

Gerência Pró-Ativa de Redes Usando Método de Previsão Baseado em Séries Temporais (Modelo de Box & Jenkins)

Afrânio César da Costa Luz, José Neuman de Souza, Mateus Mosca Viana e J. Riverson Rios

Resumo—Este artigo mostra um método de previsão aplicado a gerência pró-ativa de redes de computadores através de um estudo de caso baseado no protocolo CSMA/CD (Carrier Sense Multiple Access with Collision Detection). O método de Box & Jenkins apresenta bons resultados sobre uma heterogeneidade de séries temporais, podendo ser utilizado para prever valores dos objetos da MIB de um agente SNMP.

Palavras-Chave—Gerência de Redes, Séries Temporais, Previsão, Modelo de Box & Jenkins.

Abstract—This paper presents a time series approach to the forecast method applied to the proactive management of computer networks by means of a case study based on the CSMA/CD protocol (Carrier Sense Multiple Access with Collision Detection). An experiment shows that Box & Jenkins Method yields good results on heterogeneous time series, which enables it to be used to estimate the values of MIB objects of an SNMP agent.

Keywords—Network Management, Time Series, Forecast, Box & Jenkins Model.

I. INTRODUÇÃO

O objetivo deste trabalho é analisar o método de Box & Jenkins sobre os objetos da MIB (Management Information Base) de um agente SNMP (Simple Network Management Protocol), principalmente os objetos da MIB EtherLike, com a finalidade de antecipar possíveis problemas num ambiente de gerência de redes. Isso permite ao gerente de redes fazer modificações no ambiente gerenciado evitando que estes problemas venham realmente ocorrer.

Este trabalho está organizado da seguinte forma: a seção II aborda o método de Box & Jenkins; a seção III enfoca um estudo de caso utilizando o método proposto neste trabalho e para finalizar, a seção IV faz algumas considerações finais sobre este trabalho.

II. MODELOS DE BOX & JENKINS

O método proposto por Box & Jenkins [2] tem recebido muita atenção nos últimos anos. É um método que requer a participação de um especialista neste modelo e na metodologia de séries temporais. Alguns autores recentemente desenvolveram propostas para a automatização do modelo de Box &

Afrânio César da Costa Luz, Divisão de Comunicação de Dados, Fundação Cearense de Meteorologia e Recursos Hídricos (FUNCEME); José Neuman de Souza, Departamento de Computação, Universidade Federal do Ceará (UFC); Mateus Mosca Viana, Departamento de Engenharia de Teleinformática, Universidade Federal do Ceará (UFC); J. Riverson Rios, Departamento de Computação, Universidade Federal do Ceará (UFC). E-mails: afranio@funceme.br, neuman@ufc.br, mosca@ufc.br e riverson@lia.ufc.br.

Jenkins, tornando-o aplicável em várias áreas [7], [14], [12]. O método ajusta modelos auto-regressivos - integrados - média móveis, $ARIMA(p, d, q)$ a uma série temporal.

A abordagem clássica para a construção e ajuste de um modelo ARIMA para uma série temporal segue um ciclo iterativo formado por três fases: identificação do modelo, estimativa dos parâmetros e verificação do modelo ajustado. Este ciclo é repetido até que se encontre um modelo adequado. Um procedimento bastante utilizado é escolher vários modelos para serem estimados e verificados. Quando o objetivo da análise é fazer previsão da série temporal, o modelo que apresentar o menor erro quadrático médio de previsão é o escolhido [9]. A fase de identificação é uma das mais críticas. Há a possibilidade de vários pesquisadores identificarem modelos diferentes para a mesma série temporal.

A. Modelo de Filtro Linear

Os modelos estudados são espécies do gênero modelo de filtro linear, ou seja, casos particulares desse modelo, que consideram a série temporal gerada através de um sistema linear (ou filtro linear) [9].

A Figura 1 representa um filtro linear, com entrada a_t (ruído branco), saída Z_t (série temporal ou observada no instante "t") e função de transferência $\psi(B)$.




Fig. 1. Filtro Linear.

O modelo é representado formalmente por

$$Z_t = \mu + a_t + \psi_1 a_{t-1} + \psi_2 a_{t-2} + \dots \quad (1)$$

$$= \mu + \psi(B)a_t$$

e

$$\psi(B) = 1 + \psi_1 B + \psi_2 B^2 + \dots \quad (2)$$

A expressão $\psi(B)$ - chamada de *função de transferência*, $\{\psi_j, j \geq 1\}$ - é uma seqüência de pesos e o parâmetro μ é denominado nível da série e caso esta seja finita, ou infinita e convergente, μ é a média do processo. Desta forma, tem-se um filtro estável (somável) e Z_t é estacionária.

Chamando $\tilde{Z}_t = Z_t - \mu$, e substituindo na Equação (1) obtem-se

$$\tilde{Z}_t = \psi(B)a_t. \quad (3)$$

Escrevendo \tilde{Z}_t como uma soma ponderada de valores passados (Z_{t-1}, Z_{t-2}, \dots) mais um ruído branco resulta

$$\begin{aligned} \tilde{Z}_t &= \phi_1 \tilde{Z}_{t-1} + \phi_2 \tilde{Z}_{t-2} + \dots + a_t \quad (4) \\ \tilde{Z}_t &= \sum_{j=1}^{\infty} \phi_j \tilde{Z}_{t-j} + a_t \end{aligned}$$

$$\begin{aligned} \left(1 - \sum_{j=1}^{\infty} \phi_j B^j\right) \tilde{Z}_t &= a_t \\ \phi(B) \tilde{Z}_t &= a_t \end{aligned} \quad (5)$$

em que $\phi(B)$ é o operador

$$\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots \quad (6)$$

A partir das equações (5) e (3) tem-se:

$$\begin{aligned} \phi(B)\psi(B)a_t &= at \\ \phi(B) &= \psi^{-1}(B). \end{aligned} \quad (7)$$

Esta relação é bastante utilizada para obter os pesos ϕ em função dos pesos ψ ou vice-versa.

B. Modelo Auto-Regressivo

Se na equação (4) ocorrer que os $\phi_j = 0$, para $j > p$, então tem-se um *modelo auto-regressivo de ordem p*, denominado $AR(p)$ e representado na forma

$$\begin{aligned} \tilde{Z}_t &= \phi_1 \tilde{Z}_{t-1} + \phi_2 \tilde{Z}_{t-2} + \dots + \phi_p \tilde{Z}_{t-p} + a_t \quad (8) \\ \phi(B) \tilde{Z}_t &= a_t, \end{aligned} \quad (9)$$

em que $\phi(B)$ é o operador auto-regressivo estacionário de ordem p

$$\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p. \quad (10)$$

C. Modelo de Médias Móveis

Este modelo é obtido da equação (1) quando $\psi_j = 0$, para $j > q$. O processo linear resultante é chamado de *médias móveis de ordem q*, ou seja $MA(q)$, de *moving average*. Substituindo ϕ por θ tem-se a seguinte notação para este modelo

$$Z_t = \mu + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q}, \quad (11)$$

como $\tilde{Z}_t = Z_t - \mu$, produz

$$\begin{aligned} \tilde{Z}_t &= (1 - \theta_1 B - \dots - \theta_q B^q) a_t \quad (12) \\ &= \theta(B) a_t, \end{aligned}$$

sendo

$$\theta(B) = 1 - \theta_1 B - \dots - \theta_q B^q, \quad (13)$$

em que $\theta(B)$ é o operador de médias móveis de ordem q .

D. Modelo Misto Auto-Regressivo - Médias Móveis

O modelo misto auto-regressivo - média móvel (ARMA) é formado por uma combinação dos modelos AR e MA, sendo uma boa solução para representar séries temporais, sem utilizar um número grande de parâmetros. Este modelo é denominado de $ARMA(p, q)$ de ordem (p, q) . Formalmente tem-se

$$\begin{aligned} \tilde{Z}_t &= \phi_1 \tilde{Z}_{t-1} + \dots + \phi_p \tilde{Z}_{t-p} + a_t - \theta_1 a_{t-1} \\ &\quad - \dots - \theta_q a_{t-q} \end{aligned} \quad (14)$$

$$\phi(B) \tilde{Z}_t = \theta(B) a_t, \quad (15)$$

em que $\phi(B)$ e $\theta(B)$ são os operadores auto-regressivos e de média móveis, respectivamente.

E. Modelos ARIMA

Os modelos $AR(p)$, $MA(q)$ e $ARMA(p, q)$ são utilizados para séries temporais estacionárias, ou sejam, que variam no tempo em torno de uma média constante. A maioria das séries temporais não apresenta esse comportamento.

As séries temporais que não possuem um comportamento explosivo e apresentam alguma homogeneidade em seu comportamento não estacionário, podem ser transformadas em séries com comportamento estacionário. Geralmente, esta transformação consiste em tomar um número finito de diferenças d . As séries que tornam-se estacionárias através deste procedimento são chamadas de não estacionárias homogêneas.

Considere

$$W_t = \Delta^d Z_t$$

então, se W_t for estacionária, é possível representá-la através de um modelo $ARMA(p, q)$, que denomina de modelo $ARIMA(p, d, q)$ de ordem (p, d, q) . Neste caso, tem-se,

$$\phi(B) W_t = \theta(B) a_t. \quad (16)$$

Desde que W_t é uma diferença de Z_t , então Z_t é uma integral de W_t [9]. Portanto, Z_t segue um *modelo auto-regressivo-integrado-médias móveis de ordem (p, d, q)* , denominado de $ARIMA(p, d, q)$, expresso por

$$\phi(B) \Delta^d Z_t = \theta(B) a_t. \quad (17)$$

F. Modelos Sazonais

Altas correlações em múltiplos do período s podem indicar uma sazonalidade estocástica. As séries temporais que apresentam esse comportamento podem ser representadas pelo modelo ARIMA sazonal da seguinte forma

$$\Phi(B^s) \Delta_s^d Z_t = \Theta(B^s) \alpha_t, \quad (18)$$

em que:

- $\Phi(B^s) = 1 - \Phi_1 B^s - \Phi_2 B^{2s} - \dots - \Phi_P B^{Ps}$ é o operador auto-regressivo sazonal de ordem P , estacionário;

- $\Theta(B^s) = 1 - \Theta_1 B^s - \Theta_2 B^{2s} - \dots - \Theta_Q B^{Qs}$ é o operador de médias móveis sazonal de ordem Q , invertível;

- $\Delta_s = 1 - B^s$ é o operador diferença sazonal, tal que

$$\Delta_s Z_t = Z_t - Z_{t-s} \quad (19)$$

e $\Delta_s^D Z_t = (1 - B^s)^D$, em que D é o número de diferenças sazonais.

Uma diferença para o modelo ARIMA usual é que os parâmetros $\alpha_t, \alpha_{t+1}, \dots$ não são ruídos brancos. Relacionando-os com o ruído branco tem-se

$$\phi(B)\Delta^d \alpha_t = \theta(B)a_t, \quad (20)$$

substituindo a equação (20) na equação (18) resulta

$$\phi(B)\Phi(B^s)\Delta^d \Delta_s^D Z_t = \theta(B)\Theta(B^s)a_t, \quad (21)$$

chamado de modelo sazonal multiplicativo de ordem $(p, d, q) \times (P, D, Q)_s$, ou de $SARIMA(p, d, q) \times (P, D, Q)_s$. Significa que se deve tomar d diferenças simples e D diferenças sazonais da série Z_t , para se obter o processo estacionário

$$W_t = \Delta^d \Delta_s^D Z_t. \quad (22)$$

G. Construção e Ajuste do Modelo

A construção do modelo, segundo a abordagem clássica, segue um ciclo interativo formado pelas fases de identificação, estimativa e verificação. O processo interativo da construção do modelo é representado na Figura 2. A fase de previsão é considerada um passo adicional, quando o modelo já se encontra ajustado [14].

Na fase de *identificação* do modelo se determina a estrutura do modelo, o número de observações passadas e ruídos brancos passados que apresentam uma correlação significativa com a observação atual. Esta fase se baseia na análise de auto-correlações e auto-correlações parciais.

A fase de *estimativa* ajusta o modelo aos dados que estão sendo analisados, através da estimativa da importância da correlação encontrada nos dados, representada pelos parâmetros do modelo, ou seja, os parâmetros do modelo identificado são estimados.

Na fase de *verificação* são feitos testes estatísticos com o objetivo de verificar se a estrutura do modelo é adequada. Isso é feito através de uma análise de resíduos com objetivo de determinar se o modelo é adequado para fazer previsão.

H. Previsão com o Modelo Ajustado

Nesta fase, utiliza-se o modelo ajustado nas fases anteriores para fazer previsões. O objetivo é prever um valor Z_{t+h} , $h \geq 1$, considerando a existência de observações $(\dots, Z_{t-2}, Z_{t-1}, Z_t)$ até o instante t , chamado de origem das previsões. Tem-se que $\hat{Z}_t(h)$ é a previsão de origem t e horizonte h [9].




Fig. 2. Processo interativo do método de Box & Jenkins.

O horizonte de previsão pode ser classificado em três grupos: curto, médio e longo. O horizonte de previsão é considerado curto quando tiver de 1 a 3 passos a frente, médio quando tiver de 4 a 12 passos a frente e longo quando tiver de 13 a 18 passos a frente [6].

III. ESTUDO DE CASO

Um dos objetivos deste trabalho é verificar como o método de Box & Jenkins se comporta sobre os objetos de uma MIB e como estas informações poderão ser utilizadas pela gerência pró-ativa de redes. Para isso, implementou-se *scripts* com a função de coletar informações sobre os objetos de estudo e um aplicativo baseado neste método, automatizando todas as suas fases. Outros modelos foram utilizados em simulação para servir de comparativo. Com isso, gerou-se informações que permite fazer uma análise crítica deste método no que refere aos objetos analisados.

A quantidade de MIBs e de objetos disponíveis é muito grande, onde cada MIB agrupa determinados tipos de informações, conforme o que se pretende monitorar. A escolha dos objetos que são analisados depende do interesse do pesquisador. Escolheu-se os objetos da *EtherLike MIB* (RFC 1643), que armazenam informações relacionadas com o protocolo de acesso ao meio conhecido como *Carrier Sense Multiple Access with Collision Detection* (CSMA/CD). O motivo da escolha desses objetos é que pretendíamos analisar o número de colisões numa rede local, tornando o estudo mais específico. Entretanto, o conhecimento aplicado neste trabalho pode ser expandido para outros objetos, pois o método utilizado se adapta aos dados que estão sendo analisados.

A. Ambiente do Experimento

O ambiente do experimento descreve as plataformas de *hardware* e *software* utilizadas para demonstrar o funcionamento da proposta deste trabalho.

1) *Plataforma de Hardware*: No momento de definir a plataforma de *hardware* utilizada neste experimento, procurou montar uma estrutura que representasse um ambiente de rede local com um tráfego elevado. Optou-se por utilizar uma rede em operação e trabalhar com dados reais. Logo, a plataforma de *hardware* era a que se tinha disponível. Este ambiente se encontra em operação em uma determinada empresa denominada de Empresa X.

Escolheu-se o agente SNMP do 8271 *EtherStreamer Switch Model 108* da IBM com 8 portas *Ethernet*. Cada uma das portas de 1 a 5 estão ligadas a uma pilha de dois *Ethernet Stackable Hub* modelo 8224 da IBM com 16 portas em cada *hub*. A porta 6 está conectada a um servidor de arquivo, a porta 7 a um servidor Web e a porta 8 a um roteador. Cada pilha de *hubs* representa um departamento da Empresa X. Tem-se conectado neste ambiente aproximadamente 160 estações, todas com acesso a Internet. A Figura 3 representa a estrutura da rede local utilizada neste trabalho.

A rede da Empresa X tem outros servidores como servidor de *e-mail* e *web-mail*; servidores departamentais, servidor de banco de dados; servidor de FTP público; estações de recepção e tratamento de imagens de satélites; etc. Todos esses servidores funcionam 24 horas por dia, sete dias na semana.




Fig. 3. Ambiente do Experimento.

Utilizou-se como estação de gerência um computador Pentium III de 1GHz, 256MB de RAM e disco de 40GB. Os programas utilizados neste experimento não necessitam de elevada capacidade de processamento para executarem com desempenho razoável. O espaço livre requerido em disco depende das informações que são coletadas, do número de agentes e do período de coleta.

2) *Plataforma de Software*: Antes definir qual utilitário permitiria recuperar as informações do agente SNMP, analisou-se alguns como: Net-SNMP [11] e o AdventNet SNMP API [1]. Também foi testado um *framework* que automatiza todo o processo de coleta denominado de Sistema Genérico de Monitoração de Redes de Computadores Dirigido a Eventos (SGME) [3].

O Net-SNMP apresentou resultados adequados aos

propósitos deste trabalho que era apenas de montar uma base de dados, que em seguida seria utilizada pelos modelos.

O AdventNet SNMP API necessita do ambiente JAVA para executar. Os resultados obtidos foram satisfatórios, entretanto o tempo de execução foi superior ao Net-SNMP. Além do mais, necessita de um cuidado maior com a configuração para o ambiente JAVA, principalmente porque os processos de coleta são executados em *background*.

O SGME é um aplicativo muito promissor, pois ele implementa muitos recursos de coleta e de relatórios, agrupando-os em domínio. O preço disso tudo é a necessidade de um ambiente que requer a instalação e configuração de outros *softwares*, como o ambiente JAVA e um servidor Web com suporte a *servlet*. Uma outra desvantagem desse *framework* foi a sua instabilidade e problemas apresentados nos testes realizados.

O Net-SNMP foi o utilitário selecionado devido a sua flexibilidade e rapidez. Dentre os utilitários analisados é o que o requer menos de *hardware* e *software* para sua execução.

B. Fases do Experimento

O experimento é dividido nas seguintes fases: coleta de dados, consolidação dos dados, e construção e ajuste do modelo.

1) *Coleta de Dados*: Estando com quase tudo definido, ou seja, as plataformas de *hardware* e *software* já identificadas e os objetos de estudo devidamente catalogados, o próximo passo é a coleta de dados.

Esta fase é opcional quando já existe uma base de dados com informações suficientes para a aplicação do modelo. Os dados devem representar o comportamento do evento analisado. A quantidade de dados necessária depende de como eles serão consolidados. A amostra deste experimento se refere ao período de coleta que vai das zero hora do dia 10/04/2003 às vinte e três horas do dia 20/05/2003.

Desenvolveu-se um *script* em *C Shell* para consultar o agente SNMP e armazenar essas informações em arquivos textos, um para cada porta do switch. As informações mais recentes eram gravadas no final do arquivo. O processo de consulta utiliza os comandos básicos do Net-SNMP, intervalo de consulta de trinta minutos, e agendamento através do *cron*.

2) *Consolidação dos Dados*: Após o período de coleta, os dados brutos passaram por um processo de consolidação através de um aplicativo desenvolvido em C++. A função desse aplicativo é ler o arquivo bruto, para cada porta, separar as informações de cada objeto, agrupá-las por hora, calcular o valor do contador do objeto para o valor correspondente da hora. Após o processamento, é gerado um diretório para cada porta do agente e nele criado um arquivo para cada objeto, com o valor e o período (data e hora) correspondente.

A forma de consolidação dos dados determina o passo utilizado na fase de previsão. Se a consolidação é por hora, os passos da previsão serão por hora, o mesmo ocorre, de forma análoga, para semana, quinzena, mês, semestre, etc. O experimento utiliza uma consolidação por hora devido ao pouco tempo que se tinha para fazer a coleta de dados. Entretanto, o modelo pode perfeitamente ser utilizado para

outros tipos de consolidação, pois ele é identificado conforme os dados da amostra. Suponha que se deseje utilizar o passo por mês, então teríamos de fazer ou ter dados de um período maior que dois anos.

A porta do *switch* que teve a maior média de acesso é a selecionada para o estudo apresentado neste trabalho.

3) *Construção e Ajuste do Modelo*: Um dos principais objetivos na análise de séries temporais é o uso de previsão para auxiliar a política de decisão, permitindo que se ampliem os requisitos num período de tempo maior que o disponível. O modelo ARIMA fornece previsões de curto e longo prazo, variando o horizonte de previsão de um passo a um número arbitrário de passos à frente.

A abordagem clássica, vista na seção anterior, para os modelos de Box & Jenkins requer a intervenção do analista para examinar cuidadosamente as auto-correlações e auto-correlações parciais dos dados da série temporal, para decidir se a série é estacionária e para identificar o modelo representativo dos dados. Logo, a abordagem clássica requer que o usuário tenha experiência e domínio desses modelos.

O público alvo deste trabalho são gerentes de redes que, geralmente, não possuem conhecimento dos modelos apresentados. Por isso, procurou-se automatizar o processo de previsão de séries temporais. A idéia de automatizar modelos ARIMA não é original, mas bastante recente. Em [12], [14] são mostradas algumas propostas dessa automatização.

A fase mais delicada do processo de automatização é a de identificação do modelo, as demais não apresentam maiores dificuldades de implementação. Na abordagem clássica, previsões com os modelos ARIMA mais comuns são geradas e o modelo com o menor erro de previsão é selecionado.

Alguns pacotes computacionais específicos para previsão estão disponíveis no mercado, como: STATGRAPHICS; AUTOTOBOX; FORECASTPRO; SMARTFCS; PP-AUTOCAS; etc. Porém, optou-se por desenvolver um aplicativo em C++ para fazer as previsões das séries temporais analisadas, utilizando a abordagem sugerida por [14].

C. *Previsão com o Modelo*

A finalidade da previsão é fornecer meios para a tomada de decisões com o intuito de alcançar determinado objetivo. A palavra previsão significa o desejo de ver um fenômeno antes que ele ocorra ou que ele exista; de ter conhecimento de um processo que somente existirá no futuro.

As séries temporais analisadas são divididas em duas partes, ou seja,

$$\underbrace{Z_1, \dots, Z_m}_{1^a \text{ parte}}, \quad \underbrace{Z_{m+1}, \dots, Z_N}_{2^a \text{ parte}}$$

Os m elementos da primeira parte são utilizados nas fases de identificação, estimativa dos parâmetros do modelo ajustado aos dados da série e previsão. A segunda parte é utilizada na fase de previsão para o cálculo do erro de previsão, que é feito comparando o valor observado com o valor previsto.

A primeira parte é formada pelas primeiras 979 observações ($m = 979$) e a segunda parte é composta pelas 5 últimas

TABELA I
PREVISÃO PARA A SÉRIE DO OBJETO
DOT3STATSMULTIPLECOLLISIONFRAMES (H = 5).

t	Valor Real	Valor Previsto
980	1.141	1.244
981	151	739
982	110	898
983	95	90
984	74	133
REQM		443

observações ($N - m = 5$). O número total de observações utilizadas (N) é de 984 observações. A origem das previsões (t) é a observação 979 e gerou previsões para os seguintes passos a frente: 1, 2, 3, 4 e 5.

O critério utilizado para a escolha do valor de m e para a quantidade de passos para as previsões levou em consideração o horizonte de previsão, abrangendo previsões de curto e médio prazo.

A literatura sugere vários critérios de precisão das previsões [10]. Este trabalho utiliza a raiz quadrada do erro quadrático médio (REQM) como critério de precisão, sendo representada por

$$REQM(h) = \sqrt{\frac{\sum_{t=m+1}^N [Z_t - \hat{Z}_{t-h}(h)]^2}{N - m}} \quad (23)$$

A ocorrência de erros numa previsão é esperado e um dos objetivos dos métodos de previsão é minimizar a ocorrência desses erros, que podem acontecer devido aos seguintes fatores: uso de dados sazonais com métodos não sazonais; tamanho da série; variabilidade da componente aleatória da série; presença de picos acentuados e horizonte de previsão [13], [10].

D. *Resultados*

Os resultados obtidos para os objetos `dot3StatsMultipleCollisionFrames` e `dot3StatsExcessiveCollisions` para previsão a 5 (cinco) passos à frente são apresentados em seguida. O primeiro objeto fornece a quantidade de pacotes que são transmitidos com sucesso e que experimentaram mais de uma colisão. O segundo objeto indica o número de pacotes descartados devido ao número excessivo de colisões. A análise dos demais objetos estudados é feita por [5].

Os resultados, para cada objeto analisado, são formados por um gráfico de linha da série original e uma tabela comparando o valor observado com o valor previsto pelo modelo identificado, mostrando no final o erro das previsões.

A Figura 4 retrata o gráfico da série do objeto `dot3StatsMultipleCollisionFrames`, representada pelo modelo ARIMA(2,0,0), em que sua equação é $Z_t = 0,67Z_{t-1} - 0,09Z_{t-2} + a_t$. A Tabela I mostra os resultados obtidos para o horizonte de previsão 5 (cinco), ou seja, para cinco passos à frente.

Na Figura 5, tem-se a série do objetos `dot3StatsExcessiveCollisions`, em que foi identificado




Fig. 4. Gráfico da série do objeto dot3StatsMultipleCollisionFrames.




Fig. 5. Gráfico da série do objeto dot3StatsExcessiveCollisions.

o modelo ARIMA(2,0,0), representado pela equação $Z_t = 0,39Z_{t-1} - 0,01Z_{t-2} + a_t$. A Tabela II mostra os resultados obtidos para o horizonte de previsão 5 (cinco).

TABELA II

PREVISÃO PARA A SÉRIE DO OBJETO DOT3STATSEXCESSIVECOLLISIONS

(H = 5).

t	Valor Real	Valor Previsto
980	0	0
981	0	0
982	0	0
983	0	0
984	0	0
REQM		0

IV. CONCLUSÃO

Os resultados do experimento não indicam queda de desempenho devido ao número de colisões geradas pelo protocolo de acesso ao meio (CSMA/CD). Os valores obtidos não caracterizam um número excessivo de colisões que venham prejudicar de forma significativa o tempo de resposta. Portanto, estes resultados se encontram dentro de uma faixa considerada estável.

De acordo com os resultados obtidos pelo experimento, o método de Box & Jenkins pode perfeitamente ser utilizado para prever valores dos objetos da MIB de um agente SNMP. No estudo de caso, devido a limitação de tempo para conclusão do experimento, utilizou-se uma consolidação por hora, fornecendo previsões com passos em horas. Em geral, esta forma pode não fornecer resultados úteis para a atividade de gerência de redes, sendo em alguns casos mais adequado uma consolidação por mês. Essa limitação não inviabiliza o método utilizado, já que os modelos são identificados de acordo com a série temporal analisada. Portanto, o gerente de redes que tenha informações de dois ou mais anos, pode consolidar essas informações por mês e fazer previsões com passos em horas utilizando o método de Box & Jenkins.

REFERÊNCIAS

- [1] ADVENTNET. *AdventNet Inc - Network Management, Systems Management and Applications*. Disponível em: <http://www.adventnet.com>. 2004
- [2] BOX, G. E. P.; JENKINS, G. M. *Time series analysis, forecasting and control*. San Francisco: Holden-Day, 1976.
- [3] BRAGA, A. P.; SOUZA, J. N. *Sistema Genérico de Monitoração de Redes de Computadores Dirigido a Eventos*. Universidade Federal do Ceará, Fortaleza, 2002.
- [4] CORTEZ, P. A. *Modelos inspirados na natureza para a previsão de séries temporais*. Tese (Doutorado) - Universidade do Minho, Guimarães - Portugal, 2002.
- [5] LUZ, A. C. C.; SOUZA, J. N.; VIANA, M. M. *Modelo de previsão aplicado a gerência de redes de computadores*. Universidade Federal do Ceará, Fortaleza, 2003.
- [6] MAKRIDAKIS, S.; HIBON, M. The m3-Competition: results, conclusions and implications. *International journal of forecasting*, v. 12, p. 451 - 476, 2000.
- [7] MÉLARD, G.; PASTEELS, J. M. Automatic ARIMA modeling including interventions, using time series expert software. *International Journal of Forecasting*, v. 16, p. 497 - 508, 2000.
- [8] MILONE, G.; ANGELINI, F. *Estatística aplicada*. São Paulo: Atlas, 1995.
- [9] MORETTIN, P. A.; TOLOI, C. M. C. *Modelos para previsão de séries temporais*, v. 1. Rio de Janeiro: IMPA, 1981.
- [10] MORETTIN, P. A.; TOLOI, C. M. C. *Modelos para previsão de séries temporais*, v. 2. Rio de Janeiro: IMPA, 1981.
- [11] NET SNMP. *NET SNMP Project*. Disponível em: <http://net-snmp.sourceforge.net>. 2004.
- [12] OLIVEIRA, G. A. *Sistema de controle de estoques utilizando a metodologia de Box & Jenkins de séries temporais*. Universidade Federal do Paraná, Curitiba, 2002.
- [13] REID, D. J. Discussion of the paper by Makridakis and Hibon. *The Journal of Real Statistical Society*, v. 142, 133. 1979
- [14] TRAN, N. N. *Automatic arima time series modeling and forecasting for adaptive input/output prefetching*. University of Illinois, 2002.