

Um Mecanismo de Raciocínio para Redes Cognitivas baseado em Inferência Bayesiana

Rafael Lopes Gomes¹, Christian Facchini²,
Fabrizio Granelli², Edmundo Madeira¹, Nelson Fonseca¹

¹Instituto de Computação - IC
Universidade Estadual de Campinas - UNICAMP
Campinas, SP, Brasil

²Department of Engineering and Computer Science (DISI)
University of Trento
Via Sommarive 14, I-38123 Trento, Itália

rafaellgom@lrc.ic.unicamp.br, {facchini, granelli}@disi.unitn.it
{edmundo, nfonseca}@ic.unicamp.br

Abstract. *Cognitive networks were recently proposed to cope with the complexity and the dynamics of network management, exploiting reasoning to adapt the behavior of protocols, trying to ensure a more accurate end-to-end Quality of Service (QoS). While several approaches are available that propose different approaches, the problem of reasoning represents a challenging issue. Within this context, this paper proposes a Bayesian inference engine to control the data rate transmission, aiming to find the value of the data rate that has the highest probability of getting a high throughput. The proposal is evaluated on an Ad Hoc scenario, where the results show that the proposed mechanisms can achieve better network resources utilization when compared to other existing mechanisms in the literature.*

Resumo. *As redes cognitivas foram recentemente propostas para lidar com a complexidade e a dinâmica da gerência de rede, explorando o raciocínio para adaptar o comportamento de protocolos, e assim tentar garantir uma qualidade de serviço (Quality of Service - QoS) fim-a-fim mais apurada. Embora várias abordagens já tenham sido propostas, o problema de qual mecanismo de raciocínio usar ainda é um desafio. Dentro deste contexto, este trabalho propõe um mecanismo de inferência Bayesiana para controlar a taxa de envio de dados, visando encontrar o valor da taxa de dados que tenha a maior probabilidade de conseguir uma vazão elevada. A proposta é avaliada em um cenário Ad Hoc, onde os resultados mostram que o mecanismo proposto consegue obter uma melhor utilização da rede quando comparado a outros existentes na literatura.*

1. Introdução

A Internet tende a dar suporte a uma grande variedade de aplicações, desde uma simples transferência de dados até aplicações complexas que vão além da visão de serviços *triple play* (dados, voz e vídeo), incluindo interações de realidade aumentada, realidade virtual, HDTV, jogos online, entre outras.

Entretanto, na Internet atual a garantia e otimização de desempenho são tarefas difíceis, pois cada protocolo é projetado para trabalhar com objetivos diferentes e sem saber o comportamento dos demais.

A interação entre os protocolos de diferentes camadas pode comprometer o desempenho da rede como um todo, sendo difíceis de quantificar, prever e controlar. Além disso, as técnicas de *crosslayer* não são uma solução definitiva, visto que frequentemente são estáticas e focadas em objetivos específicos, ou seja, não consideram o dinamismo da infraestrutura da rede [Facchini et al. 2010].

Avanços recentes nas tecnologias de comunicação levaram a melhorias significativas no desempenho da rede, ao preço de maior complexidade de gerenciamento. A fim de lidar com tal complexidade, novos paradigmas de redes têm sido propostos. Neste cenário, as redes cognitivas (*Cognitive Networks*) tentam incorporar redes com inteligência para facilitar o monitoramento, raciocínio e ação, no sentido de se alcançar as metas de desempenho definidas [Thomas et al. 2005].

Redes cognitivas são compostas de nós inteligentes, capazes de raciocinar sobre o ambiente em que estão e agir, e visam atingir um objetivo fim-a-fim global, continuando a aprender sobre o contexto operacional e as consequências de suas ações.

Diferentes grupos de pesquisa usam terminologias diferentes para coisas semelhantes. Alguns grupos chamam suas arquiteturas autônomicas, o que implica que a rede pode operar sem (ou com pouca) intervenção humana. Outros grupos chamam suas arquiteturas cognitivas e se referem ao fato de que a rede está, entre outros, raciocinando e aprendendo sobre o ambiente em questão [Fortuna and Mohorcic 2009].

O conceito de cognição visa permitir a redução da complexidade do gerenciamento da rede, apoiando a adaptação dinâmica e autoconfiguração, fazendo a rede se adequar às solicitações dos usuários [Fortuna and Mohorcic 2009].

O *loop* de cognição, representado na Figura 1, é fundamental em qualquer arquitetura cognitiva. De acordo com este ciclo, durante a fase de detecção (*sensing*) uma entidade cognitiva adquire conhecimento sobre o meio ambiente e preprocessa este conhecimento. Depois, o raciocínio (*reasoning*) ocorre durante a fase de planejamento (*planning*), enquanto a decisão é tomada na fase de decisão (*decision*). Finalmente, na fase de ação (*acting*), as ações são executadas e os seus efeitos avaliados.

O raciocínio é sem dúvida a etapa mais importante no processo de cognição, pois além de determinar as ações a serem tomadas na etapa de atuação, é preciso lidar com uma possível falta de precisão das informações.

Como consequência, o processo de raciocínio tem recebido grande atenção na literatura. Embora exista um consenso geral de que o raciocínio deve explorar a informação de todas as camadas da pilha de protocolo, ainda não há nenhum padrão sobre a técnica de raciocínio a ser empregada para tal tarefa.

As redes neurais, redes bayesianas, sistemas especialistas, algoritmos de otimização multidimensional e diversas técnicas nos campos da teoria de controle e reconhecimento de padrões têm sido empregadas para este objetivo. Uma perspectiva mais prática é fornecida por Thomas et al. [Thomas et al. 2006], que lista algumas técnicas e algoritmos de aprendizado de máquina que podem ser utilizados para o processo de

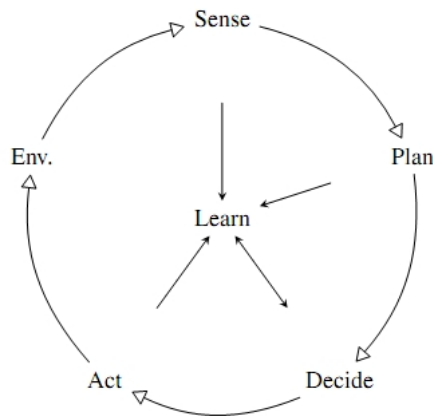


Figura 1. Loop de Cognição [Fortuna and Mohorcic 2009]

raciocínio.

Nesse contexto, este trabalho apresenta uma variação do mecanismo de cognição proposto em [Facchini and Granelli 2009], sendo que ao invés de se utilizar *Fuzzy Cognitive Maps* (FCM) no processo de raciocínio, usa-se uma rede bayesiana para o processo de inferência. Sendo assim este trabalho utiliza um mecanismo de inferência bayesiana para controlar a taxa de dados enviada, onde se visa encontrar a taxa de dados que aumenta a probabilidade de se atingir uma vazão elevada.

A proposta deste trabalho é avaliada utilizando o simulador Ns-3 [NS-3 2011], analisando-se o desempenho da proposta quando comparada com o mecanismo de cognição original (usando FCM) e a rede sem a utilização de um mecanismo de cognição.

O restante do trabalho é organizado da seguinte forma: a Seção 2 apresenta uma base teórica para o restante do trabalho, a Seção 3 mostra alguns trabalhos relacionados ao contexto deste trabalho, a Seção 4 explica o funcionamento da solução proposta, enquanto que a Seção 5 apresenta uma análise do desempenho / comportamento da mesma, e finalmente, a Seção 6 conclui o trabalho ressaltando alguns trabalhos futuros.

2. Fundamentação Teórica

Esta seção tem por objetivo realizar uma breve descrição das técnicas utilizadas neste trabalho: redes bayesianas, modelos gráficos (*Graphical Models*), mecanismos de inferência e *Fuzzy Cognitive Maps* (FCM).

2.1. Redes Bayesianas (*Bayesian Networks* – BN)

Redes Bayesianas são úteis para representar e utilizar informações probabilísticas. Há duas partes em qualquer modelo de rede bayesiana: um grafo direcionado de acordo com as variáveis observadas e uma distribuição de probabilidade associada [Neapolitan 2003].

O grafo representa as informações qualitativas sobre as variáveis aleatórias (propriedades de independência condicional). Enquanto a distribuição de probabilidade associada fornece uma descrição quantitativa de como as variáveis se relacionam entre si.

A estrutura do grafo tem duas funções importantes. Primeiramente, esta descreve as propriedades sobre a distribuição subjacente, assim mantendo a coerência entre o grafo

e a distribuição.

Além disso, uma vez que o grafo trata das propriedades de independência das variáveis aleatórias, é muito útil para a compreensão de como pode-se usar o modelo de probabilidade de forma eficiente para avaliar diversas propriedades marginais e condicionais.

2.2. Modelo Gráfico (*Graphical Model*)

Graphical Models representam a união entre a teoria de probabilidade e a teoria dos grafos. Eles fornecem uma ferramenta natural para lidar com problemas como incerteza e complexidade, e devido a isso têm um papel importante no projeto e análise de algoritmos de aprendizado de máquina [Bishop 2007].

Sobre uma perspectiva de teoria dos grafos os *Graphical Models* fornecem uma interface intuitiva para se modelar conjuntos de variáveis interativas, bem como uma estrutura de dados para o desenvolvimento de algoritmos de uso geral.

Dentro deste contexto ainda há os *Factor Graphs* [Loeliger 2004]. *Factor Graphs* são um tipo particular de *Graphical Model*, com aplicações em inferência bayesiana, que permitem o cálculo eficiente da distribuição marginal das variáveis aleatórias, através do algoritmo *Sum-Product* [Kschischang et al. 2001].

Ambos os grafos, direcionados e não direcionados, permitem que uma função global de diversas variáveis possa ser expressa como um produto de fatores sobre subconjuntos destas variáveis. Os *Factor Graphs* fazem essa decomposição explícita através da introdução de nós adicionais para os fatores, além dos nós que representam as variáveis [Loeliger 2004].

Em um *Factor Graphs* existe um nó para cada variável da distribuição. Há também nós adicionais para cada fator na distribuição conjunta. E ainda existem ligações conectando cada nó fator aos nós de variáveis a que esse fator depende.

Factor Graphs são grafos bipartidos, pois consistem em dois tipos distintos de nós, e todas as ligações são entre os nós do tipo oposto. Em geral, *Factor Graphs* podem ser descritos como duas linhas de nós (variáveis no topo e *Factor Nodes* ao fundo) com ligações entre as linhas. Um exemplo é mostrado na Figura 2.




Figura 2. Exemplo de *Factor Graphs* [Bishop 2007]: (a) Um grafo direcionado com a fatorização de $p(x_1)p(x_2)p(x_3|x_1,x_2)$. (b) Um *Factor Graphs* que representa a mesma distribuição que o grafo direcionado, cujo o fator satisfaz $f(x_1, x_2, x_3) = p(x_1)p(x_2)p(x_3|x_1,x_2)$

Neste trabalho, como será mostrado mais a frente (Seção 4), as variáveis da

distribuição definida são características da rede. No caso, utiliza-se as informações referente à taxa de dados transmitida, taxa de erros do ambiente e vazão do nó.

2.3. Inferência

O principal objetivo do mecanismo de inferência é estimar os valores dos nós escondidos, dados os valores dos nós observados. O processo de observar as “folhas” de um modelo, e tentar inferir os valores das causas ocultas é chamado de diagnóstico (*diagnosis*). Enquanto que observar as “raízes” de um modelo, e tentar prever os efeitos, é chamado de previsão (*prediction*). Redes bayesianas, por exemplo, podem ser utilizadas para ambas as tarefas.

Se o grafo subjacente é acíclico, pode-se utilizar um algoritmo de passagem de mensagens locais (algoritmo de Pearl) para realizar a tarefa de inferência. No caso da utilização de rede bayesianas, se a mesma possui ciclos, o algoritmo de Pearl corre o risco de realizar dupla contagem das mensagens, e assim não convergir.

Em situações como essa, para se realizar uma inferência exata, agrupa-se os nós gerando uma árvore, e depois se executa um algoritmo de passagem de mensagens. O esquema de passagem de mensagens poderia ser feito pelo algoritmo de Pearl, mas é mais comum o uso de uma variante projetada para modelos não direcionados, o algoritmo *Junction Tree algorithm* [Bishop 2007].

O tempo de execução destes algoritmos exatos é exponencial ao tamanho do maior grupo (supondo que todos nós ocultos são discretos), o tamanho é chamado de largura induzida do grafo, e minimizá-lo é um problema NP-Difícil, por isso é necessário o uso de uma inferência aproximada.

A inferência aproximada é muitas vezes necessária, mesmo para grafos com largura induzida baixa, pois se alguns dos nós representam variáveis aleatórias contínuas, em muitos casos, as integrais correspondentes necessárias para aplicar a regra de Bayes não podem ser realizadas de forma fechada.

Um dos métodos para inferência aproximada mais popular, o qual é utilizado neste trabalho, é o algoritmo *Loopy Belief Propagation*. A idéia é simplesmente aplicar o algoritmo *Sum-Product*, mesmo que não haja nenhuma garantia de que vai render bons resultados. No entanto, como o grafo agora tem ciclos, a informação pode fluir, muitas vezes em torno do grafo. Para alguns modelos, o algoritmo irá convergir, enquanto que para outros não.

Mais informações referentes ao funcionamento e provas relacionadas aos algoritmos *Sum-Product* e *Loopy Belief Propagation* podem ser encontradas nas referências [Kschischang et al. 2001] e [Bishop 2007], respectivamente.

2.4. Fuzzy Cognitive Maps (FCM)

Proposta na década de 80 [Kosko 1986] como uma ferramenta para o raciocínio causal, FCMs podem ser usados para modelar sistemas dinâmicos, uma vez que enfatizam as relações de causa-efeito entre as variáveis internas.

Matematicamente, FCMs podem ser representados por grafos direcionados rotulados (e por matrizes de adjacência). Os nós no grafo simbolizam os objetos de causalidade, ou seja, conceitos gerais que podem trazer ou ser decorrentes de outros conceitos.

O domínio dos nós é geralmente discreto e o mais comum é o domínio binário $\{0, 1\}$: "0" o conceito não é considerado, ao passo que "1" ele é considerado ativo. O vetor de todos os valores do nó define o estado do sistema.

Em um FCM, o processo de encontrar os efeitos decorrentes de causas, comumente é feito como um raciocínio dedutivo (ou simplesmente inferência), o qual é computacionalmente barato.

Nos FCM, o raciocínio dedutivo é feito multiplicando-se o estado do sistema pela matriz FCM e comparando o resultado da multiplicação com limites pré-definidos. Este processo pode ser repetido até convergir para uma solução adequada.

FCMs também têm algumas desvantagens, a mais limitante delas diz respeito ao raciocínio abduutivo. Ao contrário do raciocínio dedutivo, raciocínio abduutivo (processo de descoberta que faz com que levam a um dado efeito) é um problema NP-difícil (a mesma complexidade ocorre quando as redes Bayesianas são utilizadas).

3. Trabalhos Relacionados

Esta seção apresenta os principais trabalhos encontrados na literatura relacionados às redes cognitivas, mecanismo de cognição e estratégias para inferência.

Clancy et al [Clancy et al. 2007] descrevem um modelo concreto de rádios cognitivos genéricos para utilizar um mecanismo de aprendizagem. O objetivo é incorporar os resultados do mecanismo de aprendizagem em um mecanismo de cálculo de predicados de raciocínio, para que os rádios possam utilizar informações passadas e agir rapidamente no futuro. Para isso, o mesmo formaliza uma arquitetura para a utilização de técnicas de aprendizagem de máquina em redes cognitivas, onde esta arquitetura visa ser genérica com relação aos mecanismos de inferência, podendo assim resolver problemas como maximização da capacidade e acesso ao espectro dinâmico.

Thomas et al [Thomas et al. 2006] propõem uma arquitetura para possibilitar o processo cognitivo que consiste de um ou mais elementos cognitivos, operando em algum grau, entre a autonomia e plena cooperação. Onde um único elemento cognitivo pode ser fisicamente distribuído por um ou mais nós na rede. Além da arquitetura, o trabalho de Thomas et al mostra o conceito de rede cognitiva em comparação aos conceitos de rádios cognitivos e *design crosslayer*.

Miao et al [Miao et al. 1999] apresentam uma rede dinâmica cognitiva (*Dynamic Cognitive Network* - DCN), que é uma extensão do FCM. Cada conceito na DCN pode ter o seu próprio conjunto de valores, dependendo de quanta precisão seja necessária para defini-lo na rede. Isso permite que a DCN descreva a força da causa e o grau de efeitos, os quais são cruciais para a realização de inferências significativas. Estruturalmente, DCNs são escaláveis e mais flexíveis em relação à FCM. Para demonstrar as potenciais aplicações das DCNs, foram mostrados alguns resultados de simulações para a predição de rentabilidade sobre estratégias de reflorestamento e plantação. Onde o DCN apresenta uma melhor precisão na predição dos valores em questão.

Huang et al [Huang et al. 2010] desenvolvem um mecanismo de tomada de decisão e aprendizagem cognitiva baseado em redes bayesianas, onde objetiva-se obter as regras de configuração ótimas, as quais são adaptativas às variações do ambiente com o algoritmo de aprendizagem e inferência Bayesiana. Essas regras obtidas podem guiar ter-

minais cognitivos para reconfigurar os parâmetros de transmissão, e assim se adaptar às mudanças do ambiente, tornando o sistema de comunicação superior quando comparado às possíveis configurações a serem usadas.

Wang [Wang 2005] apresenta um conjunto de modelos matemáticos de abstração e inferências, como dedução, indução, abdução e analogia. Com isso, o mesmo define processos cognitivos de abstração e inferências que tenham sido formalmente descritos usando álgebra de processos em tempo real (*Real Time Processing Algebra – RTPA*), aplicando-os em um contexto de redes cognitivas.

Chen et al [Chen et al. 2009] utilizam técnicas de inferência estatística para obter informações dos links e da rede dos rádio cognitivos, além de aplicar mecanismos de detecção e técnicas de estimativa. Baseado no modelo de sensoriamento de espectro usado, eles exploraram o espectro geral de detecção afim de obter informações em nível de enlace para o funcionamento do rádio cognitivo.

Nenhum dos trabalhos mostrados anteriormente se preocupa em utilizar o paradigma de cognição para maximizar a vazão dos nós em um ambiente Ad Hoc. Ambiente este em que as características de rede (quantidade de usuários, heterogeneidade dos componentes de rede, etc) e do ambiente (interferência, ruído, obstáculos físicos, etc) possuem uma grande variação e são imprevisíveis.

4. Desenvolvimento da Proposta

Esta seção tem por objetivo apresentar o processo de desenvolvimento do mecanismo de inferência implementando. Este trabalho visa usar um mecanismo de inferência bayesiana para controlar a taxa de dados enviada, afim de encontrar o valor que eleve a vazão do nó.

Como mostrado na Seção 2, para se aplicar o mecanismo de inferência bayesiana, necessita-se definir um grafo que represente as variáveis observadas e uma distribuição de probabilidade associada ao mesmo.

Existem várias bibliotecas disponíveis na Internet que podem ser usadas para o desenvolvimento de redes Bayesianas e a execução de tarefas de inferência. Uma delas é libDAI [Mooij 2010], uma biblioteca *open-source* desenvolvida em C++ (licenciado sob a GNU *General Public License*), que fornece implementações de vários métodos de inferência exata e aproximada para *Graphical Models*.

A biblioteca libDAI suporta *Factor Graphs* com variáveis discretas. Além disso, a biblioteca libDAI suporta parâmetros de aprendizagem das tabelas de probabilidade condicional de máxima verossimilhança ou maximização de expectativa (*Expectation-Maximization*), em caso de falta de dados.

No mecanismo de inferência utilizado, foram definidas três variáveis para se montar o *Factor Graph*: taxa de dados (*Datarate*), taxa de erros (*Error Rate – ER*) e vazão (*Throughput*). A Figura 3 representa o grafo definido para o mecanismo proposto, onde a variável “D” representa a taxa de dados, a variável “E” a taxa de erros e a variável “T” representa a vazão do nó.

Seguindo o mecanismo de cognição adotada em [Facchini and Granelli 2009], para se definir o comportamento do mecanismo foram utilizadas três classes conceitos distintos: Qualidade (*Quality*), Ambiente (*Environment*) e Ação (*Action*).




Figura 3. Factor Graph definido

A classe *Quality* engloba os conceitos relacionados às métricas de qualidade do serviço (*Quality of Service – QoS*), as quais o sistema tem por objetivo maximizar a eficiência. Desta forma, no mecanismo de inferência descrito, a variável vazão é um conceito da classe *Quality*.

A classe *Environment* inclui todos os conceitos relacionados com o ambiente em que a entidade cognitiva atua, sendo assim visa coletar as informações destas variáveis para utilizá-las no sistema. Neste trabalho, a variável taxa de erros é um exemplo de um conceito da classe *Environment*.

A classe *Action* inclui o conjunto de ações que o protocolo pode realizar, sendo assim é a classe que representa as variáveis que podem ser ajustadas de acordo com a definição da estratégia de raciocínio. No mecanismo proposto, a variável taxa de dados faz parte da classe de conceitos *Action*.

Outra questão importante está relacionada ao domínio aos quais os conceitos são mapeados. Para começar, é importante notar que o domínio de alguns conceitos é claramente binário. Por exemplo, no mecanismo definido, a taxa de erro que pode ser mapeada para o conjunto discreto $\{0,1\}$, indicando ausência ou presença de erros.

Da mesma forma, o mesmo domínio pode ser utilizado para representar a vazão do nó: o valor mais baixo indica uma situação não satisfatória, enquanto que um valor mais alto indicaria uma situação favorável.

Sendo assim, decidiu-se mapear as variáveis vazão e taxa de dados em um domínio binário $\{-1,1\}$, indicando que a vazão e a taxa de dados estão sendo consideradas baixa ou alta, respectivamente. Enquanto que a variável taxa de erros foi mapeada em um domínio binário $\{1,0\}$, como descrito anteriormente.

Após a definição do *Factor Graph* e o do mecanismo de cognição utilizado, a próxima etapa é a definição da estratégia de atualização dos valores de probabilidade do *Factor Graph*.

Inicialmente a seguinte estratégia de contagem simples foi definida: a probabilidade é obtida pela quantidade de vezes em um estado e dividida pelo total de estados, ou seja, se um conceito é "1" x vezes e "0" y vezes, a partir disso então, pode-se montar o seguinte sistema representado na Equação (1).

$$\begin{cases} P(1) = \frac{x}{(x+y)} \\ P(0) = \frac{y}{(x+y)} = 1 - P(1) \end{cases} \quad (1)$$

Entretanto, esta estratégia, por considerar estados muito antigos, demora para conseguir convergir para uma nova situação da rede. Um exemplo seria quando o nó se movimenta de um local que gera uma baixa taxa de erros, para um local onde a taxa de erros se torna alta, com isso o estado antigo de baixa taxa de erros iria influenciar o cálculo da probabilidade para o estado atual.

Decidiu-se então, adotar a idéia de janela de estados para se analisar, ou seja, o cálculo da probabilidade será feito considerando somente os “ n ” últimos estados, limitando a análise do histórico de estado da rede.

Com isso foi necessário definir este valor de tamanho de janela, foram testados os seguintes valores de janela: 2, 5, 10, 20, 50 e 100 estados. Após a comparação na eficiência para o ajuste na taxa de dados, percebeu-se que a utilização dos últimos 20 estados obtia um melhor desempenho.

5. Análise dos Resultados

A análise do desempenho do mecanismo de cognição proposto foi realizada utilizando o simulador Ns-3 [NS-3 2011], onde ao mesmo foi integrada a biblioteca libDai [Mooij 2010], brevemente descrita na Seção 4.

O desempenho da proposta foi comparado com o do mecanismo de cognição utilizando *Fuzzy Cognitive Maps* [Facchini and Granelli 2009], afim de mostrar os benefício no ajuste na taxa de dados que o uso da inferência bayesiana pode trazer.

Além do FCM, foi avaliado também o comportamento da rede sem a utilização de um mecanismo adaptativo de cognição, mostrando assim o ganho de desempenho que a rede possui ao se aplicar a abordagem cognitiva.

O desempenho dos mecanismos foram avaliados em um cenário com dois nós Ad Hoc, onde o nó B realiza uma chamada VoIP para o nó A, com pacotes de 1460 bytes de tamanho. Como protocolo de rede sem fio utiliza-se o 802.11b. Onde o período de simulação foi de 200 segundos, mesmo período de transmissão da chamada VoIP.

O nó A se mantém imóvel na posição (0,5), enquanto que o nó B, que se encontra inicialmente na posição (5,5), se movimenta até a posição (200,5), a uma velocidade de 1m/s. A Figura 4 ilustra o cenário montado.




Figura 4. Cenário Utilizado

O objetivo deste cenário é mostrar a capacidade do nó de maximizar a vazão, ajustando a taxa de dados, enquanto se movimenta, visto que quanto mais longe, mais difícil se torna a transmissão dos dados.

Foram realizadas 100 simulações para cada um dos mecanismos avaliados, onde se aplicou um intervalo de confiança de 70% em cada um dos pontos de coleta dos dados referentes à vazão. A Figura 5 apresenta os dados referentes à vazão do nó B em relação ao tempo, deve-se ter em mente que, como dito anteriormente, o nó B se afasta do nó A com o passar do tempo.

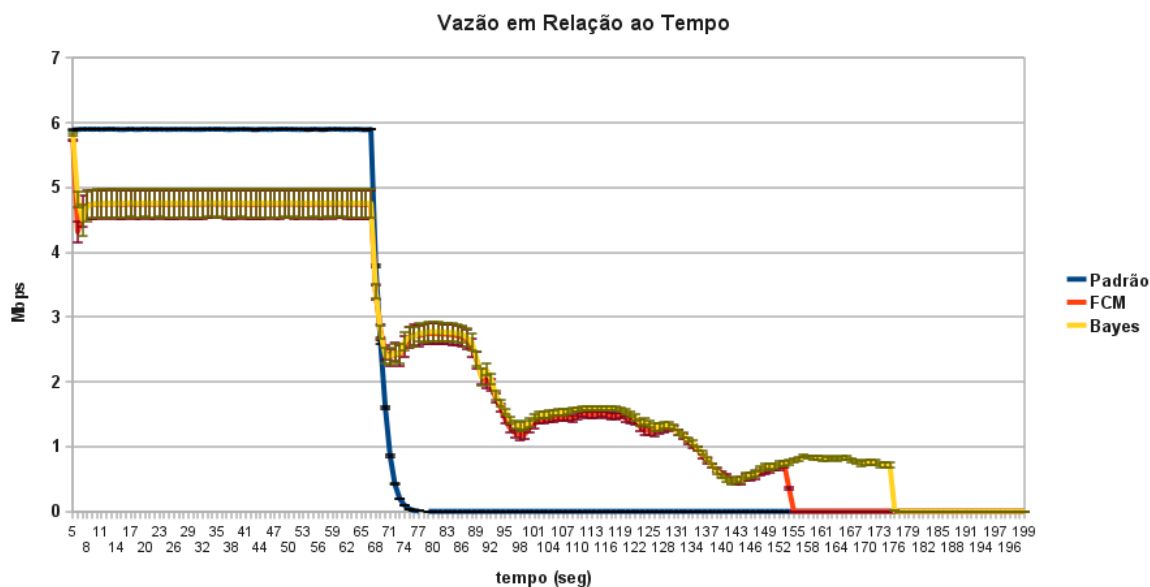


Figura 5. Vazão em relação ao Tempo do Nó B

Percebe-se que quando o nó não utiliza nenhum mecanismo de cognição sua vazão decresce rapidamente, quando se torna difícil enviar os dados na taxa configurada inicialmente (6 Mbps).

Por outro lado, ao se utilizar algum dos mecanismo de cognição, a taxa de dados é ajustada quando o mecanismo adotado percebe uma dificuldade para o envio dos dados. Desta forma, os nós só deixam de ter vazão quando realmente não há mais sinal entre os dois nós.

Ambas as abordagem de cognição, FCM e inferência bayesiana, possuem um comportamento similar conforme a distância, e conseqüentemente a dificuldade de envio, vai aumentando.

Contudo, o mecanismo FCM detecta que não há mais como enviar os dados em uma situação que ainda há como. Fato que não ocorre com o mecanismo de inferência bayesiana, como pode ser percebido no intervalo de tempo entre 150 e 170 segundos da simulação.

A fim de mostrar o desempenho dos mecanismo de maneira mais geral, a Figura 6 ilustra o gráfico contendo a vazão média durante o período de simulação dos mecanismos avaliados. Nota-se que os mecanismos de cognição apresentam uma vazão média superior em relação à utilização do mecanismo padrão, ou seja, quando não se utiliza o paradigma de cognição.

Como resultado dessa vazão média, a Figura 7 mostra o gráfico de quantidade de

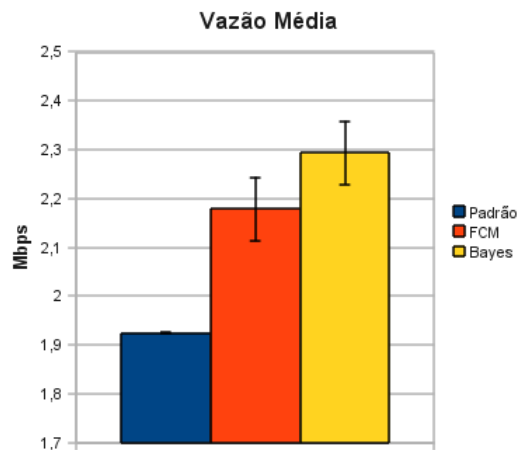


Figura 6. Vazão Média do Nó B

dados transferidos durante a simulação, ou seja, quantos *Megabits* foram transferidos do nó B ao Nó A durante a simulação. O objetivo deste gráfico é mostrar a quantidade de dados que não foram transmitidos por um mecanismo quando comparado ao outro.

Percebe-se que ao utilizar a inferência bayesiana consegue-se transmitir, em média, cerca de 80 Mb a mais, em um período de 200 segundos de simulação. Da mesma forma, quando comparado com o uso de FCM, a utilização do mecanismo de inferência bayesiana consegue enviar cerca de 25 Mb a mais.

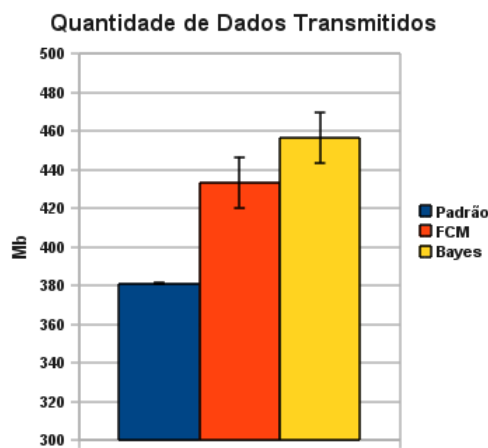


Figura 7. Montante de Dados Transferidos pelo Nó B

De forma geral, de acordo com as informações coletadas das simulações, fica claro que a utilização do mecanismo de cognição com inferência bayesiana traz benefícios ao nó, visto que o mesmo consegue tirar um maior proveito dos recursos de rede presentes.

6. Conclusão

Este trabalho apresentou um mecanismo de inferência bayesiana para controlar a taxa de dados enviada, onde se objetiva encontrar o valor da taxa de dados que leve a maior probabilidade de se ter vazão elevada.

O mecanismo de inferência montado foi baseado na observação de certas variáveis (taxa de dados, taxa de erros e vazão), para se definir um *Factor Graph* e assim através do algoritmo de *Loopy Belief Propagation* obter um valor aproximado de inferência, determinando como manipular a taxa de dados executada pelo nó.

Os resultados mostram que o mecanismo proposto consegue obter uma melhor utilização da rede quando comparada à utilização de um mecanismo baseado em FCM, e principalmente em relação a um nó que não executa nenhum mecanismo de cognição.

Entre os trabalhos futuros, espera-se comparar o desempenho do mecanismo utilizando outros algoritmos para inferência aproximada, assim como quando utilizar mais variáveis para observação, como por exemplo a relação sinal ruído (*Signal Noise Ratio*).

Referências

- Bishop, C. M. (2007). *Pattern Recognition and Machine Learning (Information Science and Statistics)*. Springer, 1st ed. 2006. corr. 2nd printing edition.
- Chen, K.-C., Tu, S.-Y., and Yu, C.-K. (2009). Statistical inference in cognitive radio networks. In *Fourth International Conference on Communications and Networking in China, ChinaCOM 2009*, pages 1–10.
- Clancy, C., Hecker, J., and Stuntebeck, E. (2007). Applications of machine learning to cognitive radio networks. *IEEE Wireless Communications Magazine*, 14.
- Facchini, C. and Granelli, F. (2009). Towards a model for quantitative reasoning in cognitive nodes. In *GLOBECOM Workshops, 2009 IEEE*, pages 1 –6.
- Facchini, C., Granelli, F., and da Fonseca, N. L. S. (2010). Identifying relevant cross-layer interactions in cognitive processes. In *IEEE GLOBECOM 2010*.
- Fortuna, C. and Mohorcic, M. (2009). Trends in the development of communication networks: Cognitive networks. *Computer Networks*, 53(9):1354–1376.
- Huang, Y., Wang, J., and Jiang, H. (2010). Modeling of learning inference and decision-making engine in cognitive radio. In *Networks Security Wireless Communications and Trusted Computing (NSWCTC), 2010 Second International Conference on*, volume 2, pages 258 –261.
- Kosko, B. (1986). Fuzzy cognitive maps. *International Journal of Man-Machine Studies*, (24):65–75.
- Kschischang, F. R., Frey, B. J., and Loeliger, H. A. (2001). Factor graphs and the sum-product algorithm. *IEEE Transactions on Information Theory*, 47(2):498–519.
- Loeliger, H. (2004). An introduction to factor graphs. *Signal Processing Magazine, IEEE*, 21(1):28 – 41.
- Miao, Y., Liu, Z.-Q., Li, S., and Siew, C. K. (1999). Dynamical cognitive network-an extension of fuzzy cognitive map. In *Tools with Artificial Intelligence, 1999. Proceedings. 11th IEEE International Conference on*, pages 43–46.
- Mooij, J. M. (2010). libDAI: A free and open source C++ library for discrete approximate inference in graphical models. *Journal of Machine Learning Research*, 11:2169–2173.
- Neapolitan, R. E. (2003). *Learning Bayesian Networks*. Prentice-Hall, Inc.

NS-3 (Acessado em 30 de Março de 2011). Disponível em: <http://www.nsnam.org/>.

Thomas, R., DaSilva, L., and MacKenzie, A. (2005). Cognitive networks. In *New Frontiers in Dynamic Spectrum Access Networks, 2005. DySPAN 2005. 2005 First IEEE International Symposium on*, pages 352–360.

Thomas, R. W., Friend, D. H., Dasilva, L. A., and Mackenzie, A. B. (2006). Cognitive networks: adaptation and learning to achieve end-to-end performance objectives. *Communications Magazine, IEEE*, 44(12):51–57.

Wang, Y. (2005). The cognitive processes of abstraction and formal inferences. In *Proceedings of the Fourth IEEE International Conference on Cognitive Informatics*, pages 18–26, Washington, DC, USA. IEEE Computer Society.