

DISSERTAÇÃO DE MESTRADO Nº 1049

**FUZZY TIME SERIES APLICADA NA PREDIÇÃO DE QOS EM REDES DE
COMPUTADORES**

FRANCIRLEY RESENDES BORGES COSTA

DATA DA DEFESA: 20/03/2018

Universidade Federal de Minas Gerais

Escola de Engenharia

Programa de Pós-Graduação em Engenharia Elétrica

**FUZZY TIME SERIES APLICADA NA PREDIÇÃO DE QOS EM
REDES DE COMPUTADORES**

FRANCIRLEY RESENDES BORGES COSTA

Dissertação de Mestrado submetida à Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em Engenharia Elétrica da Escola de Engenharia da Universidade Federal de Minas Gerais, como requisito para obtenção do Título de Mestre em Engenharia Elétrica.

Orientador: Prof. Lucas de Souza Batista

Belo Horizonte - MG

Março de 2018

C837f

Costa, Francirley Resendes Borges.

Fuzzy time series aplicada na predição de QoS em redes de computadores [manuscrito] / Francirley Resendes Borges Costa. – 2018. xvii, 89 f., enc.: il.

Orientador: Lucas de Souza Batista.

Coorientador: Cláudio de Castro Monteiro.

Dissertação (mestrado) Universidade Federal de Minas Gerais, Escola de Engenharia.

Apêndices: f. 63-80.

Bibliografia: f. 81-89.

1. Engenharia elétrica - Teses. 2. Predição (Lógica) - Teses. 3. Redes de computadores - Teses. I. Batista, Lucas de Souza. II. Monteiro, Cláudio de Castro. III. Universidade Federal de Minas Gerais. Escola de Engenharia. IV. Título.

CDU: 621.3(043)

“Ninguém pode ser inteiramente aberto a novas ideias ou completamente cético. Todos temos que traçar o limite em algum lugar.”

— Carl Sagan, 1934–1996 (cientista, astrônomo, astrofísico, cosmólogo e escritor)

Resumo

Cada vez mais é comum a necessidade de ferramentas de avaliação e previsão de qualidade em diversas áreas de conhecimento. Em redes de computadores não é diferente, principalmente devido ao grande aumento no consumo de serviços via internet. Nesse contexto este trabalho apresenta uma abordagem para previsão de qualidade de serviço em redes de computadores usando *Fuzzy Time Series*. Para isso um novo método é proposto inspirado nos métodos pioneiros em *Fuzzy Time Series*. As características de redes são estudadas e mecanismos, como regressão linear, são aplicados em conjunto com as técnicas dos métodos da literatura, na tentativa de melhorar a acurácia da abordagem. Testes estatísticos foram realizados, usando dados coletados em ambientes reais, visando validar a proposta. Os resultados são animadores, principalmente se considerarmos a taxa de acerto de mudança de tendência do método proposto, que alcançou cerca de 87,16%, indicando assim que é possível uma abordagem para previsão de qualidade de serviço em redes de computadores juntamente com *fuzzy time series*.

Abstract

Increasingly, there is a need for quality assessment tools in a number of areas. Just as in computer networks, mainly due to the large increase in consumption of services over the internet. In this context, this work presents an approach with Fuzzy Time Series to predict quality of service. For this purpose a new method is proposed inspired by the pioneering methods of Fuzzy Time Series. The characteristics of computer networks are studied and mechanisms, such as linear regression, are applied to the techniques of the literature methods in an attempt to improve the accuracy of the approach. Statistical tests were designed, based on data collected in real environments, in order to validate the proposal. The results are encouraging, especially considering the trend change rate of the proposed method, which reached 87.16%, thus indicating that it is possible to use an approach of a quality of service forecast in computer networks together with fuzzy time series.

Agradecimentos

Agradeço imensamente e primeiramente à Deus, pelo ar que respiro e pela oportunidade de viver e aprender nesse mundo com saúde e paz.

Aos meus pais, Francisco e Maria por serem minha referência de amor e caráter, além do apoio incondicional em todos os momentos da minha vida.

Aos meus queridos irmãos e sobrinhos, Franciane, Franklin, Matheus, Gabriel e Ana Júlia, por serem a válvula de escape nos momentos de dificuldade e angústia.

Ao meu orientado Prof. Lucas Batista, pela paciência e principalmente pela ajuda e orientações que foram sempre enriquecedoras durante todo o mestrado.

Ao meu co-orientador Prof. Claudio Monteiro.

Ao meu amigo, colega e "co co orientador", Petrônio Cândido, que contribuiu em muito nesta dissertação com suas incríveis sugestões, me ajudando desde a introdução à conclusão, e até mesmo na apresentação deste trabalho.

Ao meu grande amigo e Prof. Manoel Campos, pela prontidão em ajudar em todos os momentos.

Aos professores do PPGEE, em especial ao Prof. Rodney Saldanha, por ser um exemplo de profissional, e pela prontidão em ajudar a todos que o procuram.

Aos demais amigos que fiz durante essa jornada, em ordem alfabética, Carolina Goretti, Douglas Chagas, Edna Barboza, Jean Nunes e Vinícius Rios.

Aos meus colegas do IFTO José Robson, Uagne, Rogério, Reinaldo, Plínio e Jardel pela ajuda sempre que necessária.

Ao IFTO, CNPq e Capes pelo apoio financeiro, sem o qual esse trabalho não teria sido possível.

Lista de Figuras

2.1. Particionamento do Universo de discurso com 7 conjuntos <i>fuzzy</i> e funções de associação sobrepostas	10
2.2. Associação dos elementos da série aos conjuntos <i>fuzzy</i>	11
4.1. Representação do calculo de regressão aplicada ao cenário 1	29
4.2. Representação do calculo de regressão aplicada ao cenário 2	30
4.3. Representação do calculo de regressão aplicada ao cenário 3	31
4.4. Representação da regressão linear dos pontos dos conjuntos <i>fuzzy</i> A3 e A4	33
4.5. Comparação da previsão do método proposto aplicado à série temporal original <i>Enrollments</i>	34
5.1. Diagrama do coletor de amostras	39
5.2. Série temporal IFTO Lagoa da confusão - UFMG	41
5.3. Série temporal IFTO Palmas - Unicamp	42
5.4. Série temporal IFTO LabMatica - GREDES	43
5.5. Divisões do Universo de Discurso para os experimentos	44
6.1. Comportamento dos métodos: série Lagoa-UFMG (atraso)	51
6.2. Comportamento dos métodos: série Lagoa-UFMG (<i>jitter</i>)	51
6.3. Comportamento dos métodos: série Lagoa-UFMG (perda de pacotes)	52
6.4. Gráfico de caixas: desempenho dos métodos	53

6.5. Teste de Dunnett: análise de diferença significativa entre os métodos	54
6.6. Gráfico de caixas: desempenho dos métodos com a métrica POCID	56
6.7. Teste de Dunnett: análise de diferença significativa entre os métodos pela métrica POCID	56
A.1. Comportamento dos métodos: série Lagoa-UFMG com 3 partições do universo de discurso (atraso)	68
A.2. Comportamento dos métodos: série Lagoa-UFMG com 5 partições do universo de discurso (atraso)	69
A.3. Comportamento dos métodos: série Lagoa-UFMG com 3 partições do universo de discurso (<i>jitter</i>)	69
A.4. Comportamento dos métodos: série Lagoa-UFMG com 5 partições do universo de discurso (<i>jitter</i>)	70
A.5. Comportamento dos métodos: série Lagoa-UFMG com 3 partições do universo de discurso (perda de pacotes)	70
A.6. Comportamento dos métodos: série Lagoa-UFMG com 5 partições do universo de discurso (perda de pacotes)	71
A.7. Comportamento dos métodos: série LABMATICA-GREDES com 3 partições do universo de discurso (atraso)	71
A.8. Comportamento dos métodos: série LABMATICA-GREDES com 5 partições do universo de discurso (atraso)	72
A.9. Comportamento dos métodos: série LABMATICA-GREDES com 7 partições do universo de discurso (atraso)	72
A.10. Comportamento dos métodos: série LABMATICA-GREDES com 3 partições do universo de discurso (<i>jitter</i>)	73
A.11. Comportamento dos métodos: série LABMATICA-GREDES com 5 partições do universo de discurso (<i>jitter</i>)	73
A.12. Comportamento dos métodos: série LABMATICA-GREDES com 7 partições do universo de discurso (<i>jitter</i>)	74

A.13.Comportamento dos métodos: série LABMATICA-GREDES com 3 partições do universo de discurso (perda de pacotes)	74
A.14.Comportamento dos métodos: série LABMATICA-GREDES com 5 partições do universo de discurso (perda de pacotes)	75
A.15.Comportamento dos métodos: série LABMATICA-GREDES com 7 partições do universo de discurso (perda de pacotes)	75
A.16.Comportamento dos métodos: série UNICAMP-IFTO com 3 partições do universo de discurso (atraso)	76
A.17.Comportamento dos métodos: série UNICAMP-IFTO com 5 partições do universo de discurso (atraso)	76
A.18.Comportamento dos métodos: série UNICAMP-IFTO com 7 partições do universo de discurso (atraso)	77
A.19.Comportamento dos métodos: série UNICAMP-IFTO com 3 partições do universo de discurso (<i>jitter</i>)	77
A.20.Comportamento dos métodos: série UNICAMP-IFTO com 5 partições do universo de discurso (<i>jitter</i>)	78
A.21.Comportamento dos métodos: série UNICAMP-IFTO com 7 partições do universo de discurso (<i>jitter</i>)	78
A.22.Comportamento dos métodos: série UNICAMP-IFTO com 3 partições do universo de discurso (perda de pacotes)	79
A.23.Comportamento dos métodos: série UNICAMP-IFTO com 5 partições do universo de discurso (perda de pacotes)	79
A.24.Comportamento dos métodos: série UNICAMP-IFTO com 7 partições do universo de discurso (perda de pacotes)	80

Lista de Tabelas

2.1. Valor base para encontrar o tamanho ideal dos intervalos	14
2.2. Exemplo de aplicação de pesos priorizando dados mais recentes	16
2.3. Valores de ponderação baseados nas tendências de crescimento	17
2.4. Valores de pesos com base na quantidade de recorrências	18
4.1. Tabela de dados: <i>Enrollment Alabama University</i>	32
4.2. Divisão dos conjuntos <i>Fuzzy</i> para a série <i>Enrollments</i>	33
6.1. MAPEs e RMSEs Série Lagoa-UFMG	48
6.2. MAPEs e RMSEs Série LABMATICA-GREDES	49
6.3. MAPEs e RMSEs Série Palmas-UNICAMP	50
6.4. Valores de POCID para todas as séries, variáveis e divisões do universo de discurso	55
A.1. Dados brutos coletados com o experimento e usados para tabelas e testes estatísticos	63

Lista de Algoritmos

5.1. Coletor de Amostras ICMP	39
---	----

Sumário

Lista de Figuras	vii
Lista de Tabelas	xi
Lista de Algoritmos	xiii
1. Introdução	1
1.1. Apresentação	1
1.2. Motivação	3
1.3. Objetivos	4
1.3.1. Objetivos Específicos	4
1.4. Contribuições	5
1.5. Estrutura do Trabalho	6
2. <i>Fuzzy Time Series</i>	7
2.1. Introdução	7
2.2. Modelos de Primeira Ordem	8
2.2.1. Modelos de alta ordem	14
2.2.2. O impacto do particionamento do universo de discurso	14
2.3. Séries Ponderadas	16
2.4. Conclusão	18
3. Qualidade de Serviço e Experiência	19
3.1. Introdução	19
3.2. Métricas de Qualidade de Serviço	20
3.2.1. Atraso fim-a-fim	20
3.2.2. Variação do atraso (<i>jitter</i>)	21
3.2.3. Perda de Pacotes	21
3.2.4. Vazão	22

3.3. Métricas de Qualidade de Experiência	22
3.4. Coleta de informações da rede	23
3.5. Conclusão	24
4. Método de predição proposto	25
4.1. Introdução	25
4.2. Descrição do Método de Predição Proposto	26
4.3. Exemplo de Aplicação	31
4.4. Conclusão	35
5. Metodologia	37
5.1. Introdução	37
5.2. Coleta de dados e cenário de testes	37
5.3. Avaliação da capacidade preditiva da proposta	38
6. Resultados	47
6.1. Introdução	47
6.2. Resultados dos testes de acurácia	47
6.3. Conclusão	56
7. Conclusão	59
7.1. Considerações Finais	59
7.2. Trabalhos de Continuidade	61
A. Apêndices	63
Referências	81

Capítulo 1.

Introdução

1.1. Apresentação

O crescente avanço das aplicações de redes de computadores em geral está evidenciado pelo aumento do número de serviços e produtos oferecidos atualmente. No nosso cotidiano os conteúdos oferecidos são trafegados em sua grande parte através de um canal de comunicação entre computadores. Uma aplicação que oferece diversos tipos de conteúdos pode ser descrita como um software multimídia, pois combina texto, gráfico, áudio, vídeo e dados em geral. Entre os vários exemplos de tais aplicações que transmitem dados pela Internet (IP-based), pode-se citar a teleconferência em tempo real (e.g., Skype), o vídeo sob demanda (e.g., Netflix), a televisão IP (*Internet Protocol Television - IPTV*), a televisão móvel (*Mobile Television - MoTV*) e o web vídeo (e.g., YouTube, Facebook, Google) (Clark & Mayer 2016).

O atual aumento nos serviços multimídia e seu consumo promovem um maior interesse e demanda por ferramentas capazes de avaliar, gerenciar e melhorar a qualidade do conteúdo entregue aos usuários. A necessidade de ferramentas e métodos de aferição é ainda maior, dado que com a oferta de mais produtos o consumidor torna-se mais exigente e conhecedor das capacidades dos serviços multimídia (Egilmez et al. 2013). Logo, é notória a importância do desenvolvimento de métricas que ajudem a garantir que aplicações multimídia proporcionem, cada vez mais, um serviço de alta qualidade. Tais métricas contemplam as noções da percepção humana (tanto visual como auditiva) com o intuito de satisfazer as expectativas dos usuários. Da mesma forma, a implementação de métricas que avaliam a qualidade em tempo real, ou até mesmo a predizem, é de grande valia

para os provedores do serviço. As métricas em geral são capazes de fornecer informação relacionada à qualidade do sinal transmitido, permitindo aos operadores da rede controlar seus recursos em tempo real, mantendo desta forma a satisfação do usuário. O desempenho das aplicações é basicamente medido em termos de qualidade de serviço (*Quality of Service* - QoS), que considera características técnicas da rede como, por exemplo, atraso fim-a-fim, variação do atraso (*jitter*), vazão (*throughput*) e taxa de perda de pacotes (Thayammal & Linda 2017).

Dentre os procedimentos para a aferição da qualidade em aplicações multimídia, o mais preciso é a avaliação utilizando experimentos subjetivos com observadores humanos. Tais experimentos costumam ser onerosos e exigem demasiado tempo e recursos físicos, além de apresentarem difícil implementação no monitoramento de aplicações em tempo real (Pierucci & Micheli 2016). Uma alternativa para superar essas barreiras, consiste em utilizar métodos computacionais, ou seja, métricas objetivas para estimar a qualidade. Maiores detalhes sobre procedimentos de aferição de qualidade são abordados no Capítulo **3**.

Nos últimos anos, várias métricas que avaliam qualidade de áudio e vídeo têm sido propostas (Zerman et al. 2017, Duanmu et al. 2017, Usman et al. 2017, Maia et al. 2015). As métricas que apresentam os melhores resultados são aquelas que usam um sinal de referência (informação original ou livre de ruídos) para medir a qualidade. Essas são as chamadas métricas com referência ou referenciadas (Full Reference - FR) (Zhang & Liu 2017). Infelizmente, em ambientes de comunicação de dados, tais referências dificilmente estarão disponíveis por parte do usuário, o que dificulta sua utilização para aferição de qualidade em tempo real. Dessa maneira, o desenvolvimento de métricas automáticas, que não utilizem o sinal de referência ou usem apenas partes deste sinal, continua sendo foco de pesquisa (Kundu et al. 2017). Estas métricas são conhecidas como de referência reduzida (*Reduced Reference* - RR) e métricas sem referência ou não-referenciadas (*No-Reference* - NR). Entre as técnicas mais importantes da literatura para medir a qualidade de conteúdos multimídia pode-se citar *Sarnoff JND Vision* (Lubin & Fibush 1997), NROQM (Caviedes & Oberti 2003), DIIVINE (Moorthy & Bovik 2011), entre outras (Rohaly et al. 2003, Gunawan & Ghanbari 2005, Farias & Mitra 2005, Wang et al. 2004). Novas tendências na área incluem o desenvolvimento de métricas híbridas, que considerem tanto informações e comportamento da rede quanto o sistema de percepção humano (Becerra Martinez 2014).

De maneira geral, o foco desta dissertação consiste em combinar informações sobre os comportamentos de redes através de aferições de métricas de QoS, de tal forma que seja possível identificar padrões de comportamento por meio de características, informações e/ou avaliações de séries temporais. Por conseguinte, um método de predição com auxílio de séries temporais nebulosas (*Fuzzy Time Series* - FTS) é proposto. Para avaliação de desempenho, estudos comparativos entre métodos conhecidos da literatura e aplicações práticas em ambientes de rede são planejados e executados.

1.2. Motivação

As séries temporais nebulosas vêm ganhando um forte destaque na literatura e inúmeras aplicações práticas têm sido desenvolvidas em diversos contextos (Chen 2014). Algumas técnicas híbridas para análise de qualidade de rede que utilizam inteligência computacional, séries temporais, redes neurais artificiais e lógica nebulosa já são empregadas na literatura, porém, pelo que se tem conhecimento, trabalhos que utilizem técnicas de FTS ainda não são visualizados no cenário de aferição de qualidade de redes.

Alguns trabalhos no cenário de redes de computadores usam inteligência computacional combinado com análises de séries temporais tradicionais na tentativa de prever qualidade de rede. Por exemplo, em Zadeh & Seyyedi (2010) é proposta uma abordagem preditiva com uso de séries temporais e redes neurais. Parâmetros históricos de QoS são utilizados para fazer previsões do tráfego de rede, para auxiliar no seu monitoramento. A abordagem busca reduzir o *overhead* da rede e aumentar sua eficiência.

Em Satyanarayana (2009), determinado tráfego *wireless* é modelado como uma série temporal não linear e não estacionária. São propostos e comparados três modelos de predição. Os dois primeiros usam as arquiteturas de redes neurais artificiais (RNA): *Recurrent Radial Basis Function Network* (RRMFN) e *Echo state network* (ESN). O terceiro usa um modelo estatístico chamado *Fractional Auto Regressive Integrated Moving Average* (FARIMA).

Algumas outras abordagens de previsões de tráfego de rede são experimentadas em Katris & Daskalaki (2015). Entre elas destacam-se os modelos baseados em RNA: *Multilayer Perceptron* (MLP) e *Radial Basis Function* (RBF), além dos baseados na abordagem FARIMA.

Por fim, modelos de predição baseados em séries temporais como os auto regressivos (AR) e auto regressivos integrado com médias móveis (ARIMA) também são usados para prever tráfego de rede. Por exemplo, tais modelos são aplicados em Zhani et al. (2009) para tráfego de redes ethernet, em Sivakumar et al. (2011) para tráfego de redes wireless, em Won & Ahn (2005) para tráfego de vídeo, em Biernacki (2017) para tráfego em websites, e em Moussas et al. (2005) para tráfego de dados na rede de um campus universitário.

Conforme sugerido pelos trabalhos indicados anteriormente, técnicas de previsão usando séries temporais tradicionais, também conhecidas como *Crisp*, e modelos como ARIMA e FARIMA tiveram bons resultados quando aplicados em modelos para auxílio de aferição de qualidade em redes, bem como para predição de padrões de comportamento. Técnicas de FTS são uma nova abordagem no cenário de inteligência computacional e séries temporais, com grande potencial mas ainda pouco exploradas no contexto de redes de computadores. O desenvolvimento de um método que mescla características de FTS com avaliações de métricas de QoS modeladas como séries temporais representa a principal contribuição desta dissertação.

1.3. Objetivos

O objetivo principal do trabalho é propor um método FTS capaz de prever qualidade de rede em geral. O método FTS emprega séries temporais de métricas de QoS com avaliações da rede e prediz a qualidade em momentos futuros.

1.3.1. Objetivos Específicos

Com o intuito de atingir o objetivo principal, foram definidos os seguintes objetivos específicos:

- Estudar trabalhos relacionados, relevância e questões de interesse da proposta bem como fazer levantamento sobre técnicas de aferição de qualidade com uso de séries temporais.
- Selecionar métricas de QoS conhecidas para estimar qualidade em redes.
- Verificar a eficácia dos métodos FTS na predição de QoS em redes de computadores.

- Propor um método FTS que mescla características de redes de computadores e métodos FTS e realizar testes de bancada em cenários reais para avaliação e validação do método.

1.4. Contribuições

Predizer qualidade para o tráfego de dados constitui um problema desafiador. Mesmo diante de várias métricas já conhecidas, ainda não há uma técnica capaz de prever qualidade, principalmente em razão das muitas variáveis, cenários envolvidos e até mesmo aspectos subjetivos por parte dos usuários (Chagas da Silva 2015). Diversas soluções têm sido propostas no sentido de avaliar e selecionar a melhor rede disponível, considerando um conjunto de critérios. Trabalhos como (Ciccarese et al. 2009), (de Castro Monteiro 2012), (Rios 2012), (Chagas da Silva et al. 2014), (Lahby et al. 2017), (Lahby et al. 2015), (Trestian et al. 2014) abordam o tema e propõem métodos de tomada de decisão baseados em lógica *fuzzy*, algoritmos genéticos e redes neurais para o processo de *handover* em redes heterogêneas. Algumas destas soluções são computacionalmente viáveis, porém, outras impõem modelos restritivos, que requerem um esforço computacional maior, o que pode inviabilizar a solução para dispositivos com menor poder de processamento, como no caso dos dispositivos móveis.

Dessa maneira, o desenvolvimento de novas técnicas apresenta-se como uma contribuição, inclusive se considerarmos a crescente demanda do tráfego de dados que necessitam de avaliações de qualidade. Alguns exemplos incluem serviços de vídeo sob demanda, conferências em tempo real, entre outros.

De maneira específica, acredita-se que esta dissertação apresenta como contribuições originais, o desenvolvimento de um método FTS:

- dedicado à previsão de qualidade de rede.
- que mescla características de regressão linear com o intuito de prever valores de QoS;

1.5. Estrutura do Trabalho

Os assuntos discutidos neste trabalho estão organizados conforme mostrado a seguir.

Capítulo 2 – *Fuzzy Time Series*: Este capítulo discorre acerca dos principais trabalhos e conceitos de FTS presentes na literatura. Apresenta-se uma revisão detalhada sobre os métodos base para o desenvolvimento de FTS, como os métodos de primeira ordem. Conceitos sobre variações e aprimoramentos, como os métodos ponderados, de alta ordem e discussões sobre o impacto da divisão do universo de discurso também são levantados.

Capítulo 3 – Qualidade de Serviço e Experiência: Com o intuito de descrever aspectos e características referentes à qualidade de serviço e experiência, este capítulo aborda temas, características e ferramentas usados para aferição de qualidade em geral. Métricas de qualidade de serviço, qualidade de experiência além das abordagens de avaliação subjetivas e objetivas são contextualizadas.

Capítulo 4 – Método de Predição Proposto: Inicialmente é discutido o tratamento e coleta de informações que expressam o comportamento das redes, onde conceitos sobre ICMP e aplicações como o *ping* e *traceroute* são abordados. Em seguida o método proposto bem como uma aplicação de exemplo são detalhados. Nesse ponto, características como a aplicação de regressão linear e comportamento estacionário são usados para otimização do método proposto.

Capítulo 5 – Metodologia: Nesse capítulo são definidas as abordagens e ambientes de coleta de dados, bem como as métricas de QoS e métricas de aferição de qualidade utilizadas no trabalho. Tais definições são utilizadas para avaliar a capacidade preditiva da proposta frente a outros métodos.

Capítulo 6 – Resultados: Os resultados obtidos com os experimentos planejados são apresentados e analisados. Testes estatísticos são aplicados para verificar a real eficácia da proposta. Testes de análise de variância completada pelo teste de Dunnett são elaborados para identificar a existência de diferença significativa entre os métodos.

Capítulo 7 – Conclusões: Nesse capítulo finalmente são ressaltados os resultados obtidos bem como considerações pertinentes sobre o método proposto e a eficiência da abordagem FTS em redes de computadores. Perspectivas para a continuação da pesquisa deste trabalho também são discutidos.

Capítulo 2.

Fuzzy Time Series

2.1. Introdução

Neste capítulo são apresentados os principais aspectos e técnicas de FTS apresentadas na literatura. No entanto, o objetivo principal aqui não é descrever as técnicas simplesmente como soluções para o objetivo exposto. Em vez disso, o foco neste capítulo é contextualizar o que são e como foram desenvolvidas as técnicas de FTS, além de apresentar como elas são usadas no cenário tecnológico atual, visando assim evidenciar a contribuição da abordagem apresentada nesta dissertação.

As séries temporais são conjuntos de dados que representam o comportamento de uma variável (ou mais) ao longo do tempo. Segundo Chatfield (Chatfield 2001) a principal característica de uma série temporal é que as observações sucessivas da variável não são independentes entre si e a sua análise deve levar em conta a ordem em que foram coletadas. As séries temporais encontram aplicações nos mais diversos segmentos, sendo indispensáveis em áreas como a engenharia, medicina, economia, meteorologia, dentre outras.

Há duas atividades principais relacionadas a séries temporais: análise e previsão. Na análise, deseja-se descrever o comportamento da série temporal e seus fatores de influência. Na previsão, deseja-se obter valores futuros da série com base em seus valores passados. Usualmente, séries temporais são modeladas em alto nível como $X_t = T_t + C_t + R_t$, onde: X_t é uma estimativa pontual da série no tempo t ; T_t é o componente de tendência, i.e. o comportamento de longo prazo; C_t é o componente cíclico ou sazonal, i.e. as flutuações de curto e médio prazo e R_t é o componente de ruído, um valor aleatório de variância constante.

Diversos modelos estatísticos de modelagem e previsão de séries temporais são descritos na literatura, como os tradicionais ARMA, ARIMA (Granger & Joyeux 1980) e GARCH (Bollerslev 1987). Entretanto, atualmente diversas outras técnicas têm sido exploradas, como a utilização de redes neurais, algoritmos genéticos e outras meta-heurísticas (Nametala et al. 2016).

A utilização de conjuntos nebulosos para modelagem e previsão de séries temporais surge quase intuitivamente. Primeiramente, baseando-se na capacidade dos modelos nebulosos de aproximar funções, conseqüentemente, permitindo a melhor legibilidade das regras utilizando variáveis linguísticas que as tornam mais simples para a análise por especialistas.

As *Fuzzy Time Series* são métodos de previsão não-paramétricos propostos por Song & Chissom (1993b) baseados na teoria dos conjuntos *fuzzy* Zadeh (1965). Desde sua proposição, esses modelos têm sido adaptados, estendidos e melhorados para atender as mais diversas finalidades. Esses métodos são fáceis de implementar e flexíveis oferecendo maneiras de lidar com dados numéricos e linguísticos.

Os métodos FTS são comumente usados em previsões de consumo e cargas elétricas (Yasmeen & Sharif 2015, Ismail et al. 2015, Sadaei et al. 2017), matrículas universitárias (Song & Chissom 1993b, Song & Chissorn 1994, Ismail & Efendi 2011), previsão de mercado financeiro (Efendi et al. 2013, Lee et al. 2013, Chen 2014, Sadaei et al. 2016), entre outras. Os estudos com FTS ainda são recentes e há diversas áreas onde tais métodos podem ser mais explorados. Na próxima seção são introduzidos alguns conceitos sobre FTS além dos modelos e categorias presentes na literatura.

2.2. Modelos de Primeira Ordem

Os trabalhos pioneiros em séries temporais nebulosas são de Song & Chissom (1993b) e Chen (1996). Nesses trabalhos, define-se que o modelo de primeira ordem (*First Order Fuzzy Time Series*) caracteriza-se por presumir que $X(t)$, uma estimativa pontual da série no tempo t , é determinado por um único preditor $X(t-1)$ (ou $X(t-2)$ ou ... ou $X(t-m)$). A ordem indica quantos atrasos de tempo (*lags*) são usados na modelagem das séries temporais.

Na sua modelagem mais simples (invariante no tempo) a série pode ser descrita conforme em (2.1), onde R é uma matriz das relações nebulosas que descrevem a série e \circ é o operador relacional Fuzzy Max-Min, gerando assim $F(t)$ que representa a série temporal fuzificada. Essa formulação também pode ser entendida como um conjunto de regras no formato SE $X(t-1)$ ENTÃO $X(t)$. Se forem utilizados m termos então tem-se (2.2), que pode ser interpretado como uma regra no formato SE $X(t-1)$ OU $X(t-2)$ OU ... OU $X(t-m)$ ENTÃO $X(t)$.

$$F(t) = X(t-1) \circ R(t, t-1) \quad (2.1)$$

$$F(t) = X(t-m) \circ R_o(t, t-m) \quad (2.2)$$

O procedimento de modelagem e predição se baseia na criação de k conjuntos nebulosos a partir da divisão do universo de discurso de uma série de valores X_t em intervalos sobrepostos. O processo de fuzificação associa, para cada valor X_t da série $X(t)$, um grau de pertinência para cada um dos k conjuntos. Esse procedimento é descrito a seguir.

Etapa 1 Dividir o universo de discurso e criar os conjuntos nebulosos.

Dado o universo de discurso $U = [U_{min}, U_{max}]$ da série temporal $X(t)$, deve-se inicialmente particioná-lo em m intervalos u_1, u_2, \dots, u_m de igual tamanho cujos centros ou centroides são c_1, c_2, \dots, c_m . A partir dos m intervalos são definidos k conjuntos nebulosos sobrepostos A_1, A_2, \dots, A_k , descritos em (2.3), onde cada $a_i \in [0, 1]$, $1 \leq i \leq k$ representa o grau de pertinência do intervalo u_j , $1 \leq j \leq m$, ao conjunto A_i . Cada conjunto A_i pode ser simplesmente referenciado por uma função de pertinência $f_{ai}(t)$. O operador $+$ representa a operação de concatenação. A Figura 2.1 ilustra esta etapa, onde há 7 conjuntos (A1 até A7) e funções de pertinência.

$$\begin{aligned} A_1 &= [f_{a1}(u_1)/u_1 + f_{a1}(u_2)/u_2 + \dots + f_{a1}(u_m)/u_m] \\ &\dots \\ A_k &= [f_{ak}(u_1)/u_1 + f_{ak}(u_2)/u_2 + \dots + f_{ak}(u_m)/u_m] \end{aligned} \quad (2.3)$$

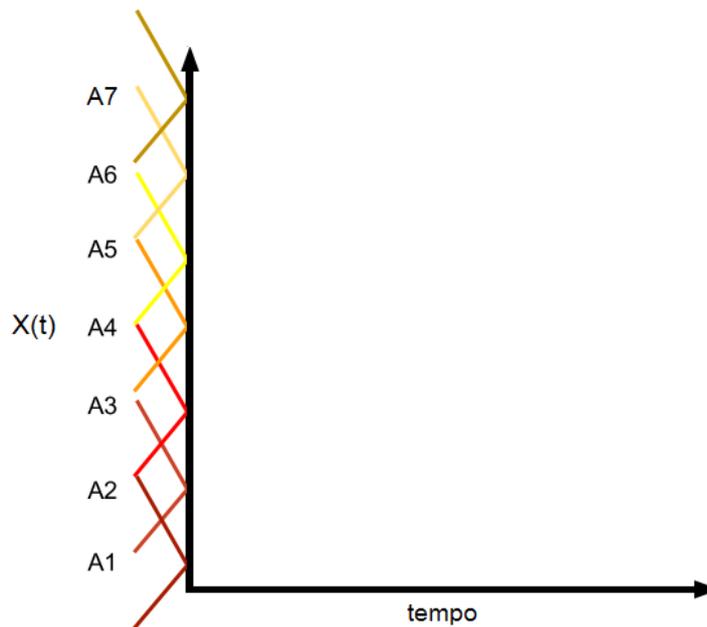


Figura 2.1.: Particionamento do Universo de discurso com 7 conjuntos *fuzzy* e funções de associação sobrepostas

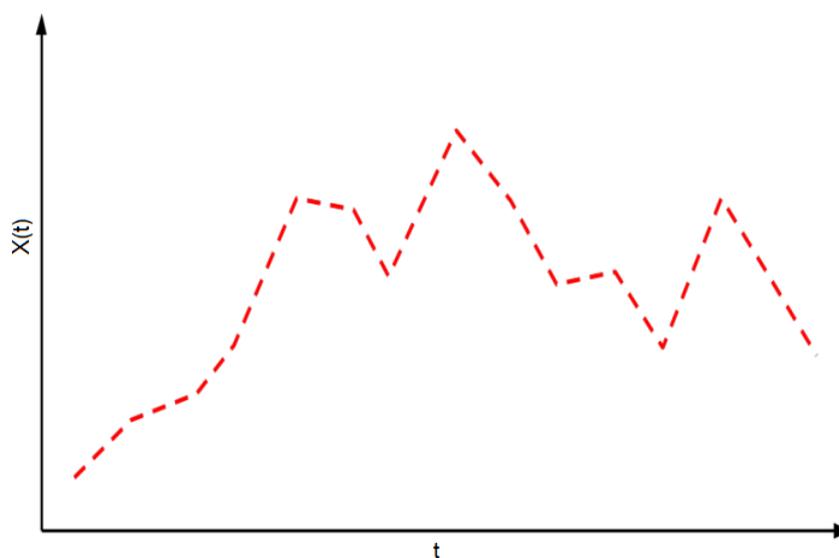
A partição do Universo do Discurso é certamente uma das etapas cruciais dos métodos FTS devido a sua influência na precisão das previsões. O número de intervalos, seus comprimentos e definição dos pontos médios são parâmetros que devem ser escolhidos com atenção. Este esquema de partição proposto em (Song & Chissom 1993b) é chamado de particionamento em grade. Nele a faixa de dados é dividida em intervalos de igual comprimento.

Etapa 2 Fuzzificar os elementos da série temporal e criar as Fuzzy Logical Relationship.

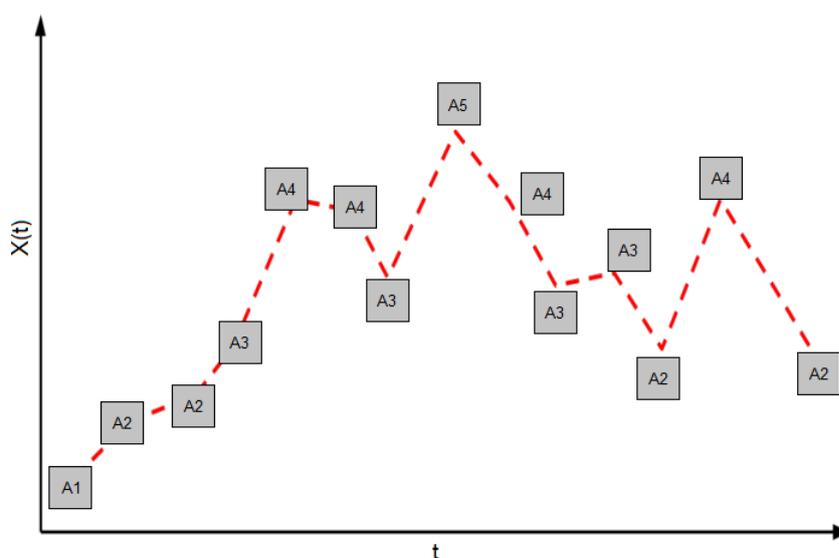
Definidos os conjuntos nebulosos, deve-se fuzzificar os elementos da série e associar a cada elemento o conjunto A_i tal que $A_i = \max\{a_i\}$, conforme ilustra a Figura 2.2b. Com a série fuzzificada, pode-se então gerar o conjunto de regras lógicas de transição, percorrendo toda a série temporal e registrando as transições distintas entre conjuntos. As regras têm o formato $A_j \rightarrow A_k$. Esse formato é conhecido como *Fuzzy Logical Relationship* (FLR), onde o precedente A_j é o conjunto nebuloso da série temporal no momento $F(t - 1)$ e o conseqüente A_k é o conjunto referente ao momento $F(t)$.

Etapa 3 Associar as FLR criando os FLRGs.

O conjunto de regras distintas é então agrupado pelo seu precedente A_j , criando os *Fuzzy Logical Relationship Groups* (FLRGs). Por exemplo, o conjunto de regras em



(a) Série Original



(b) Série Fuzificada

Figura 2.2.: Associação dos elementos da série aos conjuntos *fuzzy*

(2.4), obtido com base nas Figuras 2.2a e 2.2b, é agrupado conforme evidenciado em (2.5). Perceba que para cada precedente um conjunto de FLRs consequentes é

agrupado.

$$\begin{aligned}
&A_1 \rightarrow A_2 \quad A_2 \rightarrow A_2 \quad A_2 \rightarrow A_3 \quad A_3 \rightarrow A_4 \\
&A_4 \rightarrow A_4 \quad A_4 \rightarrow A_3 \quad A_3 \rightarrow A_5 \quad A_5 \rightarrow A_4 \\
&A_4 \rightarrow A_3 \quad A_3 \rightarrow A_3 \quad A_3 \rightarrow A_2 \quad A_2 \rightarrow A_4 \\
&A_4 \rightarrow A_2
\end{aligned} \tag{2.4}$$

$$\begin{aligned}
&A_1 \rightarrow A_2 \\
&A_2 \rightarrow A_2, A_3, A_4 \\
&A_3 \rightarrow A_2, A_3, A_4 \\
&A_4 \rightarrow A_3, A_4, A_5 \\
&A_5 \rightarrow A_4
\end{aligned} \tag{2.5}$$

Etapa 4 Predizer F(t)

Em Song & Chissom (1993b), a matriz de relações R é derivada a partir do conjunto de regras para satisfazer (2.1) e (2.2). Para cada FLRG $A_j \rightarrow A_k, A_l, A_m$ as operações $R_1 = A_j^T \times A_k, R_2 = A_j^T \times A_l, R_3 = A_j^T \times A_m$ são geradas. Ou seja, os vetores das pertinências dos conjuntos A_j e A_k, A_l, A_m são relacionados pelo operador \times , conforme (2.6). A matriz R (2.7) é a união de todas essas operações, logo, n é o total dessas operações geradas. Por exemplo, em (2.5) esse total seria 11.

$$\begin{aligned}
R_p &= A_j^T \times A_k \\
r_{jk} &= \min(a_j, a_k) \mid \forall a_j \in A_j, a_k \in A_k
\end{aligned} \tag{2.6}$$

$$R = \bigcup_{i=1}^n R_i \tag{2.7}$$

O operador de composição \circ no caso de $R(t, t-1)$ executa composição em (2.8). Para $R(t, t-m)$ tem-se (2.9).

$$R(t, t - 1) = \max\{\min(f_i(t - 1), f_j(t))\} \quad (2.8)$$

$$R_o(t, t - m) = \max\{\max_k\{\min(f_{i_k}(t - k), f_j(t))\}\} \quad (2.9)$$

A composição $F(t - 1) \circ R$ gera um vetor com a pertinência do valor de $F(t)$ para as m partições de U . Com esse vetor é possível “defuzificar” o valor de $F(t)$, ou seja, tornar o valor um dado pontual novamente. O método proposto por Chen (1996) é uma evolução do trabalho de Song & Chissom (1993b) que elimina o cálculo de R e a utilização do operador \circ . Nele é proposto apenas o agrupamento das regras FLRs, criando os FLRGs, para, na sequência, o processo seguir diretamente para a etapa de defuzificação. O processo de previsão proposto por Chen (1996) é mais simples e barato por evitar o uso de matrizes. Os FLRGs são legíveis e de fácil interpretação por humanos e representam a base de conhecimento do modelo.

Etapa 5 Defuzificar

O processo de defuzificação transforma o conjunto de pertinências de $F(t)$ em um valor pontual da série. Se o conjunto nebuloso atual em $F(t - 1)$ é A_j , então $F(t)$ é definido da seguinte forma:

1. Se existir apenas uma regra com o precedente A_j , e a partição de máxima pertinência do conseqüente A_k corresponde à partição u_k , escolha o centro c_k desta partição: $F(t) = c_k$.
2. Se existirem p regras com o precedente A_j , cujas partições de máxima pertinência dos conseqüentes são u_{k1}, \dots, u_{kp} , então a saída será a média aritmética simples dos p centros: $F(t) = \frac{\sum_{i=1}^p c_i}{p}$.
3. Se não existirem regras com o precedente A_j , e a partição de máxima pertinência de A_j corresponde à partição u_j , escolha o centro c_j desta partição: $F(t) = c_j$.

Ambos os métodos Song & Chissom (1993b) e Chen (1996) são chamados de modelos FTS convencionais e são as principais abordagens do campo FTS. Quase todos os trabalhos são baseados em um desses métodos, mas existem outros métodos e abordagens. Por exemplo, (Huarng 2001b) propõe modelos heurísticos e (Singh & Borah 2013) propõe

métodos computacionais elaborados para otimizar as previsões. No entanto, tais métodos são menos comuns.

2.2.1. Modelos de alta ordem

Os modelos de alta ordem (*High-Order Fuzzy Time Series*) são essencialmente baseados nos trabalhos de Hwang et al. (1998) e Chen (2014) e diferenciam-se dos modelos de primeira ordem por usar mais de um *lag* como preditor para definir o valor futuro da série. Nesse modelo, define-se os *High Order Fuzzy Logical Relationships* (HOFLR) no formato $LHS \rightarrow RHS$, onde o precedente LHS é um conjunto dos conjuntos *fuzzy* definidos por $F(t - (n - 1)), \dots, F(t)$, onde n representa a ordem do modelo, e o conseqüente RHS é o conjunto *fuzzy* para $F(t + 1)$.

2.2.2. O impacto do particionamento do universo de discurso

A partir da pesquisa de Huarng (2001a) tornou-se evidente o impacto que o tamanho das partições do universo de discurso tem sobre o poder preditivo dos modelos de séries temporais nebulosas. Huarng (2001a) então sugere duas metodologias de escolha, uma baseada na distribuição dos dados e outra baseada no valor médio, conforme apresentado a seguir.

1. Calcule as diferenças entre os elementos da série: $\Delta_i = A_{i+1} - A_i$ para $i = 1..n - 1$.
2. Calcule a média das diferenças: $\bar{\Delta}_i = \frac{\sum_{i=1}^n \Delta_i}{n}$.
3. Determine um valor base para o tamanho do intervalo de acordo com a Tabela 2.1.

Tabela 2.1.: Valor base para encontrar o tamanho ideal dos intervalos

Intervalo	Base
0.1-1	0.1
1.1-10	1
11-100	10
101-1000	100

4. Utilizando a base escolhida, crie uma distribuição de frequências cumulativas.

5. Escolha o intervalo que é menor do que pelo menos metade das diferenças.

Não apenas o tamanho das partições, mas sua forma e distribuição também tem impacto nos modelos. Em Cheng et al. (2006) é desenvolvida uma metodologia de particionamento do universo do discurso baseada na entropia da série temporal. Este método, chamado de *Minimize Entropy Principle Approach* (MEPA), busca dividir o universo de discurso de acordo com os seguintes pontos.

Passo 1: Determine a classe de cada elemento da série temporal.

Passo 2: Calcule os valores dos conjuntos a partir dos pontos de mínima entropia.

Nesse passo deve-se inicialmente ordenar a série temporal pelo valor dos elementos, em que o intervalo de valores é dado por $[x_{min}, x_{max}]$. O próximo passo é calcular a entropia de cada elemento x da série, para cada $x \in F(t)$. Primeiro divide-se o intervalo $[x_{min}, x_{max}]$ em dois sub intervalos, $p = [x_{min}, x_{min} + x]$ e $q = [x_{min} + x, x_{max}]$ conforme (2.10), onde:

$$\begin{aligned}
 S(x) &= p(x)S_p(x) + q(x)S_q(x) \\
 S_p(x) &= -[p_1(x) \ln(p_1(x)) + p_2(x) \ln(p_2(x))] \\
 S_q(x) &= -[q_1(x) \ln(q_1(x)) + q_2(x) \ln(q_2(x))] \\
 p_i(x) &= n_i(x) + 1/n_p + 1 \\
 q_i(x) &= n_i(x) + 1/n_q + 1 \\
 p(x) &= n_p/n \\
 q(x) &= 1 - p(x)
 \end{aligned} \tag{2.10}$$

$p(x)$ é a probabilidade de todas as classes no intervalo p , $q(x)$ é a probabilidade de todas as classes no intervalo q , $p_i(x)$ é a probabilidade condicional que a classe i esteja na região p , $q_i(x)$ é a probabilidade condicional que a classe i esteja na região q , n_p é a quantidade de elementos no intervalo p , n_q é a quantidade de elementos no intervalo q e n a quantidade total de elementos.

O elemento escolhido em cada iteração é aquele que tiver o menor valor de $S(x)$. Então esse ponto passa a dividir a série em dois conjuntos. Deve-se repetir o método em cada subconjunto até atingir o número de partições desejada. Para 7 partições,

por exemplo, seriam necessárias 3 iterações, criando uma partição primária (PRI), duas secundárias (SEC1 e SEC2) e quatro terciárias (TER1, TER2, TER3 e TER4) tal que $TER1 \leq SEC1 \leq TER2 \leq PRI \leq TER3 \leq SEC2 \leq TER4$.

Passo 3: Determinar o tamanho dos intervalos a partir dos pontos escolhidos e criar as funções de pertinência.

2.3. Séries Ponderadas

Na etapa de agrupamento das regras normalmente se considera apenas regras distintas, i.e todas as repetições são descartadas. Se um mesmo padrão de variação é muito recorrente, no momento do agrupamento de regras ele terá a mesma importância de um padrão que ocorre poucas vezes. O agrupamento por regras distintas ainda gera a perda da ordem cronológica, tornando padrões mais recentes e mais antigos iguais.

Para lidar com esses problemas, Yu (2005) propõe um modelo chamado *Weighted Fuzzy Time Series*, que inclui pesos nas FLRGs. Esses pesos aumentam monotonicamente e têm um efeito de suavização, dando mais importância aos dados mais recentes usados no processo de previsão. O *Weighted Fuzzy Logical Relationship Group* (WFLRG) possui a mesma estrutura que o FLRG, mas os pesos w_j estão associados a cada conjunto fuzzy $A_j \in RHS$. Nesse modelo as WFLRGs permitem a repetição de conjuntos no consequente das regras, e os conjuntos devem ser apresentados em ordem cronológica. A Tabela 2.2 apresenta um exemplo de pesos onde são priorizados os dados mais recentes. Se tomarmos o conjunto apresentado em (2.4), o resultado seria então diferente do apresentado em (2.5):

Tabela 2.2.: Exemplo de aplicação de pesos priorizando dados mais recentes

Regra	Pesos Não Normalizados	Pesos Normalizados
$A_1 \rightarrow A_1, A_2, A_1, A_3$	1,2,3,4	0.1,0.2,0.3,0.4
$A_2 \rightarrow A_1, A_3, A_3, A_3$	1,2,3	0.15, 0.35, 0.5

Na defuzificação, tomando como exemplo a regra $A_2 \rightarrow A_1, A_3, A_3, A_3$, cria-se uma matriz $M(t) = [m_1, m_3, m_3, m_3]$ com as centroides dos conjuntos do consequente da regra. A matriz de pesos $W(t)$ contém a ordem cronológica em que os conjuntos aparecem (uma

série monotonicamente crescente), com os valores normalizados. Logo, para o exemplo apresentado na Tabela 2.2, $W(t) = [1, 2, 3, 4]$ é normalizado para $W(t) = [0.1, 0.2, 0.3, 0.4]$. O valor final predito para a série é dado por $M(t) \times W(t)^T$ tal que $F(t) = \sum_i w_i * m_j$ para $w_i \in W(t)^T$ e $m_j \in M(t)$.

O trabalho de Cheng et al. (2009) apresenta ponderações nas regras para representar tendências na série temporal, as *Trend-weighted Fuzzy Time Series*. As regras recorrentes são classificadas em três categorias, conforme sua tendência: crescimento ($A_1 \rightarrow A_2$, $A_1 \rightarrow A_3$ e $A_2 \rightarrow A_3$), decrescimento ($A_2 \rightarrow A_1$) e sem tendência ($A_1 \rightarrow A_1$). O peso das regras é então associado pela contagem cronológica do aparecimento dos grupos dentro das categorias. Dessa forma as regras mais recorrentes de uma determinada tendência terão pesos maiores, indicando que possuem maior chance de ocorrer, conforme ilustrado na Tabela 2.3. Os pesos das regras são normalizados no momento da defuzificação. O cálculo do valor final é idêntico ao método anterior.

Tabela 2.3.: Valores de ponderação baseados nas tendências de crescimento

Regra	Tendência	Peso
$A_1 \rightarrow A_1$	Sem tendência	2
$A_1 \rightarrow A_2$	Crescimento	1
$A_1 \rightarrow A_3$	Crescimento	1
$A_2 \rightarrow A_3$	Crescimento	3
$A_2 \rightarrow A_1$	Decrescimento	1

Os trabalhos de Ismail & Efendi (2011) e Efendi et al. (2013) modificam a forma como os pesos são assinalados às regras no modelo de (Yu 2005). A diferença mais importante é que a quantidade de recorrências de cada regra é que determina o seu peso. Por exemplo, para uma regra $A_i \rightarrow A_j, A_k$, tendo $A_i \rightarrow A_j$ n_1 recorrências e $A_i \rightarrow A_k$ n_2 recorrências, o valor de cada peso será $w_k = n_k / \sum_{i=1..n} n_i$, sendo n o número de regras. Para o conjunto apresentado em (2.4), os FLRG gerados seriam $A_1 \rightarrow A_1, A_2, A_3$ e $A_2 \rightarrow A_1, A_3$, diferenciando-se das apresentadas na Tabela 2.2, cujos pesos seriam conforme mostra a Tabela 2.4.

O método *Exponentially Weighted Fuzzy Time Series* (EWFTS) é utilizado em Sadaei et al. (2014) e contrasta com o crescimento linear dos pesos proposto por (Yu 2005), modificando-os por um crescimento exponencial. Dada a FLRG $A_i \rightarrow A_1, A_3, \dots, A_k$, a

Tabela 2.4.: Valores de pesos com base na quantidade de recorrências

Regra	Recorrências	Pesos
$A_1 \rightarrow A_1, A_2, A_3$	2,1,1	2/4, 1/4, 1/4
$A_2 \rightarrow A_1, A_3$	1,3	1/4, 3/4

matriz $M(t) = [m_1, m_2, \dots, m_k]$ dos centros de A_1, A_3, \dots, A_k , a matriz de pesos $w(t)$ será definida por um parâmetro c , que formará a série exponencial c^0, c^1, \dots, c^{k-1} normalizada conforme (2.11). O parâmetro c deve ser maior do que zero.

$$w(t) = \left[\frac{1}{\sum_{h=1}^k c^{h-1}}, \frac{c^1}{\sum_{h=1}^k c^{h-1}}, \dots, \frac{c^{k-1}}{\sum_{h=1}^k c^{h-1}} \right] \quad (2.11)$$

2.4. Conclusão

Neste capítulo foram apresentados conceitos de FTS e predições, além de alguns trabalhos relacionados. Foram listados alguns dos principais modelos de FTS e suas técnicas para predição de valores futuros, bem como suas representações matemáticas e características. No trabalho corrente é proposto um método FTS que faz uso de uma série de conceitos dos trabalhos apresentados aqui. Características dos métodos de primeira ordem como os procedimentos de modelagem e predição, divisão do universo em intervalos, o uso dos FLRs e FLRGs e métodos de ponderação são referências para o desenvolvimento do método proposto neste trabalho. No Capítulo 3 são apresentadas algumas características acerca de qualidade de redes.

Capítulo 3.

Qualidade de Serviço e Experiência

3.1. Introdução

Este capítulo tem como foco descrever aspectos e características referentes a qualidade em rede. Além disso, são descritos algumas ferramentas e técnicas usadas para aferir qualidade em geral.

As redes de computadores foram criadas para substituir o antigo modelo onde apenas um computador era usado para suprir as necessidades de uma organização ou empresa. Há uma rede quando dois ou mais computadores estão interconectados entre si, trocando informações através de um meio de comunicação. Com o passar do tempo, o uso de diversos computadores interconectados se tornou comum, desde grandes empresas até ambientes domésticos (Kurose & Ross 2016).

Com o crescimento do uso das redes e a popularização do serviço de acesso à internet, não somente a disponibilidade de acesso se tornou importante, mas também a necessidade de uma conexão que possa garantir qualidade. A partir disso, alguns parâmetros para análise de qualidade, sejam eles baseados em informações da rede, conhecidas como qualidade de serviço (*Quality of Service* - QoS), ou em análises subjetivas por parte dos usuários, conhecidas como qualidade de experiência (*Quality of Experience* - QoE), ganharam destaque ou foram criados. Nas subseções seguintes são apresentadas as principais métricas para medida de qualidade, com foco especial nas métricas de QoS.

3.2. Métricas de Qualidade de Serviço

Qualidade de serviço retrata o desempenho de um fluxo de dados quando submetido à parâmetros existentes na rede, podendo assim tomar decisões no que tange ao percurso a ser seguido, a prioridade de cada pacote e os recursos necessários para o bom tráfego da informação. A partir da leitura de tais parâmetros, o tratamento do tráfego de rede pode ser otimizado pelo uso de mecanismos que ofereçam serviços adicionais ao modelo de melhor esforço, usados por padrão em redes TCP/IP, a fim de prover os recursos exigidos para o bom desempenho das aplicações, priorização assim características como largura de banda, perda de pacotes, atrasos e suas variações (Dalbem & Pinto 2016).

Oferecer níveis aceitáveis de QoS é um fator muito importante quando analisamos as conexões de rede atuais, visto que a demanda por conteúdo hoje é bem maior que há poucos anos atrás. Isso se torna mais evidente quando analisamos o comportamento de aplicações multimídias, porém, mesmo assim cada uma delas, dependendo da sua natureza, é mais sensível ao atraso, ou à variação desse, ou mesmo a perda de informação.

Mesmo com métricas de QoE bem elaboradas, que normalmente são criadas para aferir qualidade para um determinado tipo de tráfego, as aplicações multimídias podem transmitir diversos tipos de dados, mesmo que em essência uma aplicação trafegue vídeo, ela também pode enviar outras informações necessárias para o seu bom desempenho. Sendo assim, as métricas que alcançam o mais simples e melhor gerenciamento de um fluxo de informações na rede são as ditas de QoS, das quais pode-se citar como as mais conhecidas: perda de pacotes; atraso fim-a-fim; variação do atraso (*jitter*) e vazão (*throughput*) (Gomes et al. 2010).

3.2.1. Atraso fim-a-fim

Atraso fim-a-fim é o período de tempo entre o envio de uma mensagem por um nó da rede até sua recepção pelo nó destino. O atraso ocorre tanto no caminho de transmissão (cabos) quanto em um dispositivo que processa informações no meio do caminho de transmissão (roteadores e comutadores). Em um roteador, o atraso é o montante de tempo entre a recepção do pacote e a sua retransmissão. Dependendo do congestionamento de tráfego, os roteadores podem demorar mais ou menos tempo para retransmitir tais dados. Este tempo é também referido como atraso de propagação. O impacto do atraso em aplicações

de áudio, por exemplo, pode ser imperceptível para valores de até 150 milissegundos, aceitáveis para valores entre 150 e 400 milissegundos e catastróficos para valores acima de 400 milissegundos (Kurose & Ross 2016).

3.2.2. Variação do atraso (*jitter*)

Quando uma informação é enviada para um outro nó da rede ela é segmentada em um fluxo de pacotes e segue por diversos caminhos, muitas vezes, com distâncias e tempos de atraso diferentes. O *jitter* é uma distorção ocorrida do tempo de chegada de um pacote se comparado ao tempo original de transmissão entre os demais pacotes de um fluxo de informação. Caracteriza uma distorção que acontece, por exemplo, quando fluxos de voz ou vídeo são transmitidos em uma rede e os pacotes não chegam no seu destino dentro da ordem sucessiva ou em uma determinada cadência, ou seja, eles variam em termos de tempo de atraso. Evidentemente a informação completa só tem sentido contínuo quando todos os pacotes estão presentes e em ordem sucessiva. Esta distorção é particularmente prejudicial ao tráfego multimídia, fazendo com que o sinal de áudio ou vídeo tenham uma qualidade distorcida ou fragmentada na recepção. Um exemplo de aplicação que tem o *jitter* como inimigo é o serviço de Voz sobre IP (VoIP). Para este tipo de tráfego, tanto o efeito do *jitter*, quanto a solução mais simples, o uso de *buffers*, prejudicam bastante seu funcionamento. Por exemplo, a utilização de *buffer*, para reorganização de pacotes no destino de uma comunicação, seria mais prejudicial para uma comunicação VoIP, *Streaming* de Vídeo ou de jogos on-line, do que o descarte de alguns pacotes já comprometidos por altos valores de *jitter*. Pode parecer estranho, mas em redes de computadores a falta de pequenas partes de um arquivo de som ou voz pode não prejudicar o entendimento. Ainda, se a perda de partes do som da voz de um interlocutor, em uma conversa via VoIP, comprometer o entendimento do que foi dito, o próprio ouvinte pode pedir para repetir o que foi dito e a conversa segue seu curso naturalmente (Tanenbaum 2016).

3.2.3. Perda de Pacotes

A perda de pacotes representa o número de pacotes que foram transmitidos na rede, mas não alcançaram seu destino em um determinado período de tempo. A perda de pacotes causa um impacto direto no desempenho de aplicações, principalmente as multimídias, muitas vezes ocasionando a falha catastrófica de uma aplicação. Normalmente, as perdas

são relacionadas a erros de transmissão dos dados ou limitação dos dispositivos envolvidos na transmissão dos dados (Costa et al. 2012).

Em geral, todo tipo de aplicação pode ser ou não sensível à perda de pacotes. Basicamente o que determina se uma aplicação será afetada é a porcentagem de pacotes perdidos em uma transmissão. Taxas de perdas entre 1 e 20% são aceitáveis, porém uma aplicação dificilmente funcionará para valores acima de 20% (Kurose & Ross 2016).

3.2.4. Vazão

Largura de banda é uma medida de capacidade de transmissão de dados, normalmente expressa em *bits* por segundo (bps), *kilobits* por segundo (Kbps) ou *megabits* por segundo (Mbps). A largura de banda indica a capacidade máxima de transmissão teórica de uma conexão. Entretanto, na medida em que a taxa de transmissão utilizada se aproxima da largura de banda teórica máxima, fatores negativos como atraso na transmissão das informações podem causar deterioração na qualidade. A largura de banda de uma rede pode ser vista como um tubo que transfere dados. Quanto maior o diâmetro do tubo, mais dados podem ser enviados através dele simultaneamente. A vazão é o montante de tráfego de dados movidos de um nó da rede para outro em um determinado período de tempo (Kurose & Ross 2016).

3.3. Métricas de Qualidade de Experiência

Diferentemente de QoS, que analisa qualidade do ponto de vista do comportamento de valores relacionados à rede, QoE mensura qualidade a partir de fatores subjetivos como a percepção do usuário sobre um determinado serviço ou aplicação. O processo de avaliação baseado em QoE pode ser feito tanto de forma subjetiva, e.g., quando a avaliação tem por base a expressa opinião dos usuários através de fatores como emoção e experiência, quanto objetiva, e.g., onde há a tentativa de modelar a percepção humana através de algoritmos baseados em informações da rede, transporte e fatores de aplicação (da Silva 2015).

A abordagem mais precisa para se avaliar qualidade é a subjetiva, simplesmente porque não há melhor indicador do que o concedido por seres humanos. Porém, o índice de qualidade dado por um ser humano depende de diversos fatores como a experiência em

avaliação, o grau de conhecimento e discernimento do avaliador e até mesmo o humor e emoções presentes no momento da avaliação (ITU-T 2007).

Os métodos de avaliação subjetiva se baseiam em técnicas definidas por padrões internacionais, como a ITU-T. Existem normas específicas para cada área de atuação, como televisão, rádio, aplicações multimídia entre outras. Além disso, há recomendações para cada etapa da análise, desde o ambiente, escolha dos avaliadores e metodologia de testes. Existem algumas normas específicas para avaliação por tipo de conteúdo multimídia, como as ITU-T BT.500 e P.900 para vídeo (Takahashi et al. 2008).

Os métodos de avaliações objetivos usam de artifícios computacionais e matemáticos para tentar simular a percepção humana. Entre as diversas técnicas pode-se citar o *Peak Signal to Noise Ratio* (PSNR) que tenta estimar o nível de qualidade para *streaming* de vídeo de acordo com a percepção humana. O PSNR verifica a soma das diferenças quadráticas de todos os *pixels* entre uma imagem processada e a imagem original através do cálculo de *Mean Square Error* (MSE). Outra métrica bastante usada para aferir qualidade é a *Structural Similarity Index*(SSIM) que avalia *frame a frame* os componentes de cor, luminosidade e estrutura e combina-os em um único valor chamado índice (*index*). A SSIM leva em consideração aspectos que refletem com mais prioridade a maneira como o sistema visual humano extrai informação das imagens. Já a métrica *Video Quality Metric* (VQM) define um conjunto de modelos computacionais que tentam avaliar a qualidade de um vídeo usando parâmetros de distorção da cor, *pixels*, ruídos e nível de borramento. Os vídeos original e processado são usados como entrada e a partir de então se verifica o nível de qualidade baseado na percepção do olho humano (Hore & Ziou 2010).

3.4. Coleta de informações da rede

O primeiro passo no processo que envolve a identificação e o tratamento de dados é a coleta de informações da rede. Essa traz detalhes que permitem entender o comportamento das métricas de QoS. Isto facilitará o desenvolvimento da proposta, visto que as características dos dados coletados acabam por nortear as decisões ao longo da sua construção. Há diferentes formas de se coletar informações de uma rede, e essa escolha passa por questões como a quantidade de recursos disponíveis e o tipo de problema que se deseja identificar.

Métricas de QoS como atraso fim-a-fim, *jitter* e perda de pacotes podem ser facilmente obtidas através de requisições de *Internet Control Message Protocol* (ICMP) pela rede. O

ICMP, definido pela RFC 792, foi originalmente desenvolvido para relatar erros no envio de pacotes IP. Ele é um protocolo leve e presente em todo sistema operacional e equipamento que utiliza protocolo IP. Aplicações como o *ping* e *traceroute* podem obter tais valores, mesmo que sejam corriqueiramente classificadas com imprecisas. Seu funcionamento consiste no envio e recebimento de pacotes para um equipamento de destino. Se o destino estiver ativo, o pacote é recebido e uma resposta é enviada de volta. Com isso, o tempo de ida e volta do pacote pode ser calculado. O envio sistemático de requisições ICMP permite que se identifique também a variação do atraso. A perda é facilmente identificada, caso não haja resposta (Pelsser et al. 2013).

Outro protocolo utilizado para se obter dados de monitoramento é o *Simple Network Management Protocol* (SNMP). Definido pela RFC 1157, é o protocolo padrão para gerência de redes TCP/IP. O SNMP é um padrão de gerência simples, que requer poucos recursos para ser implementado. Ele oferece um conjunto de operações que permitem o monitoramento de diferentes dispositivos de rede como roteadores, servidores, switches, impressoras entre outros. As informações que podem ser coletadas utilizando o protocolo SNMP variam desde estatísticas como a quantidade de bytes que ingressaram numa determinada interface, a indicadores como a temperatura interna de um equipamento (Zarpelão et al. 2010). Sistemas como Nagios e Zabbix suportam SNMP para monitoramento e gerenciamento de redes.

3.5. Conclusão

Neste capítulo foi apresentado em vias gerais as definições de QoS e QoE em redes de pacotes. Foram introduzidas métricas de qualidade de serviço e de qualidade de experiência para redes baseadas em IP, e suas respectivas características. De forma geral, definir quais métricas podem representar a melhor leitura do comportamento de uma rede é essencial para o presente trabalho. Métricas de QoE demandam tempo, processamento e são mais complicadas de serem implementadas enquanto as métricas de QoS são basicamente leituras dos parâmetros da rede, o que representa bem seu comportamento e pode ser usada para descrevê-lo. Desta forma as métricas de QoS apresentadas aqui foram escolhidas para modelar as séries temporais utilizadas neste trabalho. Tais series são as entradas usadas na tentativa de prever a qualidade das redes.

Capítulo 4.

Método de predição proposto

4.1. Introdução

O uso de séries temporais para a predição de qualidade de redes vem sendo estudada há algum tempo, conforme exposto na seção 1.2, e é, sem dúvida, uma abordagem com resultados promissores. Os métodos FTS são uma evolução na metodologia de séries temporais e, mesmo assim, ainda são muito restritas, em sua aplicação, ao mercado financeiro, medicina, entre outras áreas. O uso de FTS para predição de qualidade de rede é ainda pouco explorado. Adicionalmente, os métodos clássicos são, em sua maioria, desenvolvidos com foco em outras áreas .

Desenvolver metodologias ou métricas capazes de avaliar ou mesmo predizer qualidade de rede, conforme comentado no Capítulo 3, é de suma importância para o atual cenário. Cada vez mais há a necessidade de tais mecanismos para auxiliar tanto na medição de qualidade quanto no gerenciamento dos provedores de serviços da rede.

Neste capítulo, é descrito o método de predição proposto que busca aplicar uma metodologia FTS para predição de qualidade em redes. No desenvolvimento da proposta, inicialmente, realiza-se o levantamento das características e comportamentos de métricas em redes de computadores. As definições de qualidade, usadas para descrever o comportamento das redes, são obtidas pelas métricas de QoS atraso fim-a-fim, *jitter* e perda de pacotes. O método proposto introduz uma fórmula de regressão linear calculada a partir das FLRs geradas. O intuito dessa inovação é capturar as tendências locais de cada conjunto *fuzzy* precedente (*LHS*), tornando a predição mais dinâmica e suave. A proposta é um método de primeira ordem invariante no tempo, os quais possuem a característica de serem de baixo

custo computacional. Mesmo que não seja foco do trabalho criar um método de baixo custo é algo que pode agregar valor à proposta, visto as dinâmicas mudanças nas avaliações de QoS/QoE em redes. Além disso, buscando descrever melhor os comportamentos futuros da rede, a proposta utiliza características dos métodos FTS ponderados. Usando informações presentes nas FRLs obtidas, o método pondera os valores de predições de acordo com as quantidades de ocorrências de mudanças presentes na série e seus conjuntos *fuzzy*.

4.2. Descrição do Método de Predição Proposto

Métodos de regressão estimam modelos que quantificam as relações de dependência entre variáveis por meio de coeficientes estimados a partir da correlação linear entre elas. No caso das séries temporais são utilizados n atrasos temporais $F(t - 1), \dots, F(t - n)$, da mesma variável, como preditores para um valor futuro $F(t)$. A estimação dos coeficientes desse modelo é utilizada nos métodos AR, ARMA e ARIMA. A metodologia de Box-Cox utiliza a função de autocorrelação (*Auto Correlation Function* - ACF) para determinar o número de regressores do modelo.

Técnicas que usam regressão linear são frequentemente aplicadas na tentativa de estimar valores em geral, inclusive para QoS em redes de computadores. Em Costa et al. (2012) e Leite de Araújo & de Castro Monteiro (2013) são propostas equações de ajuste com regressão na tentativa de prever QoS a partir do nível de sinal (*Received signal strength indication* - RSSI) de redes sem fio, obtendo resultados promissores de correlação. Em Cavalca (2011) regressão linear é aplicada na tentativa de estimar valores de processamento e uso de memória em roteadores, vazão e número de pacotes em *links ethernet* para gerenciamento de recursos de rede, identificando alto grau de correlação entre as variáveis estudadas.

Como proposta original, o método apresentado nesta dissertação agrega as características das funções de auto regressão com modelos de séries temporais nebulosas. Isto objetiva melhorar a acurácia em estudos com séries temporais modeladas a partir de variáveis de redes. Essa metodologia identifica tendências de crescimento e decrescimento lineares dos valores da série que estão presentes nos conjuntos *fuzzy*. Para cada tentativa de prever um momento $F(t + 1)$, são ajustadas regressões lineares com base em alguns pontos presentes em cada conjunto *fuzzy* consequente (RHS) até o momento $F(t)$. Determinadas as equações de ajuste, é então calculado um valor que auxilia o processo de predição de $F(t + 1)$. Os

métodos clássicos da literatura, mesmo os que usam ponderações, tendem a usar os valores dos centroides dos conjuntos *fuzzy* como valor de referência para os cálculos de predição. O método proposto introduz os valores obtidos através das equações de regressão para se tornarem a base preditiva por trás do modelo.

Em métodos FTS o processo de construção do modelo passa pela divisão do universo de discurso em conjuntos *fuzzy*. A predição de um valor futuro é estritamente relacionada ao ponto médio do conjunto, que é definido pelo centroide dessa partição. Os valores de variáveis que descrevem o comportamento em redes de computadores são altamente estocásticas e estacionárias. Partindo desse pressuposto, na tentativa de aprimorar as previsões dos valores das variáveis de rede, o método proposto define os centroides de cada conjunto pela média dos valores presentes na partição. Com essa modificação, ao definir o valor futuro da série, estima-se que a acurácia do método seja melhorada.

O método proposto é explicado em duas partes: procedimento de construção e previsão. Por fim é apresentada a aplicação do método na série temporal *Enrollment* da Universidade do Alabama. O procedimento de construção do modelo baseia-se em Song & Chissom (1993b) e Chen (1996) e pretende construir a base de regras FLRG, conforme apresentado a seguir:

Procedimento de construção de modelo:

1. Definir o universo do discurso U dos dados D como $U = [D_{min} - D_1, D_{max} + D_2]$. D_1 e D_2 devem ser, preferivelmente, valores inteiros, que tornem o universo de discurso U um conjunto com os possíveis valores de predição esperados. Porém, escolher um universo de discurso muito amplo, que alcance uma área onde não há ocorrência de observações, não é recomendado;
2. Particionar o universo do discurso em k intervalos u_i de igual tamanho $\frac{(D_{max}+D_2)-(D_{min}-D_1)}{k}$, onde D_1 e D_2 são apenas números usados para arredondar D_{max} e D_{min} para o próximo múltiplo inteiro de 10;
3. Definir os conjuntos *fuzzy* A_i no universo U . Cada conjunto *fuzzy* será relacionado a um intervalo u_i , terá um ponto médio m_{A_i} e será associado a uma função de associação *fuzzy* triangular $\mu_{A_i}(x)$. O vetor $\mu_{A_i} = [\mu_{A_i}(u_1), \dots, \mu_{A_i}(u_k)]$ representa os valores de associação do conjunto *fuzzy* A_i com os pontos médios de todos os u_i intervalos. Os valores de u_i são definidos pela média dos valores presentes no conjunto. Caso não

existam valores presentes em um determinado conjunto, esse valor de ponto médio representará o centroide do intervalo;

4. Fuzificar os dados históricos D , gerando um novo conjunto de dados D_f . Cada ponto de dados $d_i \in D$ será substituído pelo conjunto *fuzzy* A_k que tem o maior valor de associação $\mu_{A_k}(d_i)$;
5. A partir de D_f são estabelecidos todos os *Fuzzy Logical Relationship* (FLR) entre dois conjuntos no formato $A_i \rightarrow A_j$ onde A_i é um valor fuzificado no tempo t e A_j é o valor fuzificado no tempo $t + 1$ (4.1). Depois de geradas todas as FLRs, as regras duplicadas são eliminadas;

$$\begin{array}{lll}
 A_i \rightarrow A_j & A_i \rightarrow A_k & A_i \rightarrow A_l \\
 A_j \rightarrow A_j & A_j \rightarrow A_l & A_i \rightarrow A_l \\
 A_i \rightarrow A_j & A_j \rightarrow A_l & A_j \rightarrow A_j
 \end{array} \tag{4.1}$$

6. Gerar os FLRGs. O conjunto de regras distintas é então agrupado pelo seu precedente A_i , criando os FLRGs. Por exemplo, o grupo de FLRs em (4.1) gerará o FLRG apresentado em (4.2).

$$\begin{array}{ll}
 A_i \rightarrow A_j, A_k, A_l \\
 A_j \rightarrow A_j, A_l
 \end{array} \tag{4.2}$$

As FLRGs compõem a base de regras do modelo e são legíveis, permitindo sua utilização por especialistas na aquisição de conhecimento. Uma FLRG tem a forma $LHS \rightarrow RHS$ em que: LHS sempre tem um conjunto *fuzzy*, representando $F(t - 1)$; e o RHS tem todos os conjuntos *fuzzy* que seguiram LHS nas FLRs, representando assim todos os possíveis $F(t)$ provenientes de $F(t - 1)$. O número de regras na base está intimamente relacionado com as propriedades estatísticas (esperança, variância e estacionariedade) da série temporal.

Procedimento de previsão:

O procedimento de previsão usa as FRLGs como base. Para cada momento $F(t)$ que pertence a uma FLR, é identificada a FLRG e suas FLRs consequentes, para então se determinar o valor de $F(t + 1)$ considerando três cenários diferentes:

1. $A_i \rightarrow A_j$. Nesse caso $F(t + 1)$ é calculado ajustando-se a regressão linear dos últimos três pontos dentro do conjunto A_j , conforme demonstra a Figura 4.1. Caso não existam pontos necessários para tal, é usado então o valor de m_j , ponto médio do próprio conjunto.

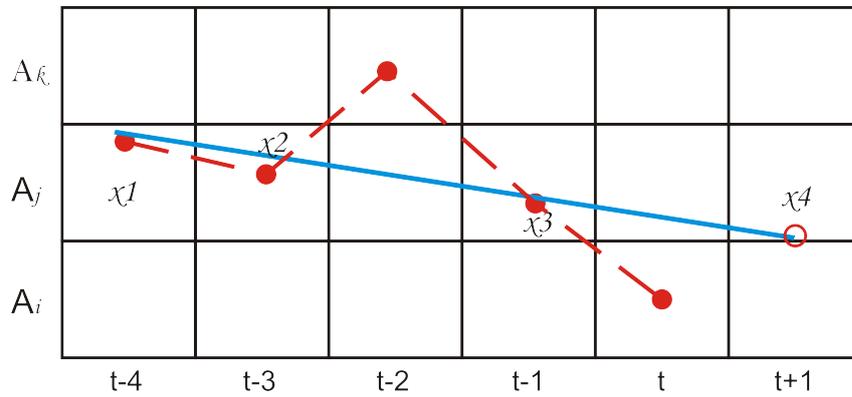


Figura 4.1.: Representação do cálculo de regressão aplicada ao cenário 1

Obtendo-se a equação de regressão linear $Ax + b$, o valor de x será então 4. Em Costa et al. (2017) é proposto um método preliminar ao apresentado aqui, onde todos os pontos presentes no conjunto *fuzzy* são utilizados para se determinar a equação de regressão. O valor de x é obtido por (4.3), nesse caso, se até o momento t existirem 10 pontos dentro do conjunto A_j , o valor de x seria 11. O uso de todos os pontos presentes no conjunto tende a tornar a equação uma reta sem tendência, devido ao comportamento estacionário dos dados aqui estudados, o que pode prejudicar justamente a identificação dessas tendências. Além disso, preditores mais recentes tendem a ser mais significativos por demonstrar um comportamento mais próximo do atual momento. Mesmo que isso não seja uma regra, imagina-se que os dados mais antigos, considerando o presente trabalho, são menos significativos. Assim sendo, o trabalho usa apenas os três últimos pontos de cada conjunto, na tentativa de aprimorar o modelo baseando-se nos comportamentos de redes de computadores.

$$x = 1 + \sum_{i=1}^n i \quad (4.3)$$

2. $A_i \rightarrow A_{j1}, A_{j2}, A_{j3}, \dots, A_{jn}$. Nesse cenário $F(t+1)$ é calculado de forma similar ao cenário 1, porém são ajustadas regressões lineares para cada um dos conjuntos *fuzzy* consequentes, conforme ilustra a Figura 4.2.

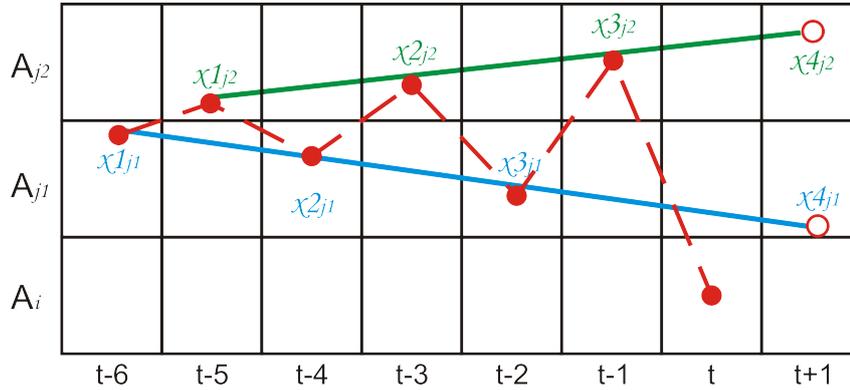


Figura 4.2.: Representação do cálculo de regressão aplicada ao cenário 2

Após obtidas e calculadas as equações de regressão para cada consequente, a média aritmética ponderada desses valores representa o valor final para $F(t+1)$. A média aritmética ponderada x_P de um conjunto de números $x_{j1}, x_{j2}, x_{j3}, \dots, x_{jn}$ cuja importância relativa (peso) é respectivamente $p_{j1}, p_{j2}, p_{j3}, \dots, p_{jn}$ é calculada conforme (4.4).

$$x_P = \frac{\sum_{h=1}^n (p_{jh} * x_{jh})}{\sum_{h=1}^n p_{jh}} \quad (4.4)$$

As ponderações p_{jh} são calculadas de acordo com as quantidades de ocorrências de cada FLR consequente (RHS) presente nos conjuntos A_{jh} . Os valores de x_{ji} são os valores obtidos através do cálculo das equações de regressão. Assim como no cenário 1, caso não existam pelo menos três pontos em cada conjunto A_{jh} consequente (necessários para se ajustar uma regressão linear), o valor de ponto médio do referido conjunto é usado em seu lugar.

3. $A_j \rightarrow \emptyset$. Nesse cenário não há recorrências consequentes com base na série de treinamento, assim $F(t+1)$ é calculado pelo ajuste da equação de regressão linear obtida com base nos últimos 3 valores da série F , observe a Figura 4.3. Na equação $Ax + b$, assim como no cenário 1, o valor de x será 4.

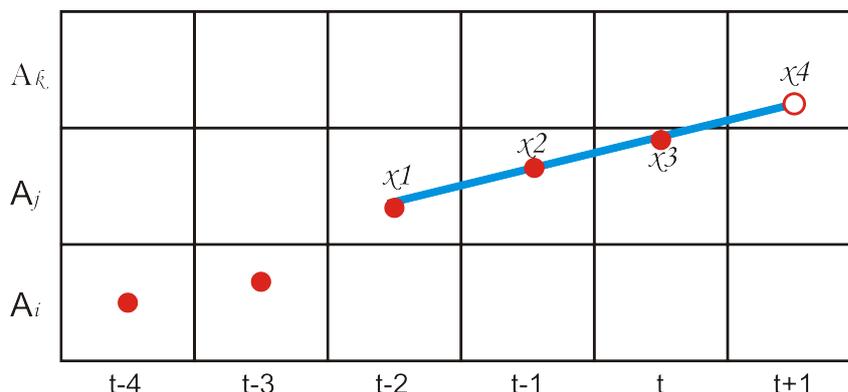


Figura 4.3.: Representação do cálculo de regressão aplicada ao cenário 3

4.3. Exemplo de Aplicação

Para elucidar o funcionamento do método proposto, esta seção se dedica em demonstrar um exemplo de sua aplicação. Para isso emprega-se o conjunto de dados *Enrollments* da Universidade de Alabama, recuperado de Song & Chissom (1993a) e apresentado na Tabela 4.1. Usando um esquema de particionamento com 7 intervalos de mesmo tamanho e funções de pertinência triangulares, obtém-se os conjuntos *fuzzy* listados na Tabela 4.2. Os FLRGs gerados são listados na Equação 4.5. Perceba que os valores de ponto médio dos intervalos A_i são as médias dos valores presentes em cada intervalo. Por exemplo, no intervalo A_1 estão os valores 13055, 13563 e 13867, que resultam no ponto médio de 13495. Perceba também que no intervalo A_5 não há pontos, sendo assim, seu ponto médio é o valor central do intervalo. Neste exemplo, os dados usados para treinamento e testes são os mesmos, uma vez que a proposta desta seção é demonstrar apenas o funcionamento do método. Em aplicações práticas, se convém que tais dados sejam separados.

$$\begin{aligned}
A_1 &\rightarrow A_1, A_2 \\
A_2 &\rightarrow A_3 \\
A_3 &\rightarrow A_3, A_4 \\
A_4 &\rightarrow A_4, A_3, A_6 \\
A_5 &\rightarrow \emptyset \\
A_6 &\rightarrow A_6, A_7 \\
A_7 &\rightarrow A_7, A_6
\end{aligned} \tag{4.5}$$

Dado um valor de entrada, por exemplo $F(t) = 15.984$, pertencente ao conjunto A_3 , tem-se FLRG $A_3 \rightarrow A_3, A_4$. Esse caso encaixa-se no cenário 2 do procedimento de previsão. Logo, ajustando as duas equações de regressão, tem-se os seguintes valores: $A_3 : y = -167x + 15602$ e; $A_4 : y = -209,5x + 17124$, com base nos pontos presentes em cada conjunto da série *Enrollment* (observe a Figura 4.4 com um exemplo ilustrativo).

Como comentado anteriormente, os últimos três pontos presentes no conjunto são utilizados para ajustar a equação de regressão. Logo, para se calcular o valor obtido com

Tabela 4.1.: Tabela de dados: *Enrollment Alabama University*

Date	Enrollment	FLR	Date	Enrollment	FLR
1971	13055	A1	1982	15433	A3
1972	13563	A1	1983	15497	A3
1973	13867	A1	1984	15145	A3
1974	14696	A2	1985	15163	A3
1975	15460	A3	1986	15984	A3
1976	15311	A3	1987	16859	A4
1977	15603	A3	1988	18150	A6
1978	15861	A3	1989	18970	A6
1979	16807	A4	1990	19328	A7
1980	16919	A4	1991	19337	A7
1981	16388	A4	1992	18876	A6

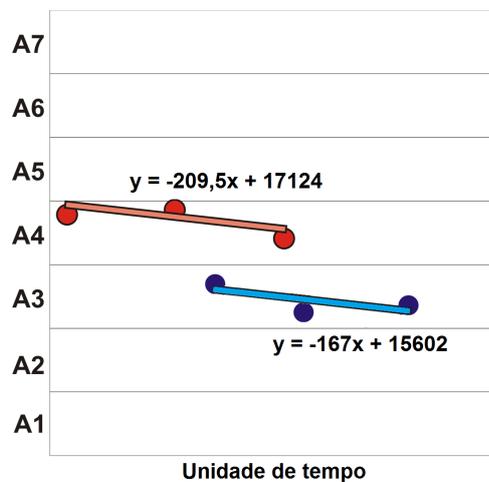


Figura 4.4.: Representação da regressão linear dos pontos dos conjuntos *fuzzy* A3 e A4

as equações de regressão, substitui-se x por 4. Por exemplo, para as equações de A_3 e A_4 obtém-se: $y = -167 * 4 + 15602$ e $y = -209,5 * 4 + 17124$. Resolvendo as equações obtém-se: $A_3 : y = 14934$ e $A_4 : y = 16286$.

Para calcular o valor final de $F(t + 1)$, ainda é necessário identificar o peso de cada conseqüente, nesse caso, A_3 e A_4 . Os pesos são definidos pela quantidade de ocorrências de cada conseqüente a partir da regra precedente, ou seja, A_3 ($A_3 \rightarrow A_3, A_4$). As ocorrências das FLRs podem ser observadas nas colunas FLRs da Tabela 4.1, onde o ano mais anterior é a precedente (LHS) e o ano seguinte é a conseqüente (RHS). Há sete ocorrências de $A_3 \rightarrow A_3$ e duas de $A_3 \rightarrow A_4$, desse modo, aplicando (4.4) obtém-se:

Tabela 4.2.: Divisão dos conjuntos *Fuzzy* para a série *Enrollments*

Fuzzy	Limite Inferior	Ponto Médio	Limite Superior
A_1	13000	13495	14000
A_2	14000	14696	15000
A_3	15000	15495,22	16000
A_4	16000	16743,25	17000
A_5	17000	17500	18000
A_6	18000	18668,33	19000
A_7	19000	19332,50	20000

$$F(t + 1) = \frac{14934 * 7 + 16286 * 2}{9} = 15234,44 \quad (4.6)$$

O valor obtido em (4.6) é o valor final para $F(t + 1)$. O valor original da série nesse momento é de 16859. A Figura 4.5 expõe o resultado obtido aplicando o método em toda a série temporal *Enrollment* com os parâmetros supracitados.

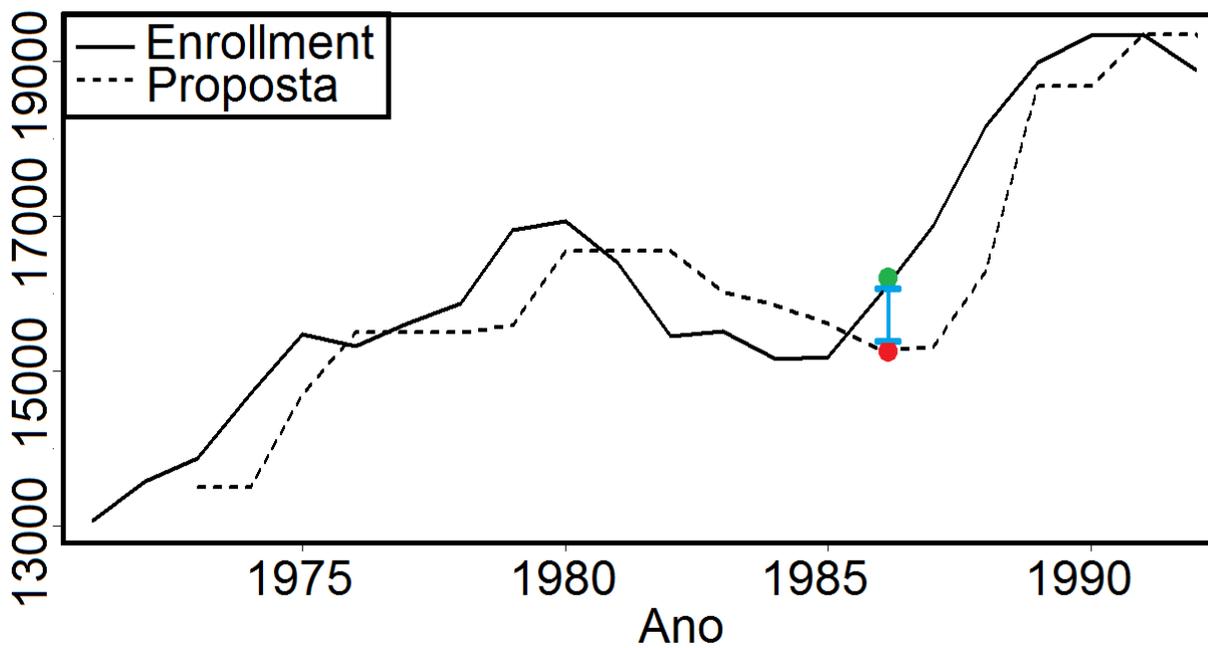


Figura 4.5.: Comparação da previsão do método proposto aplicado à série temporal original *Enrollments*

4.4. Conclusão

Neste capítulo foi discutido e explanado o método FTS proposto. Foram discutidas algumas características presentes em redes de computadores e as estratégias para direcionar a construção do método para os ambientes de redes.

O método proposto foi construído e explicado, de forma teórica, em duas partes. Na primeira, o procedimento de construção e previsão, baseado principalmente nos trabalhos de (Song & Chissom 1993b) e (Chen 1996) demonstra características de como se deve definir o universo de discurso, seu particionamento e geração das regras FLRs. O procedimento de previsão determina como devem ser os cálculos dos valores futuros da série, com base em 3 cenários possíveis.

Com a explicação através de um exemplo de aplicação do método proposto, torna-se mais claro como é o procedimento de construção e previsão. A série *Enrollment* é usada para demonstrar o funcionamento do método.

No exemplo de aplicação, não é apresentada uma comparação do método proposto com os métodos presentes na literatura, visto que o intuito aqui é apenas de demonstrar seu funcionamento. Porém, em (Costa et al. 2017), um método preliminar ao apresentado neste trabalho demonstrou competitividade com os demais. Observa-se que, modelando o método para atender às características específicas de redes, a proposta apresentada tem mais chances de acurácia.

Capítulo 5.

Metodologia

5.1. Introdução

Detalhada a proposta de construção do método FTS, partiu-se para a definição do cenário de testes, que tem como objetivo validar a proposta. Nesta etapa do trabalho, busca-se verificar a eficácia do método, analisando leituras de comportamento de métricas de QoS de redes em geral.

Para a validação da proposta, o método é confrontado contra outros métodos conhecidos na literatura, mensurando sua acurácia através de métricas de avaliação. Nesta etapa, dados de QoS de rede são coletados e modelados como séries temporais.

Para medir a acurácia do método as métricas *Mean Absolute Percent Error* e *Root Mean Squared Error* são utilizadas. Uma variação da métrica *Prediction of Change in Direction* também é usada para medir a eficiência do método. Testes estatísticos são planejados para verificar se o método proposto é superior aos demais.

5.2. Coleta de dados e cenário de testes

Inicialmente partiu-se para a definição de quais métricas de avaliação de qualidade seriam usadas no trabalho. As métricas de QoS, atraso fim-a-fim, *jitter* e perda de pacotes foram escolhidas para mensurar a qualidade das redes estudadas. Como comentado na seção [3.2](#), as métricas de QoS alcançam o mais simples e melhor gerenciamento de um fluxo de informações na rede. Neste trabalho busca-se prever a qualidade do tráfego de rede em

geral, sem de fato priorizar um tipo de tráfego. A escolha das métricas de QoS se deu em função de sua fácil obtenção e capacidade de descrever características de qualidade para diversos tipos de aplicações.

Consequentemente, foi necessário definir como os dados de QoS seriam coletados e modelados em séries temporais. Para a coleta de dados, optou-se por usar o envio e recebimento de requisições ICMP, a partir de uma rede de origem até uma rede de destino, via aplicação **Ping**.

O Ping é baseado em duas mensagens, o *echo request* e *echo reply*. Um computador de origem envia uma mensagem de *echo request* para uma outra máquina de destino, essa, por sua vez, ao receber a mensagem de “*echo request*”, responde ao computador de origem com um “*echo reply*”. Medindo-se o tempo de ida-e-volta das requisições é possível mensurar as variáveis de atraso fim-a-fim e *jitter*. Caso o computador de destino não responda, indicará um *timeout* (tempo de resposta expirado), indicando que houve a perda de um pacote.

Para modelar as requisições ICMP obtidas através do Ping, um coletor de amostras foi desenvolvido usando a linguagem de programação *Python*. A aplicação Ping envia uma requisição ICMP e aguarda o seu retorno. Mesmo em um prazo curto de tempo, através do Ping, é possível enviar e receber milhares de requisições ICMP. Os dados recebidos através do Ping são amostras isoladas e não representam uma série de tempo. Sendo assim, para que esses dados possam representar uma série temporal, o coletor de amostras modela os dados obtidos através do Ping em amostras com a média valores de atrasos fim-a-fim e *jitter* e a quantidade de pacotes perdidos em intervalos definidos de tempo. Tais intervalos normalmente são escolhidos arbitrariamente ou de acordo com as características de uma aplicação. A Figura 5.1 e o Algoritmo 5.1 ilustram a estrutura geral do coletor.

5.3. Avaliação da capacidade preditiva da proposta

O cenário proposto aqui visa, como objetivo principal, medir a acurácia da proposta em prever o comportamento futuro da série, frente aos demais métodos da literatura. Logo, não tem como foco a avaliação de um determinado tráfego de rede, considerando as características específicas de uma aplicação como, por exemplo, vídeo sob demanda. Sendo assim, é preciso primeiramente modelar a coleta de dados como uma série temporal. Para isso, arbitrariamente, a série foi modelada em intervalos de 1 minuto. Esse intervalo de tempo expressa bem a variação do comportamento de uma rede, sendo que tempos

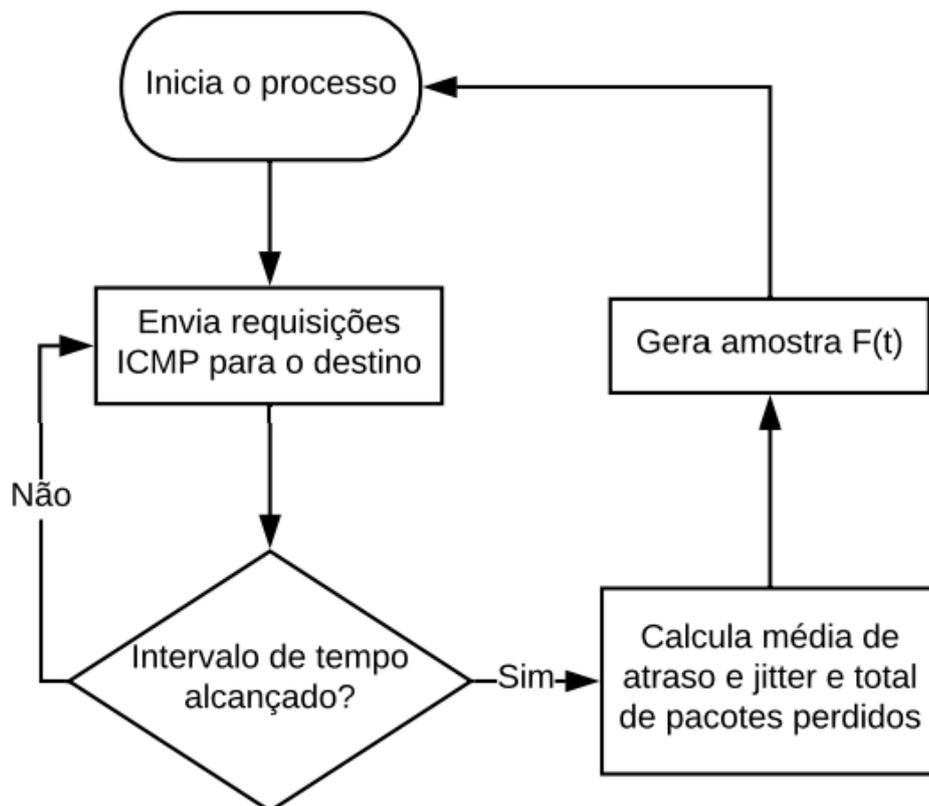
Algoritmo 5.1: Coletor de Amostras ICMP**Input:** t (Tempo em minutos), n (Quantidade de requisições ICMP)

```

1 begin
2   inicio = time(now);
3   i = 0;
4   while  $time(now) \leq inicio + t$  do
5     |  $QoS[i] = ExecPing(n)$ ;
6     | i++;
7   end
8    $t_a = mean(QoS.atraso)$ ;
9    $t_j = mean(QoS.jitter)$ ;
10   $t_p = sum(QoS.perda)$ ;

```

11 end

Output: $inicio, t_a, t_j, t_p$ **Figura 5.1.:** Diagrama do coletor de amostras

maiores podem gerar valores médios das variáveis muito próximos, já que os dados possuem comportamento estocástico.

Na tentativa de testar o método com diferentes tipos de tráfego de redes, 3 séries temporais foram coletadas em ambientes com características distintas e em horários diferentes. As coletas foram realizadas a partir dos campi do Instituto Federal de Educação, Ciência e Tecnologia do Tocantins (IFTO) de Palmas-TO e Lagoa da Confusão-TO. Os horários e datas das coletas são horários de pleno funcionamento dos campi. Os computadores envolvidos na coleta estão conectados às respectivas redes locais através de uma conexão *ethernet* de 100 Mbps. Os links dos provedores de internet entre as localidades escolhidas não são controlados.

A primeira série coletada possui os dados de QoS entre o servidor *firewall* da rede do IFTO Campus Lagoa da Confusão e o servidor HTTP da UFMG (<http://ufmg.br>), no dia 28/08/2017 de 08:20 às 11:40, ilustrados na Figura 5.2. Essa conexão tem características como: tecnologias *Wi-Fi* na entrega dos *links*; a operadora local, que entrega o *link*, terceiriza serviço a partir de operadoras maiores.

A segunda detém os dados de QoS entre um computador cliente da rede do IFTO campus Palmas e o servidor HTTP da UNICAMP (<http://www.unicamp.br>) no dia 20/09/2017 de 07:40 às 11:00, ilustrados na Figura 5.3. Nessa conexão o link de dados é entregue pela Rede Nacional de Pesquisa (RNP) com acessos via fibra ótica e boa qualidade de conexão.

Por fim, a terceira série contém os dados de QoS entre um computador cliente da rede LabMática e o servidor *Gateway* do GREDES, ambos localizados na rede LAN do IFTO campus Palmas, no dia 19/09/2017 de 16:55 até 20:15, ilustrados pela Figura 5.4. Nessa conexão há um enlace de 100 *mbps* e as máquinas estão ligadas ao *backbone* do IFTO Campus Palmas, onde toda a conexão do campus, como tráfego dos laboratórios e acesso à internet por estudantes, passa.

Coletadas as amostras, para a validação do método, os dados foram divididos em dois subconjuntos disjuntos de instâncias, p e $1 - p$, onde tipicamente $p = 1/2$ ou $p = 2/3$. O primeiro subconjunto serve como conjunto de treinamento e o segundo como conjunto de teste (Ishibuchi & Nojima 2013). Logo, o conjunto de dados obtido foi dividido em dois subconjuntos em que $2/3$ dos dados são utilizados para treinamento e os demais $1/3$ para previsão.

Após realizado o treinamento, todas as previsões são feitas com o modelo obtido baseado nos dados de teste. Ou seja, não há atualização do modelo de previsão com a inclusão de regras mais recentes. O universo do discurso dos dados foi definido e conseqüentemente

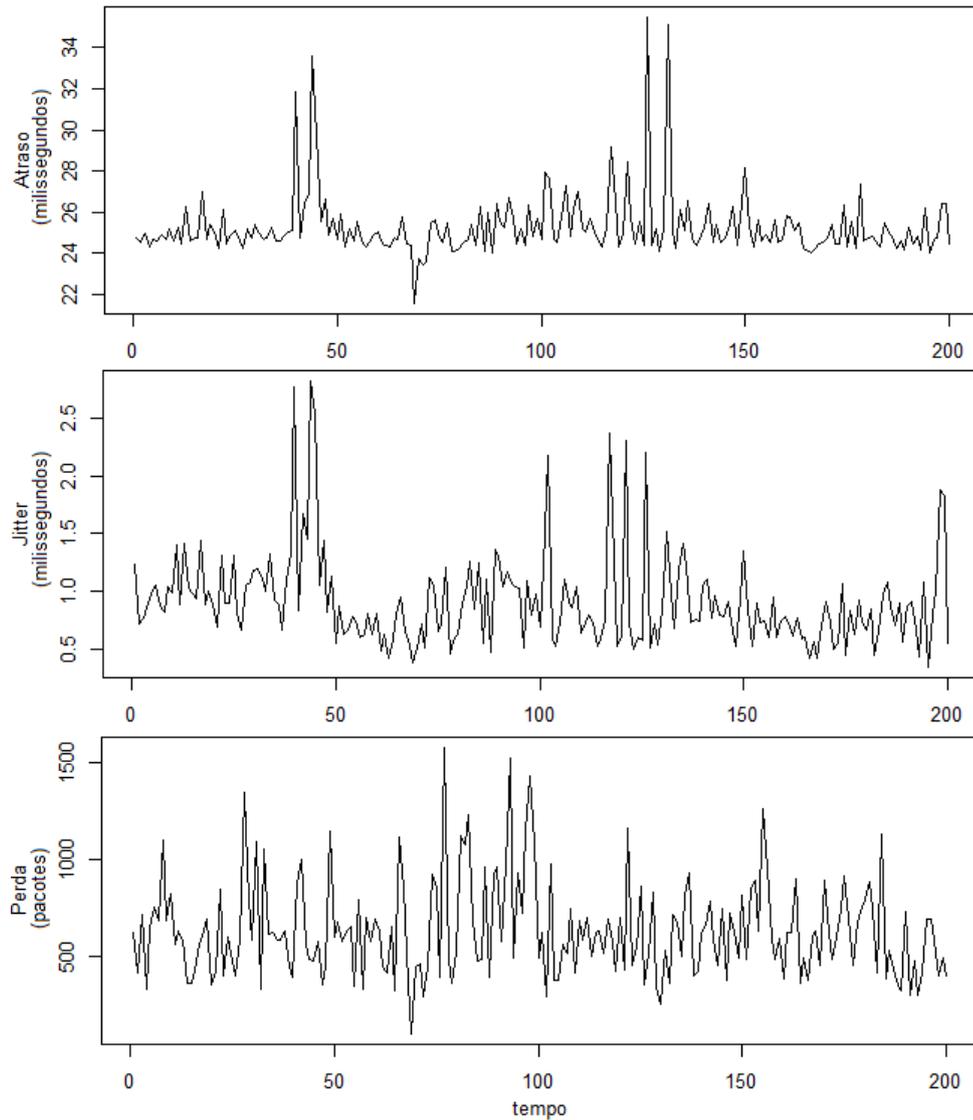


Figura 5.2.: Série temporal IFTO Lagoa da confusão - UFMG

dividido em um esquema de grade, com um total de 3 conjuntos, cada um com o mesmo comprimento e associados à uma função de pertinência triangular. Toda a definição do universo de discurso é baseada apenas nos dados de treinamento. Cada modelo foi treinado e testado para os conjuntos de 3, 5 e 7 partições, conforme ilustra a Figura 5.5.

As métricas usadas para avaliar e medir a acurácia do modelo foram o *Mean Absolute Percent Error* (MAPE), descrito em (5.1), e *Root Mean Squared Error* (RMSE), descrito em (5.2). Y representa os dados reais e \hat{Y} os valores previstos. O MAPE possui uma desvantagem quando existem valores zerados na série temporal, pois, se algum dos valores

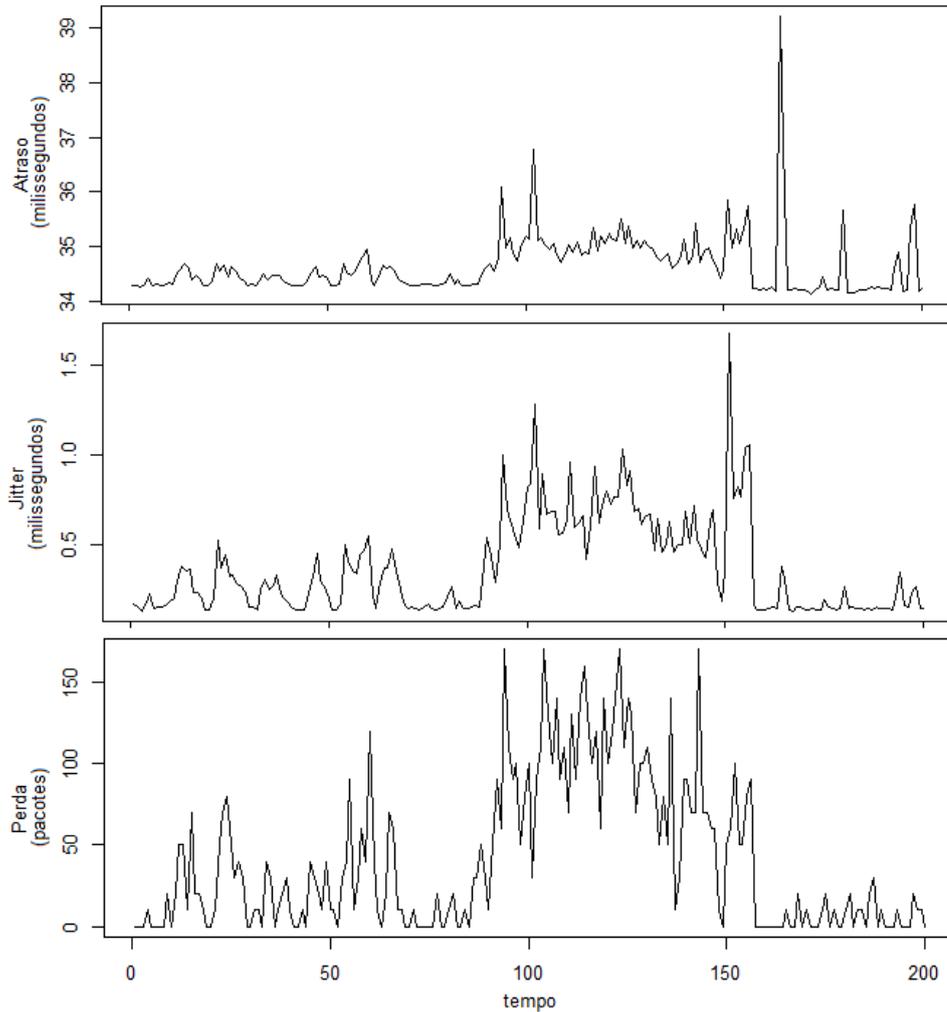


Figura 5.3.: Série temporal IFTO Palmas - Unicamp

observados for igual a zero, o MAPE tenderá ao infinito. Caso o MAPE não demonstre bem o resultado, ainda pode-se usar o valor de RMSE. A medida RMSE usa a mesma unidade dos valores de referência. Sendo assim, é uma boa medida porque geralmente representa explicitamente o que vários métodos tendem a minimizar. O RMSE é a medida da magnitude média dos erros estimados. Ele tem valor sempre positivo e quanto mais próximo de zero, maior a qualidade dos valores medidos ou estimados (Chai & Draxler 2014).

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{Y_i - \hat{Y}_i}{Y_i} \right| \quad (5.1)$$

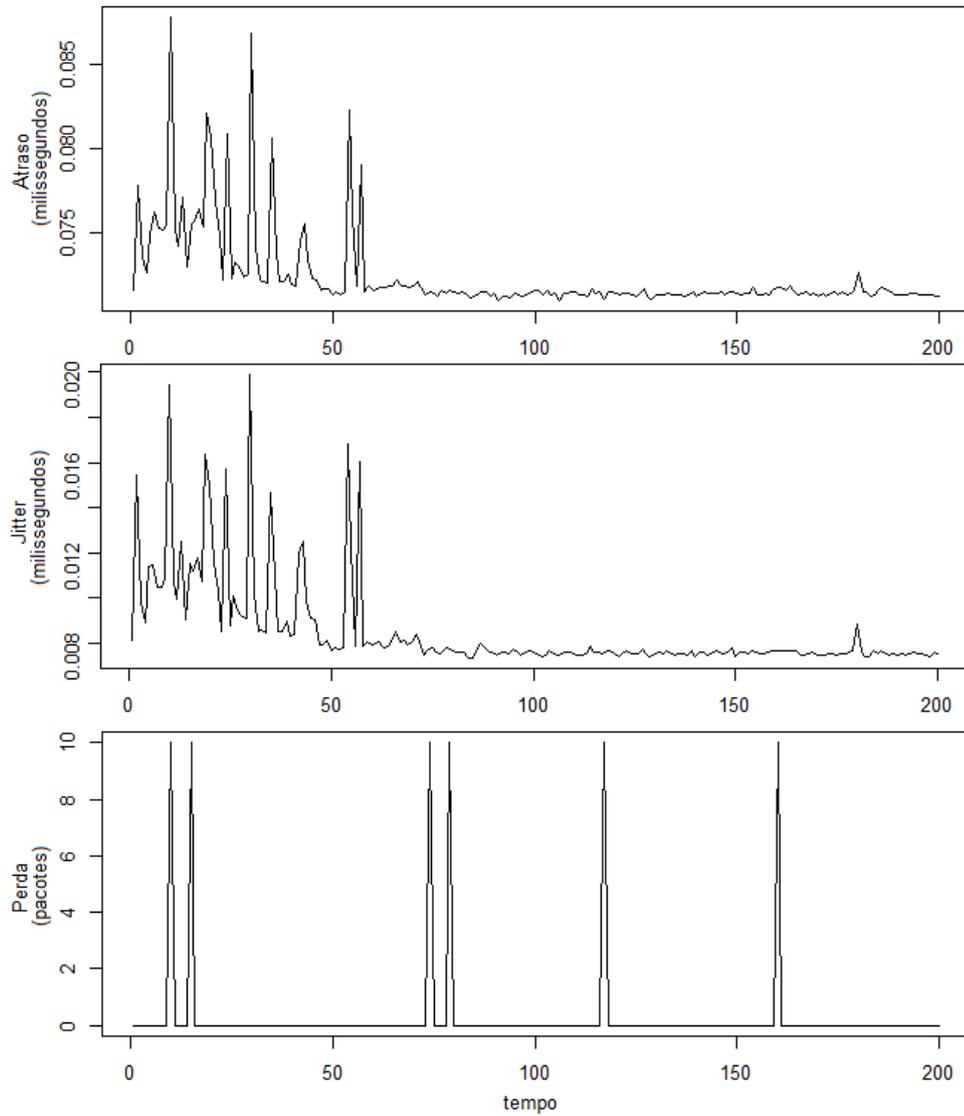


Figura 5.4.: Série temporal IFTO LabMatica - GREDES

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}} \quad (5.2)$$

As métricas MAPE e RMSE consistem basicamente em uma medida de erro e essa medida não necessariamente é o melhor indicador de acerto. Por exemplo, se o erro é pequeno, porém o método não prevê adequadamente as tendências de mudança, isso pode levá-lo a indicar uma decisão ruim. Logo, um método que prevê melhor a tendência de

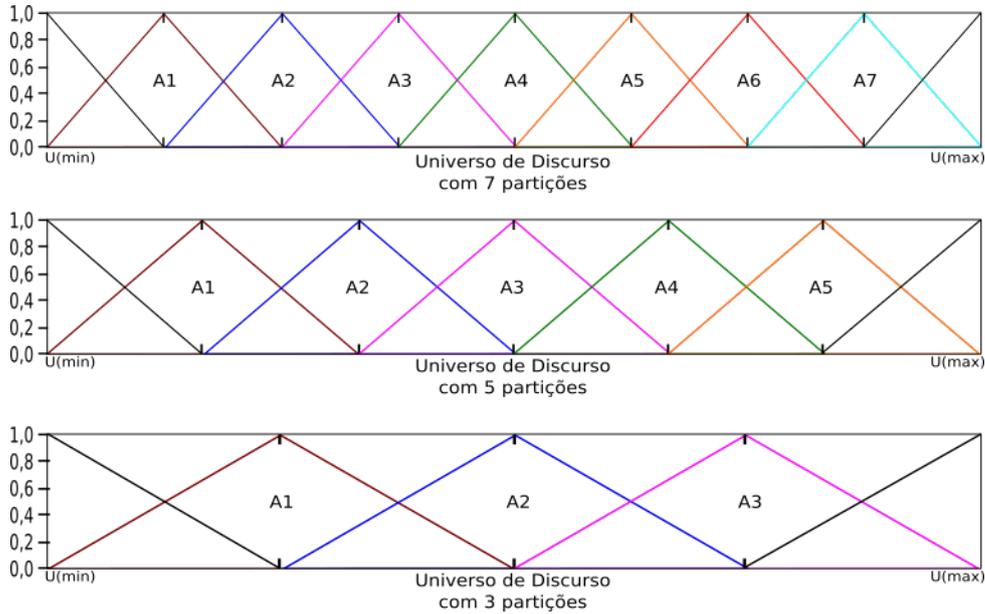


Figura 5.5.: Divisões do Universo de Discurso para os experimentos

mudança entre os conjuntos *fuzzy*, mesmo que não minimize o erro, pode ser mais útil para auxiliar na tomada de decisões *a posteriori*.

Nesse contexto, a métrica POCID (*Prediction of Change in Direction*) pode ser um bom indicador complementar para ser utilizado nas comparações entre os métodos. A métrica POCID, com uma pequena modificação, foi utilizada para mensurar porcentagem de acerto em prever o conjunto *fuzzy* consequente (RHS) das previsões em comparação aos valores reais da série. As FLRs, comentadas no capítulo 2, descrevem as regras de transição entre os conjuntos *fuzzy*. Elas seguem o formato $A_j \rightarrow A_k$ onde A_j representa o conjunto do valor \hat{Y}_{t-1} e A_k de \hat{Y}_t . Dessa forma, POCID foi definida como descrita em (5.3).

$$POCID = \frac{1}{N} \sum_{i=1}^n a_i, \text{ onde } \begin{cases} a_i = 1, & \text{se } RHS(\hat{Y}_i) = RHS(Y_i); \\ a_i = 0, & \text{caso contrário.} \end{cases} \quad (5.3)$$

onde $RHS(\hat{Y}_i)$ diz respeito ao conjunto consequente de transição do valor previsto no momento i e $RHS(Y_i)$ ao conjunto consequente do valor real da série no momento i .

O valor de POCID varia entre 0 e 1. Quanto mais próximo de 1, maior o número de acertos das tendências de mudança entre os conjunto *fuzzy*. Se multiplicado por 100, equivale à taxa de acerto.

Os resultados foram então comparados com os métodos Song&Chissom FTS (Song & Chissom 1993b), *Conventional FTS* (Chen 1996), *Weighted FTS* (Yu 2005), e *Exponentialy Weighted FTS* (Javedani Sadaei 2013), sendo todos eles treinados e avaliados com as mesmas definições, dados e métricas.

Capítulo 6.

Resultados

6.1. Introdução

Neste capítulo são detalhados os resultados obtidos através dos experimentos descritos no Capítulo 5. Inicialmente são detalhados os dados obtidos nos experimentos, os testes estatísticos aplicados e, por fim, a análise e discussões sobre os resultados obtidos para cada um dos testes considerados.

6.2. Resultados dos testes de acurácia

Os resultados dos testes realizados revelam a acurácia do método proposto frente aos métodos conhecidos da literatura. Foram realizadas 3 baterias de testes para cada uma das séries temporais obtidas com dados de QoS. Essas, por sua vez, continham os dados de atraso fim-a-fim, *jitter* e perda de pacotes.

Os resultados obtidos com o experimento, em cada uma das séries estudadas, podem ser visualizados nas Tabelas 6.1, 6.2 e 6.3, que apresentam as médias, desvios-padrões e intervalos de confiança, ao nível de 95%, das métricas MAPE e RMSE de cada método nas 3 partições propostas para universo de discurso definido.

As Figuras 6.1, 6.2 e 6.3 ilustram os comportamentos dos métodos na série **IFTO Campus Lagoa da Confusão - UFMG**, série essa que apresenta maior diversidade de variações. As imagens ilustram os testes com 7 partições do universo de discurso, em que a maioria dos métodos obteve o melhor desempenho. Vale salientar que foram realizadas 3

baterias de testes, em 3 cenários diferentes, para 3 variáveis de QoS, totalizando 27 testes. As demais imagens, que demonstram o comportamento dos métodos, e dados utilizados para os testes podem ser observadas no Apêndice A.

Tabela 6.1.: MAPEs e RMSEs Série Lagoa-UFMG

MÉTODOS	Atraso fim-a-fim					
	MAPE			RMSE		
	Média	Desvio Padrão	Intervalo de Confiança	Média	Desvio Padrão	Intervalo de Confiança
Proposta	3,1474	0,2700	± 0,3055	1,0745	0,1324	± 0,1498
Song & Chissom	7,5992	4,0483	± 4,5810	2,0061	1,0042	± 1,1363
Conventional FTS	15,4205	4,1122	± 4,6533	3,9253	1,0082	± 1,1409
Weighted FTS	19,5648	9,1024	± 10,3001	4,9481	2,2530	± 2,5494
Exp. Weighted	21,3005	13,0623	± 14,7811	5,4140	3,2360	± 3,6618
	<i>Jitter</i>					
Proposta	27,4707	3,2333	± 3,6588	0,2950	0,0474	± 0,0537
Song & Chissom	48,5435	12,9160	± 14,6155	0,3764	0,0744	± 0,0842
Conventional FTS	86,3212	26,1010	± 29,5355	0,5903	0,1628	± 0,1842
Weighted FTS	118,0616	38,7520	± 43,8512	0,8083	0,2468	± 0,2793
Exp. Weighted	139,0176	32,2261	± 36,4666	0,9520	0,2033	± 0,2301
	Perda de Pacotes					
Proposta	25,2973	1,6575	± 1,8756	181,3108	14,2783	± 16,1571
Song & Chissom	43,1518	13,5659	± 15,3510	253,0311	54,9988	± 62,2359
Conventional FTS	54,9859	7,5996	± 8,5996	297,7510	34,4527	± 38,9862
Weighted FTS	70,3350	14,7986	± 16,7459	374,9384	60,8942	± 68,9070
Exp. Weighted	84,0100	17,9680	± 20,3323	453,1907	64,7463	± 73,2660

De posse dos dados do experimento, sob o ponto de vista de cada uma das séries temporais, partiu-se para uma análise descritiva, com o objetivo de verificar se há diferenças significativas entre os resultados de previsão obtidos por cada um dos métodos.

Tabela 6.2.: MAPEs e RMSEs Série LABMATICA-GREDES

MÉTODOS	Atraso fim-a-fim					
	MAPE			RMSE		
	Média	Desvio Padrão	Intervalo de Confiança	Média	Desvio Padrão	Intervalo de Confiança
Proposta	0,2535	0	± 0	0,0003	0	± 0
Song & Chissom	7,8655	3,6360	± 9,0324	0,0056	0,0026	± 0,0064
Conventional FTS	16,1563	4,0162	± 9,9767	0,0115	0,0028	± 0,0071
Weighted FTS	20,4131	7,3462	± 18,2491	0,0145	0,0052	± 0,0130
Exp. Weighted	20,4131	7,3462	± 18,2491	0,0145	0,0052	± 0,0130
	<i>Jitter</i>					
Proposta	1,4961	0,2292	± 0,5694	0,00022	0,0005	± 0,0012
Song & Chissom	16,9564	13,3090	± 33,0613	0,0013	0,0010	± 0,0024
Conventional FTS	58,7043	14,7567	± 36,6578	0,0044	0,0011	± 0,0027
Weighted FTS	59,9446	15,9703	± 39,6726	0,0045	0,0012	± 0,0030
Exp. Weighted	63,9205	18,6194	± 46,2532	0,0048	0,0014	± 0,0035
	Perda de Pacotes					
Proposta	Inf	Inf	Inf	1,3018	0	± 0
Song & Chissom	Inf	Inf	Inf	4,9599	0,00204	± 0,0051
Conventional FTS	Inf	Inf	Inf	5,0905	0,01430	± 0,0355
Weighted FTS	Inf	Inf	Inf	6,3435	0,17037	± 0,4232
Exp. Weighted	Inf	Inf	Inf	6,3435	0,1703	± 0,4232

Sendo assim, partiu-se para o seguinte teste de hipótese:

$$\begin{aligned}
 H_0 &: \text{Não há diferença entre a proposta e os demais métodos} \\
 H_1 &: \text{Existe diferença entre a proposta e os demais métodos}
 \end{aligned}
 \tag{6.1}$$

Tabela 6.3.: MAPEs e RMSEs Série Palmas-UNICAMP

MÉTODOS	Atraso fim-a-fim					
	MAPE			RMSE		
	Média	Desvio Padrão	Intervalo de Confiança	Média	Desvio Padrão	Intervalo de Confiança
Proposta	1,0073	0,3513	± 0,8727	0,6511	0,2635	± 0,6547
Song & Chissom	5,1114	0,8305	± 2,0631	1,9661	0,2835	± 0,7044
Conventional FTS	2,5025	2,5593	± 6,3578	0,9450	0,8923	± 2,2166
Weighted FTS	3,4816	3,0734	± 7,6347	1,2552	1,0709	± 2,6603
Exp. Weighted	3,5649	3,0089	± 7,4745	1,2863	1,0458	± 2,5979
	<i>Jitter</i>					
Proposta	30,6771	11,0850	± 27,53672	0,1554	0,0062	± 0,0155
Song & Chissom	301,9534	177,9062	± 441,9435	0,5855	0,2694	± 0,6693
Conventional FTS	144,1987	91,6561	± 227,6865	0,2706	0,1562	± 0,3881
Weighted FTS	182,8514	107,6983	± 267,5374	0,3430	0,1849	± 0,4595
Exp. Weighted	183,7439	106,8095	± 265,3295	0,3480	0,1800	± 0,4473
	Perda de Pacotes					
Proposta	Inf	Inf	Inf	10,8464	0,9162	± 2,2760
Song & Chissom	Inf	Inf	Inf	32,2605	5,6083	± 13,9319
Conventional FTS	Inf	Inf	Inf	43,8157	11,1499	± 27,6979
Weighted FTS	Inf	Inf	Inf	55,7868	14,0032	± 34,7860
Exp. Weighted	Inf	Inf	Inf	60,8212	14,5942	± 36,2541

Definidas as hipóteses, foi realizada a leitura dos dados a partir de um arquivo texto usando o programa *Rstudio*¹, uma interface com diversos recursos visuais para o programa R². Em sequência, foram realizadas as inferências estatísticas (testes de normalidade, independência e verificação de diferença significativa entre os dados).

Para tratar a questão acima, foi necessário analisar as diferenças entre as médias das métricas de avaliação do método proposto contra os demais métodos da literatura, ou seja,

¹<https://www.rstudio.com>

²<https://www.r-project.org>

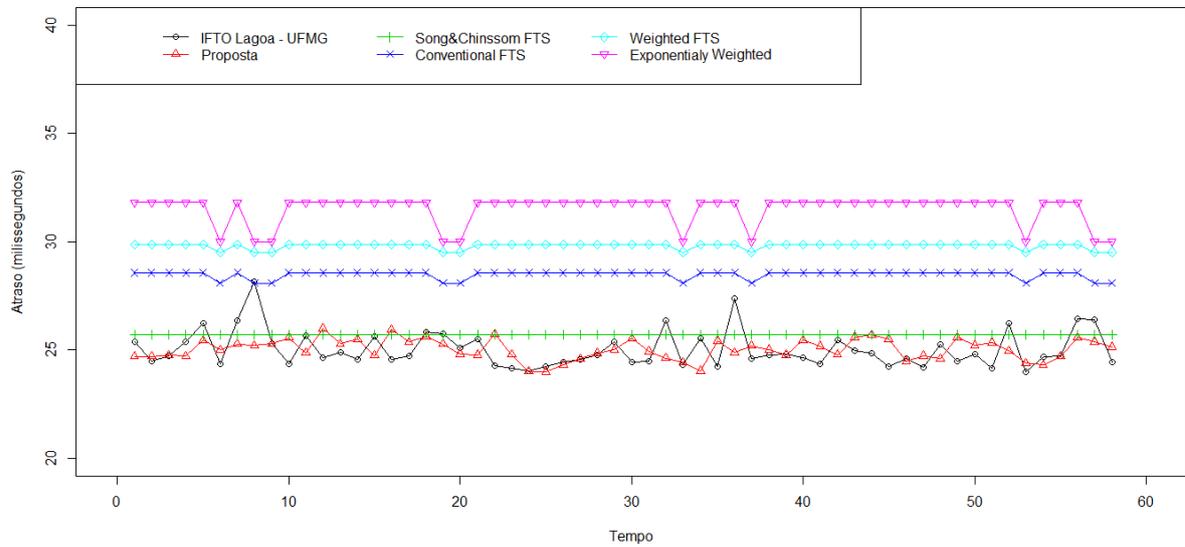


Figura 6.1.: Comportamento dos métodos: série Lagoa-UFMG (atraso)

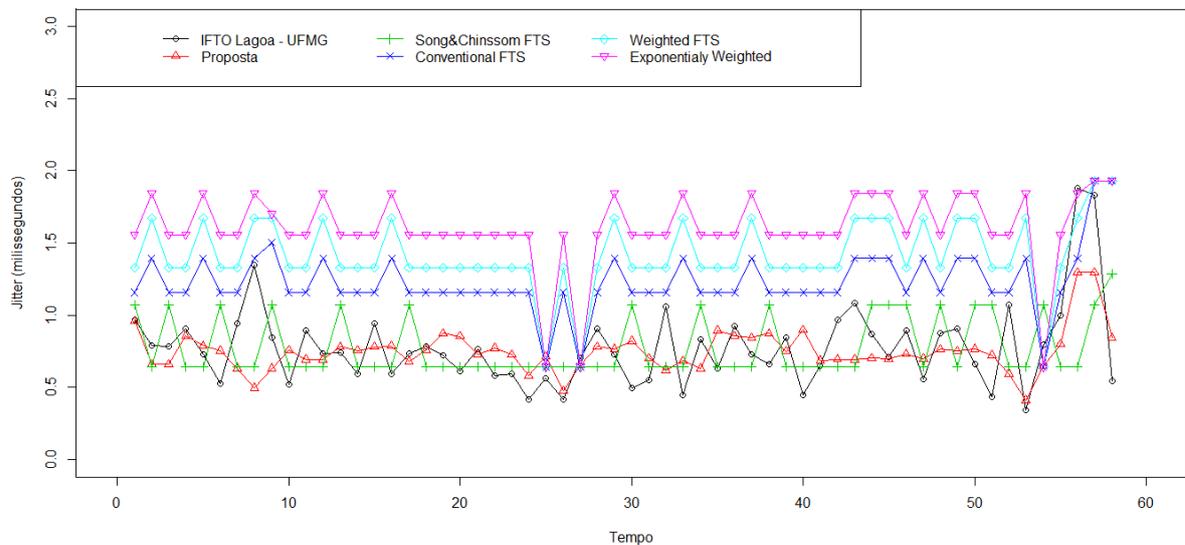


Figura 6.2.: Comportamento dos métodos: série Lagoa-UFMG (*jitter*)

o teste estatístico implementado foi planejado na forma de múltiplas comparações, do tipo “1 contra todos”. Para realizar esse tipo de teste, pode-se usar a aplicação estatística de análise de variância (ANOVA) completada pelo teste de Dunnett. O método de Dunnett é uma modificação do teste t usual que permite comparar diversos parâmetros de interesse com um parâmetro de referência (Montgomery 2017). Devido à ocorrência de valores zerados nas séries temporais LABMATICA-GEREDES e Palmas-UNICAMP, os valores

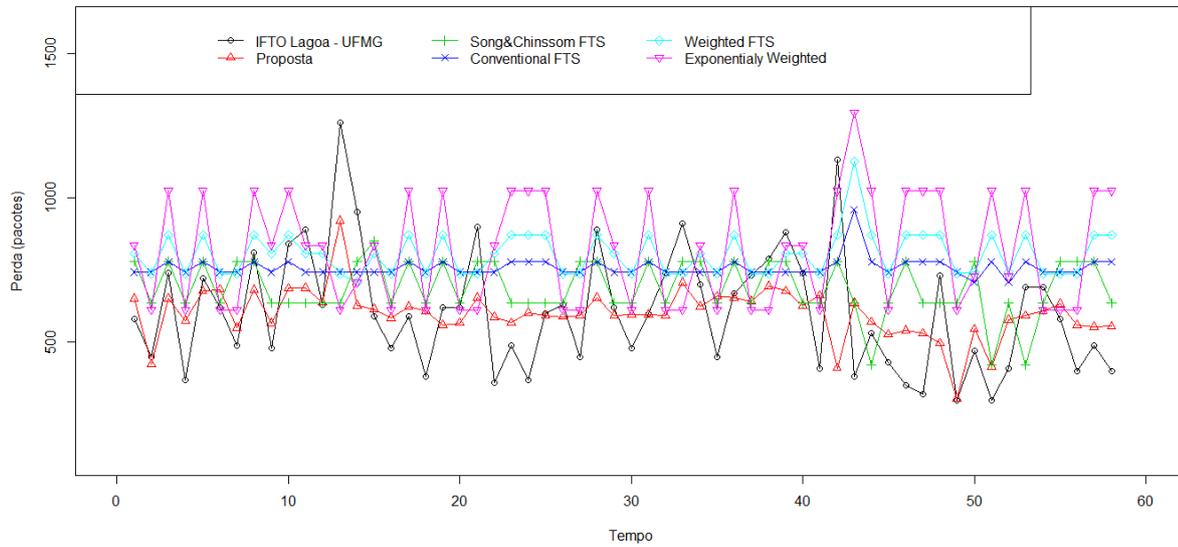


Figura 6.3.: Comportamento dos métodos: série Lagoa-UFMG (perda de pacotes)

de MAPE para a variável *perda de pacotes* não puderam ser mensurados, de modo que se decidiu por usar os valores de RMSE para os testes estatísticos.

Antes dos dados serem analisados, o teste de Dunnett precisa avaliar se as premissas de normalidade, homocedasticidade e independência dos dados são verdadeiras. Para tal, os testes Shapiro-Wilk, Fligner-Killeen e Durbin-Watson, respectivamente, foram realizados com $\alpha = 0,05$, que representa 95% de nível de significância. As premissas foram avaliadas separadamente, em cada série e variável, visto que os valores das métricas de avaliação MAPE e RMSE são diretamente afetadas, de acordo com os valores de cada cenário de coleta e variável de QoS, o que pode gerar inconsistência nos testes. Analisados os dados, verificou-se que as premissas foram satisfeitas, ou seja, os dados se mostraram como uma distribuição normal, com variâncias constantes (premissa da homocedasticidade) e sem correlação.

Partindo para uma análise visual dos dados e buscando evidenciar possível diferença significativa dos valores obtidos, um gráfico de caixas (*box-plot*) é ilustrado na Figura 6.4. Esse sugere que há variações dos valores das métricas de avaliação, de forma que pode existir diferença entre o método proposto e os demais métodos.

Realizadas as experimentações, os dados da análise de variância e do teste de Dunnett podem ser observados na Figura 6.5. Após esses testes, observou-se que o *p-value* é menor que o nível de significância em seis dos nove testes realizados. Nas ocasiões: variável atraso

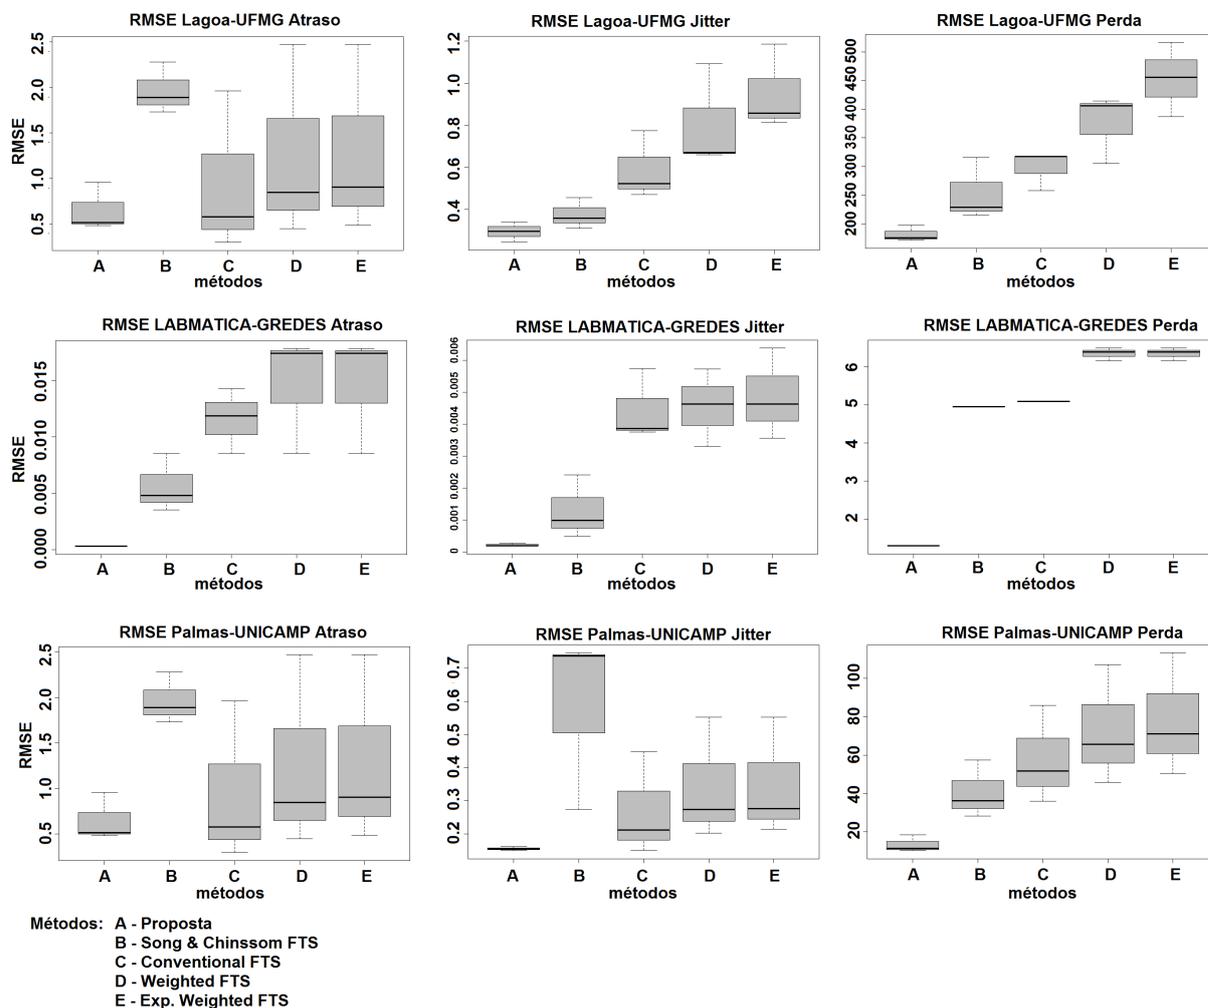


Figura 6.4.: Gráfico de caixas: desempenho dos métodos

na série Lagoa-UFMG; e atraso e *jitter* na série Palmas-UNICAMP, sendo que nessas os testes falharam em rejeitar a hipótese nula. Dessa forma conclui-se que, em pelo menos uma variável (perda), o método proposto é significativamente superior aos demais.

Se forem observados apenas os valores médios, os desvios-padrão e intervalos de confiança, a proposta tende a apresentar melhores avaliações e maior estabilidade.

Em poucas partições do universo de discurso o método proposto conseguiu melhores valores de avaliação e intervalos de confiança menores, se comparado com os demais. Mesmo com o aumento da quantidade de partições, os valores de MAPE e RMSE não sofreram grandes variações.

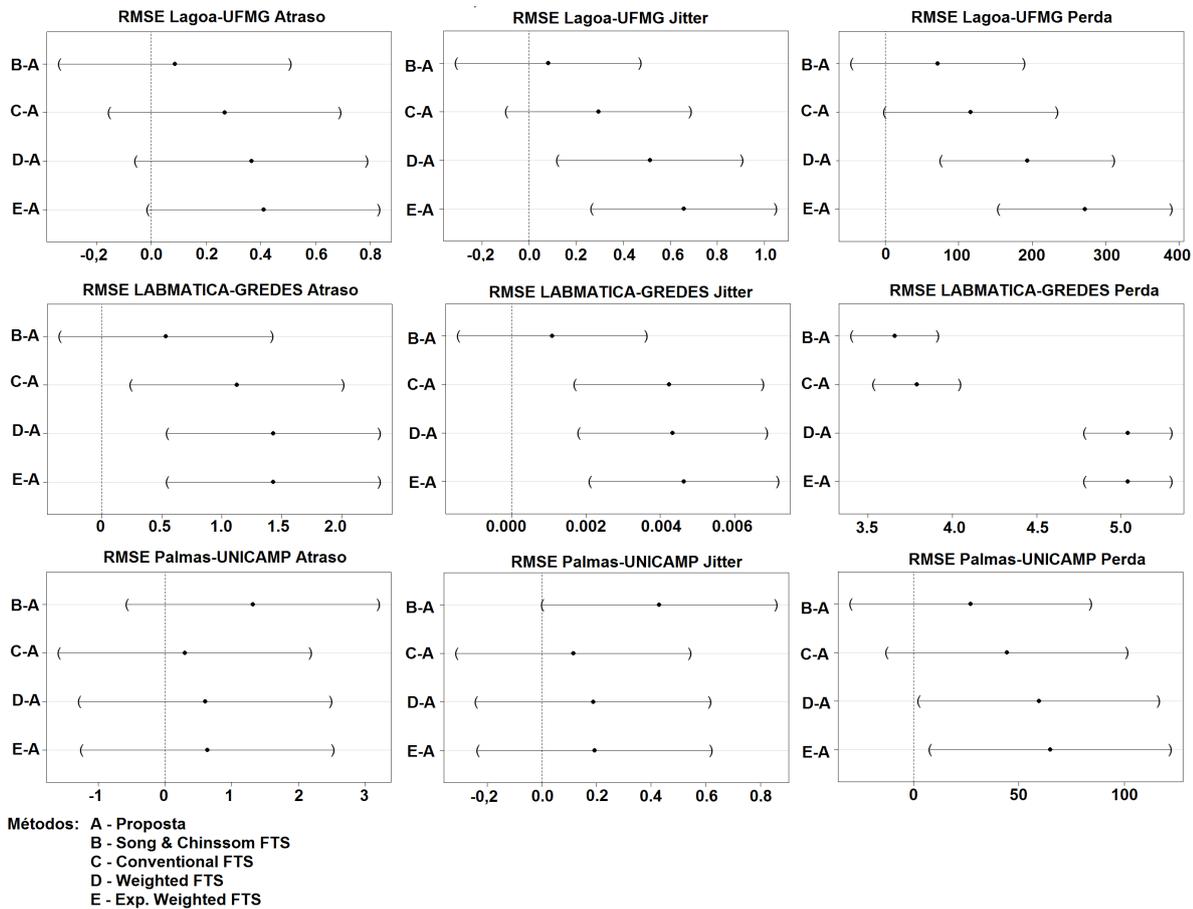


Figura 6.5.: Teste de Dunnett: análise de diferença significativa entre os métodos

O aumento da quantidade de partições tende a melhorar os valores de avaliação das métricas, basicamente, quanto mais partições, maior a possibilidade de os pontos médio dos conjuntos se aproximarem dos dados. Assim, aumentar a quantidade de partições do universo de discurso indiscriminadamente, além de deixar a leitura dos dados mais complexa, pois não faria sentido usar termos linguísticos, pode gerar problemas de sobreajuste (*overfitting*).

Nas séries LABMATICA-GREDES e Palmas-UNICAMP, os valores de MAPEs não são obtidos devido haver valores zerados na série. Como comentado na seção 5.2, o cálculo de MAPE possui essa desvantagem, porém através dos valores de RMSE ou mesmo observando o comportamento dos gráficos é possível notar um maior proximidade da série predita com a série original.

Observado as Figuras 6.1, 6.2 e 6.3, é possível identificar que o método proposto tem um comportamento mais dinâmico e suave do que os métodos da literatura, que por sua vez, possuem comportamento estático dentro dos conjuntos *fuzzy*. Os demais métodos tendem a buscar o valor de ponto médio dos intervalos, enquanto o método proposto consegue alcançar diversos valores dentro de um mesmo conjunto. Tal comportamento já era esperado, já que a proposta identifica as tendências dentro de cada conjunto *fuzzy*, com o auxílio dos ajustes com regressões lineares, o que já havia sido demonstrado em (Costa et al. 2017).

Os resultados de avaliação da métrica POCID podem ser observados na Tabela 6.4, onde são apresentadas as médias, desvios-padrões e intervalos de confiança ao nível de 95%. Os dados obtidos através da métrica POCID foram agrupados por método. Além disso, a Figura 6.6 apresenta um gráfico de caixas demonstrando visualmente a disposição dos dados de avaliação da métrica. A Figura 6.7 ilustra a diferença entre o método proposto frente aos demais métodos, usando ANOVA com o teste de Dunnett. As mesmas premissas anteriormente citadas foram verificadas e satisfeitas para o conjunto de dados usados para o teste.

Tabela 6.4.: Valores de POCID para todas as séries, variáveis e divisões do universo de discurso

MÉTODO	Média	Desvio Padrão	Intervalo de Confiança
Proposta	0,8716	0,1706	0,8041 a 0,9391
Song & Chinsson	0,5938	0,3813	0,4430 a 0,7447
Conventional FTS	0,4833	0,4432	0,3080 a 0,6587
Weighted FTS	0,2650	0,3824	0,1137 a 0,4163
Exp. Weighted FTS	0,2646	0,3821	0,1134 a 0,4158

Os valores da média de POCID para o método proposto se apresentou bem mais próxima de 1 do que os demais métodos, mostrando que ele possui boa taxa de previsão das tendências. Além disso, os desvios-padrão e intervalos de confiança são bem menores, evidenciando maior estabilidade do método, o que também pode ser visualizado na Figura 6.6. O teste de Dunnett demonstrou que há diferença estatística significativa, entre o método proposto e os demais.

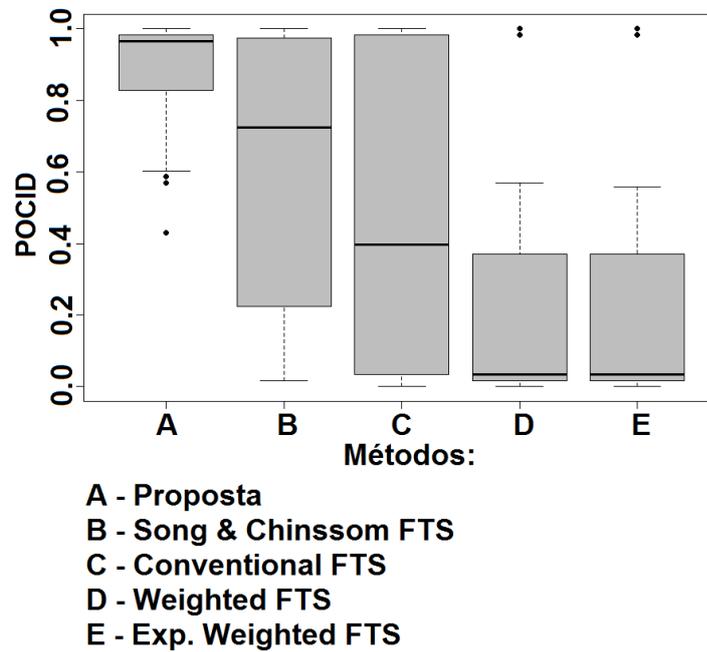


Figura 6.6.: Gráfico de caixas: desempenho dos métodos com a métrica POCID

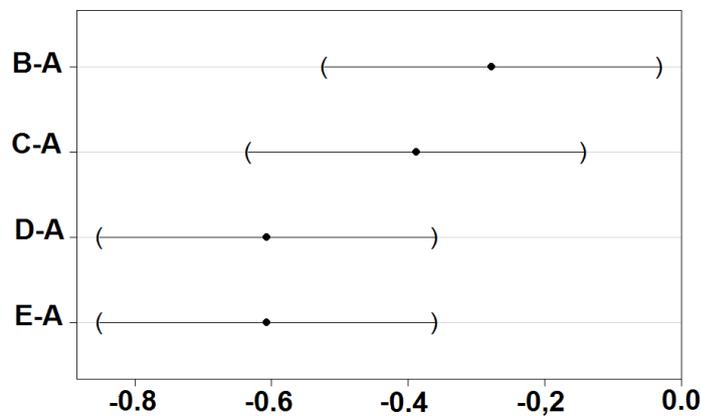


Figura 6.7.: Teste de Dunnett: análise de diferença significativa entre os métodos pela métrica POCID

6.3. Conclusão

Neste capítulo apresentou-se os resultados e análise para os cenários de teste definidos no Capítulo 5. Observa-se a partir dos resultados obtidos e das análises estatísticas aferidas que a proposta se mostrou eficiente e significativamente superior aos demais métodos da literatura.

A análise estatística, através dos teste de ANOVA e Dunnett, conseguiu demonstrar que a proposta é significativamente melhor, se analisada a variável perda. Analisando apenas os valores médios, desvios-padrão e intervalos de confiança, a proposta apresenta resultados que tendem a ser melhores que os demais métodos. Em vista disso, foi possível verificar que, mesmo com poucas partições do universo de discurso, a proposta apresenta melhores valores de avaliação. Com o aumento da quantidade de partições o método não sofreu grandes variações dos valores de avaliação, mostrando assim mais estabilidade e desempenho satisfatório. Este fato tende a ser um diferencial se houver a intenção de usar modelos de leitura de dados mais simples, já que, com menos partições do universo de discurso, mais simplificado é o modelo de leitura dos dados. Essa característica é essencial quando os recursos computacionais são limitados. Além disso, facilita a aplicação da proposta por usuários leigos.

Analisando os resultados da métrica POCID é possível admitir que a proposta apresenta resultados animadores. Tanto pela a capacidade do método proposto de prever as tendências de mudança dos conjuntos *fuzzy* quanto por apresentar diferença estatística significativa aos demais métodos. O método proposto foi capaz de acertar a tendência de mudança, em média, 87,16% enquanto o método mais próximo, Song & Chissom, conseguiu apenas 59,38%.

Capítulo 7.

Conclusão

7.1. Considerações Finais

Este trabalho concentrou esforços em propor um estudo e aplicação de métodos FTS para análise e previsão de QoS em redes de computadores. A combinação dos sistemas *fuzzy* com os conceitos clássicos das séries temporais tem demonstrado ser uma área de pesquisa bastante promissora. A aplicação de FTS na área de redes de computadores ainda é carente de trabalhos e através desse estudo é possível verificar que a aplicação de tais métodos é viável.

Dessa forma, buscou-se identificar os métodos e técnicas FTS disponíveis na literatura para realizar um estudo aplicado à previsão de QoS em redes de computadores. Inicialmente foi necessário um estudo abrangente, para conhecer as características e parâmetros dos métodos para então propor uma solução que abordasse as características da área em questão. Assim, optou-se pelo uso de métodos de primeira ordem invariantes no tempo, por sua simplicidade, eficiência e notória fonte para o desenvolvimento da maioria dos métodos encontrados na literatura recente.

Em seguida, partiu-se para a definição das características gerais e de qualidade em redes de computadores. Métricas de QoS e QoE, o comportamento estocástico e estacionário das séries e estudos de predição usando regressões foram a base para a escolha dos parâmetros de ajuste do método FTS proposto.

Após a definição das características base e específicas para o desenvolvimento do modelo FTS, partiu-se para a validação da proposta. Para tal, foram coletados e testados dados

obtidos em três cenários diferentes, visando submeter a proposta a problemas distintos. Os dados coletados foram então submetidos à proposta e demais métodos da literatura. Os resultados obtidos, mensurados por métricas de avaliação conhecidas, foram então submetidos à testes estatísticos para verificar acurácia e superioridade da proposta.

De maneira geral as abordagens FTS apresentam valores de aferição de qualidade (MAPE e RMSE) relativamente pequenos, sugerindo que seu uso pode ser praticável na predição de qualidade de rede. O método proposto tenta otimizar a aplicação dos métodos FTS levando em conta as características de comportamento de redes, propondo assim alterações nos procedimentos de previsão do modelo. Com base nessas experiências, foi possível identificar que a proposta melhora significativamente os resultados dos demais métodos.

Uma das vantagens das FTS é a descrição do comportamento das séries temporais por meio de regras no formato $LHS \rightarrow RHS$, em que LHS é o precedente da regra e indica o estado da série no tempo t , e RHS é o conseqüente e contém o conjunto de estados possíveis no tempo $t + 1$ dado o conjunto RHS no tempo t . Os estados previamente citados são conjuntos nebulosos e abarcam em si uma série de valores. Ao defuzificar essas regras, no entanto, os valores de predição são estáticos, representados pela média dos pontos médios de conjunto nebuloso da RHS . Outros modelos de FTS incluem um termo de tendência linear, único para toda a série. Dependendo da série em questão, as tendências podem não ser lineares ou variarem conforme a época.

O método proposto apresenta uma solução para esses inconvenientes com a introdução de uma fórmula de regressão linear no RHS , calculada a partir dos conjuntos nebulosos que formavam esse conseqüente. O intuito dessa inovação é capturar as tendências locais de cada conjunto precedente LHS , tornando assim a predição mais dinâmica.

Desta forma, o objetivo geral do trabalho foi alcançado através dos resultados com experimentos práticos e avaliações estatísticas. Especificamente: foi possível estudar trabalhos relacionados e relevância da pesquisa; métricas de QoS conhecidas foram utilizadas para estimar qualidade; a eficácia dos métodos FTS na predição de QoS em redes pode ser comprovada, com resultados satisfatórios; foi proposto um método FTS que aborda as características de redes.

Pode-se concluir que o estudo obteve resultados promissores e alcançou seus objetivos. O uso de FTS pode ser planejado e aplicado na predição de QoS em redes de computadores.

7.2. Trabalhos de Continuidade

Como trabalhos futuros pretende-se refinar a proposta e desenvolver uma aplicação prática do método para sistemas operacionais *Linux*. Dessa forma a implementação poderia ser usada diretamente como um gatilho para tomada de decisão em seleção de redes.

Para alcançar tal objetivo, no tocante ao refinamento da proposta, pode-se realizar estudos comparativos aplicando na implementação: outras abordagens de divisão de universo de discurso; o uso de modelos de alta ordem e probabilísticos; e testes de *trade-off* entre aumento de complexidade e ganho de desempenho com o uso de abordagens mais onerosas.

No tocante ao desenvolvimento de uma aplicação, essa pode dar suporte à gerência de redes, por exemplo, assistindo aos administradores de recursos quanto ao dimensionamento e melhor aproveitamento dos links de comunicação ou planejamento e previsão de uso dos recursos.

No ambiente de dispositivos móveis, tais aplicações poderiam ser utilizadas para seleção de redes em ambientes heterogêneos, onde um aplicativo poderia dar suporte à tomada de decisão tanto para o usuário quanto para métodos computacionais. O método tem característica de ser de baixo custo computacional, o que pode auxiliar tais dispositivos. O processo de seleção de redes pode usar os valores de predição para optar por escolher uma rede A ou B de acordo com as possíveis variações de qualidade.

Por se tratar de uma área com um grande potencial de pesquisas, diversas são as possibilidades de trabalhos futuros além das apresentadas nesta seção. Sistemas que possuem as mesmas características de dados estocásticos e estacionários podem usar a proposta para previsão, assim como: sistemas de seleção e dimensionamento de conteúdo multimídia (e.g. YouTube, Netflix, entre outros); e sistemas de balanceamento e dimensionamento de links de internet e banda para usuários em geral.

Trabalhos que abordam a teoria *fuzzy* permitem lidar, com mais facilidade, com níveis de incertezas, tornando-os ideais para lidar com variáveis imprecisas e linguísticas. Dessa maneira, a abordagem FTS, pode, também, alcançar bons ou melhores resultados se aplicada na predição de QoE, a qual normalmente aplica métodos na tentativa de lidar com incertezas cognitivas e estocásticas.

Apêndice A.

Apêndices

Tabela A.1.: Dados brutos coletados com o experimento e usados para tabelas e testes estatísticos

Met	Serie	Div	Var	MAPE	RMSE	POCID
A	lagoa-ufmg	3	atraso	3.192585	1.11731	0.93103448
A	lagoa-ufmg	5	atraso	3.391966	1.180116	0.9827586
A	lagoa-ufmg	7	atraso	2.857661	0.9260053	0.7758621
A	lagoa-ufmg	3	jitter	31.20028	0.297757	0.8793103
A	lagoa-ufmg	5	jitter	25.75393	0.34095	0.67241379
A	lagoa-ufmg	7	jitter	25.45788	0.2462234	0.58620690
A	lagoa-ufmg	3	perda	27.02334	197.6088	0.6034483
A	lagoa-ufmg	5	perda	25.15047	171.0056	0.56896552
A	lagoa-ufmg	7	perda	23.71806	175.3179	0.4310345
A	labmatica-gredes	3	atraso	0.2535713	0.0002839	1
A	labmatica-gredes	5	atraso	0.2535713	0.0002839	1
A	labmatica-gredes	7	atraso	0.2535713	0.0002839	1
A	labmatica-gredes	3	jitter	1.760803	0.000271793	1
A	labmatica-gredes	5	jitter	1.363768	0.000188651	0.98275862

A	labmatica-gredes	7	jitter	1.363768	0.000188651	0.98275862
A	labmatica-gredes	3	perda	Inf	1.301889	0.98275862
A	labmatica-gredes	5	perda	Inf	1.301889	0.98275862
A	labmatica-gredes	7	perda	Inf	1.301889	0.98275862
A	palmas-unicamp	3	atraso	1.371416	0.9549625	0.96551724
A	palmas-unicamp	5	atraso	0.9802893	0.5149498	0.9137931
A	palmas-unicamp	7	atraso	0.6703619	0.4835361	0.6034483
A	palmas-unicamp	3	jitter	42.25617	0.1550357	0.91379310
A	palmas-unicamp	5	jitter	29.61225	0.1618657	0.9137931
A	palmas-unicamp	7	jitter	20.16298	0.1493775	0.94827586
A	palmas-unicamp	3	perda	Inf	18.54437	0.9655172
A	palmas-unicamp	5	perda	Inf	11.49435	0.98275862
A	palmas-unicamp	7	perda	Inf	10.19861	0.98275862
B	lagoa-ufmg	3	atraso	6.963448	1.847831	0.96551724
B	lagoa-ufmg	5	atraso	11.927712	3.08006	0.9827586
B	lagoa-ufmg	7	atraso	3.906404	1.0904856	0.8275862
B	lagoa-ufmg	3	jitter	47.91428	0.3589441	0.8965517
B	lagoa-ufmg	5	jitter	61.76262	0.4579733	0.55172414
B	lagoa-ufmg	7	jitter	35.95373	0.3122095	0.48275862
B	lagoa-ufmg	3	perda	58.70448	316.0374	0.4310345
B	lagoa-ufmg	5	perda	33.75738	214.6342	0.51724138
B	lagoa-ufmg	7	perda	36.99339	228.4216	0.3965517
B	labmatica-gredes	3	atraso	6.7196019	0.004807607	1
B	labmatica-gredes	5	atraso	12	0.008532855	1
B	labmatica-gredes	7	atraso	4.9404478	0.003536488	1
B	labmatica-gredes	3	jitter	31.793572	0.002415453	1
B	labmatica-gredes	5	jitter	6.070422	0.000498147	0.98275862
B	labmatica-gredes	7	jitter	13.005363	0.000993172	0.98275862

B	labmatica-gredes	3	perda	Inf	4.962192	0.01724138
B	labmatica-gredes	5	perda	Inf	4.959155	0.01724138
B	labmatica-gredes	7	perda	Inf	4.958318	0.01724138
B	palmas-unicamp	3	atraso	5.254393	1.8882417	0.03448276
B	palmas-unicamp	5	atraso	5.8612135	2.280538	0.1379310
B	palmas-unicamp	7	atraso	4.218694	1.7297076	0.3103448
B	palmas-unicamp	3	jitter	407.50776	0.7458085	0.08620690
B	palmas-unicamp	5	jitter	401.80102	0.7363585	0.1206897
B	palmas-unicamp	7	jitter	96.55142	0.2744695	0.72413793
B	palmas-unicamp	3	perda	Inf	57.41611	0.8965517
B	palmas-unicamp	5	perda	Inf	36.22631	0.82758621
B	palmas-unicamp	7	perda	Inf	28.29487	0.82758621
C	lagoa-ufmg	3	atraso	20.047062	5.053024	0.03448276
C	lagoa-ufmg	5	atraso	12.182061	3.111093	0.9827586
C	lagoa-ufmg	7	atraso	14.032238	3.6116639	0.1724138
C	lagoa-ufmg	3	jitter	116.14168	0.7758002	0.1034483
C	lagoa-ufmg	5	jitter	75.19483	0.5239061	0.67241379
C	lagoa-ufmg	7	jitter	67.62715	0.4712337	0.05172414
C	lagoa-ufmg	3	perda	59.37352	317.6423	0.4310345
C	lagoa-ufmg	5	perda	59.37352	317.6423	0.25862069
C	lagoa-ufmg	7	perda	46.21055	257.9685	0.3965517
C	labmatica-gredes	3	atraso	16.6004976	0.011865467	1
C	labmatica-gredes	5	atraso	12	0.008532855	1
C	labmatica-gredes	7	atraso	19.9319404	0.01424611	1
C	labmatica-gredes	3	jitter	75.724762	0.005744699	1
C	labmatica-gredes	5	jitter	49.493626	0.003754744	0.01724138
C	labmatica-gredes	7	jitter	50.894607	0.003862061	0.01724138
C	labmatica-gredes	3	perda	Inf	5.074771	0

C	labmatica-gredes	5	perda	Inf	5.094031	0
C	labmatica-gredes	7	perda	Inf	5.102715	0
C	palmas-unicamp	3	atraso	5.403072	1.9626395	0.98275862
C	palmas-unicamp	5	atraso	1.5428977	0.5759745	0.9827586
C	palmas-unicamp	7	atraso	0.5616703	0.2963794	0.9310345
C	palmas-unicamp	3	jitter	246.4548	0.4475837	0.89655172
C	palmas-unicamp	5	jitter	116.7061	0.2124951	1
C	palmas-unicamp	7	jitter	69.43539	0.1517246	0.96551724
C	palmas-unicamp	3	perda	Inf	85.81612	0.0862069
C	palmas-unicamp	5	perda	Inf	51.69992	0.03448276
C	palmas-unicamp	7	perda	Inf	35.93154	0.03448276
D	lagoa-ufmg	3	atraso	28.803781	7.233557	0.03448276
D	lagoa-ufmg	5	atraso	10.60552	2.729069	0.9827586
D	lagoa-ufmg	7	atraso	19.285109	4.8815702	0
D	lagoa-ufmg	3	jitter	162.66937	1.0931577	0.1034483
D	lagoa-ufmg	5	jitter	98.81131	0.6706845	0.01724138
D	lagoa-ufmg	7	jitter	92.70404	0.6609227	0.05172414
D	lagoa-ufmg	3	perda	78.00671	405.6303	0.4310345
D	lagoa-ufmg	5	perda	79.7225	414.3793	0.03448276
D	lagoa-ufmg	7	perda	53.27581	304.8055	0.5689655
D	labmatica-gredes	3	atraso	24.3738641	0.017420433	1
D	labmatica-gredes	5	atraso	12	0.008532855	1
D	labmatica-gredes	7	atraso	24.9291046	0.017817231	1
D	labmatica-gredes	3	jitter	61.081032	0.004634297	1
D	labmatica-gredes	5	jitter	75.316511	0.005723197	0.01724138
D	labmatica-gredes	7	jitter	43.436448	0.003297878	0.01724138
D	labmatica-gredes	3	perda	Inf	6.155463	0
D	labmatica-gredes	5	perda	Inf	6.387812	0

D	labmatica-gredes	7	perda	Inf	6.487489	0
D	palmas-unicamp	3	atraso	6.958362	2.4699374	0.01724138
D	palmas-unicamp	5	atraso	2.3596408	0.8487741	0.2586207
D	palmas-unicamp	7	atraso	1.1268243	0.447117	0.3103448
D	palmas-unicamp	3	jitter	303.18062	0.552769	0.01724138
D	palmas-unicamp	5	jitter	149.88222	0.2735057	0.1896552
D	palmas-unicamp	7	jitter	95.49145	0.2029766	0.01724138
D	palmas-unicamp	3	perda	Inf	106.99974	0.0862069
D	palmas-unicamp	5	perda	Inf	65.6887	0
D	palmas-unicamp	7	perda	Inf	45.88507	0
E	lagoa-ufmg	3	atraso	31.247562	7.850893	0.03448276
E	lagoa-ufmg	5	atraso	6.507782	1.742463	0.9827586
E	lagoa-ufmg	7	atraso	26.146024	6.6486913	0
E	lagoa-ufmg	3	jitter	176.22557	1.185443	0.1034483
E	lagoa-ufmg	5	jitter	120.85782	0.8134792	0.01724138
E	lagoa-ufmg	7	jitter	119.96954	0.8571297	0.05172414
E	lagoa-ufmg	3	perda	87.89808	455.8252	0.4310345
E	lagoa-ufmg	5	perda	99.71552	516.5796	0.03448276
E	lagoa-ufmg	7	perda	64.41624	387.1674	0.5589655
E	labmatica-gredes	3	atraso	24.3738641	0.017420433	1
E	labmatica-gredes	5	atraso	12	0.008532855	1
E	labmatica-gredes	7	atraso	24.9291046	0.017817231	1
E	labmatica-gredes	3	jitter	61.081032	0.004634297	1
E	labmatica-gredes	5	jitter	83.796562	0.006378637	0.01724138
E	labmatica-gredes	7	jitter	46.883914	0.003557704	0.01724138
E	labmatica-gredes	3	perda	Inf	6.155463	0
E	labmatica-gredes	5	perda	Inf	6.387812	0
E	labmatica-gredes	7	perda	Inf	6.487489	0

E	palmas-unicamp	3	atraso	6.958362	2.4699374	0.01724138
E	palmas-unicamp	5	atraso	2.5142072	0.9021034	0.2586207
E	palmas-unicamp	7	atraso	1.2223588	0.4869996	0.3103448
E	palmas-unicamp	3	jitter	303.18062	0.552769	0.01724138
E	palmas-unicamp	5	jitter	150.66075	0.277085	0.1896552
E	palmas-unicamp	7	jitter	97.3904	0.2142225	0.01724138
E	palmas-unicamp	3	perda	Inf	113.17704	0.0862069
E	palmas-unicamp	5	perda	Inf	71.14097	0
E	palmas-unicamp	7	perda	Inf	50.50158	0

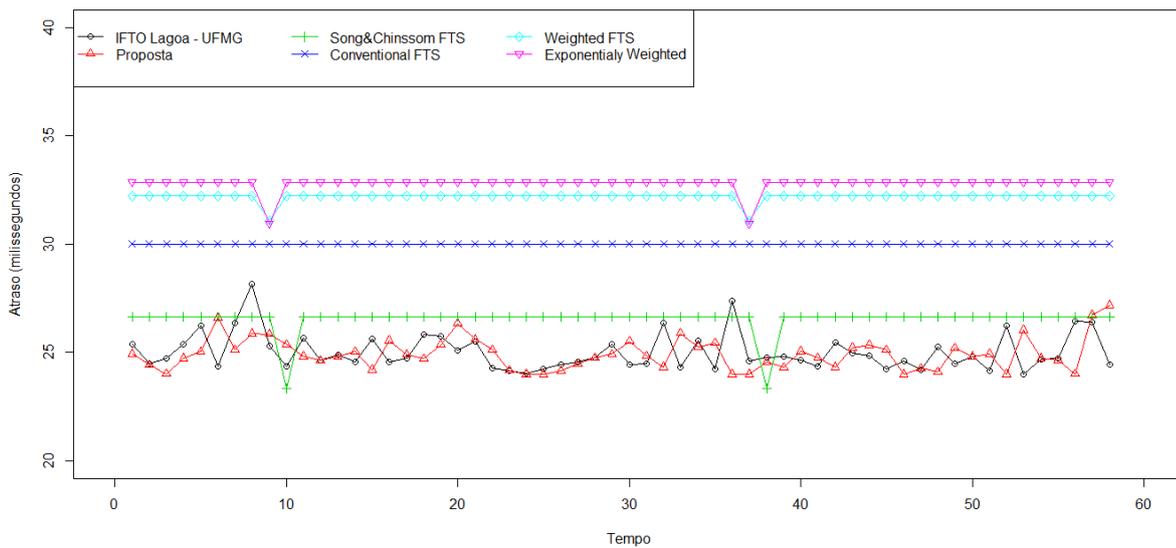


Figura A.1.: Comportamento dos métodos: série Lagoa-UFMG com 3 partições do universo de discurso (atraso)

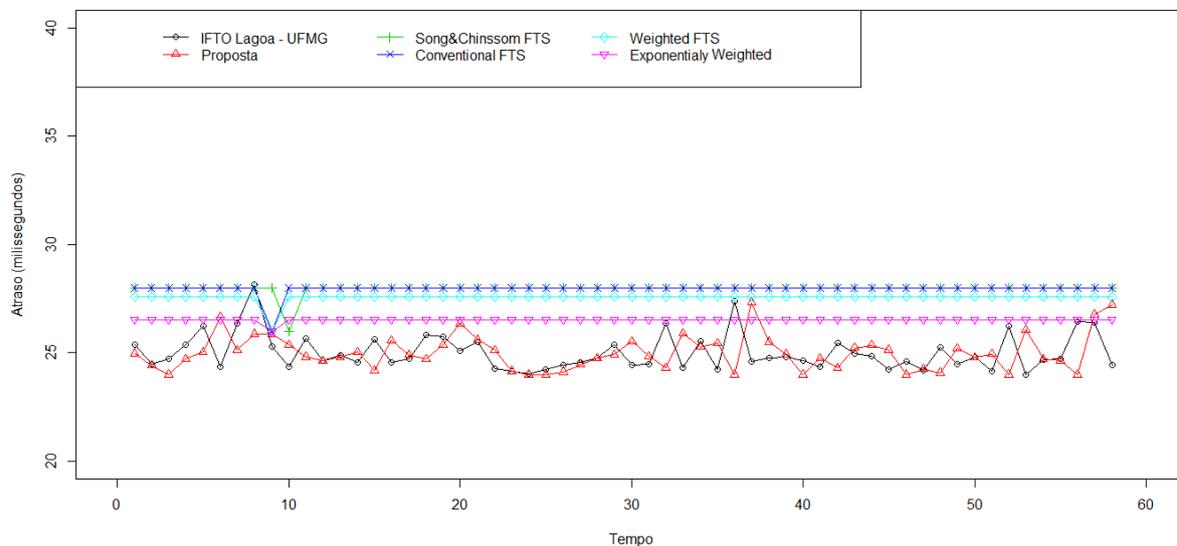


Figura A.2.: Comportamento dos métodos: série Lagoa-UFMG com 5 partições do universo de discurso (atraso)

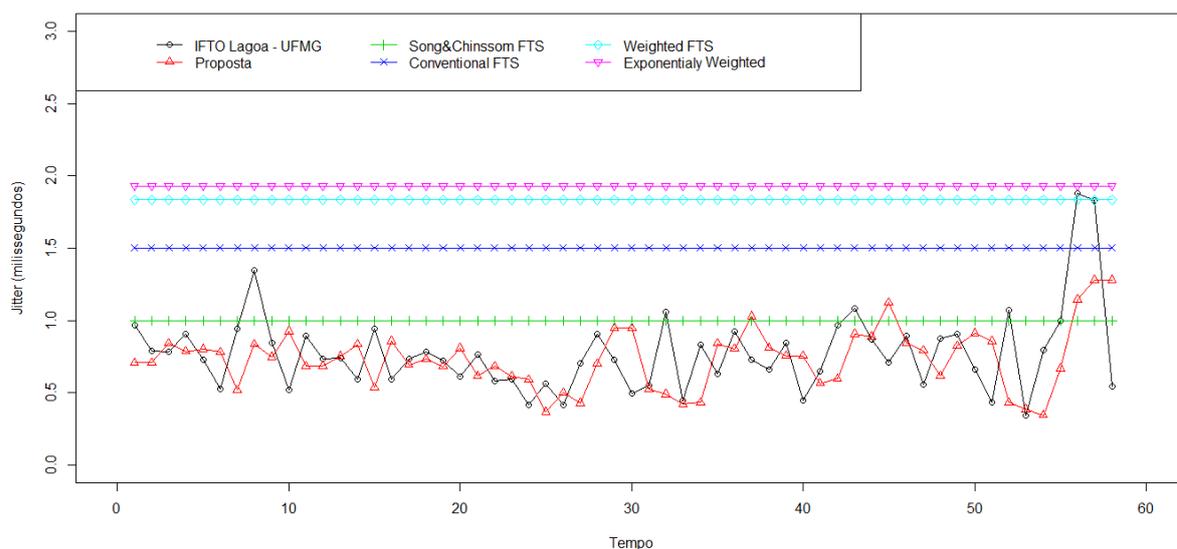


Figura A.3.: Comportamento dos métodos: série Lagoa-UFMG com 3 partições do universo de discurso (*jitter*)

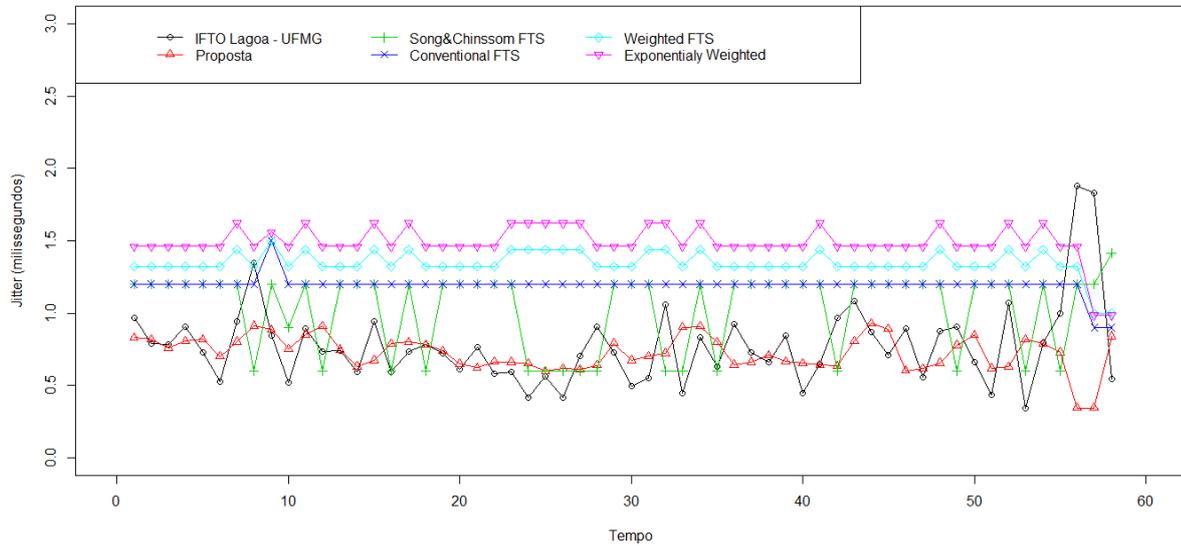


Figura A.4.: Comportamento dos métodos: série Lagoa-UFMG com 5 partições do universo de discurso (*jitter*)

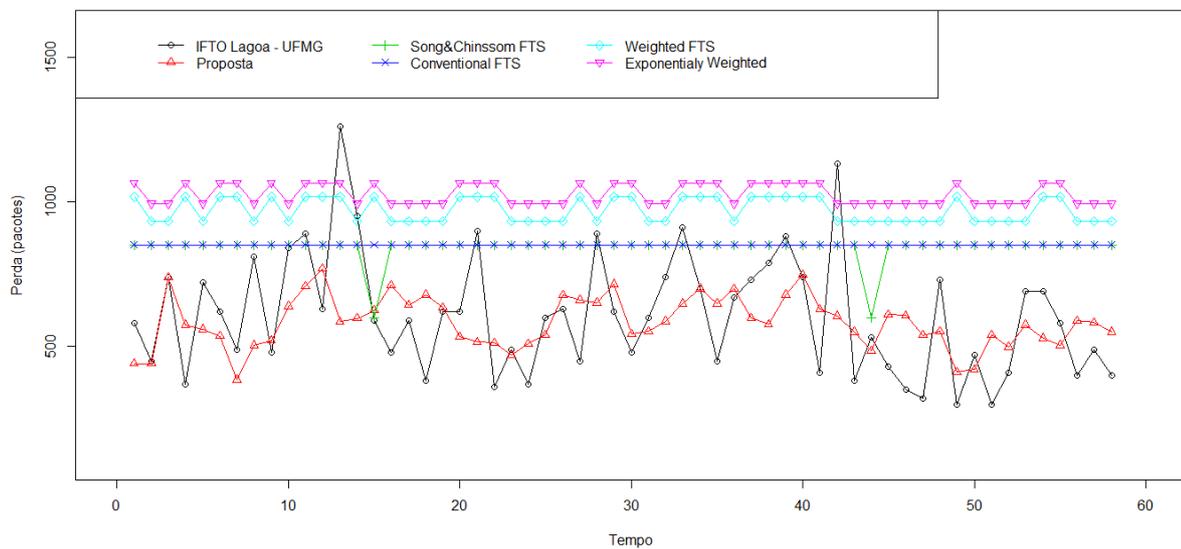


Figura A.5.: Comportamento dos métodos: série Lagoa-UFMG com 3 partições do universo de discurso (perda de pacotes)

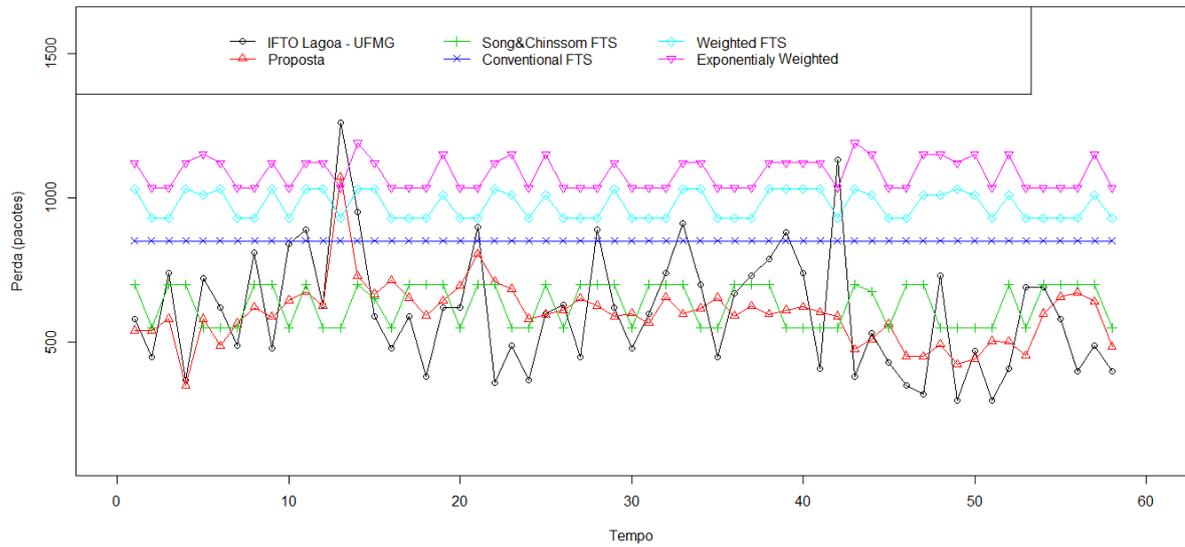


Figura A.6.: Comportamento dos métodos: série Lagoa-UFMG com 5 partições do universo de discurso (perda de pacotes)

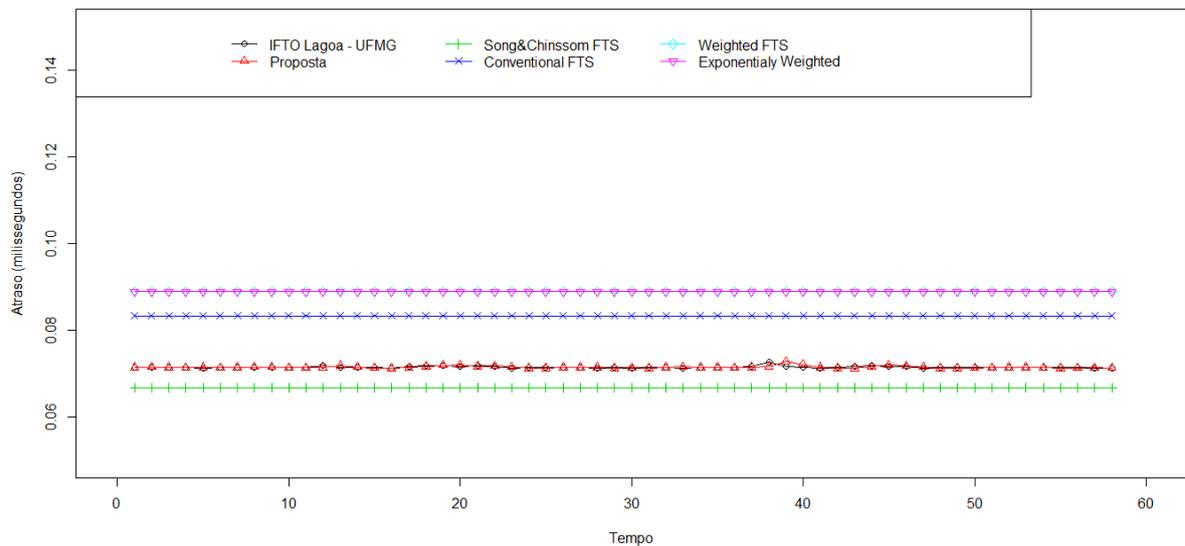


Figura A.7.: Comportamento dos métodos: série LABMATICA-GREDES com 3 partições do universo de discurso (atraso)

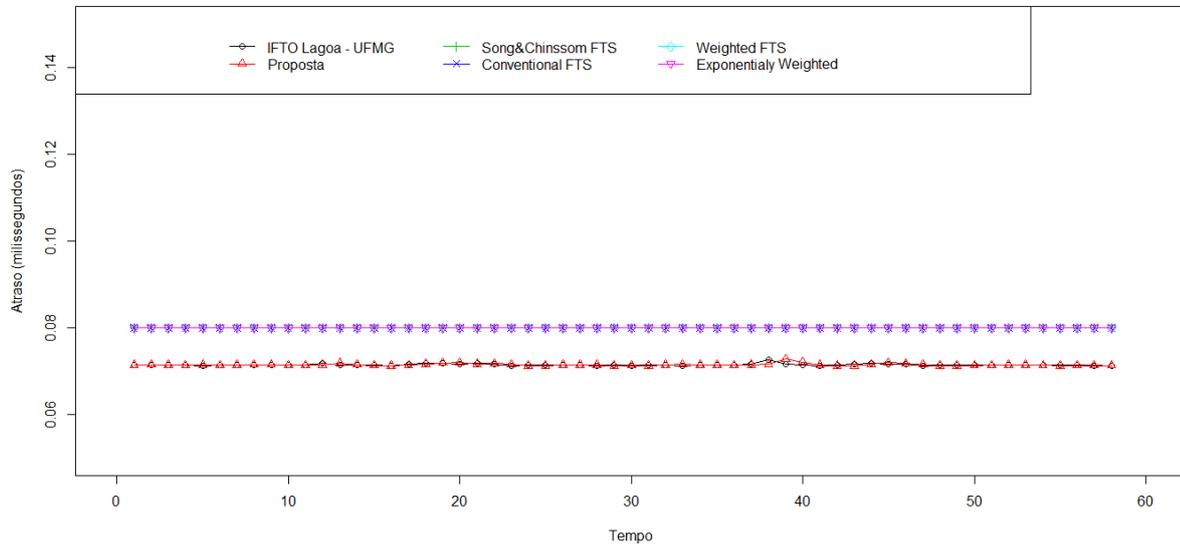


Figura A.8.: Comportamento dos métodos: série LABMATICA-GREDES com 5 partições do universo de discurso (atraso)

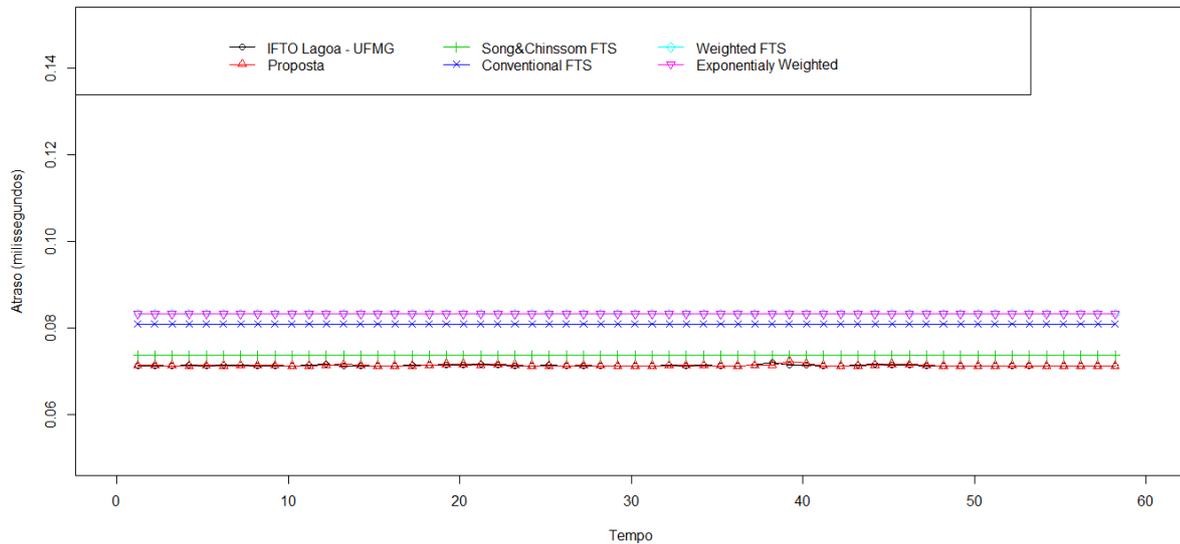


Figura A.9.: Comportamento dos métodos: série LABMATICA-GREDES com 7 partições do universo de discurso (atraso)

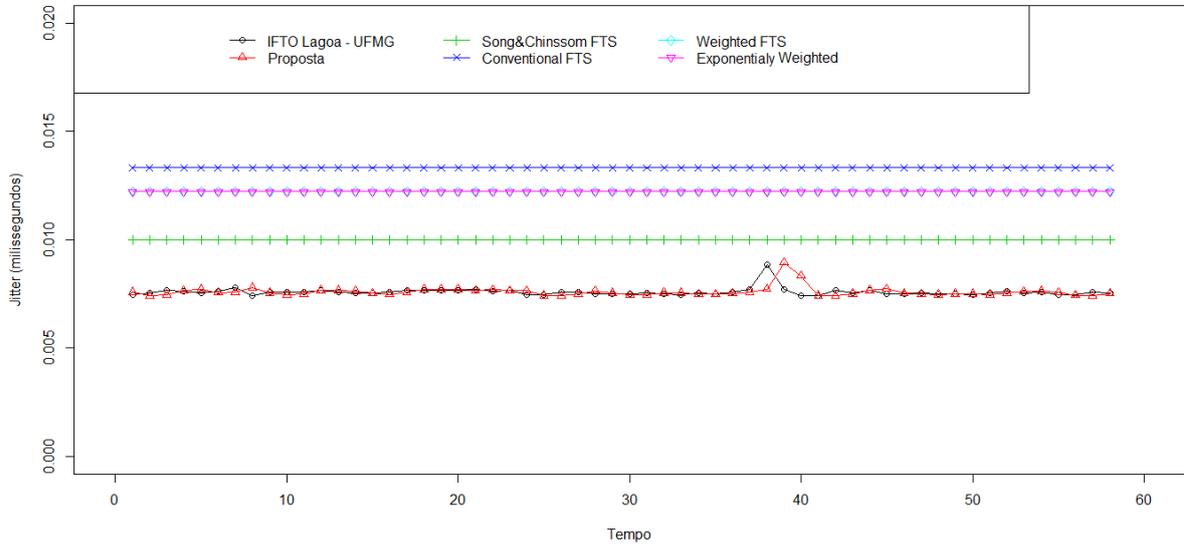


Figura A.10.: Comportamento dos métodos: série LABMATICA-GREDES com 3 partições do universo de discurso (*jitter*)

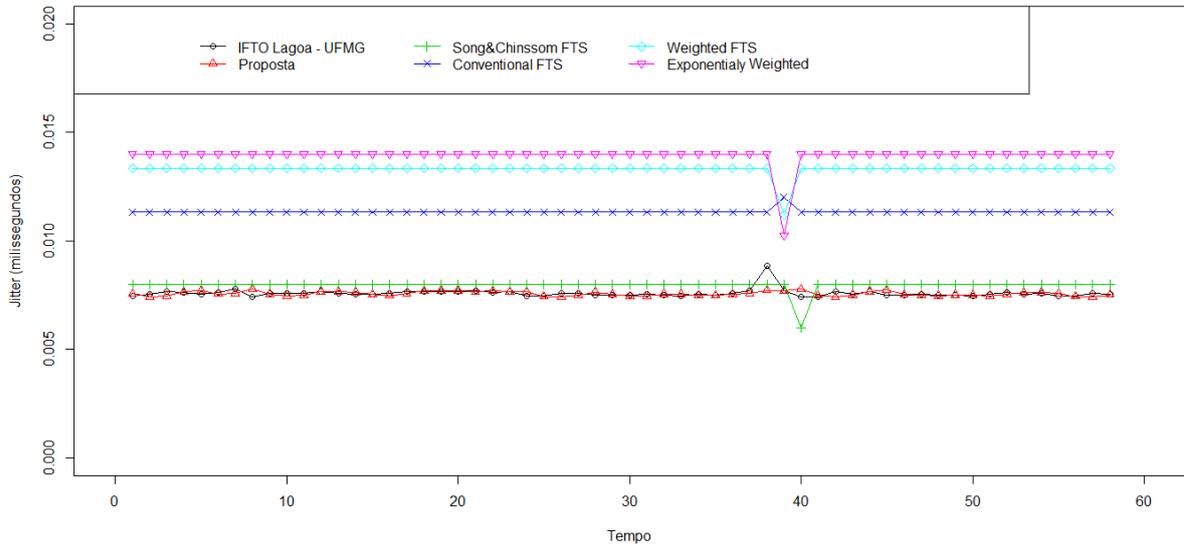


Figura A.11.: Comportamento dos métodos: série LABMATICA-GREDES com 5 partições do universo de discurso (*jitter*)

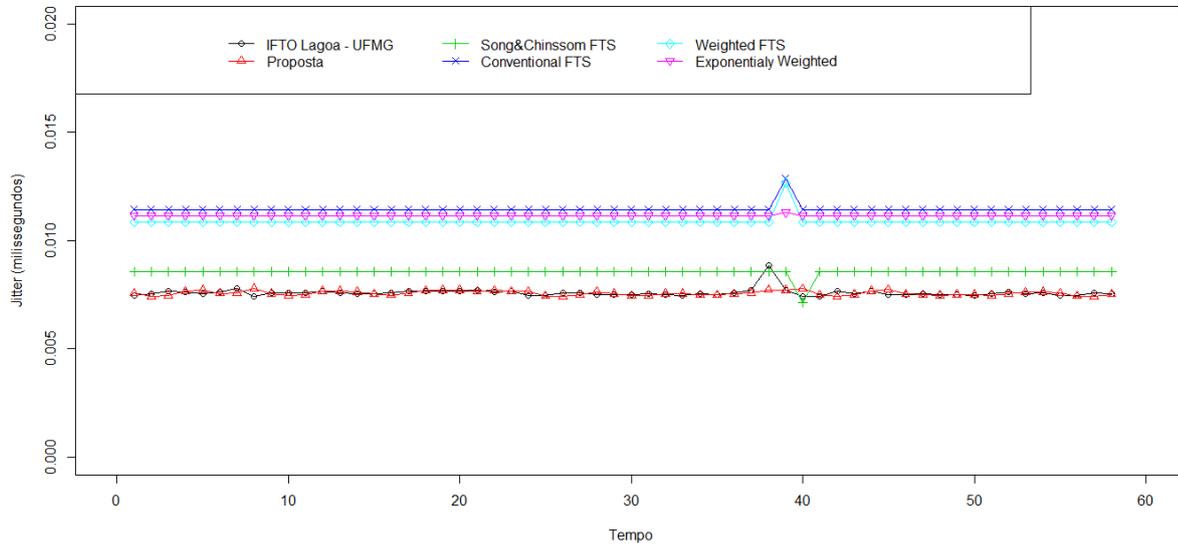


Figura A.12.: Comportamento dos métodos: série LABMATICA-GREDES com 7 partições do universo de discurso (*jitter*)

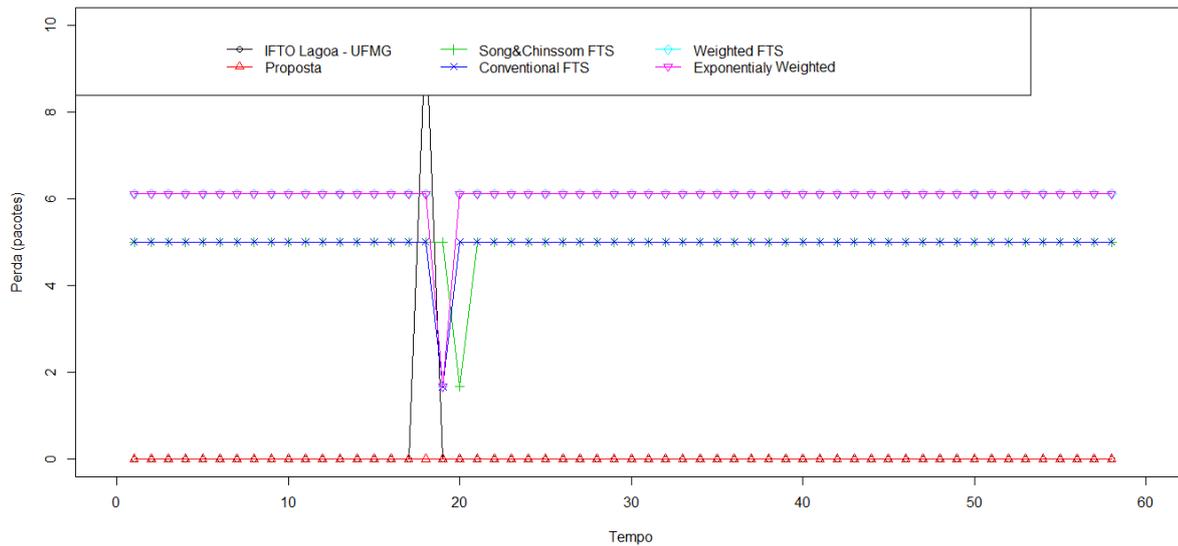


Figura A.13.: Comportamento dos métodos: série LABMATICA-GREDES com 3 partições do universo de discurso (perda de pacotes)

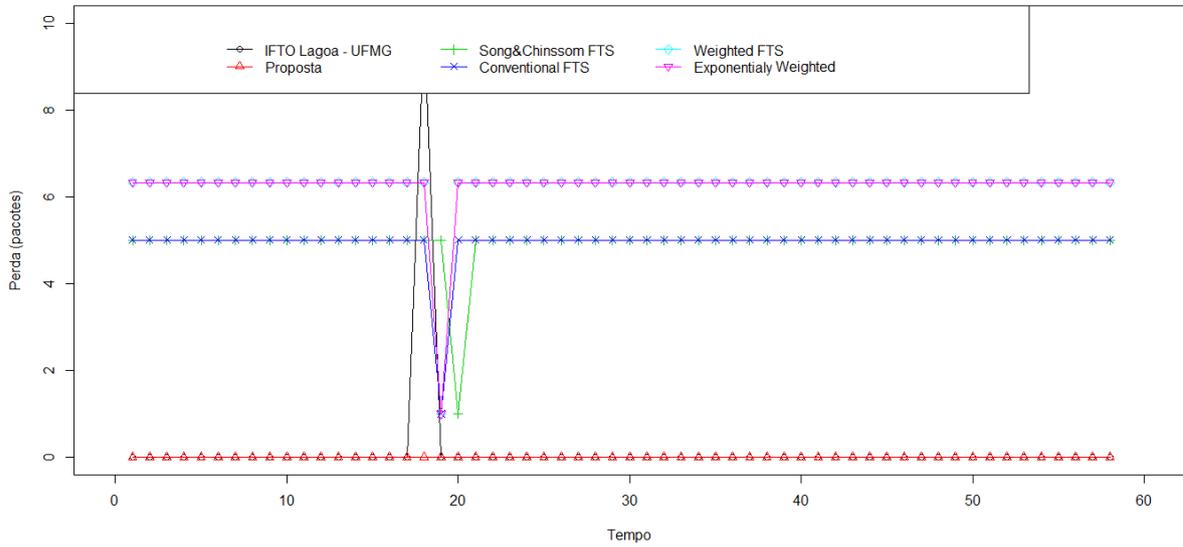


Figura A.14.: Comportamento dos métodos: série LABMATICA-GREDES com 5 partições do universo de discurso (perda de pacotes)

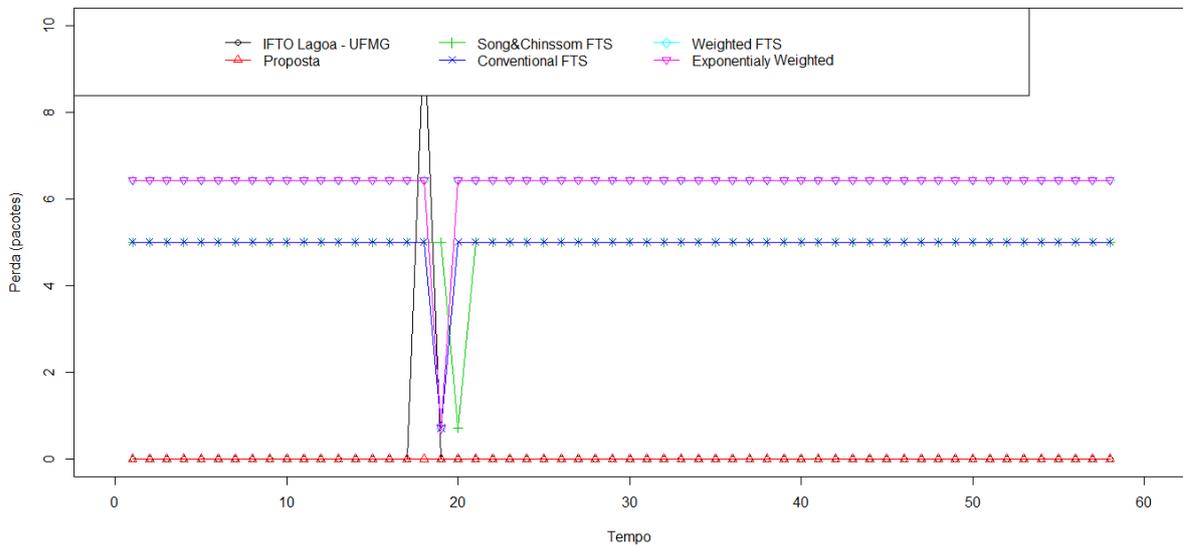


Figura A.15.: Comportamento dos métodos: série LABMATICA-GREDES com 7 partições do universo de discurso (perda de pacotes)

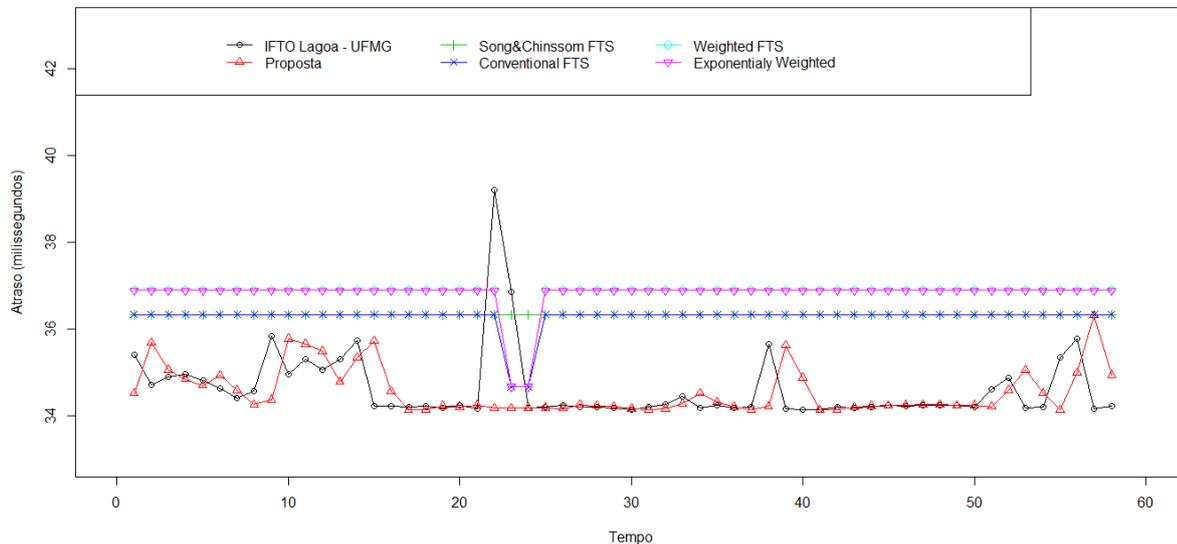


Figura A.16.: Comportamento dos métodos: série UNICAMP-IFTO com 3 partições do universo de discurso (atraso)

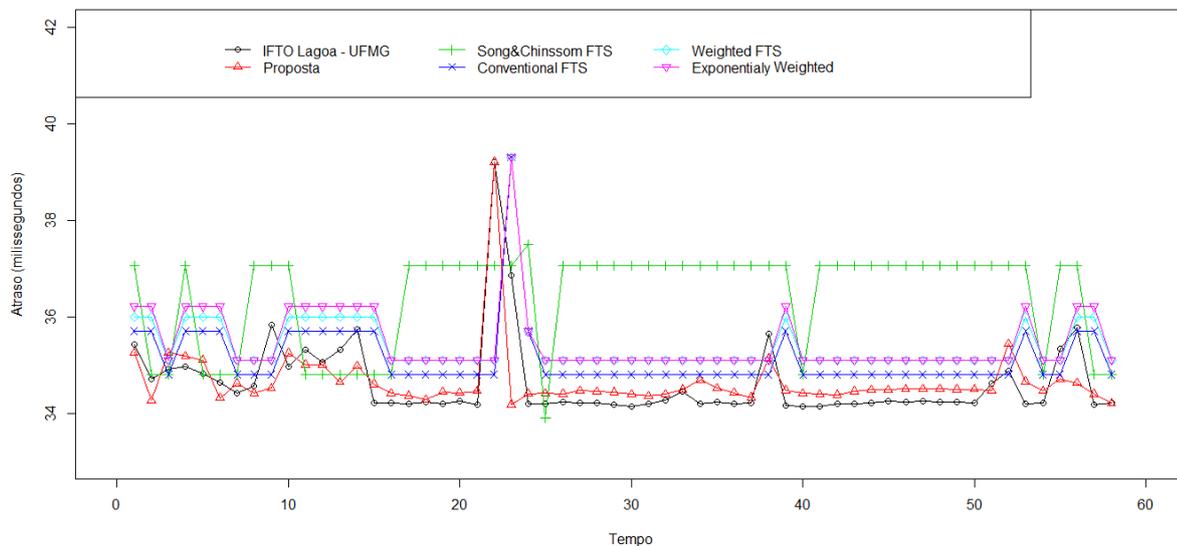


Figura A.17.: Comportamento dos métodos: série UNICAMP-IFTO com 5 partições do universo de discurso (atraso)

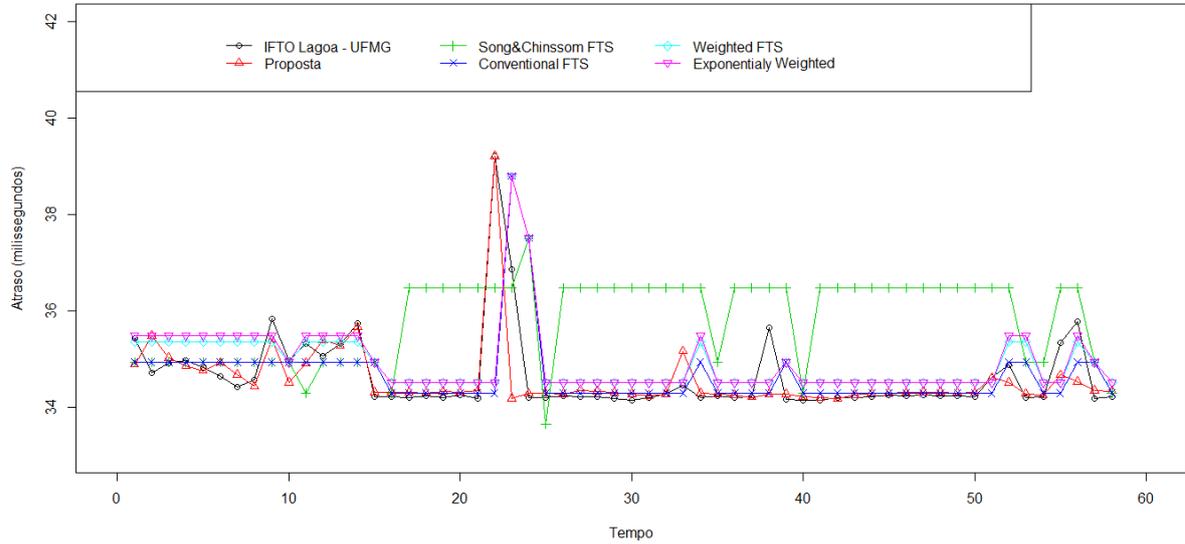


Figura A.18.: Comportamento dos métodos: série UNICAMP-IFTO com 7 partições do universo de discurso (atraso)

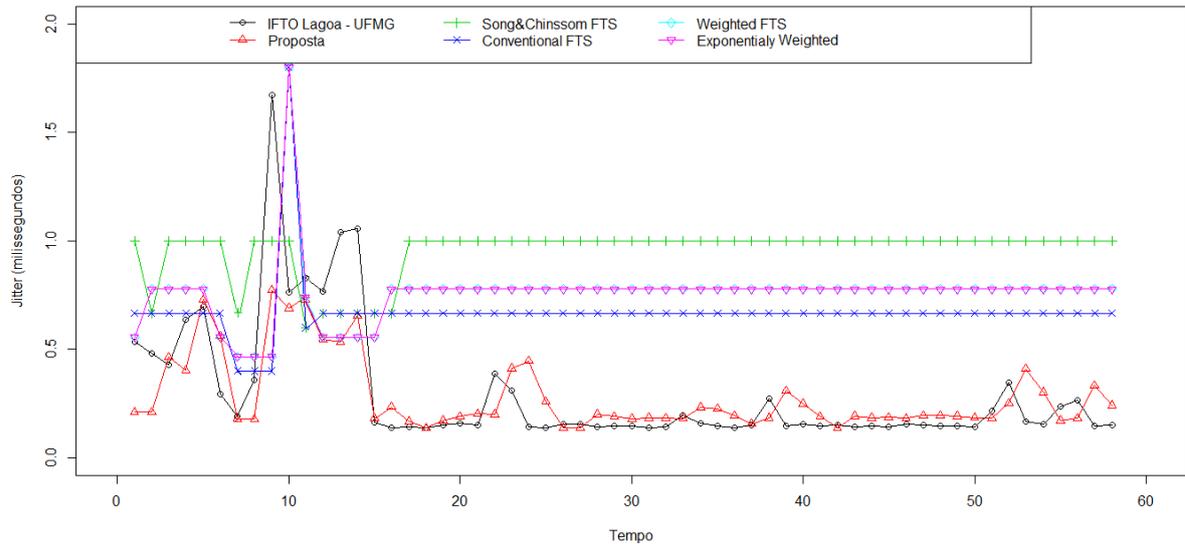


Figura A.19.: Comportamento dos métodos: série UNICAMP-IFTO com 3 partições do universo de discurso (*jitter*)

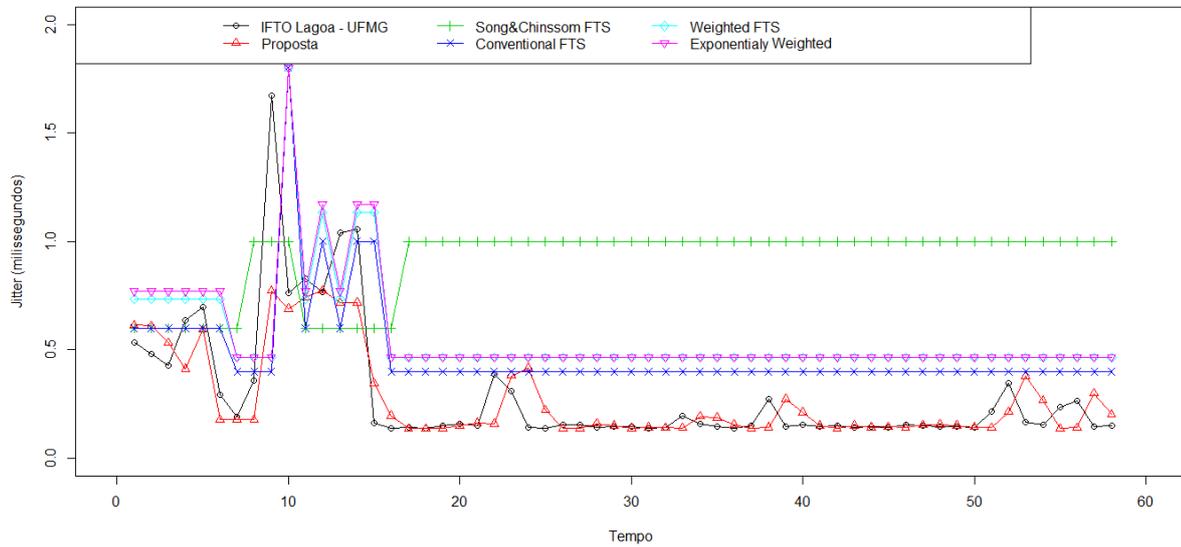


Figura A.20.: Comportamento dos métodos: série UNICAMP-IFTO com 5 partições do universo de discurso (*jitter*)

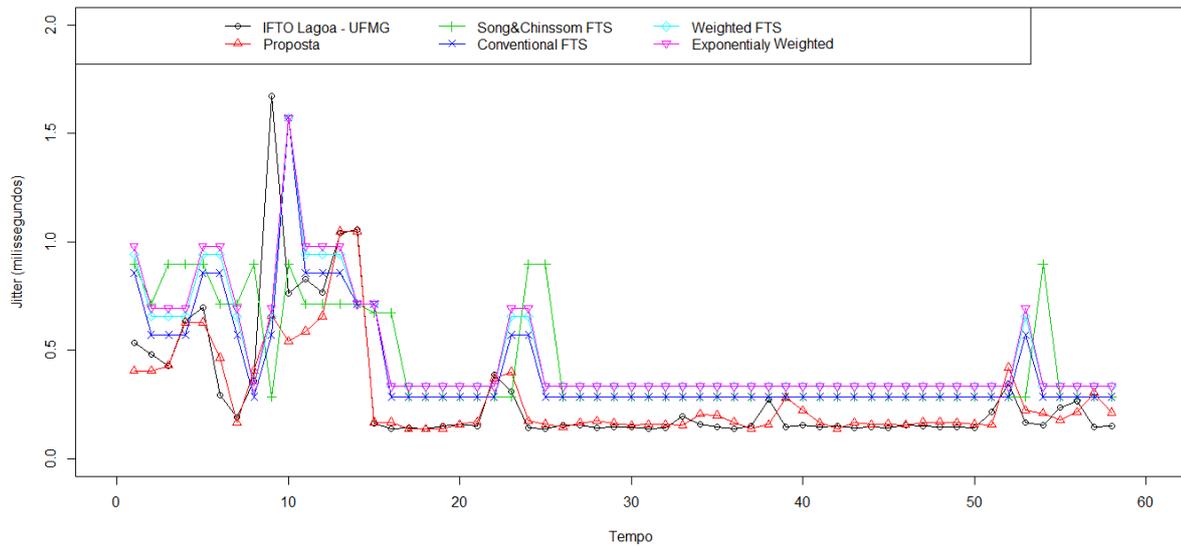


Figura A.21.: Comportamento dos métodos: série UNICAMP-IFTO com 7 partições do universo de discurso (*jitter*)

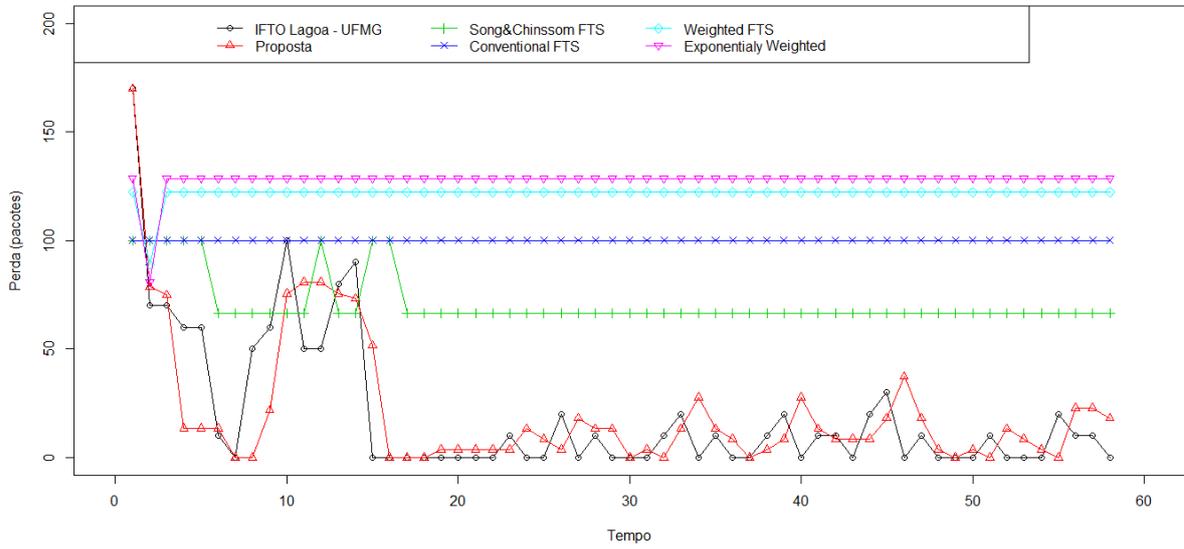


Figura A.22.: Comportamento dos métodos: série UNICAMP-IFTO com 3 partições do universo de discurso (perda de pacotes)

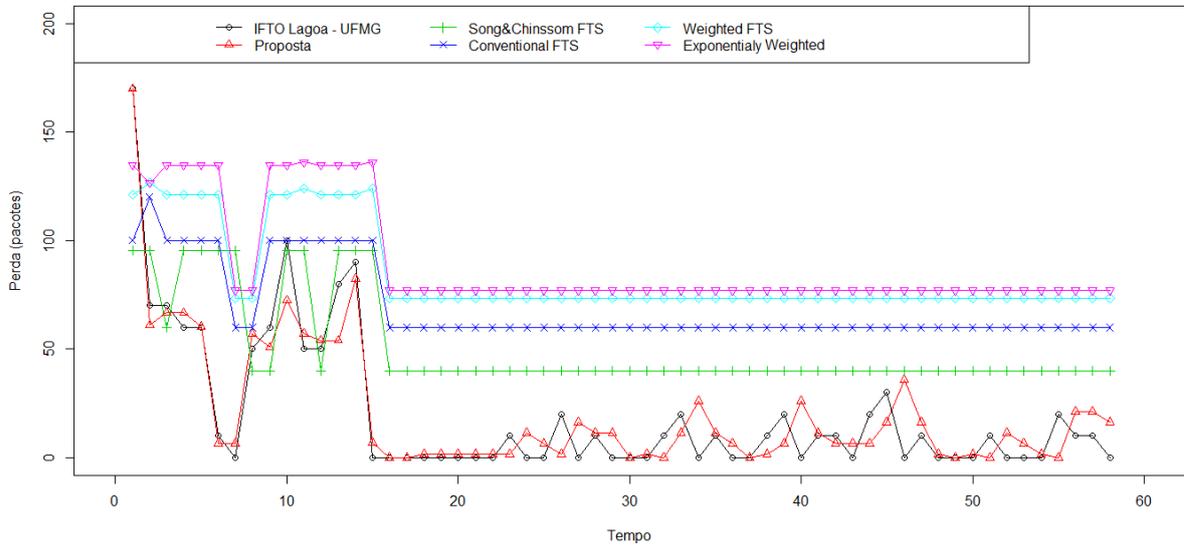


Figura A.23.: Comportamento dos métodos: série UNICAMP-IFTO com 5 partições do universo de discurso (perda de pacotes)

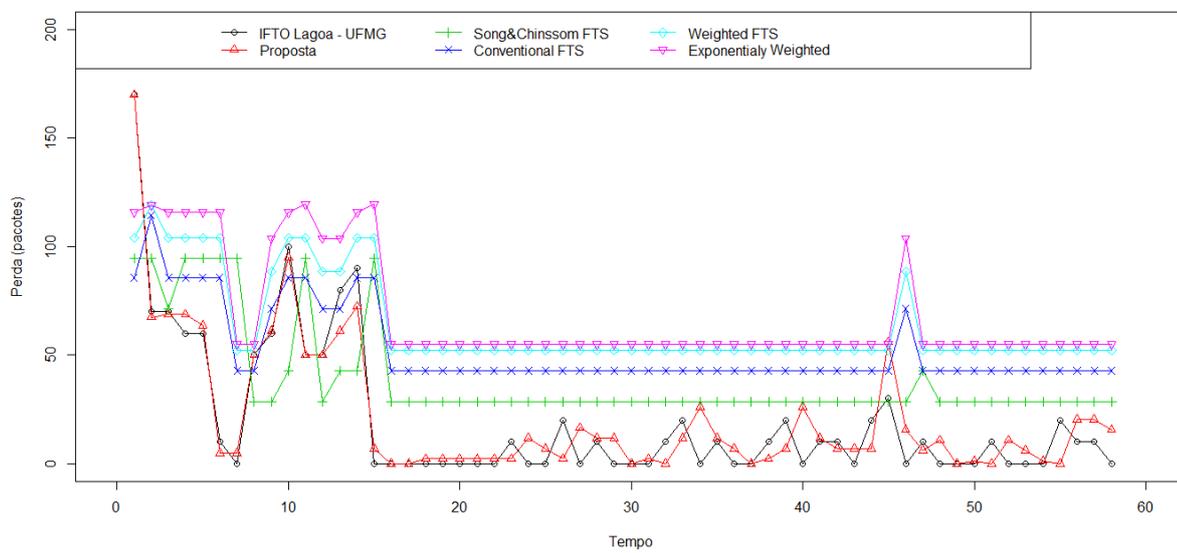


Figura A.24.: Comportamento dos métodos: série UNICAMP-IFTO com 7 partições do universo de discurso (perda de pacotes)

Referências

- Becerra Martinez, H. (2014). Métricas de qualidade para sinais áudio-visuais, Master's thesis, Universidade de Brasília.
- Biernacki, A. (2017). Analysis and modelling of traffic produced by adaptive http-based video., Multimedia Tools Appl.
76(10): 12347–12368.
- Bollerslev, T. (1987). A conditionally heteroskedastic time series model for speculative prices and rates of return, The Review of Economics and Statistics
69(3): 542–547.
- Cavalca, U. C. (2011). Uso de ferramentas estatísticas na gerência de performance de redes de computadores. Monografia (Especialização em Administração de Redes Linux) - Universidade Federal de Lavras.
- Caviedes, J. E. & Oberti, F. (2003). No-reference quality metric for degraded and enhanced video, Visual Communications and Image Processing 2003, International Society for Optics and Photonics, pp. 621–632.
- Chagas da Silva, D. (2015). Uma arquitetura de seleção de redes móveis para ambientes heterogêneos, Master's thesis, Universidade Federal de Minas Gerais.
- Chagas da Silva, D., de Castro Monteiro, C. & Batista, L. S. (2014). Classificação e seleção de redes via tomada de decisão multicritério, VI Congresso Internacional de Computação e Telecomunicações pp. 259–265.
- Chai, T. & Draxler, R. R. (2014). Root mean square error (RMSE) or mean absolute error (MAE)?—arguments against avoiding RMSE in the literature, Geoscientific Model Development
7(3): 1247–1250.

- Chatfield, C. (2001). Time-Series Forecasting, Chapman and Hall/CRC, New York.
- Chen, M.-Y. (2014). A high-order fuzzy time series forecasting model for internet stock trading, Future Generation Computer Systems 37: 461–467.
- Chen, S.-M. (1996). Forecasting enrollments based on fuzzy time series, Fuzzy Sets and Systems 81(3): 311–319.
- Cheng, C.-H., Chang, J.-R. & Yeh, C.-A. (2006). Entropy-based and trapezoid fuzzification-based fuzzy time series approaches for forecasting it project cost, Technological Forecasting and Social Change 73(5): 524–542.
- Cheng, C.-H., Chen, Y.-S. & Wu, Y.-L. (2009). Forecasting innovation diffusion of products using trend-weighted fuzzy time-series model, Expert Systems with Applications 36(2): 1826–1832.
- Ciccarese, G., De Blasi, M., Marra, P., Mighali, V., Palazzo, C., Patrono, L. & Stefanizzi, M. L. (2009). Vertical handover algorithm for heterogeneous wireless networks, INC, IMS and IDC, 2009. NCM'09. Fifth International Joint Conference on, IEEE, pp. 1948–1954.
- Clark, R. C. & Mayer, R. E. (2016). E-learning and the science of instruction: Proven guidelines for consumers and designers of multimedia learning, John Wiley & Sons, San Francisco: Jossey-Bass.
- Costa, F., Cândido, P., Guimarães, F. & Batista, L. (2017). Regressão linear aplicada na predição de series temporais fuzzy, XIII Simpósio Brasileiro de Automação Inteligente pp. 268–275.
- Costa, F., Monteiro, C. d. C., Silva, M. C. d. & Joaquim, J. d. C. (2012). Análise de dados para previsão de qualidade de rede sem fio a partir do nível de sinal, VII CONNEPI - Congresso Norte Nordeste de Pesquisa e Inovação .
- da Silva, M. P. (2015). Qualidade de experiência: Uma abordagem interdisciplinar, Revista de Exatas e TECNológicas

- 1(7): 20–30.
- Dalbem, E. E. & Pinto, R. P. (2016). Qualidade de serviço em redes IPv6 com tratamento justo de fluxos TCP e UDP, Revista Tecnológica da Fatec Americana 3(2): 23.
- de Castro Monteiro, C. (2012). Um Ambiente para Apoio à Integração de Redes Sem Fio Heterogêneas, PhD thesis, Universidade de Brasília.
- Duanmu, Z., Zeng, K., Ma, K., Rehman, A. & Wang, Z. (2017). A quality-of-experience index for streaming video, IEEE Journal of Selected Topics in Signal Processing 11(1): 154–166.
- Efendi, R., Ismail, Z. & Deris, M. M. (2013). Improved weight fuzzy time series as used in the exchange rates forecasting of us dollar to ringgit malaysia, International Journal of Computational Intelligence and Applications 12(01): 1350005.
- Egilmez, H. E., Civanlar, S. & Tekalp, A. M. (2013). An optimization framework for QoS-enabled adaptive video streaming over openflow networks, IEEE Transactions on Multimedia 15(3): 710–715.
- Farias, M. C. & Mitra, S. K. (2005). No-reference video quality metric based on artifact measurements, Image Processing, 2005. ICIP 2005. IEEE International Conference on, Vol. 3, IEEE, pp. III–141.
- Gomes, I. R. et al. (2010). Modelo de propagação indoor multi-andar em 2.4 GHz com estimativa de parâmetros de QoS em chamadas VoIP, Master's thesis, Universidade Federal do Pará.
- Granger, C. W. & Joyeux, R. (1980). An introduction to long-memory time series models and fractional differencing, Journal of time series analysis 1(1): 15–29.
- Gunawan, I. P. & Ghanbari, M. (2005). Image quality assessment based on harmonics gain/loss information, Image Processing, 2005. ICIP 2005. IEEE International Conference on, Vol. 1, IEEE, pp. I–429.

- Hore, A. & Ziou, D. (2010). Image quality metrics: PSNR vs. SSIM, Pattern recognition (ICPR), 2010 20th international conference on, IEEE, pp. 2366–2369.
- Huarng, K. (2001a). Effective lengths of intervals to improve forecasting in fuzzy time series, Fuzzy Sets and Systems
123(3): 387–394.
- Huarng, K. (2001b). Heuristic models of fuzzy time series for forecasting, Fuzzy sets and systems
123(3): 369–386.
- Hwang, J.-R., Chen, S.-M. & Lee, C.-H. (1998). Handling forecasting problems using fuzzy time series, Fuzzy sets and systems
100(1): 217–228.
- Ishibuchi, H. & Nojima, Y. (2013). Repeated double cross-validation for choosing a single solution in evolutionary multi-objective fuzzy classifier design, Knowledge-Based Systems
54: 22–31.
- Ismail, Z. & Efendi, R. (2011). Enrollment forecasting based on modified weight fuzzy time series, Journal of Artificial Intelligence
4(1): 110–118.
- Ismail, Z., Efendi, R. & Deris, M. M. (2015). Application of fuzzy time series approach in electric load forecasting, New Mathematics and Natural Computation
11(03): 229–248.
- ITU-T, R. P. (2007). 10/g. 100 amendment 1, “New Appendix I–Definition of Quality of Experience (QoE)”, International Telecommunication Union .
- Javedani Sadaei, H. (2013). Improved models in Fuzzy Time Series for forecasting, PhD thesis, Universiti Teknologi Malaysia.
- Katris, C. & Daskalaki, S. (2015). Comparing forecasting approaches for internet traffic, Expert Systems with Applications
42(21): 8172–8183.

- Kundu, D., Ghadiyaram, D., Bovik, A. C. & Evans, B. L. (2017). No-reference quality assessment of tone-mapped HDR pictures, IEEE Transactions on Image Processing 26(6): 2957–2971.
- Kurose, J. F. & Ross, K. W. (2016). Computer networking: a top-down approach.
- Lahby, M., Attioui, A. & Sekkaki, A. (2017). An optimized vertical handover approach based on m-anp and tophis in heterogeneous wireless networks, Advances in Ubiquitous Networking 2, Springer, pp. 15–29.
- Lahby, M., Baghla, S. & Sekkaki, A. (2015). Survey and comparison of madm methods for network selection access in heterogeneous networks, New Technologies, Mobility and Security (NTMS), 2015 7th International Conference on, IEEE, pp. 1–6.
- Lee, M. H., Sadaei, H. J. & Suhartono (2013). Improving TAIEX forecasting using fuzzy time series with Box–Cox power transformation, Journal of Applied Statistics 40(11): 2407–2422.
- Leite de Araújo, M. A. & de Castro Monteiro, C. (2013). Um estudo de QoS para predição da perda de pacotes em redes sem fio a partir do nível de sinal, V Congresso Internacional de Computação e Telecomunicações pp. 244–249.
- Lubin, J. & Fibush, D. (1997). Sarnoff jnd vision model: Algorithm description and testing, Presentation by Jeffrey Lubin of Sarnoff to T1A1 5.
- Maia, O. B., Yehia, H. C. & de Errico, L. (2015). A concise review of the quality of experience assessment for video streaming, Computer Communications 57: 1–12.
- Montgomery, D. C. (2017). Design and analysis of experiments, John Wiley & Sons.
- Moorthy, A. K. & Bovik, A. C. (2011). Blind image quality assessment: From natural scene statistics to perceptual quality, IEEE transactions on Image Processing 20(12): 3350–3364.
- Moussas, V. C., Daglis, M. & Kolega, E. (2005). Network traffic modeling and prediction using multiplicative seasonal ARIMA models, Proceedings of the 1st International Conference on Experiments/Process/System Modeling/Simulation/Optimization,

Athens, pp. 6–9.

- Nametala, C. A., Pimenta, A., Pereira, A. C. M. & Carrano, E. G. (2016). Uma estratégia automatizada de investimento por meio de redes neurais artificiais e preditores econométricos, Simpósio Brasileiro de Sistemas de Informação .
- Pelsser, C., Cittadini, L., Vissicchio, S. & Bush, R. (2013). From paris to tokyo: On the suitability of ping to measure latency, Proceedings of the 2013 conference on Internet measurement conference, ACM, pp. 427–432.
- Pierucci, L. & Micheli, D. (2016). A neural network for quality of experience estimation in mobile communications, IEEE MultiMedia 23(4): 42–49.
- Rios, V. d. M. (2012). Seleção de redes sem fio baseada em técnicas de apoio à decisão, Master's thesis, Universidade de Brasília.
- Rohaly, A. M., Libert, J., Corriveau, P., Webster, A. et al. (2003). Final report from the video quality experts group on the validation of objective models of video quality assessment, phase ii, ITU-T Standards Contribution COM 1: 9–80.
- Sadaei, H. J., Enayatifar, R., Abdullah, A. H. & Gani, A. (2014). Short-term load forecasting using a hybrid model with a refined exponentially weighted fuzzy time series and an improved harmony search, International Journal of Electrical Power & Energy Systems 62(from 2005): 118–129.
- Sadaei, H. J., Enayatifar, R., Guimarães, F. G., Mahmud, M. & Alzamil, Z. A. (2016). Combining arfima models and fuzzy time series for the forecast of long memory time series, Neurocomputing 175: 782–796.
- Sadaei, H. J., Guimarães, F. G., da Silva, C. J., Lee, M. H. & Eslami, T. (2017). Short-term load forecasting method based on fuzzy time series, seasonality and long memory process, International Journal of Approximate Reasoning 83: 196–217.

- Satyanarayana, P. (2009). A time series modeling and prediction of wireless network traffic., International Journal of Interactive Mobile Technologies 3(1).
- Singh, P. & Borah, B. (2013). An efficient time series forecasting model based on fuzzy time series, Engineering Applications of Artificial Intelligence 26(10): 2443–2457.
- Sivakumar, R., Kumar, E. A. & Sivaradje, G. (2011). Prediction of traffic load in wireless network using time series model, Process Automation, Control and Computing (PACC), 2011 International Conference on, IEEE, pp. 1–6.
- Song, Q. & Chissom, B. S. (1993a). Forecasting Enrollments with Fuzzy Time Series - part I, Fuzzy Sets And Systems 54: 1–9.
- Song, Q. & Chissom, B. S. (1993b). Fuzzy time series and its models, Fuzzy Sets and Systems 54(3): 269–277.
- Song, Q. & Chissorn, B. S. (1994). Forecasting enrollments with fuzzy time series-part II, Fuzzy Sets and Systems 62: 1–8.
- Takahashi, A., Hands, D. & Barriac, V. (2008). Standardization activities in the ITU for a QoE assessment of IPTV, IEEE Communications Magazine 46(2).
- Tanenbaum, A. S. (2016). Structured computer organization, Pearson Education India.
- Thayammal, M. C. & Linda, M. M. (2017). A comprehensive study on efficient resource allocation by QoS in wireless networks., ICTACT Journal on Communication Technology 8(1).
- Trestian, R., Ormond, O. & Muntean, G.-M. (2014). Enhanced power-friendly access network selection strategy for multimedia delivery over heterogeneous wireless networks, IEEE Transactions on Broadcasting

- 60(1): 85–101.
- Usman, M. A., Shin, S. Y., Shahid, M. & Lövsström, B. (2017). A no reference video quality metric based on jerkiness estimation focusing on multiple frame freezing in video streaming, IETE Technical Review
34(3): 309–320.
- Wang, Z., Lu, L. & Bovik, A. C. (2004). Video quality assessment based on structural distortion measurement, Signal processing: Image communication
19(2): 121–132.
- Won, Y. & Ahn, S. (2005). GOP ARIMA: Modeling the nonstationarity of VBR processes, Multimedia systems
10(5): 359–378.
- Yasmeen, F. & Sharif, M. (2015). Functional time series (fts) forecasting of electricity consumption in pakistan, International Journal of Computer Applications
124(7).
- Yu, H.-K. K. (2005). Weighted fuzzy time series models for TAIEX forecasting, Physica A: Statistical Mechanics and its Applications
349(3): 609–624.
- Zadeh, L. A. (1965). Fuzzy sets, Information and control
8(3): 338–353.
- Zadeh, M. H. & Seyyedi, M. A. (2010). Qos monitoring for web services by time series forecasting, 2010 3rd International Conference on Computer Science and Information Technology, Vol. 5, pp. 659–663.
- Zarpelão, B. B. et al. (2010). Detecção de anomalias em redes de computadores.
- Zerman, E., Valenzise, G. & Dufaux, F. (2017). An extensive performance evaluation of full-reference HDR image quality metrics, Quality and User Experience
1(2): 1–16.
- Zhang, W. & Liu, H. (2017). Study of saliency in objective video quality assessment, IEEE Transactions on Image Processing

26(3): 1275–1288.

Zhani, M. F., Elbiaze, H. & Kamoun, F. (2009). Analysis and prediction of real network traffic., JNW

4(9): 855–865.