demais variações, não explicadas pela tendência, ciclo e sazonalidade são denominadas variações aleatórias. Estas são causadas principalmente por eventos particulares e não recorrentes.

Entre as técnicas estatísticas mais conhecidas de previsão de séries estão os amortecimentos exponenciais (simples, duplo e triplo)[93], as médias móveis (simples e dupla)[94], o ARIMA e o SARIMA [41]. Essas técnicas são bastante utilizadas, porém exigem uma análise prévia da série, de forma a identificar as componentes presentes, e assim possibilitar a seleção da técnica mais adequada. Além disso, todas se baseiam na premissa de relação linear entre os valores passados e os futuros. Assim, no caso de séries com comportamentos mais complexos, técnicas de inteligência computacional vêm sendo aplicadas com o objetivo de se obter previsões mais exatas.

3.3. Técnicas de Inteligência Computacional aplicadas em Previsão

Mais recentemente, as técnicas de inteligência computacional, principalmente Redes Neurais Artificiais (RNA)[95][96][97] [98][99] [100][101] [102] e Sistemas de Inferência Fuzzy (FIS) [103] [104][105][106][107] [108], vêm sendo aplicadas com sucesso na previsão de séries temporais. Observa-se também o crescente desenvolvimento de modelos híbridos, nos quais duas ou mais técnicas de inteligência computacional são combinadas.

3.3.1. Sistemas de Inferência Fuzzy aplicadas em Previsão

Em sistemas de inferência fuzzy aplicados em previsão de séries temporais, os dados de entrada são as observações passadas e o dado de saída é o valor previsto da série h passos à frente.

No entanto, gerar regras fuzzy para a previsão de séries temporais em função unicamente do conhecimento de especialistas pode se mostrar inviável. Assim, o método de extração de regras descrito no item 2.2.5 se torna a base de um modelo fuzzy de previsão[1].

Assim, o primeiro passo para a geração das regras do sistema de inferência fuzzy é a divisão do universo de discurso da variável em conjuntos fuzzy, conforme apresentado na Figura 15.




Figura 15 – Divisão do universo de discurso da série em conjuntos fuzzy

Adotando conjuntos fuzzy com funções de pertinência triangular, tem-se a formação da variável fuzzy representando $x(t)$, conforme Figura 16.




Figura 16 – Variável fuzzy composta por conjuntos triangulares representando o domínio da série temporal $x(t)$

No segundo passo, para a extração de regras, devem-se definir dois parâmetros: o tamanho da janela (n) e o horizonte da previsão (h). Como exemplo, considere uma janela de 3 períodos ($n = 3$) e um horizonte de um período ($h = 1$), ou seja, as três últimas observações são usadas para prever o valor um passo à frente. Definidos os parâmetros, a primeira regra é gerada calculando os graus de pertinência de cada elemento do primeiro par entrada/saída $\{x(1), x(2), x(3), x(4)\}$, onde $x(1)$, $x(2)$ e $x(3)$ são as entradas e $x(4)$ é a saída, conforme detalhado na Figura 17.




Figura 17 – Graus de pertinência dos elementos das janelas

Grau de pertinência de $x(1)$:

$$\mu_{S2}(x(1)) = 0,7$$

$$\mu_{S1}(x(1)) = 0,3$$

Grau de pertinência de $x(2)$:

$$\mu_{CE}(x(2)) = 0,4$$

$$\mu_{B1}(x(2)) = 0,6$$

Grau de pertinência de $x(3)$:

$$\mu_{B1}(x(3)) = 0,2$$

$$\mu_{B2}(x(3)) = 0,8$$

Grau de pertinência de $x(4)$:

$$\mu_{CE}(x(4)) = 0,1$$

$$\mu_{S1}(x(4)) = 0,9$$

Então, para cada valor, atribui-se o conjunto fuzzy que apresentou o maior grau de pertinência, definindo o antecedente e o conseqüente da primeira regra:

$$\text{Se } x(1) \text{ é } S2 \text{ E } x(2) \text{ é } B1 \text{ E } x(3) \text{ é } B2, \text{Então } x(4) \text{ é } S1$$

Repete-se o procedimento para todos os pares entrada/saída possíveis.

No terceiro passo, atribui-se um grau para cada uma das regras geradas, multiplicando-se o grau de pertinência de cada elemento da regra. O grau da regra 1 é:

$$D(\text{regra } 1) = 0,7 \cdot 0,6 \cdot 0,8 \cdot 0,9 = 0,3024$$

Em caso de regras conflitantes, elimina-se as de menor grau.

No quarto passo, cria-se a base de regras, consolidando as regras geradas pela análise dos dados numéricos com eventuais regras estabelecidas por especialistas. No caso de ausência de especialistas, a base de regras é composta somente pelas regras extraídas dos dados numéricos.

No quinto passo, define-se a estratégia de defuzzificação. Conforme proposto por MENDEL[1], o valor previsto em $t + h$ é calculado percorrendo todas as regras da base, calculando o grau de ativação de cada uma, em função da janela $\{x(t - n + 1), x(t - n + 2), \dots, x(t)\}$:

$$\mu_{O_i}^i = \mu_{I_1^i}(x(t - n + 1)) \cdot \mu_{I_2^i}(x(t - n + 2)) \cdot \dots \cdot \mu_{I_n^i}(x(t))$$

Onde O_i denota a região (conjunto fuzzy) do conseqüente da regra i , e I_j^i denota a região do antecedente j na regra i

Ao final, a saída fuzzy é transformada em saída crisp aplicando um método de defuzzificação, como o método do centróide sugerido por MENDEL [1]:

$$y = \frac{\sum_{i=1}^K \mu_{O_i}^i \cdot \bar{y}^i}{\sum_{i=1}^K \mu_{O_i}^i}$$

Onde \bar{y}^i denota o centro da região O_i e K é o número de regras fuzzy presente na base de regras.

Vale ressaltar que outros métodos de defuzzificação podem ser utilizados no procedimento de extração de regras, levando a diferentes equações para o cálculo das saídas fuzzy e crisp.

3.3.2. Sistemas de Inteligência Computacional Híbridos Aplicados à Previsão

Existem três formas básicas de construção de sistemas híbridos[22]:

- **Híbrido seqüencial:** um subsistema baseado na técnica A atua como entrada de outro subsistema baseado na técnica B . Essa é a forma mais fraca de hibridização, não sendo sempre considerado efetivamente como um sistema híbrido. Exemplo: um sistema pré-processador fuzzy acionando uma RNA.
- **Híbrido auxiliar:** um subsistema baseado na técnica A invoca um subsistema baseado na técnica B para executar uma tarefa. Essa forma apresenta maior grau de hibridização que a forma anterior. Exemplos: um FIS invoca um GA para otimização de seus parâmetros; uma RNA invoca um FIS para ajustar sua taxa de aprendizado.
- **Híbrido incorporado:** não há separação visível entre os dois subsistemas, sendo a forma de maior grau de hibridização. Exemplo: sistema neuro-fuzzy híbrido onde um sistema de inferência fuzzy é implementado segundo a estrutura de uma rede neural.

Os tipos mais comuns de sistemas híbridos aplicados à previsão de séries são:

- **Sistemas Neuro-Fuzzy**[27][28] [109][110][111]: Combinação de Redes Neurais Artificiais com Sistema de Inferência Fuzzy. O conceito principal consiste em implementar um FIS por meio da

arquitetura de uma RNA, com o objetivo de se utilizar os algoritmos de aprendizado para ajustar o FIS. Enquadra-se na hibridização do tipo incorporado. O ANFIS [112] é um dos sistemas Neuro-Fuzzy mais utilizados em previsão de séries temporais.

- **Sistemas Neuro-Genéticos** [29][30]: Combinação de Redes Neurais Artificiais com Algoritmos Genéticos. Nesta hibridização, a RNA invoca um GA para otimização dos parâmetros da rede (pesos), para definição da arquitetura da rede (número de camadas, quantidade de neurônios por camada) ou para ajuste dos parâmetros de aprendizagem (taxa de aprendizado, momentum). Enquadra-se na hibridização do tipo auxiliar.
- **Sistemas Fuzzy-Genéticos** [31][32][113][114]: Combinação de Sistemas de Inferência Fuzzy com Algoritmos Genéticos. Como dito anteriormente, a definição do número de conjuntos fuzzy que compõem as variáveis de entrada – e de saída –, assim como os seus formatos, tem impacto direto no desempenho do sistema de inferência fuzzy. Como alternativa mais eficiente a realizar ajustes manuais nas funções de pertinência até que se alcance um desempenho satisfatório, é comum empregarem-se métodos automáticos. A integração entre sistemas de inferência e algoritmos genéticos tem se mostrado adequada para definição de funções de pertinência e de outros parâmetros do modelo, como o próprio número de conjuntos fuzzy e o tamanho da janela e até da base de regras. Enquadra-se na hibridização do tipo auxiliar.
- **Sistemas Neuro-Fuzzy-Genéticos** [33][34][115][116]: Combinação das técnicas de RNA, GA e FIS. São sistemas neuro-fuzzy com otimização de parâmetros por GA.

O sistema de previsão desenvolvido nesta dissertação é um sistema híbrido auxiliar do tipo Fuzzy-Genético, no qual os parâmetros dos conjuntos fuzzy são ajustados automaticamente por um algoritmo genético, aumentando a exatidão das previsões geradas pelo modelo.

3.4. Avaliação do Desempenho de uma Previsão

Geralmente o desempenho de um modelo de previsão é definido a partir da comparação dos valores previstos com os valores reais, calculando-se o erro

da previsão. Para isso, recomenda-se dividir a série de dados disponíveis em três conjuntos: treino, validação e teste (Figura 18).

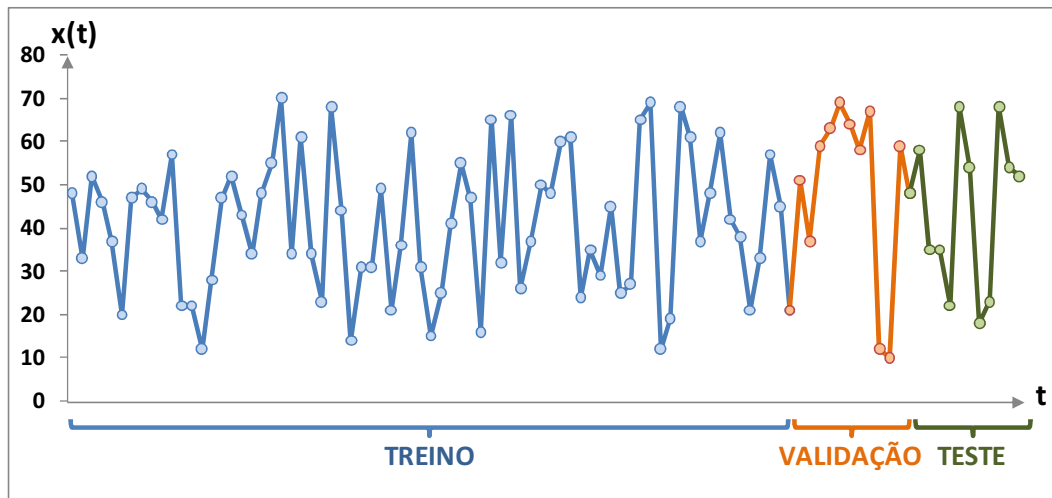


Figura 18 – Divisão da série de dados nos conjuntos de treino, validação e teste

O conjunto de treino tem como objetivo servir de base para o ajuste dos parâmetros de um modelo de previsão. Os parâmetros devem ser ajustados de forma a minimizar o erro da previsão.

Quando se busca um modelo eficiente como predictor para uma determinada série temporal, é comum avaliar diversos modelos, ou diversas configurações de um modelo. Por exemplo, pode-se avaliar o desempenho de diversas técnicas estatísticas, ou avaliar diversas arquiteturas de redes neurais, ou diversas configurações de sistemas de inferência fuzzy. Nesses casos, primeiramente deve-se ajustar os parâmetros de cada predictor conforme descrito no parágrafo anterior (utilizando o conjunto de treino) para, em seguida, calcular o erro de cada predictor no conjunto de validação.

Após a seleção do predictor através do melhor desempenho obtido no conjunto de validação, deve-se avaliar sua eficiência calculando-se o erro da previsão no conjunto de teste. Como esse conjunto de dados não foi utilizado para ajuste de parâmetros nem para seleção de predictors, constitui em uma base limpa (*out-of-sample*) para simular o desempenho do modelo em caso prático real, no qual nenhuma informação futura é conhecida para ser utilizada no desenvolvimento do modelo.

Existem diversas métricas de erro que podem ser utilizadas para calcular a exatidão de uma previsão. Todas descrevem de alguma forma a diferença entre os valores reais e os valores previstos. As métricas de erros mais utilizadas para

avaliar a exatidão de uma previsão são *Mean Percentual Error* (MPE), *Mean Absolute Percentual Error* (MAPE), *Rooted Mean Squared Error* (RMSE) e *Symmetric Mean Absolute Percentual Error* (SMAPE). Sejam R_t o valor real no período t , P_t o valor previsto no período t e n o número de períodos nos quais estão sendo comparados os valores reais e os valores previstos. As métricas citadas são definidas pelas seguintes equações:

$$MPE = \frac{1}{n} \cdot \sum_{t=1}^n \frac{R_t - P_t}{R_t} \times 100$$

$$MAPE = \frac{1}{n} \cdot \sum_{t=1}^n \frac{|R_t - P_t|}{R_t} \times 100$$

$$RMSE = \sqrt{\frac{1}{n} \cdot \sum_{t=1}^n (R_t - P_t)^2}$$

$$SMAPE = \frac{1}{n} \cdot \sum_{t=1}^n \frac{|R_t - P_t|}{(R_t + P_t)/2} \times 100$$

O capítulo seguinte apresenta detalhadamente a ferramenta computacional de previsão de séries desenvolvida nesta dissertação, baseada na teoria de Sistemas de Inferência Fuzzy, em conjunto com a otimização de parâmetros por Algoritmos Genéticos.