



Universidade Federal de Pernambuco
Centro de Informática
Graduação em Sistemas de Informação



Uma Abordagem Híbrida Para Predição de Séries Temporais

(Proposta De Trabalho De Graduação)

Aluno: Avyner Henrique Bezerra da Fonseca Lucena. (ahbfl@cin.ufpe.br)

Orientador: Paulo Salgado Gomes de Mattos Neto. (psgmn@cin.ufpe.br)

Recife, 14 de Setembro de 2016

Sumário

1. Contexto	2-3
2. Objetivo	3
3. Cronograma	4
4. Referências	4
5. Possíveis Avaliadores	4
6. Assinaturas	5

1. Contexto

A tarefa de análise e predição de séries temporais é um problema que abrange diversas áreas, como por exemplo: medicina, ciências sociais, negócios e economia. A importância deste tipo de análise e predição se dá na medida, em que estas servem como insumo para tomadas de decisão, como por exemplo o lançamento de um novo produto no mercado ou a escolha de um investimento.

Uma série temporal é basicamente uma sequência numérica de dados encontrada em uma ordem relacionada a observações em um determinado espaço de tempo, enquanto a sua predição é composta por seus prováveis valores futuros [1].

Para um melhor entendimento acerca deste trabalho se faz necessária a apresentação de alguns conceitos relacionados ao séries temporais [2], como por exemplo os de linearidade, estacionariedade e acerca dos modelos univariados e multivariados. E também sobre técnicas utilizadas para realizar suas predições, como o ARIMA e Redes Neurais Artificiais [2]. Tais conceitos serão demonstrados de maneira resumida nesta contextualização.

Sobre o conceito de linearidade, séries temporais lineares são geradas através da observação de processos lineares definidos por modelos matemáticos lineares. Se uma série temporal é linear então esta pode ser representada por uma função linear de seus valores presentes e seus valores passados. As séries não lineares seguem a mesma ideia mudando se o tipo de processo e incluindo assim a necessidade de uma modelagem não linear para as representar.

O conceito de estacionariedade, se refere a maneira como o comportamento desta série se modifica com o passar do tempo, onde uma série temporal é estacionária caso a média de seus valores e o sua função de auto-relação não se alterem com o decorrer do tempo, e são não estacionárias caso contrário. Segundo a literatura, a grande maioria das séries temporais possuem algum nível de não estacionariedade, o que torna necessária a aplicação de métodos que consigam tratar esta não estacionariedade de forma a melhorar a predição de valores.

Quanto a modelos de séries temporais, e se esta é multivariada ou univariada; a diferença se dá basicamente na quantidade de padrões observados, um exemplo seria a observação da temperatura emitida por um sensor hipotético em um determinado período de tempo, se tratando assim de uma série univariada e caso este mesmo sensor fornecesse alguma outra variável além da temperatura estaríamos lhe dando com uma série multivariada. Vale salientar que o tempo não é tratado explicitamente como uma variável nas séries univariadas, sendo assim algo implícito como por exemplo um índice.

ARIMA ou Autoregressive Integrated Moving Average, se trata de um modelo amplamente utilizado na predição de séries temporais, devido a suas propriedades estatísticas e seu bom nível de flexibilidade tendo como única limitação o fato de tratar basicamente de padrões com disposição linear. Este modelo é muito útil ao ser aplicado sobre séries que possuem um comportamento não estacionário porém que se tornam estacionárias após sua diferenciação, onde uma série temporal é construída ao receber sucessivas subtrações entre valores de uma série temporal não estacionária. EX: $X(t) - X(t-1)$.

Redes Neurais Artificiais, podem ser definidas de maneira simplificada, como sistemas de processamento distribuídos massivamente paralelos, construídas com o intuito de criar uma analogia a maneira que um ser humano processa informações. Desde a década de 60, vem sendo comprovada a capacidade de predição de redes neurais sobre séries temporais que é possível devido a sua flexibilidade em criar modelos não lineares, que são construídos dinamicamente à medida que novos padrões são apresentados a rede.

Abordagens híbridas [3], desde que pesquisas indicaram que a utilização de mais de um tipo de modelo tende a melhorar a acurácia das previsões sobre séries temporais, começaram a ganhar espaço, vindo então a ser amplamente utilizadas na área. Boa parte da motivação relativa à utilização de uma modelagem híbrida no corrente trabalho onde as previsões das partes lineares e não lineares do problema serão tratados separadamente por técnicas diferentes, se dá devido ao fato de ser impraticável a coleta de informações relativas ao processo de geração de uma série temporal. Onde dificilmente ocorre uma exclusividade quanto a utilização de processos lineares ou não. Formando assim, séries que variam entre padrões com disposição linear e não linear.

2. Objetivo

Este trabalho terá como objetivo, o desenvolvimento e avaliação de um modelo híbrido composto por um método estatístico (ARIMA) e duas redes neurais. Esta modelagem será aplicada sobre séries temporais univariadas distintas, frequentemente utilizadas como benchmark na área.

Tal trabalho faz parte de um projeto maior, coordenado pelo professor Paulo Salgado, onde serão desenvolvidos e avaliados modelos híbridos a partir da combinação do modelo ARIMA com diferentes Redes Neurais Artificiais; Possibilitando assim a aplicação futura e continuidade deste trabalho de graduação.

3. Cronograma

Atividades	Setembro				Outubro				Novembro				Dezembro			
Preparação da Proposta	■	■														
Estudo e Levantamento de Material	■	■	■													
Implementação do Modelo				■	■	■	■									
Testes e Análises de Resultados						■	■	■	■							
Preparação do Relatório e Apresentação										■	■	■	■			

4. Referências

[1] Montgomery, Douglas; Jennings, Cheryl; Kulahci, Murat. Introduction To Time Series Analysis And Forecasting, Second Edition. (2 - 6)

[2] Ajoy K. Palit; Dobrivoje Popovic. Computational Intelligence in Time Series Forecasting, Theory and Engineering Applications. (17-74)

[3] G. Peter Zhang, Time series forecasting using a hybrid ARIMA and neural network model, Neurocomputing, vol. 50, pp. 159 - 175, 2003.

5. Possíveis Avaliadores

Adriano Lorena Inácio de Oliveira
George Darmiton da Cunha Cavalcanti

6. Assinaturas

Avyner Henrique Bezerra da Fonseca Lucena
(Orientando)

Paulo Salgado Gomes de Mattos Neto
(Orientador)