

Caracterização e Previsão de Falhas em Serviços de Conectividade: uma Aplicação à Rede Ipê

Vitor F. Zanotelli¹, Giovanni Comarela¹, Rodolfo S. Villaca¹, Magnos Martinello¹

¹Departamento de Informática – Universidade Federal do Espírito Santo

fz.vitor@edu.ufes.br, {gc, rodolfo.villaca, magnos}@inf.ufes.br

Abstract. *The Ipê Network is essential for the Brazilian scientific community as it interconnects universities and research centers across the country. This paper analyzes some characteristics of the Ipê Network and explores the use of machine learning techniques for predicting failures in connectivity services using public data provided by the ViaIpê monitoring tool. The problem is modeled as a binary classification task using recurrent neural networks. The results show that the dependability of the connectivity service varies significantly in the different PoPs of the Ipê Network. In addition, despite the heterogeneity of this service, the prediction models are promising, presenting good accuracy and good precision in some scenarios.*

Resumo. *A Rede Ipê é fundamental para a comunidade científica brasileira por interconectar universidades e centros de pesquisa de todo o país. Este artigo analisa algumas características da Rede Ipê e explora o uso de técnicas de aprendizado de máquina para previsão de falhas em serviços de conectividade usando dados públicos disponibilizados pela ferramenta ViaIpê. O problema é abordado como uma tarefa de classificação binária utilizando redes neurais recorrentes. Os resultados mostram que a dependabilidade do serviço de conectividade varia significativamente nos diferentes PoPs da Rede Ipê. Além disso, apesar da heterogeneidade deste serviço, os modelos de previsão mostram-se promissores, apresentando boa acurácia e boa precisão em alguns cenários.*

1. Introdução

As redes modernas têm evoluído tanto do ponto de vista de arquitetura quanto na perspectiva de sua operação. De fato, as redes não são mais caracterizadas apenas por dispositivos físicos que provêm conectividade. O modelo clássico de uma coleção de *appliances* de hardware conectados por enlaces está mudando para modelos de redes virtualizados que podem ser provisionados sob demanda. Essa evolução têm trazido uma quantidade ainda maior de dados que são gerados, transmitidos e armazenados a todo instante, e a alta disponibilidade de dados de monitoramento, em combinação com o avanço da programabilidade de redes, tem impulsionado o uso de modelos de aprendizado de máquina na operação destas redes [Boutaba et al. 2018].

Quanto à infraestrutura de redes, dependências adicionais têm sido impostas devido à natureza distribuída e virtualizada das aplicações. Há uma necessidade emite de oferecer garantias das propriedades de dependabilidade, em particular disponibilidade, confiabilidade e desempenho no serviço de conectividade [Martinello 2005]. Para oferecer tais garantias, é preciso entender o processo de caracterização de falhas

nas suas múltiplas dimensões: localização, causas, tipos/classes, frequência e duração. Esse processo requer uma análise da operação de redes, passando pela coleta, análise e sumarização de dados para definir ações de garantia da dependabilidade. A premissa fundamental desta análise é transformar dados em *insights* plausíveis, que podem ser manifestados por capacidades analíticas, descritivas e preditivas. Essa análise precisa explorar um enorme volume de dados referentes a falhas de redes, configurações e métricas de tráfego a fim de gerar *insights* efetivos para o planejamento, *troubleshooting* ou migração de serviços.

Dessa forma, a primeira contribuição deste trabalho está na análise e caracterização dos dados coletados a partir da ferramenta de visualização do serviço de conectividade da Rede Ipê da Rede Nacional de Ensino e Pesquisa (RNP), denominado ViaIpê¹. O pressuposto básico é entender as características das falhas do serviço de conectividade para construir um modelo preditivo usando técnicas de aprendizado de máquina. Como definição de falha, considera-se a situação em que a taxa de perda de pacotes do serviço ultrapasse um certo limiar (nesse trabalho, 3%). A partir dessa definição e de um conjunto de dados com 67.6 milhões de observações, relativo ao mês de novembro de 2020, algumas características são identificadas: existem falhas que apresentam correlação geográfica, outras que podem ser longas e repentinas, algumas com grande variação ou ainda oscilação entre muitos períodos curtos. Com base nestas características, uma análise mais específica se concentra na classificação dos estados brasileiros quanto a sua dependabilidade, mostrando que essa dependabilidade não é homogênea em todos os Pontos de Presença (PoPs) do país.

A segunda contribuição do trabalho está na proposição de uma metodologia para a predição de falhas. A abordagem adotada diferencia-se da literatura não apenas pelas características singulares da aplicação de interesse, com foco na Rede Ipê, mas também pelas informações utilizadas para a obtenção de modelos, pela forma como falhas são definidas e pela especificação do problema de previsão de falhas. Neste trabalho, um modelo baseado em redes LSTM (*Long Short-Term Memory*) é utilizado, uma vez que tais redes são apropriadas para tarefas que envolvem dados de natureza sequencial ou temporal.

Como conclusão, o modelo proposto não se mostrou capaz de atingir bons resultados no cenário global, i.e., quando serviços de conectividade de todo o Brasil são considerados, devido heterogeneidade dos dados e alto grau de desbalanceamento de classes no problema de aprendizado. No entanto, o potencial da metodologia é revelado quando o escopo do problema é reduzido (do ponto de vista geográfico e da frequência de falhas). Nesse cenário, foi possível obter resultados significativamente melhores, com a precisão chegando a 85%, no melhor caso.

A organização do restante deste texto é descrita a seguir. A Seção 2 apresenta os trabalhos relacionados. A especificação da tarefa de caracterização e a definição do problema de predição são apresentadas na Seção 3. A Seção 4 descreve a ferramenta ViaIpê, o processo de coleta e as características básicas dos dados utilizados. A Seção 5 define o conceito de falhas em serviços de conectividade e apresenta a caracterização destas falhas a partir dos dados disponíveis. Na Seção 6, são apresentados os resultados

¹viaipe.rnp.br

da tarefa de previsão de falhas. A Seção 7 apresenta conclusões e elenca direções para trabalhos futuros e, por fim, a Seção 8 apresenta os agradecimentos.

2. Trabalhos Relacionados

O objetivo desta seção é posicionar este trabalho na literatura, principalmente no que tange a exploração de aprendizado de máquina para previsão de falhas em redes de computadores. De forma geral, redes de computadores têm o potencial de originar uma grande e variada quantidade de dados para serem analisados. Tradicionalmente, tais análises eram realizadas *offline* e as conclusões (e.g., modelos de previsão) raramente podiam ser incorporadas nos sistemas para uso em tempo real. No entanto, com os avanços e a difusão de técnicas e tecnologias de redes programáveis nos últimos anos [Bosshart et al. 2014, Liberato et al. 2018], esse cenário mudou consideravelmente e, agora, modelos de aprendizado de máquina são comumente implantados em ambientes de produção. De fato, a literatura demonstra o potencial de técnicas de aprendizado em diversas áreas, entre elas: classificação de tráfego, roteamento e predição de tráfego, controle de congestionamento, segurança de redes e gestão de controle, recursos, falhas, QoS e QoE [Boutaba et al. 2018].

A importância do estudo e caracterização de falhas em redes de computadores é reconhecida pela comunidade de redes há décadas. Exemplos de estudos renomados nesse cenário são os trabalhos de [Markopoulou et al. 2008] e [Gill et al. 2011]. No primeiro, os autores categorizam e analisam as falhas em uma rede IP, focando, primariamente, nos enlaces da rede. O segundo trabalho toma uma abordagem similar, i.e., categorizar e entender os impactos de falhas, mas no cenário de um *Data Center*.

Exemplos de trabalhos recentes que fazem uso de técnicas avançadas de aprendizado de máquina para a tarefa de previsão de fenômenos em redes são [Azzouni and Pujolle 2018] e [Lens Shiang et al. 2020]. O primeiro utiliza redes recorrentes LSTM (*Long Short-Term Memory*) para prever valores em matrizes de tráfego. O segundo utiliza GRUs (*Gated Recurrent Units*) para prever o tráfego em uma rede 5G.

Já no contexto específico de previsão de falhas em redes, diferentes aplicações e abordagens foram empregadas. Em [Giannakou et al. 2020], explora-se o problema de previsão de retransmissão de pacotes em fluxos TCP relacionados a transferências de dados acadêmicos no NERSC (*National Energy Research Scientific Computing Center*). Com um modelo relativamente simples (Florestas Aleatórias) e vetores de características inerentes aos fluxos TCP, os autores obtiveram acurácia quase perfeita. Técnicas de redução de dimensionalidade para seleção de características e algoritmos de aprendizado de máquina são usados em [Zhou and Zhang 2018] para a detecção de perda de pacotes a partir de dados de telemetria de uma rede 4G LTE obtidos de um ambiente de virtualização de funções de rede vEPC (*Virtual Evolved Packet Core*). Um outro exemplo é o trabalho de [Zhong et al. 2016], no qual são utilizadas informações e vetores de características extraídos de *logs* de uma rede metropolitana para a predição da existência ou não de falhas numa janela de tempo predeterminada.

Apesar de se basear em ferramentas de aprendizado de máquina já previamente exploradas (i.e., redes LSTM), o presente trabalho distingue-se do estado-da-arte da caracterização de falhas em serviços de conectividade em vários aspectos: (i) a aplicação de interesse tem foco na Rede Ipê, a qual possui características diferentes das redes ex-

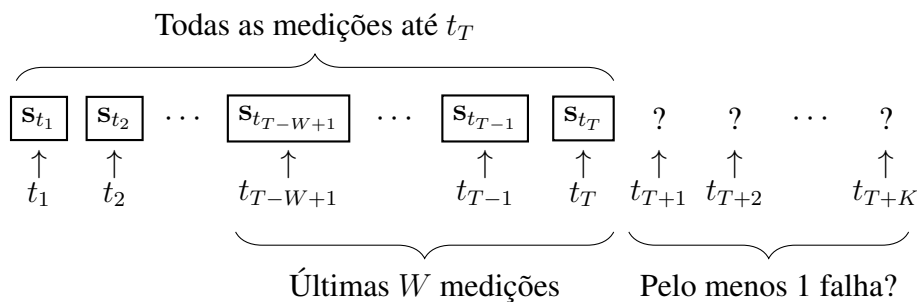


Figura 1. Ilustração do problema de previsão. Dadas as últimas W observações do estado do serviço e dado que no tempo t_T o serviço não está em estado de falha, o serviço se encontrará em estado de falha em pelo menos uma das K medições futuras?

ploradas nos trabalhos acima; (ii) conforme será apresentado nas Seções 3 e 4, tanto o tipo dos dados utilizados para a obtenção de modelos de aprendizado de máquina, quanto o acesso público a esses dados são inovadores; e (iii) a forma como falhas são definidas e o problema de previsão em si diferem significativamente dos trabalhos existentes na literatura.

3. Definição do Problema

O objetivo desta seção é apresentar a notação necessária para o entendimento do restante do trabalho e definir, formalmente, a tarefa de caracterização e o problema de predição de falhas em serviços de conectividade de rede. Apesar de a aplicação ser a Rede Ipê, a formalização será conduzida de forma genérica, podendo ser utilizada em outros cenários.

De acordo com [Martinello 2005], uma *falha* de serviço é uma transição do estado em que o serviço está funcionando de forma correta/esperada para o estado em que não esteja. No caso de um serviço de conectividade entre entidades x e y , uma falha ocorre quando a comunicação entre x e y fica impossibilitada ou ocorre com qualidade inferior a um certo limite tolerável.

Em mais detalhes, seja s_t o estado do serviço de conectividade, entre x e y , no tempo t . A composição de s_t pode incluir tanto informações sobre o serviço em si (e.g., operadora e tecnologia utilizada) quanto métricas de desempenho e qualidade. Desta forma, diz-se que há uma falha no tempo t quando s_t viola ao menos um dos parâmetros previamente estabelecidos (e.g., interrupção total da transmissão de dados ou alto percentual de perda de pacotes) e $s_{t'}$, para $t' < t$, representa o sistema funcionando corretamente.

Considere que medições sejam realizadas e o vetor s seja observado nos tempos t_1, t_2, \dots, t_T . Assume-se, neste trabalho, que os intervalos entre as medições são constantes, ou seja, $t_i - t_{i-1}$ é um valor fixo ($i = 2, \dots, T$). Desta forma, este trabalho tem dois objetivos principais: caracterizar o serviço de conectividade e realizar a predição de falhas neste serviço.

O primeiro objetivo diz respeito à caracterização e ao entendimento da dependabilidade do serviço de conectividade. Mais especificamente, tem-se interesse em entender a dinâmica do funcionamento do serviço de conectividade na Rede Ipê e responder os seguintes questionamentos:

1. Sobre a *confiabilidade*, qual o tempo típico entre duas falhas?
2. Sobre a *disponibilidade*, qual a fração do tempo que o serviço passa no estado de falha?
3. Sobre a *manutenibilidade*, qual a duração típica do período em que o serviço fica, continuamente, em estado de falha?

Já no segundo objetivo, deseja-se prever se o serviço entrará em estado de falha num futuro próximo dado que na última medição este estava funcionando normalmente. A Figura 1 ilustra o problema. A ideia básica é considerar as últimas W medições para saber se em ao menos umas das K medições futuras o serviço falhará. A definição dos parâmetros W e K depende de vários fatores, entre eles: a natureza do serviço, a granularidade das medições e variáveis que compõem o vetor s . Os valores escolhidos para tais parâmetros nesse trabalho e as técnicas utilizadas para abordar o problema serão apresentados na Seção 6.

4. A Ferramenta ViaIpê e o Conjunto de Dados

A primeira parte desta seção aborda a definição da Rede Ipê, da ferramenta ViaIpê, e a descrição do procedimento de coleta de dados (Seção 4.1). Em seguida, a descrição formal do conjunto de dados obtido e o pré-processamento realizado são apresentados na Seção 4.2.

4.1. A Ferramenta ViaIpê

O crescimento na demanda por conectividade resulta em grandes desafios enfrentados pelos provedores para garantir as expectativas de disponibilidade e qualidade na comunicação de dados. No Brasil, pela sua extensão territorial, isso se torna ainda mais desafiador, e essa é a realidade encontrada pelos PoPs que operam o serviço de conectividade da RNP. Sabe-se que para conhecer a qualidade dessas redes é preciso um serviço de monitoramento constante, eficiente, que opere em nível nacional e, nesse contexto, surtiu o seguinte questionamento: como viabilizar transparência da qualidade das conexões de acesso até o PoP para um público geral?

Para responder esse questionamento, a RNP criou e disponibilizou o ViaIpê, uma ferramenta que reúne estatísticas de qualidade da conectividade da rede acadêmica brasileira: a Rede Ipê. Essa ferramenta tem por objetivo dar transparência na utilização e qualidade dos enlaces (ou serviços de conectividade) de acesso dessa rede, por meio de uma interface simplificada, disponível publicamente para toda a comunidade de ensino e pesquisa do país. A partir de uma infraestrutura distribuída de coleta de dados, a plataforma ViaIpê disponibiliza, a cada 60s, dados instantâneos sobre a qualidade de todos os enlaces da Rede Ipê (esses dados estarão descritos na Seção 4.2). Após cada coleta, esses dados são sobrescritos e sumarizados por suas médias, valores máximos e mínimos em intervalos diários, semanais e mensais. Tanto os dados instantâneos quanto as sumarizações diárias, semanais e mensais são disponibilizadas em formato JSON (*JavaScript Object Notation*), de forma agrupada por cada PoP nas diferentes regiões do país.

Considerando esta característica de não armazenar os dados instantâneos, coletados a cada minuto, para obtenção do conjunto de dados usando neste artigo foi implementado um *script* em Python que acessa a interface do ViaIpê a cada 60s via protocolo HTTP, faz o *download* do arquivo JSON correspondente às medições instantâneas e os

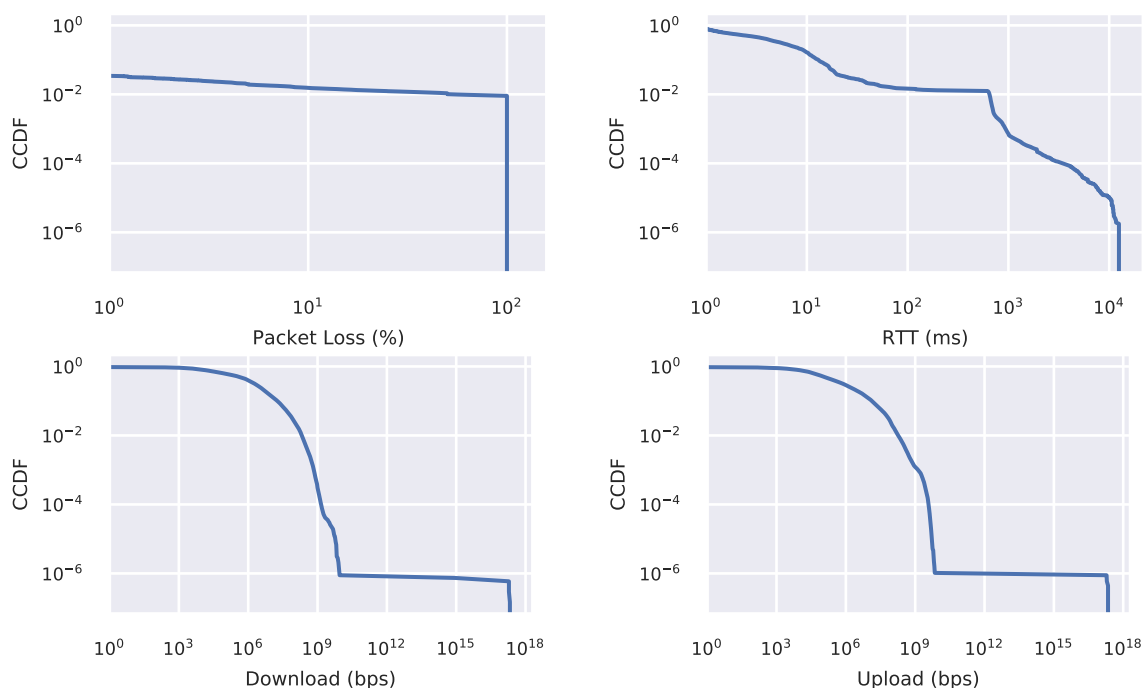


Figura 2. Distribuições empíricas das variáveis coletadas para todas as interfaces em todos os instantes de tempo disponíveis.

armazena localmente em um servidor no laboratório Nerds (Núcleo de Estudos em Redes Definidas por Software) da Ufes. Esses arquivos são organizados de acordo com o *timestamp* da coleta para posterior processamento, treinamento e avaliação dos modelos de aprendizado usados neste artigo.²

Apesar da ferramenta ViaIpê não ter, como objetivo principal, a disponibilização de dados para fins de gerenciamento e tomada de decisões na Rede Ipê, sua interface pública e a diversidade dos dados disponibilizados a torna uma importante aliada para o cumprimento dos objetivos deste artigo e provoca o seguinte questionamento: será possível caracterizar o serviço de conectividade provido pela Rede Ipê e realizar previsões de falhas de conectividade a partir dos dados disponibilizados publicamente pela ferramenta ViaIpê? Este questionamento é respondido nas seções a seguir.

4.2. Descrição do Conjunto de Dados

Após a coleta, o conjunto de dados foi transformado em estruturas do tipo *Data Frames* do *Pandas*,³ uma para cada dia, seguindo o modelo *tidy data* proposto por [Wickham 2014], onde cada coluna representa uma variável⁴ e cada linha representa um objeto de interesse. Para cada objeto de interesse, i.e., informações sobre uma **interface de rede**, conectada a um PoP, em um dado **instante de tempo**, as seguintes variáveis numéricas foram extraídas: *Packet Loss* (em percentual), *RTT* (em milissegundos), *Download* e *Upload* (em bits por segundo).

O período de tempo selecionado para análise contém os dias referentes ao mês

²Os dados utilizados são disponibilizados em: <https://doi.org/10.5281/zenodo.5042650>

³<https://pandas.pydata.org/>

⁴Neste artigo, os termos variável, *feature* e característica serão utilizados no mesmo sentido.




Figura 3. Variação da qualidade de serviço para quatro interfaces ao longo da primeira semana de novembro de 2020. Informações atualizadas a cada minuto.

de novembro de 2020. O conjunto de dados selecionado compreende um total de 67,6 milhões de observações. Dados faltantes podem decorrer das falhas no coletor (e.g., devido a falta de energia elétrica, quando o minuto completo está ausente no conjunto de dados para todas as interfaces) ou quando uma observação não apresenta alguma de suas variáveis, sendo essa então descartada. Nesse período, 55 minutos são faltantes, os quais se encontram distribuídos em 11 dias do mês. Esses minutos são em sua maioria isolados e o dia 27 concentra a maior quantidade, com um total de 20 minutos. Além disso, notou-se que uma interface de rede não “existe” necessariamente durante todo o período de tempo. Apesar de os identificadores das interfaces serem únicos, observou-se em várias situações que eles podem mudar durante o período de monitoramento.

A Figura 2 apresenta as distribuições empíricas, por meio de CCDFs (do inglês *Complementary Cumulative Distribution Function* – a CCDF de uma variável aleatória X é dada por $P(X > x)$) referentes às variáveis numéricas. Pode-se observar que eventos de perda de pacote são pouco frequentes quando considerada a rede como um todo, e que altos percentuais de perda são ainda mais raros. Já sobre a variável RTT, tem-se que valores típicos são da ordem de dezenas de milissegundos, com apenas aproximadamente 1% das observações superando 100ms. As distribuições das taxas de *download* e *upload* são similares. Em geral, as taxas de transferência estão na faixa de Mbps, com, raros, picos de alguns Gbps. Algumas observações reportaram taxas, irrealistas, da ordem de 10^{18} bps. Estes valores são considerados anomalias, provavelmente oriundos de problemas de medição ou processamento dos dados e por representarem apenas dezenas entre milhões de observações, não foram removidas do conjunto de dados.

5. Caracterização das Falhas

A definição de falha em um serviço de conectividade usada neste trabalho foi inspirada pela categorização da qualidade do serviço feita pela ferramenta ViaIpê. Nessa ferramenta, a qualidade possui quatro categorias, definidas em função da taxa de perda de pacotes: um valor de perda até 0,01%, implica em qualidade *Ótima*; a partir de 0,01% e até 1%, tem-se qualidade *Boa*; a partir de 1% e até 3%, a qualidade é *Regular*; e por fim, se a perda estiver acima de 3%, a qualidade é dada como *Ruim*. Baseado nesta classificação, este trabalho define o estado de **falha** como sendo os períodos em que a **taxa de perda de pacotes é superior a 3%**.

A Figura 3 apresenta a variação da qualidade de serviço em quatro interfaces, co-

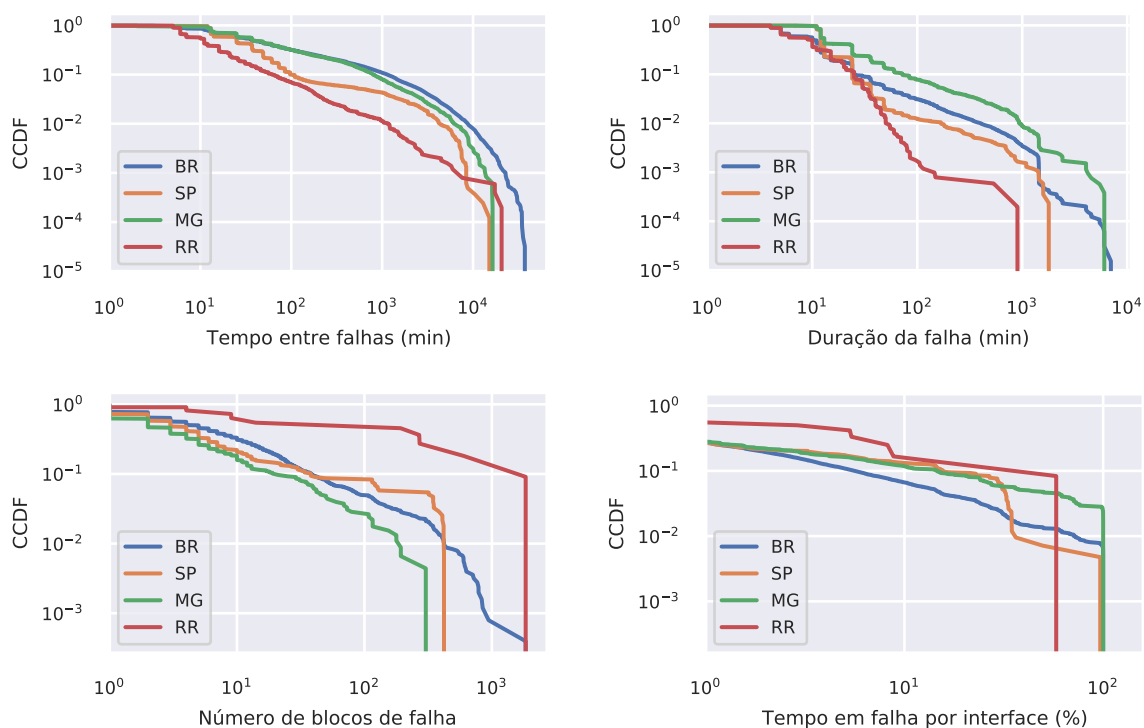


Figura 4. Distribuições empíricas das métricas de dependabilidade das interfaces de diversas regiões/PoPs.

nectadas a um mesmo PoP, durante a primeira semana de novembro de 2020. A Figura expõe diferentes aspectos sobre a dinâmica das falhas em uma mesma interface e em interfaces distintas. É importante destacar aqui que em um PoP, cada interface de rede está associada ao serviço de conectividade entre este PoP e alguma instituição de ensino ou pesquisa. Essa conectividade se materializa com a contratação de um enlace de rede entre esses dois pontos. Primeiro, há vários perfis de interfaces. Por exemplo, enquanto a Interface 2 é estável na categoria *Ótima*, a Interface 3 falha frequentemente. Segundo, existem falhas correlacionadas em diferentes interfaces, como evidenciado pela linha vermelha vertical próxima ao dia 6 de novembro. Por fim, pode-se observar que enquanto algumas falhas são precedidas pela degradação da qualidade (em amarelo ou verde claro), algumas são repentinas. Isso indica que a tarefa de predição de falhas, descrita na próxima seção, pode ser simples em algumas situações, mas até mesmo inviável em outras.

O próximo passo consiste em entender as métricas de dependabilidade dos serviços de conectividade, assim como descritas na Seção 3. Com essa finalidade, foram obtidas as distribuições empíricas, dadas novamente por CCDFs, para todas as interfaces do conjunto de dados e quatro métricas de interesse: tempo entre falhas; duração das falhas; número de blocos contíguos de falhas; e percentual de tempo em estado de falha. Os resultados, apresentados na Figura 4, agrupam interfaces de quatro formas diferentes: todas as interfaces do Brasil e as interfaces conectas aos PoPs de São Paulo, Minas Gerais e Roraima.

Pela Figura 4, pode-se perceber que o tempo contíguo de operação normal é relativamente baixo. Por exemplo, apenas 10% dos períodos entre falhas, i.e., de funcionamento normal do serviço, duram mais do que mil minutos (16,7 horas). As durações dos

períodos de falha, por outro lado, tendem a ser curtas, sendo que 90% das falhas duram menos que meia hora. Complementando esses resultados, tem-se que poucas interfaces apresentam um grande número de falhas (e.g., 70% das interfaces tiveram 10 ou menos blocos contíguos de falhas durante o mês de novembro de 2020), mas o percentual do tempo em estado de falha é alto (e.g., apenas 70% das interfaces tiveram disponibilidade acima de 99%). Uma outra conclusão que pode ser tirada da Figura 4 é que a qualidade do serviço não é homogênea em todos os PoPs do país. Nesse contexto, pode-se observar que as distribuições empíricas para São Paulo, Minas Gerais e Roraima diferem, em alguns casos até significativamente, do Brasil e entre si.

6. Previsão de Falhas

O objetivo desta seção é apresentar a metodologia e os resultados relativos à predição de falhas em serviços de conectividade na Rede Ipê. Nesse contexto, os parâmetros W e K foram fixados em 60 e 15, respectivamente. Desta forma, a tarefa se resume a prever, num tempo t , se um serviço falhará ao menos uma vez nos próximos 15 minutos, dadas as medições realizadas nos últimos 60 minutos. O valor de W resultou do processo de seleção de hiperparâmetros (descrito na seção a seguir). Aumentar o valor de K deixa o problema de previsão mais “fácil”, mas diminui a aplicabilidade do modelo. Assim, $K = 15$ foi um compromisso para atender a essas duas demandas.

Para atacar tal problema, decidiu-se fazer uso de técnicas de aprendizado de máquina. Mais especificamente, técnicas para classificação binária, sendo o rótulo 1 (positivo) referente à ocorrência de ao menos uma falha nos próximos 15 minutos e o rótulo 0 (negativo) referente à ausência de falhas.

6.1. Descrição do Modelo e Características Relevantes

Uma vez que o problema proposto e os dados utilizados possuem natureza temporal, optou-se por utilizar um modelo baseado em Redes LSTM (*Long Short-Term Memory* [Hochreiter and Schmidhuber 1997]). Testes iniciais foram conduzidos para definir os hiperparâmetros do modelo, e a arquitetura resultante consiste de cinco camadas: duas camadas LSTM (com 32 unidades cada); duas camadas, uma após cada LSTM, de *Dropout* (com probabilidade de descarte de unidade de entrada igual a 0,2); e, no final, uma camada densa (com apenas uma unidade). Além disso, os parâmetros da rede foram escolhidos pelo algoritmo de otimização NADAM (*Nesterov Adaptive Moment Estimation*) com taxa de aprendizado 10^{-4} e função de perda baseada na entropia cruzada, assim como definida por [Lin et al. 2017]. Está fora do escopo deste texto detalhar o funcionamento dos componentes do modelo escolhido. Para os leitores interessados, além dos textos já citados, sugere-se o trabalho de [Goodfellow et al. 2016].

As características (i.e., *features*) escolhidas para representar o estado do serviço em um dado instante de tempo, t , foram as quatro variáveis numéricas descritas na Seção 4.2: percentual de perda de pacotes, RTT, taxa de *download* e taxa de *upload*. A Figura 5 motiva essa escolha. Na figura, para cada uma dessas quantidades, são apresentadas as distribuições das variáveis nos três minutos que precedem a criação dos rótulos para todo o conjunto de dados. Assim, as distribuições associadas ao Rótulo 1 são para as medições feitas nos minutos t , $t - 1$ e $t - 2$, dado que nas medições realizadas nos minutos $t + 1, \dots, t + 15$ houve ao menos uma falha e que o serviço não estava em estado

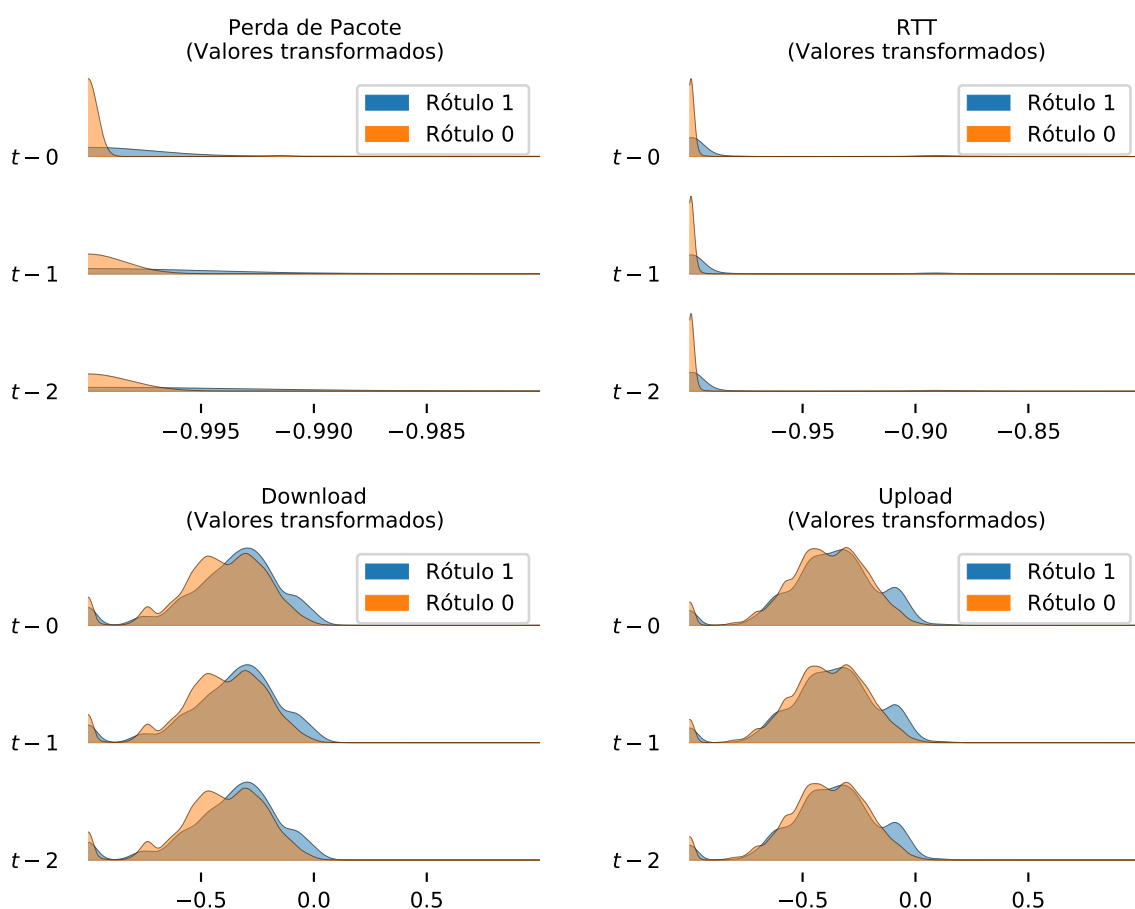


Figura 5. Distribuições, dadas por densidades empíricas, das variáveis do modelo para os três minutos que precedem: um período com ao menos uma falha (Rótulo 1); um período sem falhas (Rótulo 0). Os valores do eixo x foram transformados para o intervalo $[-1, 1]$.

de falha na medição do minuto t . As distribuições associadas ao Rótulo 0 foram feitas de forma similar, apenas com a exigência de não ter havido nenhuma falha nas medições dos minutos $t + 1, \dots, t + 15$.

A principal conclusão que pode ser tirada da Figura 5 é o fato de que, apesar de pouca, há uma diferença entre as distribuições associadas aos Rótulos 0 e 1. Em especial, tem-se que os instantes que precedem um período contendo ao menos uma falha são caracterizados por um aumento das taxas de transferência, RTT e percentual de perda de pacotes. Esse resultado confirma a observação inicial, feita a partir da Figura 3, de que há falhas precedidas por uma degradação gradual das métricas de desempenho e qualidade do serviço.

6.2. Resultados e Discussões

Para avaliar a qualidade do modelo proposto, foram seguidas boas prática experimentais provenientes da literatura de aprendizado de máquina e redes neurais. O conjunto de dados, rotulado conforme descrito na seção anterior, foi dividido em conjuntos de *treino*, *validação* e *teste*. A porção para treino do modelo é dada pelos dias de 1/11 até 21/11. Os dados dos dias 22/11 e 23/11 foram usados como conjunto de validação e os demais

Tabela 1. Resultados para interfaces selecionadas em todo o Brasil. Comparativo de resultados de acordo com diferentes proporções de instâncias da classe positiva.

Proporção classe positiva	Acurácia	Precisão	Revocação
~10%	0,92	0,56	0,55
~25%	0,88	0,80	0,61
~33%	0,84	0,87	0,60

dias do mês de novembro de 2020 formam o conjunto de teste. As métricas escolhidas para quantificar a qualidade do modelo são a *acurácia*, a *precisão* e a *revocação* (sendo as duas últimas calculadas com respeito à classe positiva). Todos os experimentos foram realizados utilizando a linguagem de programação Python e a biblioteca TensorFlow⁵.

Quando o modelo foi treinado e testado para interfaces selecionadas em todo o Brasil, foi obtida uma alta acurácia (0,97), mas baixos valores para precisão e revocação (0,19 e 0,43, respectivamente). A explicação para tal discrepância é o fato de que aproximadamente 99% das instâncias do conjunto de teste possuem rótulos negativos. Dessa forma, um modelo que majoritariamente associa instâncias à classe negativa sempre terá boa acurácia, mas será um modelo ruim com respeito à classe positiva, como evidenciado pela precisão e revocação ruins. Com o intuito de entender melhor as razões para a baixa precisão do modelo, duas hipóteses foram estabelecidas⁶. Primeiro, o modelo utilizado não é adequado para dados com alto grau de desbalanceamento. Segundo, é improvável que um único modelo global funcione adequadamente para um conjunto heterogêneo de interfaces (vide Seção 5).

Para investigar a primeira hipótese, um novo experimento foi conduzido. Utilizando a técnica de *undersampling*, três novos conjuntos de dados foram criados, cada um com uma proporção diferente de instâncias da classe positiva. Em cada caso, as instâncias da classe positiva foram mantidas e um subconjunto das instâncias negativas foi selecionado, aleatoriamente e sem reposição. Os resultados, apresentados na Tabela 1, mostram que o desempenho do modelo melhora significativamente, com relação a precisão, a medida que o grau de desbalanceamento dos dados diminui.

Por um lado, os resultados da Tabela 1 evidenciam que o modelo utilizado é capaz de reconhecer o sinal dos dados e separar as duas classes de uma forma satisfatória. Por outro lado, do ponto de vista operacional, esses resultados não são úteis, uma vez que não é possível aplicar *undersampling* em um cenário onde os rótulos das instâncias testadas não são conhecidos (e.g., num ambiente de produção). O problema de classificação em bases altamente desbalanceadas é desafiador na literatura de aprendizado de máquina. A própria definição do problema, apresentada na Seção 3, introduziu a janela futura, de tamanho K , para aumentar a proporção de instâncias positivas sem prejudicar a aplicabilidade da definição em situações reais (desde que o valor de K não seja grande). Novas

⁵<https://www.tensorflow.org/>

⁶Nesse trabalho, a precisão é tida como métrica mais relevante. Como discutido anteriormente, nem todas as falhas podem ser previstas (e.g., aquelas causadas por fatores exógenos). No entanto, deseja-se, do ponto de vista operacional, que um sinal de falha esteja errado com baixa probabilidade.

Tabela 2. Resultados para interfaces selecionadas no Brasil, região Sudeste e região Norte. Comparativo entre todas as interfaces e o top-5% com relação ao número de falhas.

	Conjunto de interfaces	Acurácia	Precisão	Revocação
Brasil	Todas	0,97	0,19	0,43
	5% piores	0,87	0,38	0,50
Sudeste	Todas	0,96	0,22	0,72
	5% piores	0,86	0,44	0,65
Norte	Todas	0,94	0,25	0,61
	5% piores	0,83	0,51	0,32

formas para resolver esse problema de desbalanceamento nos dados constituem direções para eventuais trabalhos futuros.

Experimentos também foram conduzidos para investigar a segunda hipótese relacionada à baixa precisão do modelo, i.e., a heterogeneidade das interfaces no conjunto de dados. Inicialmente, os resultados nacionais foram comparados com os resultados obtidos para as regiões Sudeste e Norte. Além disso, para cada cenário, também investigou-se a qualidade do modelo para as respectivas piores interfaces, em termos do total de falhas. A Tabela 2 mostra que os resultados para as regiões Sudeste e Norte são, marginalmente, melhores que os resultados nacionais, indicando que escolher um conjunto mais homogêneo de interfaces (assumindo que a redução do número de PoPs implica em um conjunto menos heterogêneo) é uma direção que vale a pena ser investigada. A Tabela também mostra que ao considerar as piores interfaces de cada região, uma melhoria significativa é obtida para a precisão (o que está simultaneamente relacionado à homogeneidade das interfaces e à proporção de instâncias da classe positiva).

Por fim, os experimentos foram repetidos para um pequeno conjunto de PoPs/Estados, assim como é mostrado na Tabela 3. Pode-se perceber que a qualidade do modelo varia significativamente. No pior caso, o modelo se comporta de forma similar ao cenário nacional nas interfaces do PoP de Minas Gerais, apontando que o estado mineiro possa ser mais heterogêneo que os demais. Por outro lado, em Roraima, a precisão chega a 0,83 – isso sem a aplicação de *undersampling* ou seleção das piores interfaces. Esse resultado sugere que há interfaces/situações cujas falhas são mais fáceis de prever. A investigação de fatores que influenciam a dificuldade da tarefa de predição é uma outra direção para os trabalhos futuros.

7. Conclusão

A Rede Ipê tem sido fundamental no desenvolvimento e evolução da comunidade científica nacional. Ela interconecta universidades e centros de pesquisa em todo o país. Salvo melhor juízo, este é o primeiro trabalho a caracterizar o serviço de conectividade em nível nacional da Rede Ipê, a partir de dados do serviço ViaIpê, para construir um modelo preditivo de falhas usando técnicas de aprendizado de máquina.

Com base nas características, algumas observações foram extraídas em relação à dependabilidade do serviço. Pode-se afirmar que a qualidade do serviço de conectividade

Tabela 3. Resultados para interfaces selecionadas em diversos estados do Brasil. Linhas ordenadas em ordem decrescente de precisão.

Estado	Acurácia	Precisão	Revocação
Roraima	0,96	0,83	0,69
São Paulo	0,96	0,41	0,83
Amazonas	0,92	0,35	0,48
Pará	0,95	0,30	0,46
Minas Gerais	0,95	0,20	0,79

não é homogênea em todos os PoPs do país. Por exemplo, no estado de Roraima, apesar de suas falhas serem curtas, elas são frequentes e em grande quantidade. Pode-se perceber que o tempo contíguo de operação normal é relativamente baixo. Por exemplo, apenas 10% dos períodos entre falhas, i.e., de funcionamento normal do serviço, duram mais do que mil minutos (16.7 horas). As durações dos períodos de falha, por outro lado, tendem a ser curtas, sendo que 90% das falhas duram menos que meia hora. Uma pequena proporção das interfaces de rede (30%) concentra um grande número de falhas.

Os resultados relacionados à previsão de falhas mostram que a metodologia proposta é promissora. De fato, quando fatores como a heterogeneidade das interfaces e o desbalanceamento entre classes positiva (falha) e a negativa (sem falha) são controlados, uma precisão de até, aproximadamente, 85% é obtida. Apesar disso, vale ressaltar que uma metodologia geral (i.e., para toda e qualquer interface) e que funcione de forma satisfatória ainda não está disponível.

Com o objetivo de disponibilizar uma ferramenta de predição de falhas para operadores de serviços de conectividade de rede, este trabalho abre oportunidades para abordar vários desafios técnico-científicos. Do ponto de vista de aprendizado de máquina, há espaço para estudar algoritmos mais refinados, outras estratégias de seleção de hiperparâmetros e diferentes formas de utilizar/transformar os dados de entrada do modelo. Outra possibilidade de melhoria é criação de modelos específicos para grupos de interfaces que possuam o mesmo “perfil”. Isso pode ser feito tanto do ponto de vista do padrão/frequência de falhas, quanto pela adição de metadados sobre os serviços de conectividade. Neste último caso, os dados disponibilizados pela ferramenta ViaIpê não contemplam a demanda e novas fontes de dados devem ser buscadas, tais como a tecnologia utilizada para implementação do serviço de conectividade, a reputação da empresa contratada (em caso de subcontratação) e até mesmo informações sobre a topologia física da rede (e.g., se duas ou mais instituições compartilham infraestrutura de conectividade).

8. Agradecimentos

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001, FAPES, FAPESP/MCTIC/CGI.br (#2020/05182-3) e CNPq.

Referências

Azzouni, A. and Pujolle, G. (2018). Neutm: A neural network-based framework for traffic matrix prediction in sdn. In *NOMS 2018 - 2018 IEEE/IFIP Network Operations and*

Management Symposium, pages 1–5.

- Bosshart, P., Daly, D., Gibb, G., Izzard, M., McKeown, N., Rexford, J., Schlesinger, C., Talayco, D., Vahdat, A., Varghese, G., and Walker, D. (2014). P4: Programming protocol-independent packet processors. *SIGCOMM Comput. Commun. Rev.*, 44(3):87–95.
- Boutaba, R., Salahuddin, M. A., Limam, N., Ayoubi, S., Shahriar, N., Estrada-Solano, F., and Caicedo, O. M. (2018). A comprehensive survey on machine learning for networking: evolution, applications and research opportunities. *Journal of Internet Services and Applications*, 9(1):16.
- Giannakou, A., Dwivedi, D., and Peisert, S. (2020). A machine learning approach for packet loss prediction in science flows. *Future Generation Computer Systems*, 102:190–197.
- Gill, P., Jain, N., and Nagappan, N. (2011). Understanding network failures in data centers: Measurement, analysis, and implications. *SIGCOMM Comput. Commun. Rev.*, 41(4):350–361.
- Goodfellow, I., Bengio, Y., and Courville, A. (2016). *Deep Learning*. MIT Press. <http://www.deeplearningbook.org>.
- Hochreiter, S. and Schmidhuber, J. (1997). Long short-term memory. *Neural Comput.*, 9(8):1735–1780.
- Lens Shiang, E. P., Chien, W., Lai, C., and Chao, H. (2020). Gated recurrent unit network-based cellular trafile prediction. In *2020 International Conference on Information Networking (ICOIN)*, pages 471–476.
- Liberato, A., Martinello, M., Gomes, R. L., Beldachi, A. F., Salas, E., Villaca, R., Ribeiro, M. R. N., Kondepu, K., Kanellos, G., Nejabati, R., Gorodnik, A., and Simeonidou, D. (2018). Rdna: Residue-defined networking architecture enabling ultra-reliable low-latency datacenters. *IEEE Transactions on Network and Service Management*, 15(4):1473–1487.
- Lin, T., Goyal, P., Girshick, R., He, K., and Dollár, P. (2017). Focal loss for dense object detection. In *2017 IEEE International Conference on Computer Vision (ICCV)*, pages 2999–3007.
- Markopoulou, A., Iannaccone, G., Bhattacharyya, S., Chuah, C., Ganjali, Y., and Diot, C. (2008). Characterization of failures in an operational ip backbone network. *IEEE/ACM Transactions on Networking*, 16(4):749–762.
- Martinello, M. (2005). *Availability Modeling and Evaluation of Web-based Services-A pragmatic approach*. PhD thesis, Institut National Polytechnique de Toulouse, INPT.
- Wickham, H. (2014). Tidy data. *The Journal of Statistical Software*, 59.
- Zhong, J., Guo, W., and Wang, Z. (2016). Study on network failure prediction based on alarm logs. In *2016 3rd MEC International Conference on Big Data and Smart City (ICBDSC)*, pages 1–7.
- Zhou, Z. and Zhang, T. (2018). Applying machine learning to service assurance in network function virtualization environment. In *2018 First International Conference on Artificial Intelligence for Industries (AI4I)*, pages 112–115.