

UNIVERSIDADE FEDERAL DE JUIZ DE FORA
INSTITUTO DE CIÊNCIAS EXATAS
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

Breno Almeida dos Santos Rodrigues Machado

Evolução do Comportamento dos Usuários em Serviços de *Streaming* de
Vídeo em Larga Escala

Juiz de Fora
2020

Breno Almeida dos Santos Rodrigues Machado

Evolução do Comportamento dos Usuários em Serviços de *Streaming* de
Vídeo em Larga Escala

Dissertação apresentada ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal de Juiz de Fora, como requisito parcial para obtenção do título de Mestre em Ciência da Computação.

Orientador: Prof. Dr. Alex Borges Vieira

Coorientador: Prof. Dr. Ítalo Fernando Scotá Cunha

Juiz de Fora

2020

Ficha catalográfica elaborada através do Modelo Latex do CDC da UFJF
com os dados fornecidos pelo(a) autor(a)

Machado, Breno Almeida dos Santos Rodrigues.

Evolução do Comportamento dos Usuários em Serviços de *Streaming* de
Vídeo em Larga Escala / Breno Almeida dos Santos Rodrigues Machado.
– 2020.

53 f. : il.

Orientador: Alex Borges Vieira

Coorientador: Ítalo Fernando Scotá Cunha

Dissertação (Mestrado) – Universidade Federal de Juiz de Fora, Instituto
de Ciências Exatas. Programa de Pós-Graduação em Ciência da Computa-
ção, 2020.

1. Streaming de vídeo. 2. Qualidade de experiência. 3. Vídeo em larga
escala. I. Vieira, Alex Borges, orient. II. Cunha, Ítalo Scotá, coorient. III.
Título.

Breno Almeida dos Santos Rodrigues Machado

Evolução do Comportamento dos Usuários em Serviços de *Streaming* de
Vídeo em Larga Escala

Dissertação apresentada ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal de Juiz de Fora, como requisito parcial para obtenção do título de Mestre em Ciência da Computação.

Aprovada em: 17 de novembro de 2020.

BANCA EXAMINADORA

Professor Dr. Alex Borges Vieira - Orientador
Universidade Federal de Juiz de Fora

Professor Dr. Ítalo Fernando Scotá Cunha -
Coorientador
Universidade Federal de Minas Gerais

Professor Dr. Artur Ziviani
Laboratório Nacional de Computação Científica

Professor Dr. Idilio Drago
Universidade de Turim

Dedico este trabalho aos meus pais, Sérgio e Claudia,
pelo apoio, sustento e oportunidades que me deram.

AGRADECIMENTOS

À toda minha família, por todo o apoio que me dá, especialmente meus pais, que me deram muitas oportunidades que foram geradas com base em muitos sacrifícios.

Ao meu orientador, Prof. Dr. Alex Borges Vieira, pelos ensinamentos, paciência, apoio e amizade que se iniciou no início da minha graduação e se estende até hoje.

Ao meu coorientador, Prof. Dr. Ítalo Fernando Scotá Cunha, pelos inúmeros *feedbacks* que me fizeram enxergar com outros olhos os resultados desse trabalho e a me ajudaram a ter uma visão mais detalhista e crítica.

Ao Leandro Moreira e Vagner Santana, do time do Globo.com, que forneceram informações importantes sobre a infraestrutura de transmissão do sistema avaliado.

Aos meus colegas do Netlab, principalmente ao Thiago Guarneri, que me ajudaram inúmeras vezes quando precisei durante o desenvolvimento desse trabalho.

Por fim, agradeço ao Prof. Dr. Artur Ziviani, à CAPES e à FAPESP.

“Mede o que é mensurável e torna mensurável o que não o é.” (Galileu Galilei).

RESUMO

Streaming de vídeo é o responsável pela maior parte do tráfego na Internet atualmente, o que gera investimentos massivos em infraestrutura por parte dos principais provedores de conteúdo como Netflix, Youtube e Hulu. Ao longo dos últimos anos, esses investimentos geraram diversas modificações na infraestrutura de transmissão como melhora nas redes de distribuição de conteúdo (CDN), aumento do poder computacional e mudanças na tecnologia de transmissão. O objetivo final dos provedores de serviço ao realizar todos esses investimentos é ser capaz de realizar uma transmissão com a maior qualidade possível para agradar seus clientes, de modo que suas plataformas se destaquem de seus concorrentes. Nesse sentido, é necessário ter métricas que representem questões como o impacto causado nos servidores por conta da quantidade grande de clientes, o padrão de comportamento desses clientes e a qualidade do vídeo que está sendo assistido, para que seja possível saber os efeitos das mudanças de infraestrutura no engajamento final do cliente. Nesse contexto, esse trabalho avalia a evolução da infraestrutura de transmissão, do comportamento do cliente e da experiência do usuário de sistemas de *streaming* ao vivo na Internet, utilizando como objeto de estudo os registros de acesso das transmissões das Copas do Mundo da FIFA de 2014 e 2018 realizadas pelo maior provedor de conteúdo do Brasil. Alguns dos resultados obtidos mostram que o tráfego gerado cresceu mais de 300% e o público médio cerca de 175% nos quatro anos entre os eventos. A taxa de chegada também mudou e passou a ser mais concentrada no início do 1º e 2º tempo do jogo. Além disso, em relação ao engajamento do usuário, foram avaliadas diferentes métricas e, em geral, o engajamento aumentou no torneio de 2018 para todas as métricas utilizadas.

Palavras-chave: Transmissão de vídeo sob HTTP. Qualidade de experiência (QoE). Medições de sistema.

ABSTRACT

Video streaming is responsible for most of the traffic flowing on the Internet nowadays, which leads to massive investments in the infrastructure from the main content providers like Netflix, Youtube, and Hulu. In the past few years, these investments generated multiple changes in the transmission infrastructure, improving the content delivery networks (CDN), enhancing the computer processing power and changing the transmission technology used. The ultimate goal of the content providers when making these investments is to transmit streaming video over the Internet with the best quality as possible to please their clients and stand out from their competitors. In this sense, it is necessary to have metrics capable of capturing the impact imposed on the servers, user behavior, and in the quality of the video to know how changes in the transmission infrastructure affect user engagement. In this context, in this work, we characterize the evolution of transmission infrastructure, user behavior, and quality of experience from live video streaming systems over the Internet, using for this purpose the logs generated from the transmission of the 2014 and 2018 FIFA World Cups that were transmitted by the biggest content provider located in Brazil. Some of the results in this work show that traffic has increased more than 300% and the average public increased about 175%. The arrival rate also changed and now it is more concentrated at the beginning of the 1st and 2nd half of the match. Besides that, user engagement was evaluated using different metrics and, in general, it has increased in the 2018 tournament for all metrics.

Keywords: Video streaming over HTTP. Quality of Experience (QoE). System measurements.

LISTA DE ABREVIATURAS E SIGLAS

QoE	<i>Quality of Experience</i>
QoS	<i>Quality of Service</i>
CDN	<i>Content Delivery Network</i>
ABS	<i>Adaptive Bitrate Streaming</i>
HLS	<i>HTTP Live Streaming</i>
NAT	<i>Network Address Translation</i>
ISP	<i>Internet Service Provider</i>

SUMÁRIO

1	INTRODUÇÃO	10
1.1	PROBLEMA	11
1.2	OBJETIVO	11
1.3	CONTRIBUIÇÕES	11
1.4	ORGANIZAÇÃO	12
2	STREAMING DE VÍDEO NA INTERNET	13
2.1	MULTICAST	13
2.2	PEER-TO-PEER (P2P)	13
2.3	PROTOCOLO DE MENSAGEM EM TEMPO REAL (RTMP)	15
2.4	STREAMING DE BITRATE ADAPTATIVO (ABS)	15
2.5	INFRAESTRUTURA DO SISTEMA ESTUDADO	17
3	TRABALHOS RELACIONADOS	19
4	METODOLOGIA	21
5	CARACTERIZAÇÃO	23
5.1	VOLUME DE ACESSO	23
5.2	QUANTIDADE DE SESSÕES	24
5.3	TAXA DE CHEGADA DE NOVAS SESSÕES	26
5.4	TRÁFEGO GERADO	27
5.5	QUALIDADE MÉDIA DAS SESSÕES	27
6	COMPORTAMENTO DOS USUÁRIOS	30
6.1	MODELO DE COMPORTAMENTO DO USUÁRIO	30
6.2	RESULTADOS	30
7	QUALIDADE DE EXPERIÊNCIA DO USUÁRIO	36
8	CONCLUSÃO	42
	REFERÊNCIAS	44
	APÊNDICE A – SESSÕES E TRÁFEGO DOS JOGOS MAIS POPULARES	47

1 INTRODUÇÃO

Streaming de vídeo gera a maior parte do tráfego da Internet nos dias atuais, impulsionado por plataformas populares como Netflix, Youtube e Hulu [Sandvine 2020]. Para suportar essa demanda crescente, provedores de serviço e redes de distribuição de conteúdo (CDNs) investem massivamente em infraestrutura [Schlinker et al. 2017], [Netflix Open Connect 2011].

Em 2002 um *reality show* popular no Brasil foi transmitido ao vivo pela Internet continuamente (24 horas por dia), chegando a atrair cerca de 690 mil usuários em um período de 28 dias [Veloso et al. 2002]. Já a transmissão da 87^a edição do Oscar, que foi realizada em 2015, contou com pico de quase 100 mil usuários simultâneos e cerca de 600 mil em um período de 5 horas [Ahmed et al. 2017]. Sendo assim, se tratando de dois eventos populares transmitidos ao vivo na Internet, ambos se assemelham no número total de usuários mesmo que o primeiro tenha tido uma duração de 28 dias e o outro de apenas 5 horas. Esses exemplos ilustram como a popularidade de *streaming* ao vivo pela Internet cresceu nos últimos anos gerando vários desafios para suprir essa demanda.

Em primeiro lugar, a infraestrutura de transmissão precisa ser atualizada para lidar com o crescimento do público e com sua crescente expectativa em relação à qualidade de serviço (QoS) ao assistir vídeo *online*. O desafio para realizar transmissões de vídeo ao vivo é ainda maior, já que exige restrição no atraso máximo para disseminação do conteúdo e há concentração de demanda. Além disso, perguntas como: O que interfere na experiência do usuário? Como mensurar os fatores impactantes no engajamento? Como prever o engajamento de um cliente? são essenciais para entender os requisitos necessários para realizar uma transmissão de vídeo pela Internet que satisfaça as expectativas dos usuários.

Além de possuir uma infraestrutura capaz de servir milhões de usuários, os provedores de conteúdo também se preocupam em realizar transmissões com boa qualidade e estáveis para agradar seus clientes e, conseqüentemente, conseguir se destacar em relação aos seus concorrentes. Métricas que representam a qualidade de serviço (QoS) podem ser utilizadas para avaliar o estado da rede, mas não refletem a experiência do usuário [Nam, Kim e Schulzrinne 2016]. Sendo assim, uma alternativa é estimar a qualidade de experiência (QoE), que reflete o grau de satisfação do usuário com o serviço, utilizando os dados provenientes dos registros de acesso das sessões dos usuários. Os resultados dessas análises guiam tanto melhorias na infraestrutura dos provedores de conteúdo quanto modificações na infraestrutura de CDNs, permitindo que seus clientes usufruam um serviço de melhor qualidade.

1.1 PROBLEMA

O aumento constante do poder de processamento dos dispositivos como *smartphones* e a melhora da infraestrutura de rede, com conexões cada vez mais rápidas, geram maiores expectativas nos usuários de serviços de *streaming*. Esses serviços exigem alta qualidade de serviço (QoS) para suprir a demanda crescente de usuários desse tipo de aplicação. Com isso, há um desafio em relação ao dimensionamento da infraestrutura de transmissão, pois o superdimensionamento gera custos adicionais, enquanto que o subdimensionamento gera frustração nos usuários. No entanto, o dimensionamento correto não é o único fator determinante na satisfação geral do usuário com o serviço, pois a insatisfação pode ocorrer por problemas que não possuem relação com a qualidade de serviço, por exemplo, quando a qualidade de vídeo é menor do que a esperada. Sabendo disso, o maior problema existente consiste em conseguir identificar quais são os principais fatores envolvidos na satisfação do usuário.

É difícil adquirir dados para realizar esse tipo de análise por se tratarem de informações proprietárias e confidenciais, o que torna escasso esse tipo de trabalho. Além disso, o aumento constante de público e exigências crescentes tornam os resultados de trabalhos anteriores desatualizados rapidamente.

1.2 OBJETIVO

Esse trabalho é um estudo de caracterização em um sistema de vídeo de larga escala e avalia o comportamento do usuário desse serviço. Mais ainda, visa comparar e avaliar como o sistema e comportamento dos usuários mudaram em 4 anos, avaliando as transmissões da Copa do Mundo da FIFA de 2014 e 2018. Fazemos isso pois ainda existem poucos trabalhos atualizados que caracterizam sistemas de *streaming* de vídeo ao vivo em larga escala e avaliam o comportamento dos usuários.

1.3 CONTRIBUIÇÕES

A principal contribuição dessa dissertação é a avaliação de um conjunto de dados único de um dos maiores provedores de conteúdo da América Latina o que permite atualizar os trabalhos existentes na área de caracterização e QoE. Os resultados aqui apresentados podem ser utilizados para auxiliar na criação de infraestruturas de transmissão melhores e auxiliar no desenvolvimento de novas heurísticas de adaptação da qualidade do vídeo para reprodutores de vídeo (*players*). Uma parte do trabalho aqui apresentado foi publicado no *Workshop* em Desempenho de Sistemas Computacionais e de Comunicação (WPerformance) em 2019 através do artigo **Comportamento do Usuário em Eventos de Larga Escala na Internet** [Machado et al. 2019].

1.4 ORGANIZAÇÃO

O restante desse trabalho está organizado da seguinte maneira. O capítulo 2 apresenta uma contextualização do cenário de *streaming* na Internet mostrando um pouco sobre como ocorreu a evolução desse tipo de serviço. Em seguida, os trabalhos relacionados são mostrados no Capítulo 3. O capítulo 4 apresenta pontos importantes sobre a metodologia utilizada no decorrer das análises desse trabalho. Já o capítulo 5 exhibe caracterizações gerais sobre o conjunto de dados avaliado. O capítulo 6 avalia o comportamento do usuário com base nas interações do cliente com o serviço durante a transmissão. Por sua vez, o capítulo 7 investiga a qualidade de experiência do usuário utilizando algumas métricas muito usadas na literatura. Por fim, o capítulo 8 apresenta a conclusão e os trabalhos futuros que podem ser realizados.

2 STREAMING DE VÍDEO NA INTERNET

Serviços de *streaming* de vídeo demandam muitos recursos de processamento e rede [Merwe, Sen e Kalmanek 2002]. Essa exigência alta de recursos gera alguns problemas que dificultam a transmissão e que uma alta qualidade de serviço seja recebida pelos usuários finais. Vários protocolos e tipos de arquiteturas surgiram ao longo do tempo com o objetivo de solucionar esses problemas e, até hoje, muita pesquisa é feita nessa área. Esse capítulo tem como principal objetivo contextualizar a evolução de *streaming* de vídeo na Internet que ocorreu nas últimas décadas. A seção 2.1 mostra a solução de *multicast* como arquitetura alternativa para transmissões de vídeo. Na seção 2.2 é mostrada a arquitetura descentralizada par-a-par (P2P). Em seguida, a seção 2.3 comenta sobre o protocolo RTMP. A seção 2.4 apresenta a técnica de *streaming* de *bitrate* adaptativo. Por fim, a seção 2.5 apresenta detalhes sobre a infraestrutura do sistema avaliado nesse trabalho.

2.1 MULTICAST

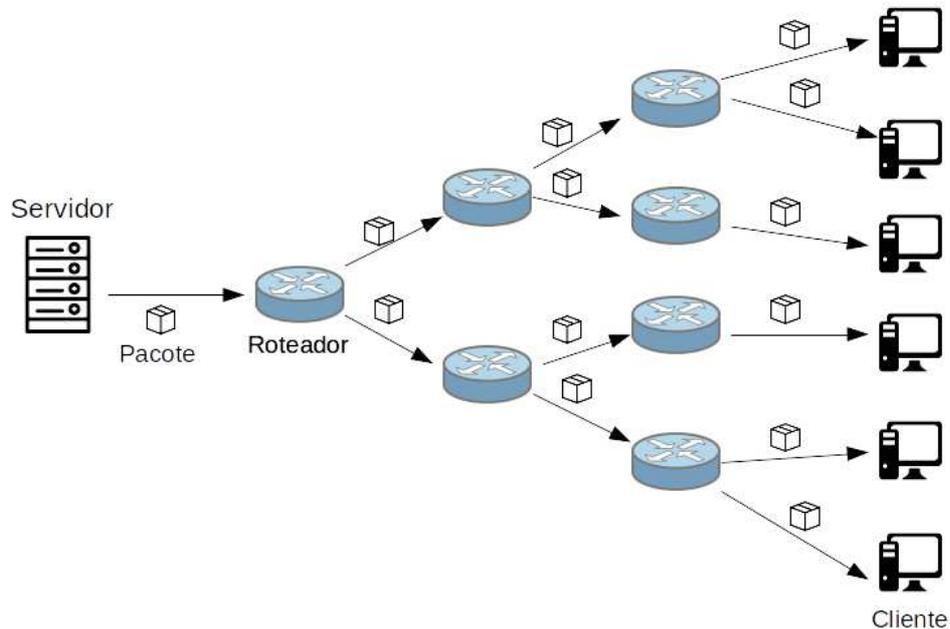
Serviços de *streaming* de vídeo exigem um grande poder de processamento e de rede, principalmente quando a quantidade de usuários do serviço é alta. Por conta disso, é necessário construir arquiteturas capazes de suportar uma alta demanda de tráfego, mantendo a qualidade e disponibilidade do serviço. Para contornar o problema de limite de tráfego existente no servidor responsável pela transmissão do conteúdo, foram criadas infraestruturas com o objetivo de realizar transmissões *multicast*. Em uma arquitetura *multicast*, vários clientes se conectam a um grupo com o objetivo de receber conteúdo de um transmissor comum e esses clientes são organizados em uma rede em formato de árvore como mostra a Figura 1. Nessa estrutura o transmissor precisa enviar o conteúdo uma única vez e os pacotes são transmitidos para todos os membros do grupo, gerando uma economia de tráfego considerável para o provedor de conteúdo e em roteadores intermediários.

Multicast possui alguns problemas como controle de *feedback* [Nonnenmacher e Biersack 1998], necessário para que o receptor consiga comunicar ao transmissor questões como a velocidade de transmissão para controlar o fluxo ou pedir por pacotes perdidos para controlar os erros e ser resiliente a eles. Além disso, *multicast* exige que roteadores tenham suporte para esse modelo de transmissão. Ao longo do tempo, outras alternativas para transmissão de vídeo foram sendo criadas, por exemplo, transmissões *peer-to-peer* (P2P).

2.2 PEER-TO-PEER (P2P)

Como *streaming* de vídeos demanda muitos recursos de processamento e de rede nos servidores, uma forma de distribuir essa carga é utilizar arquitetura descentralizada

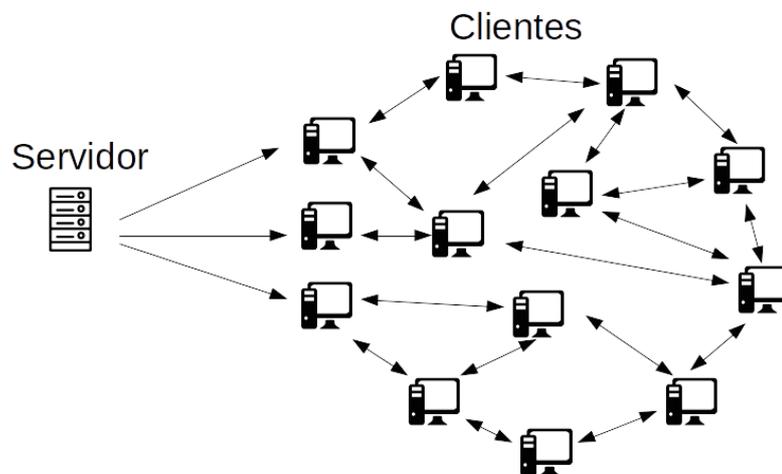
Figura 1 – Arquitetura de transmissão *multicast*. Pacotes são replicados pelos roteadores.



Fonte: Elaborado pelo autor. (2020).

peer-to-peer (P2P). Nesse tipo de arquitetura os usuários contribuem com a distribuição do vídeo ao mesmo tempo em que assistem, dessa forma o servidor fica responsável apenas por codificar o vídeo e distribuí-lo para um número menor de clientes. Sistemas de *streaming* P2P utilizam estrutura de rede baseada em árvore ou malha (*mesh*) para interconectar os usuários do sistema [Liu, Guo e Liang 2008], como mostra a Figura 2.

Figura 2 – Arquitetura de sistemas de *streaming* P2P



Fonte: Elaborado pelo autor. (2020).

Apesar da grande vantagem de economia de recursos que essa abordagem proporciona, há também pontos negativos importantes. Serviços de *streaming* são dinâmicos, com

clientes entrando e saindo a todo momento, o que exige uma reorganização da estrutura de rede para que não haja degradação da qualidade do serviço [Liu, Guo e Liang 2008]. Em eventos ao vivo, esse é um desafio ainda maior já que esse tempo impacta negativamente no atraso da transmissão. Existe também o problema de banda de rede assimétrica em redes domésticas que limitam a contribuição de clientes da rede. Além disso, serviços P2P exigem que *software* seja instalado no cliente e que portas sejam abertas em *firewalls* e NATs, tornando inconveniente a utilização para muitas pessoas. Essas são algumas das desvantagens de P2P que motivaram a busca por outras alternativas para transmissão de vídeo na Internet.

2.3 PROTOCOLO DE MENSAGEM EM TEMPO REAL (RTMP)

Um protocolo bastante popular em *streaming* de vídeo é o Protocolo de Mensagem em Tempo Real (RTMP) [Swaminathan 2013]. O RTMP é um protocolo da camada de aplicação desenvolvido para transmissão de mídia na Internet, onde um servidor transmite o conteúdo para os clientes, que devem ter um reprodutor (*player*) de *Flash* instalado na máquina para reproduzir o vídeo. Inicialmente o RTMP era um protocolo proprietário, mas em 2012 a *Adobe*, empresa responsável por sua criação, decidiu criar uma especificação livre do protocolo¹. Esses *players* passaram a se tornar nativos nos navegadores devido a ampla utilização, mas nos dias atuais seu uso é desencorajado², principalmente por motivos de segurança.

2.4 STREAMING DE BITRATE ADAPTATIVO (ABS)

Atualmente, a técnica conhecida como streaming de *bitrate* adaptativo, ou *Adaptive Bitrate Streaming (ABS)*, é amplamente utilizada para transferência de vídeos na Internet. Essa técnica é escolhida pelos maiores provedores desse tipo de serviço na atualidade, como Youtube, Hulu e Netflix. O objetivo dela é transferir o vídeo ao usuário na maior qualidade possível de acordo com alguns parâmetros como o poder de processamento do dispositivo do usuário e a largura de rede disponível no momento. ABS pode ser dividido em quatro etapas, como mostrado na Figura 3.

Primeiramente é feita a codificação do vídeo original em diferentes qualidades, o que permite o usuário requisitar a qualidade mais apropriada para sua largura de banda disponível no momento e o dispositivo utilizado.

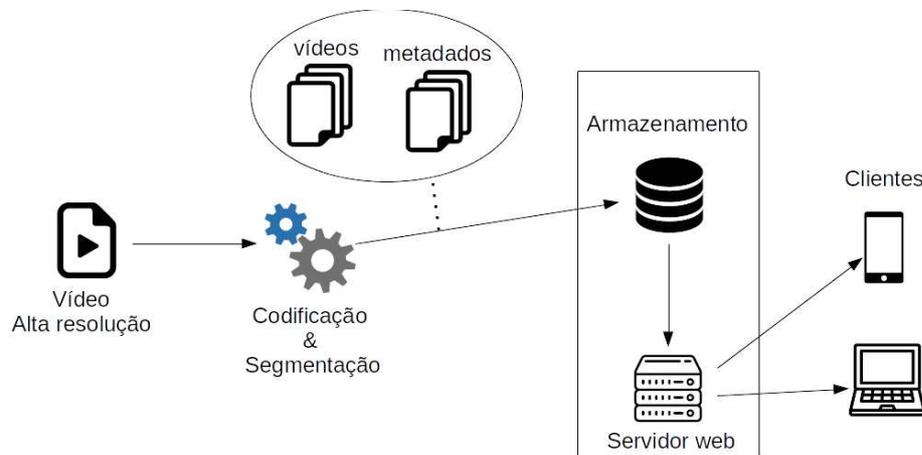
Após a codificação, é feita a segmentação dos vídeos gerados na etapa anterior. Essa etapa consiste em dividir o vídeo em vários segmentos menores que serão transferidos para o usuário final, cada um desses segmentos podem ser decodificados no lado do cliente de maneira independente. Além dos segmentos de vídeo, são criados os arquivos de manifestos

¹ <https://www.adobe.com/devnet/rtmp.html>

² <https://www.blog.google/products/chrome/saying-goodbye-flash-chrome/>

que contêm metadados como as URIs dos segmentos de vídeo e as qualidades disponíveis. O tamanho dos segmentos de vídeo escolhido nessa etapa irá interferir no resultado final da transmissão. Por exemplo, caso um segmento tenha 15 segundos de vídeo, o vídeo irá possuir uma latência maior já que será necessário aguardar esse tempo antes da codificação ser feita e a transmissão ocorrer. Por outro lado, quanto menor o tamanho do segmento, maior é o consumo de processador exigido dos servidores visto que mais requisições são realizadas pelos clientes durante a transmissão. Esse valor também impacta no atraso inicial da reprodução (*startup delay*) e eventos ao vivo, em geral, utilizam valores pequenos (por volta de 5 segundos) para diminuir esse impacto. No entanto, o fator mais impactante no *startup delay* é o tamanho do *buffer* presente no reproduutor de vídeo do cliente, que varia de acordo com o navegador utilizado. Existem navegadores que definem o *buffer* máximo considerando o número de segmentos de vídeo enquanto outros consideram o valor em segundos de vídeo armazenado. Os arquivos gerados na etapa de segmentação são distribuídos para os clientes através de um servidor HTTP [Bentaleb et al. 2018]. O usuário que assiste o *streaming* possui em seu dispositivo um reproduutor de vídeo que é responsável por avaliar qual a qualidade do vídeo que deverá ser requisitada. Por fim, após o reproduutor de vídeo (*player*) ter requisitado um número de segmentos de vídeo suficiente para preencher todo o *buffer*, a reprodução é iniciada.

Figura 3 – *Streaming* de *bitrate* adaptativo



Fonte: Elaborado pelo autor. (2020).

É necessário que exista uma infraestrutura de transmissão adequada para permitir que *streaming* de *bitrate* adaptativo funcione adequadamente de maneira escalável. Nesse sentido, são usadas redes de distribuição de conteúdo (CDNs) que permitem armazenar o conteúdo mais próximo do usuário final e aumentar a qualidade da transmissão. Também são utilizados pontos de troca de tráfego (PPT) onde diferentes redes se interconectam

para melhorar a conectividade de diversas formas. Os PTTs melhoram a conectividade pois diminuem os custos já que o tráfego é resolvido localmente, economizam banda, utilizam um caminho mais curto para entregar o conteúdo e diminui a latência.

Apesar de ABS ser amplamente utilizado nos dias de hoje, nem todas as soluções que utilizam essa técnica são iguais. Existem diversos protocolos que implementam ABS de maneiras diferentes, como: *MPEG Dynamic Adaptive Streaming over HTTP (MPEG-DASH ou DASH)* [Stockhammer 2011], *Microsoft Smooth Streaming (MSS)* [Zambelli 2009], *HTTP Dynamic Streaming (HDS)* [Adobe 2009], *HTTP Live Streaming (HLS)* [Apple 2009].

O MPEG-DASH [Sodagar 2011] é o primeiro protocolo que utiliza a técnica de *streaming* adaptativo que se tornou padrão internacional [Sodagar 2011], as demais soluções existentes são proprietárias e possuem diferenças de implementação. O *Microsoft Smooth Streaming (MSS)* é a solução de ABS criada pela *Microsoft*, o *HTTP Dynamic Streaming (HDS)* é a solução da *Adobe* e o *HTTP Live Streaming (HLS)* foi criado pela *Apple*.

O *HTTP Live Streaming (HLS)* é um protocolo para transmissão de *streaming* de vídeo adaptativo que pode ser usado para transmissão tanto de vídeos sob demanda quanto para vídeos ao vivo. A RFC 8216³ descreve o funcionamento da última versão do protocolo (versão 7).

Todas essas abordagens que utilizam ABS possuem vantagens que contribuíram para que essa forma de transmitir vídeo na Internet se tornasse a mais popular dentre todas as maneiras existentes. Em primeiro lugar, é utilizado o protocolo HTTP, desse modo não é necessário abrir portas adicionais em *firewalls* para que a transmissão seja realizada. Outra vantagem é que os *players* não precisam ser instalados no cliente, rodando direto no navegador, o que permite a compatibilidade com qualquer dispositivo sem esforço adicional por parte do usuário. Por fim, ao adaptar a qualidade do vídeo de acordo com os recursos disponíveis pelo usuário no momento, há um número menor de pausas durante a reprodução, o que ocasiona em aumento na satisfação do usuário.

2.5 INFRAESTRUTURA DO SISTEMA ESTUDADO

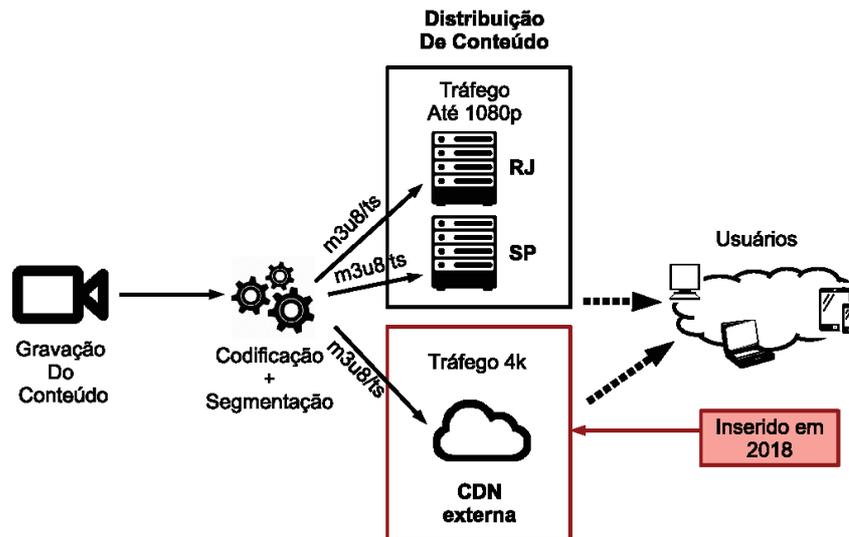
A Figura 4 resume a infraestrutura de transmissão do sistema estudado. A infraestrutura existente em 2014 consistia em dois *data centers* localizados em São Paulo e no Rio de Janeiro. Ambos são conectados a Pontos de Troca de Tráfego (PTT) e se conectam com centenas de Provedores de Acesso à Internet (ISPs). Essa infraestrutura utiliza *anycast*⁴ para definir o centro de distribuição responsável por servir o cliente. *Anycast* é uma forma de roteamento que escolhe o servidor mais apropriado para tratar a requisição do usuário, geralmente escolhendo o caminho mais curto do servidor ao cliente com o objetivo de

³ <https://tools.ietf.org/html/rfc8216>

⁴ <https://www.cloudflare.com/pt-br/learning/cdn/glossary/anycast-network/>

diminuir a latência. Em 2018 a infraestrutura foi estendida por uma rede de distribuição de conteúdo (CDN) contratada para distribuir conteúdo com resolução 4K. O *dataset* avaliado nesse trabalho não contempla os dados dessa CDN e, por isso, uma fração do tráfego das transmissões não são considerados.

Figura 4 – Infraestrutura de transmissão



Fonte: Elaborado pelo autor. (2020).

Como mostra a Figura 4, os jogos são capturados no estádio e o vídeo é codificado em diferentes qualidades e segmentado em vários arquivos pequenos (*chunks*), contendo 3 segundos de vídeo cada um para o torneio de 2014 e 4 segundos em 2018. Esses passos são realizados utilizando o *HTTP Live Streaming (HLS)*. Além dos segmentos de vídeo, de extensão *.ts*, o HLS cria arquivos de índice (*.m3u8*) que contêm metadados com parâmetros de configuração como ordem para reprodução e URLs dos segmentos de vídeo. Clappr⁵, um *player* de vídeo de código aberto criado pelo time da Globo.com, foi o *player* utilizado nas copas do mundo de 2014 e 2018. Ele é responsável por considerar fatores como taxa de ocupação do *buffer*, qualidade da rede e tamanho do dispositivo para escolher qual qualidade do vídeo deverá ser requisitada ao servidor.

⁵ <https://github.com/clappr/clappr>

3 TRABALHOS RELACIONADOS

Existem vários trabalhos que avaliam o desempenho de serviços de *streaming* de vídeo [Costa et al. 2004, Vieira et al. 2013, Borges et al. 2012] e auxiliam na tomada de decisão durante mudanças na infraestrutura de transmissão desses serviços. Trabalhos como os de [Hands e Wilkins 1999, Mok, Chan e Chang 2011] avaliaram métricas de serviço (QoS) da rede do usuário (por exemplo, *jitter* e perda de pacotes) e os impactos causados na qualidade de vídeo e experiência percebida pelos usuários. No entanto, embora essas métricas de QoS ajudem a identificar problemas na transmissão, elas não refletem fielmente a qualidade de experiência do usuário (QoE) em um dado momento. Por exemplo, uma oscilação na rede pode aumentar a perda de pacotes, mas o usuário não será afetado por queda de qualidade caso o *buffer* possua vídeo suficiente para ser reproduzido durante o momento de instabilidade da rede. Por conta disso, a maior parte dos trabalhos atuais avaliam QoE utilizando dados históricos de transmissões anteriores, impulsionados também pelo custo cada vez menor de armazenamento.

Até onde sabemos, [Dobrian et al. 2011] é o primeiro trabalho dessa natureza que ganhou bastante notoriedade. Eles analisaram um conjunto de dados com informações sobre a reprodução de vídeos sob-demanda e ao vivo. Essas informações foram coletadas por instrumentação no cliente. Nesse trabalho os autores definiram algumas métricas de QoE e avaliaram como cada uma delas interfere no engajamento, além de mostrarem a magnitude da correlação entre essas métricas e o engajamento. Para contornar limitações da avaliação de correlação realizada, os autores fizeram uso da noção de ganho de informação (*Information Gain*) para quantificar o quanto cada métrica impacta no engajamento. Eles notaram que embora o *bitrate* médio possua correlação baixa com o engajamento, o ganho de informação é não trivial. Isso ocorreu pois o relacionamento do *bitrate* médio com o engajamento é não monotônico. Nós também identificamos esse relacionamento não monotônico em nosso trabalho. Já [Krishnan e Sitaraman 2013] foram além e avaliaram o relacionamento causal entre métricas de QoE e o engajamento. Nesse trabalho os autores mostraram a magnitude do impacto de vários fatores no QoE, como *start-up delay*, pausas na reprodução e qualidade da conexão do usuário. [Guarnieri et al. 2017] também avaliaram o impacto de métricas de QoE no engajamento, mas utilizaram um conjunto de dados de um evento ao vivo ao invés de eventos vídeo sob demanda, a copa do mundo da FIFA de 2014. Além disso, avaliaram separadamente o engajamento de usuários utilizando computadores pessoais e dispositivos móveis. Nesse trabalho utilizamos o mesmo conjunto de dados (copa de 2014), juntamente com os dados do torneio de 2018 para realizar um estudo sobre a evolução do engajamento dos usuários desse evento.

[Balachandran et al. 2013] utilizaram métricas semelhantes a [Dobrian et al. 2011] e incluíram alguns fatores como tipo de vídeo, dispositivo utilizado e conectividade para criar um modelo de predição de QoE baseado em árvore de decisão que pode ser

utilizado para aumentar o engajamento de clientes ao escolher melhores parâmetros de configuração da transmissão, como *bitrate* e CDN, quando uma nova sessão é iniciada. Em suma, conseguiram mostrar que uma infraestrutura de transmissão que utiliza o modelo proposto pode aumentar o engajamento em mais de 20% se comparado com outras abordagens. Nessa mesma linha, [Guarnieri et al. 2018] propuseram um modelo de previsão de engajamento em tempo real que utiliza (i) regressão para prever o tempo de permanência de um cliente no sistema e (ii) árvore de decisão para prever se o usuário continuará assistindo à transmissão nos próximos n minutos. Esse modelo teve até 81% de acurácia na etapa de previsão e se mostrou eficaz para aplicação em dados diferentes, com acurácia de quase 70%.

[Ahmed et al. 2017] abordaram o problema de predição de outra maneira ao utilizar um procedimento matemático chamado de análise de componentes principais para detectar prejuízos na qualidade de experiência do usuário em tempo real para vídeos ao vivo. Além disso, os autores avaliaram a magnitude do relacionamento causal entre métricas de QoE e o engajamento. Para isso, utilizaram *logs* de acesso da transmissão ao vivo do Oscar de uma grande CDN.

A maneira mais precisa de capturar métricas relacionadas à QoE é através do monitoramento do *player* do cliente, mas esses dados só estão disponíveis para análise pelo provedor de serviço ou CDNs. Para construir um *dataset* independente [Nam, Kim e Schulzrinne 2016] criaram um *plugin*¹ para o Google Chrome. Ao instalá-lo o usuário passa a contribuir para o *dataset* dos autores com as estatísticas de uso do Youtube. Eles definiram uma nova métrica para tentar avaliar o impacto de adaptações na taxa de abandono e avaliaram sua eficácia. Nessa mesma linha, [Robitza et al. 2020] desenvolveram uma extensão chamada *YTCrowdMon* tanto para o Google Chrome, quanto para o Mozilla Firefox para capturar o comportamento do usuário e a QoE dos clientes da Netflix, Amazon Prime e Youtube. Nesse trabalho os autores compararam como usuários desses diferentes serviços interagem com o sistema e como questões como provedor de serviço, conectividade e dispositivo afetam o comportamento.

Em nossa análise nós complementamos esses trabalhos ao realizar uma avaliação detalhada tanto do impacto nos servidores quanto do comportamento dos clientes ao avaliar os *logs* do servidor de dois eventos ao vivo em larga escala. Além disso, fazemos um estudo comparativo da evolução ocorrida em um intervalo de quatro anos para um mesmo tipo de vídeo e conteúdo.

¹ <http://dyswis.cs.columbia.edu/youslow/>

4 METODOLOGIA

O conjunto de dados (*dataset*) utilizado nesse trabalho é originado das transmissões dos jogos da Copa do Mundo da FIFA de 2014 e 2018, realizadas por um grande provedor de conteúdo do Brasil. Os eventos ocorreram entre 12 de Junho e 13 de Julho em 2014 e entre 14 de Junho e 15 de Julho em 2018.

Esses dados (*logs*) consistem em respostas às requisições HTTP feitas pelo *player* de vídeo contido no navegador do cliente. Cada registro possui informação como endereço IP do cliente, código do estado da resposta, *user agent*, horário, URL e número de *bytes* transmitidos. Os *logs* não possuem identificador de sessão ou identificador do usuário dono da sessão. Por conta disso, para identificar unicamente um usuário foi considerado o endereço IP juntamente com o *user agent*. O endereço IP por si só é menos eficiente do que a abordagem escolhida já que a existência de NAT (*Network Address Translation*) causaria o efeito colateral de considerar requisições de múltiplas sessões como sendo de uma mesma sessão. Ao considerar também o *user agent* foi possível diminuir esse tipo de erro pois dessa forma só há problema quando os usuários por trás de NAT utilizam a mesma versão do navegador. Essa abordagem se mostrou eficaz pois, ao avaliar o número de requisições duplicadas para o mesmo segmento de vídeo, foi constatado que isso acontece em menos de 5% das sessões. Como esse número é baixo, não eliminamos essas sessões antes de executar nossas análises.

As sessões dos usuários foram reconstruídas com base nas informações contidas nesses *logs* para que a maior parte das análises presentes nesse trabalho fossem realizadas. Reconstruir sessões utilizando registros de acesso exige cuidado para que a sessão reflita o que ocorreu de fato. Uma decisão a se tomar nesse sentido é em relação a como decidir que uma requisição pertence à mesma sessão ou a uma nova sessão. Nesse sentido, foram avaliados diferentes valores para o tempo entre requisições, entre 30 e 180 segundos, para definir qual o valor mais adequado a ser considerado como intervalo para considerar que uma requisição não pertence mais a uma mesma sessão. Os resultados obtidos foram similares para todos os valores avaliados e, por isso, foi escolhido um valor de 180 segundos.

Uma métrica bastante importante para avaliar qualidade de experiência do usuário de serviços de *streaming* é a quantidade de interrupções durante a transmissão, que ocorre quando o *buffer* do *player* esvazia e a reprodução do vídeo é interrompida. Nesse trabalho, para identificar as interrupções durante uma sessão, simulamos o comportamento do *buffer* a cada requisição feita pelo usuário, considerando o *buffer* como capaz de suportar 12 segundos de vídeo. Optamos por esse valor pois notamos que, em geral, eram feitas quatro requisições ao mesmo tempo no início da sessão e, após isso, as requisições eram feitas em um intervalo igual ao tamanho do segmento de vídeo. O tamanho dos segmentos de vídeo em *streaming* adaptativo é configurável e variou no *dataset* estudado, sendo 3 segundos de

vídeo por segmento no torneio de 2014 e 4 segundos em 2018. Um fator interessante a se notar é que um tamanho de segmento maior causa aumento na latência, sendo assim é aceitável pensar que esse valor não deveria ter aumentado para manter o mínimo de atraso possível na transmissão. No entanto, uma simples mudança como essa exige maior consumo de CPU nos servidores, por exemplo, se formos considerar apenas as requisições feitas por um usuário para os segmentos de vídeo, um segmento de 4 segundos exige que o servidor lide com 15 requisições por minuto, enquanto que um segmento de 3 segundos gera 20 requisições em um minuto, um aumento de cerca de 33%.

Outras métricas importantes que foram consideradas são o *bitrate* médio das sessões e a quantidade de mudanças de qualidade em uma sessão. O *bitrate* médio foi calculado com base no tamanho de bytes de cada requisição de segmento de vídeo. A quantidade de mudanças de qualidade foi calculada utilizando o valor de *bitrate* de cada segmento que foi extraído da URI da requisição feita ao servidor.

Alguns dados presentes nesse trabalho foram separados levando em conta o provedor de acesso à internet (ISP) do usuário final, que foi identificado a partir da tradução de endereço IP para ISP utilizando a biblioteca PyISP¹. Houve também uma separação considerando a origem da transmissão que variou entre Rio de Janeiro e São Paulo, essa distinção foi fácil identificar pois constava no nome dos arquivos onde os *logs* estavam contidos.

¹ <https://github.com/ActivisionGameScience/pyisp>

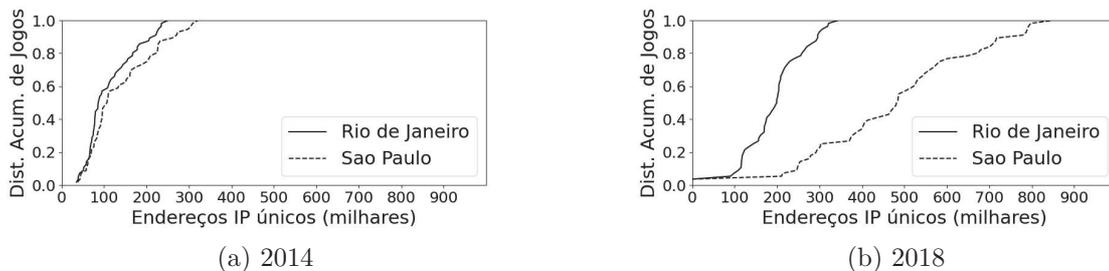
5 CARACTERIZAÇÃO

Esse capítulo apresenta caracterizações geradas a partir do conjunto de dados estudado com o principal objetivo sendo avaliar melhor o impacto das transmissões nos servidores. Em primeiro lugar, o volume de acesso durante as transmissões é mostrado na Seção 5.1. Na seção 5.2 é mostrada a quantidade de clientes durante as transmissões levando em conta o aspecto temporal. A seção 5.3 avalia a taxa de chegada de usuários, também levando em conta o aspecto temporal. Em seguida, na seção 5.4, comparamos o tráfego gerado levando em consideração, além do aspecto temporal, a localização do servidor onde a carga foi imposta. Por fim, a seção 5.5 trás a qualidade média do vídeo considerando as sessões agrupadas de acordo com o provedor de Internet utilizado.

5.1 VOLUME DE ACESSO

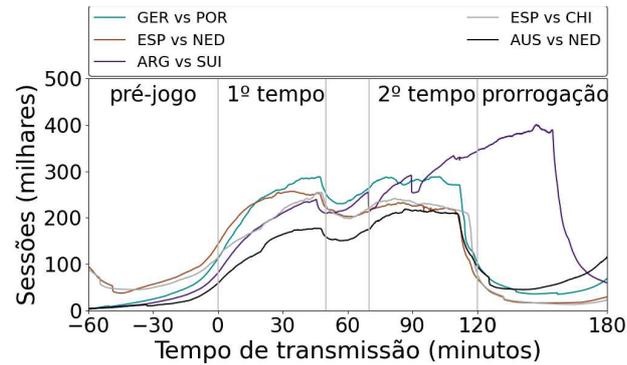
Para iniciar a caracterização desse trabalho, foi contabilizado a quantidade de endereços IP observados em cada partida transmitida, levando em conta o *data center* responsável pela distribuição do conteúdo. As Figuras 6a e 6b mostram a função de distribuição acumulada (CDF) para os endereços IP únicos de todos os jogos das Copas do Mundo de 2014 e 2018, agrupados por servidor de transmissão. Podemos ver que no primeiro torneio os usuários eram distribuídos quase que igualmente entre São Paulo e Rio de Janeiro, enquanto que no torneio mais recente os servidores de São Paulo foram responsáveis pela maior parte da transmissão. O jogo com maior número de endereços IP únicos em 2014 teve 555.931 endereços IP. Em 2018, o período mais popular foi durante a transmissão de dois jogos que ocorreram no mesmo momento com cerca de 1.195.315 endereços IP únicos participando da transmissão em algum momento da partida, um acréscimo de 115% quando comparado com a maior audiência de 2014.

Figura 5 – Função de distribuição acumulada do número de endereços IP únicos considerando todos os jogos dos torneios de 2014 e 2018 separados por servidor

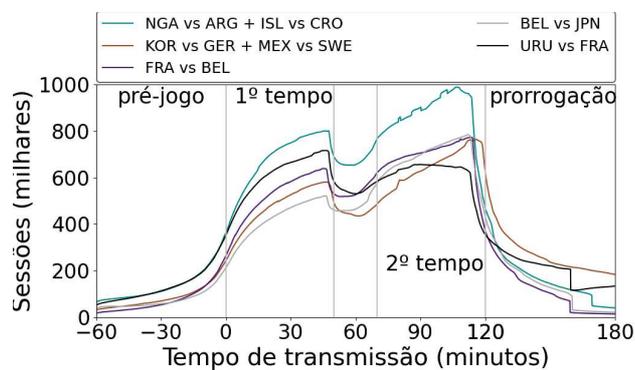


Fonte: Elaborado pelo autor. (2020).

Figura 6 – Sessões ao longo do tempo para os 5 jogos com maior número de clientes



(a) 2014



(b) 2018

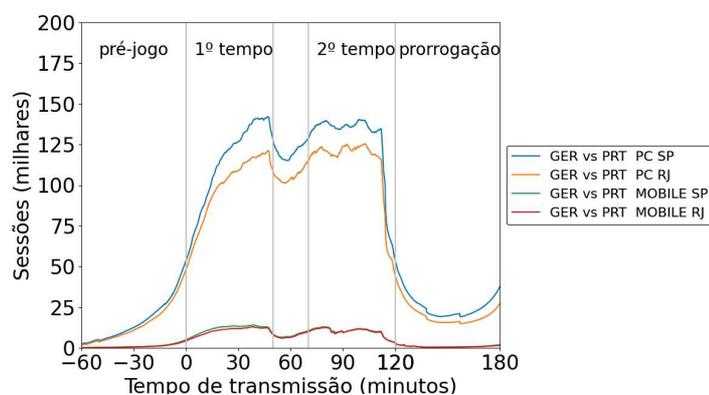
Fonte: Elaborado pelo autor. (2020).

5.2 QUANTIDADE DE SESSÕES

Além de saber a quantidade de clientes atendidos em uma transmissão, também é importante entender como esses clientes estão distribuídos ao longo do tempo da transmissão, pois essa questão é importante para dimensionamento da infraestrutura.

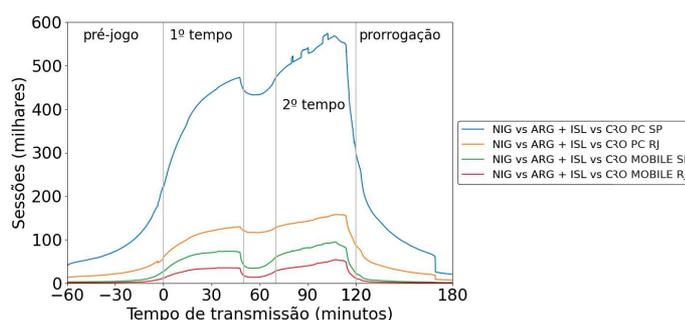
As Figuras 7a e 7b mostram a quantidade de sessões ao longo do jogo para os 5 jogos com maior número de clientes para os torneios de 2014 e 2018, respectivamente. Decidimos escolher essa abordagem para escolher os jogos mais representativos em relação à carga imposta nos servidores. Nos gráficos são indicados com linhas verticais e rótulos os seguintes períodos: *pré-jogo*: 1 hora antes do início da partida, *1º tempo*: 45 minutos, 15 minutos de intervalo, *2º tempo*: 45 minutos e 1 hora após o jogo que pode ter 30 minutos de tempo extra dependendo da partida. Todos os jogos seguem o mesmo padrão: um aumento das sessões no começo do 1º tempo e abandono no final do 2º tempo, com um declive no final do 1º tempo. Apenas uma dessas partidas possuem prorrogação, sendo a partida entre Argentina e Suíça. Em 2018, algumas das transmissões que atraíram maior número de clientes possuíam dois jogos no mesmo horário e não era possível distinguir o tráfego relativo a cada jogo, por conta disso eles foram analisados em conjunto.

Figura 7 – Número de sessões para o jogo Alemanha x Portugal (2014) separado por servidor e dispositivo



Fonte: Elaborado pelo autor. (2020).

Figura 8 – Número de sessões para o jogo Nigéria x Argentina + Islândia x Croácia (2018) separado por servidor e dispositivo



Fonte: Elaborado pelo autor. (2020).

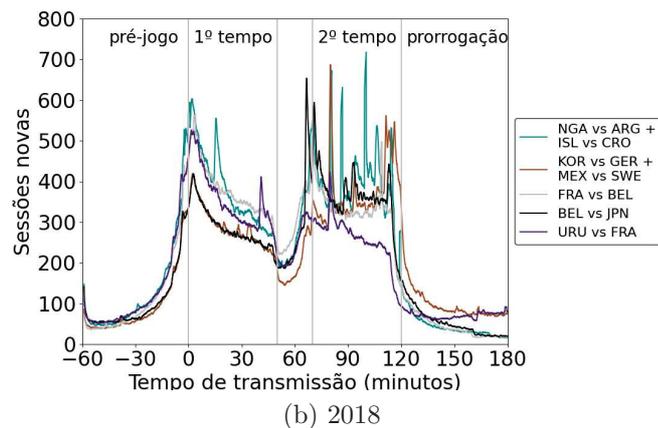
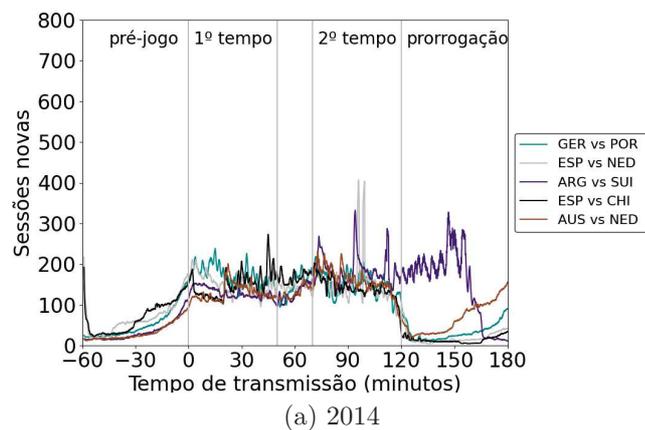
Vários fatores influenciam o nível de interesse do expectador durante um jogo, como o placar da partida, horário e seleções envolvidas. A Figura 7a mostra que o maior número de sessões ativas no torneio de 2014 ocorreu durante a prorrogação da partida entre Alemanha e Portugal. Com mais de 400.000 sessões, esse jogo permaneceu sem gols até 27 minutos do segundo tempo da prorrogação. Na Figura 7b nota-se que o número de sessões aumentou significativamente, alcançando mais de 1 milhão de sessões nos jogos entre Nigéria vs Argentina e Islândia vs Croácia.

Já as Figuras 7 e 8 mostram como as sessões de um jogo se distribuem dependendo do servidor de transmissão e do dispositivo utilizado. Utilizamos os jogos com maior número de clientes como forma de exemplificação. Os gráficos para os demais jogos podem ser encontrados no apêndice A. Percebe-se que o número de sessões no servidor de São Paulo e do Rio de Janeiro se assemelham em 2014, enquanto que em 2018 é bastante diferente, onde o servidor de São Paulo é responsável pela maior parte da transmissão.

5.3 TAXA DE CHEGADA DE NOVAS SESSÕES

A Figura 9 mostra a taxa de chegada de usuários usando uma janela deslizante de 60 segundos. Nessa figura, é possível notar que, na maioria dos casos, os picos ocorrem no início dos tempos do jogo e no fim da partida nos jogos do torneio de 2018, enquanto que em 2014 parece constante. O pico inicial é esperado por ser um evento ao vivo e programado, então os usuários acessam o serviço no início do evento. Com isso, a taxa de chegada apresenta um comportamento em rajadas [Sripanidkulchai, Maggs e Zhang 2004]. Picos no final do jogo talvez ocorram devido a curiosidade e interesse em saber o placar final e como ele influenciará no restante do torneio. Mais importante, no entanto, é o fato de que sessões começam e terminam de maneira mais concentrada no início e final da partida no torneio de 2018 em relação a 2014.

Figura 9 – Número de sessões novas para os cinco jogos mais assistidos

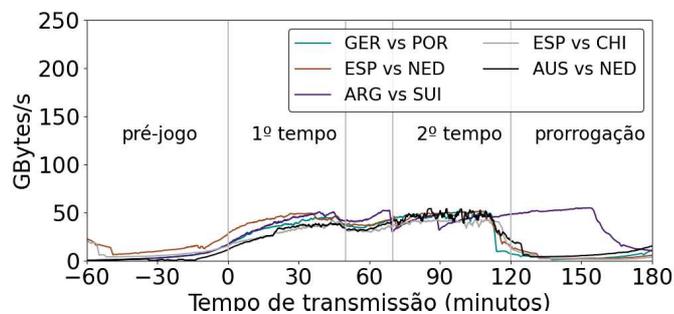


Fonte: Elaborado pelo autor. (2020).

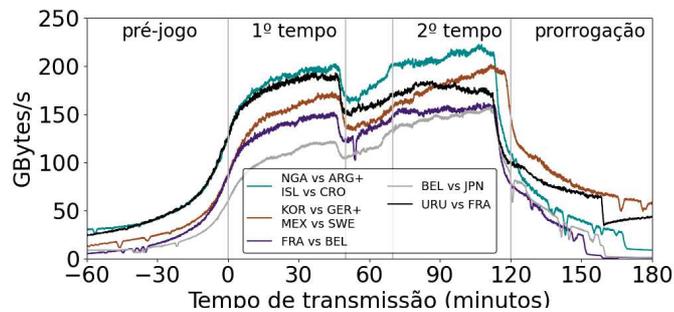
5.4 TRÁFEGO GERADO

A Figura 10 apresenta o tráfego de rede que a transmissão ao vivo impôs no provedor de conteúdo. Ela mostra a média de volume de tráfego por segundo, computada utilizando uma janela deslizante de 60 segundos para suavizar a curva e facilitar a visualização do gráfico. O crescimento no número de usuários mostrado anteriormente é acompanhado de um aumento significativo na demanda de rede. De fato, ela se comporta de maneira similar à Figura 6 e indica um aumento de mais de 300% em 2018, se comparado com 2014, com pico de mais de 200GB/s. Mais ainda, note que, enquanto o tráfego cresceu mais de 300%, o número médio de endereços IP únicos cresceu menos de 200%. Esse comportamento demonstra que usuários receberam qualidade de vídeo superior no torneio de 2018.

Figura 10 – Tráfego ao longo do tempo para ambos os servidores de transmissão



(a) 2014



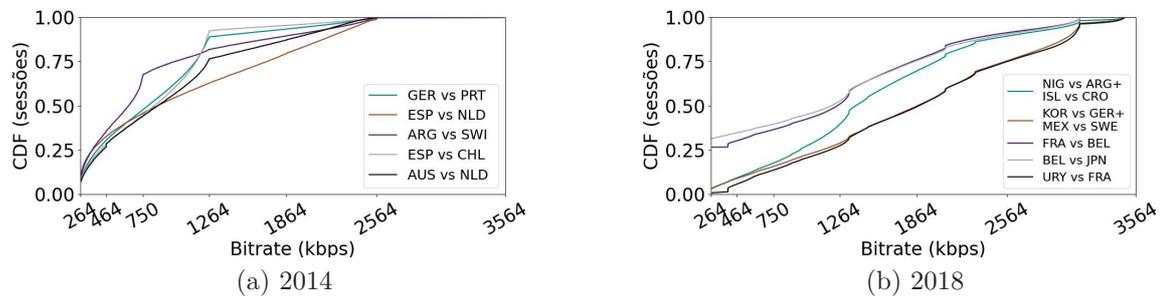
(b) 2018

Fonte: Elaborado pelo autor. (2020).

5.5 QUALIDADE MÉDIA DAS SESSÕES

Toda requisição possui em sua URI um valor que representa o *bitrate* do segmento requisitado. Levando em conta esse valor de todos os segmentos transferidos em uma sessão, foi calculado o *bitrate* médio. Com isso, foi considerado o *bitrate* médio como a qualidade média da transmissão de um usuário. As Figuras 12a e 12b mostram a CDF do *bitrate* médio das sessões de computador dos 5 jogos com maior número de clientes para ambos os torneios. É possível notar que tanto o *bitrate* médio aumentou significativamente quanto o

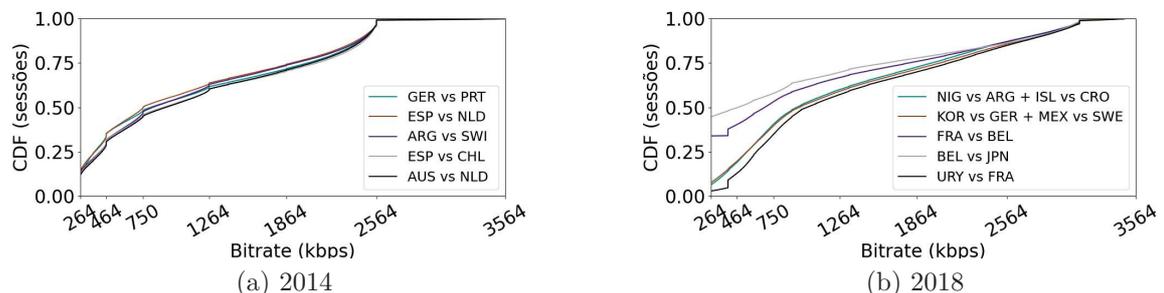
Figura 11 – Função de distribuição acumulada do *bitrate* médio para os cinco jogos mais assistidos em PC



Fonte: Elaborado pelo autor. (2020).

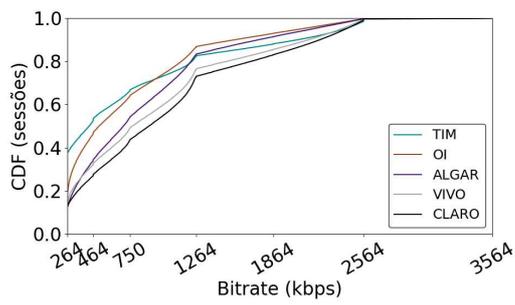
bitrate máximo subiu de 2564 para 3475kbps. Nas Figuras 13a e 13b são mostrados os mesmos gráficos, mas agora para as sessões de dispositivos móveis. Note que a qualidade das sessões de PC em 2014 é bastante inferior se comparada com a qualidade das sessões de dispositivos móveis do mesmo ano, isso ocorreu porque houve limitação de qualidade para usuários de PC por parte do provedor de conteúdo. Por fim, nas Figuras 14a e 14b, foram avaliadas as qualidades das sessões levando em consideração os provedores de acesso à Internet (ISP) utilizados pelos clientes, aqui não houve distinção em relação ao dispositivo utilizado para acesso à transmissão. A qualidade média aumentou significativamente para todos os provedores, sem distinção, com destaque para a ALGAR que possui maior qualidade no torneio mais recente.

Figura 12 – Função de distribuição acumulada do *bitrate* médio para os cinco jogos mais assistidos em dispositivos móveis

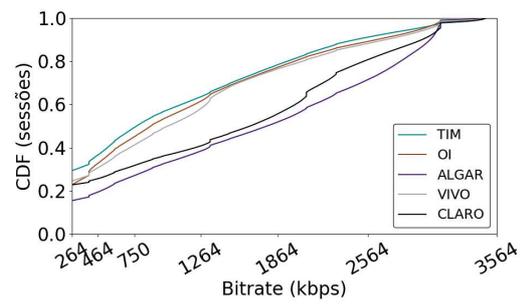


Fonte: Elaborado pelo autor. (2020).

Figura 13 – Função de distribuição acumulada do *bitrate* médio para os cinco jogos mais assistidos por provedor de acesso



(a) 2014



(b) 2018

Fonte: Elaborado pelo autor. (2020).

6 COMPORTAMENTO DOS USUÁRIOS

Nesse Capítulo é apresentado um modelo de comportamento do usuário que captura as interações que um cliente tem ao assistir à transmissão. Com base nesse modelo, foram avaliados os tempos de duração das sessões existentes, definido como tempo de ON, e também o tempo entre sessões, no caso em que o usuário possua mais de uma sessão, chamado de tempo de OFF. Por fim, foram avaliadas diversas distribuições estatísticas para verificar qual delas representa melhor os dados reais e quais são os seus parâmetros.

6.1 MODELO DE COMPORTAMENTO DO USUÁRIO

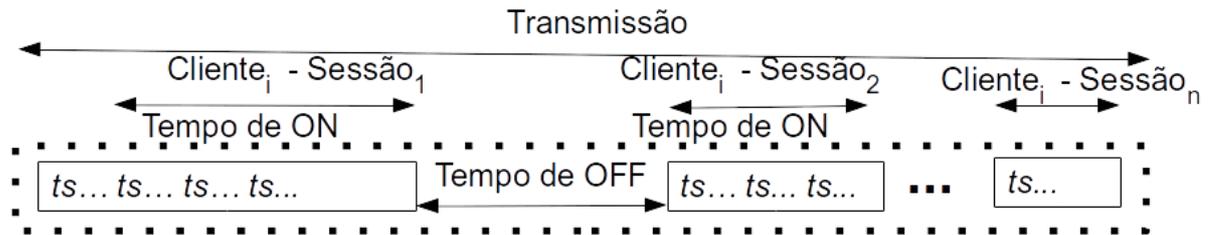
Um modelo de comportamento do usuário permite avaliar como um usuário interage com o sistema. Esse modelo deve refletir o que ocorre na realidade, caso contrário não é possível utilizá-lo para melhorar a infraestrutura de transmissão existente. Diferentemente de um sistema de transmissão de vídeo sob-demanda, onde um usuário tem a flexibilidade de pular o conteúdo do vídeo para qualquer momento, em um sistema de transmissão ao vivo essa flexibilidade não existe. Sendo assim, o cliente possui as seguintes opções durante a transmissão: (i) reproduzir o vídeo, (ii) pausar o vídeo ou (iii) abandonar a transmissão. Nesse caso, o vídeo ao vivo ao ser pausado não continuará de onde parou.

A Figura 14 representa o modelo de interação de um determinado cliente i com o sistema estudado. Durante uma sessão, o cliente recebe diversos segmentos de vídeo contendo entre 3 e 5 segundos de vídeo cada, com extensão *.ts*, como indicado nessa figura. Em geral, o tempo entre requisições desses segmentos é igual ao tamanho do segmento, mas pode variar por várias questões, como oscilações na rede ou abandono do usuário. Se o tempo entre requisições de segmentos de vídeo for maior que 180 segundos, é considerado que o determinado segmento pertence a uma nova sessão. O tempo total decorrido entre a chegada do primeiro segmento de uma sessão de um usuário e o último segmento de sua sessão anterior é chamado de tempo de OFF, ou tempo entre sessões. Já a duração de uma sessão é definida como tempo de ON. Desse modo, apenas usuários com duas ou mais sessões possuem tempos de OFF.

6.2 RESULTADOS

Modelar o comportamento dos usuários através dos seus tempos de ON e OFF é uma prática comum e aqui o modelo foi estendido para avaliar também as adaptações de *bitrate* que ocorrem dentro de uma mesma sessão. A Figura 15 apresenta uma visão parcial do modelo construído em [Guarnieri et al. A ser publicado] a partir do conjunto de dados do torneio de 2018 onde as arestas com probabilidade de transição menor que 2% foram removidas para melhorar a visualização. Note que os sete estados representam as sete qualidade disponíveis na transmissão. Note também que, para cada vértice, a soma

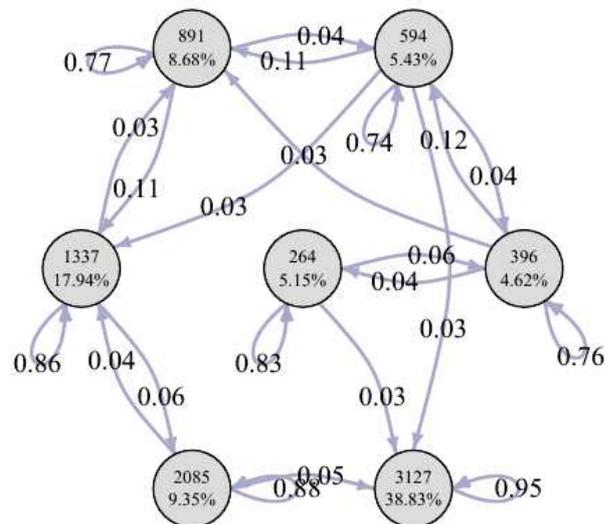
Figura 14 – Modelo de comportamento do usuário.



Fonte: Elaborado por [Santos et al. 2016].

das probabilidades das transições de saída (incluindo as omitidas) deve ser igual a 1. A figura também mostra em cada vértice que a probabilidade de um cliente permanecer em determinado *bitrate*. Podemos ver que em relação a permanência em determinado *bitrate*, essa figura mostra que a probabilidade de manter a mesma qualidade ao receber segmentos de 1337 kbps e 3127 kbps são por volta de 18% e 39%, respectivamente, um valor muito maior do que para os demais *bitrates*. Em outras palavras, os clientes tendem a permanecer por períodos maiores para esses *bitrates*.

Figura 15 – Modelando o comportamento do usuário: camada do segmento de vídeo.



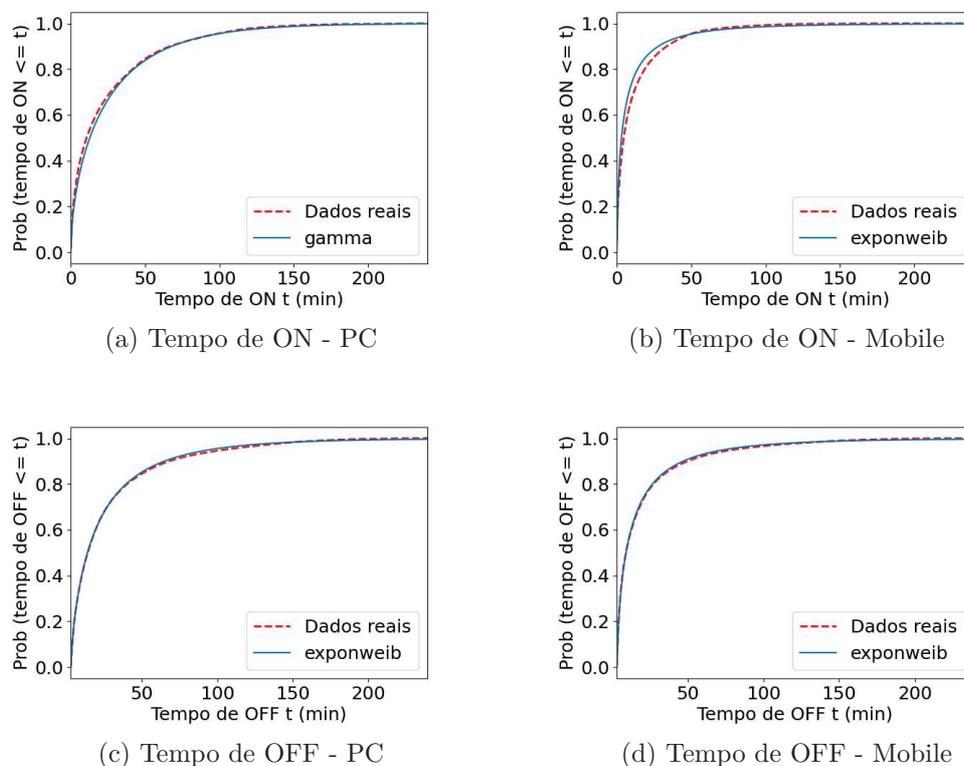
Fonte: Elaborado por [Guarnieri et al. A ser publicado].

Utilizando o modelo mostrado na Figura 14 foram calculados os tempos de ON e OFF dos 10 jogos com maior número de endereços IP únicos de ambos os torneios. Nessa análise, escolhemos mais jogos do que anteriormente para melhorar o resultado final do modelo. Esses valores foram utilizados para avaliar qual distribuição estatística mais se assemelha aos dados empíricos e quais são os seus parâmetros. Foram avaliadas

as distribuições mais comumente utilizadas na literatura como Normal, Log-Normal, Exponencial, Gamma, Logística, Beta, Uniforme, Weibull e Weibull Exponencial. Nós utilizamos o teste de Kolmogorov-Smirnov (KS) para avaliar a diferença entre a curva originada dos dados empíricos e a curva dos dados gerados e escolhemos a distribuição que apresentava o menor valor, desde que a probabilidade de significância (valor-p) fosse maior que 0.05, com exceção da distribuição Gamma dos dispositivos móveis em 2018 que o valor-p não satisfaz o esperado e, portanto, não podemos afirmar que ela representa fielmente os dados reais. As curvas geradas foram avaliadas de maneira visual para identificar quais delas representavam melhor a realidade e estão indicadas na Tabela 1.

As Figuras 16 e 17 mostram as funções de distribuição acumulada dos tempos de ON e OFF a as distribuições que melhor se ajustam aos dados. Enquanto que para o tempo de OFF a distribuição Exponencial Weibull se manteve como a curva mais apropriada para dispositivos móveis e computadores para ambos os torneios, as distribuições mudaram para o tempo de ON. Em 2014, as distribuições Gamma e Weibull Exponencial representavam melhor os dados para PC e dispositivos móveis, respectivamente. Já em 2018, para computadores pessoais a Beta foi a melhor distribuição e para dispositivos móveis foi a Gamma.

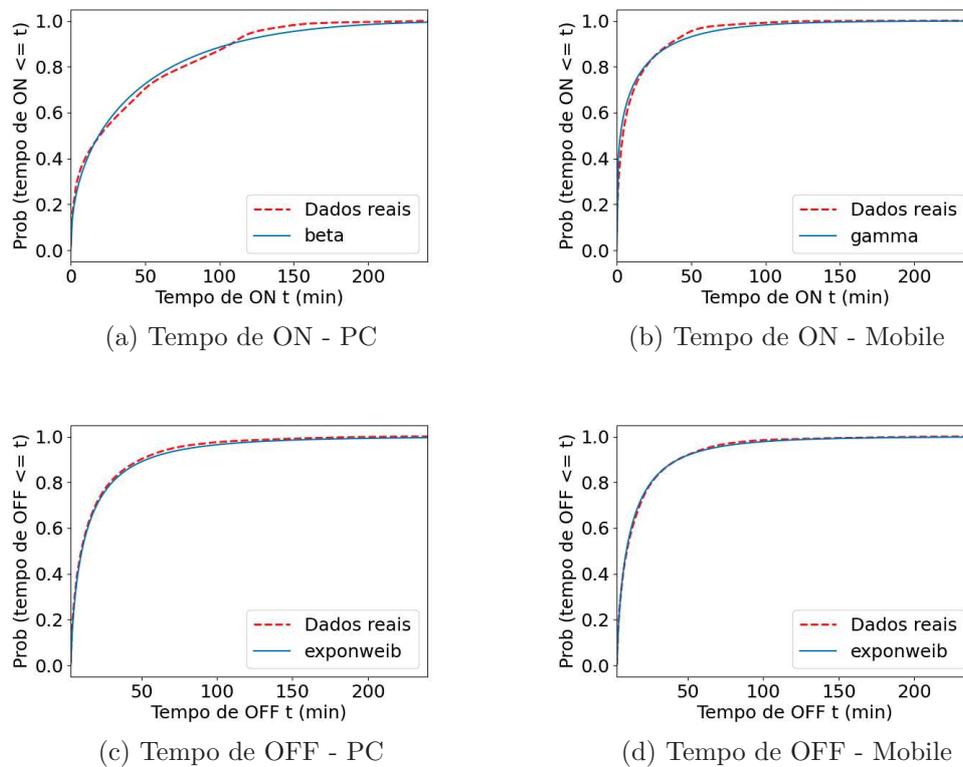
Figura 16 – Modelando tempo de ON e OFF dos usuários - 2014



Fonte: Elaborado pelo autor. (2020).

Por fim, a Figura 18 exibe a função massa de probabilidade (PMF) do número de

Figura 17 – Modelando tempo de ON e OFF dos usuários - 2018



Fonte: Elaborado pelo autor. (2020).

Tabela 1 – Parâmetros dos *fittings* para os tempos de ON e OFF dos os dez jogos mais acessados em cada torneio.

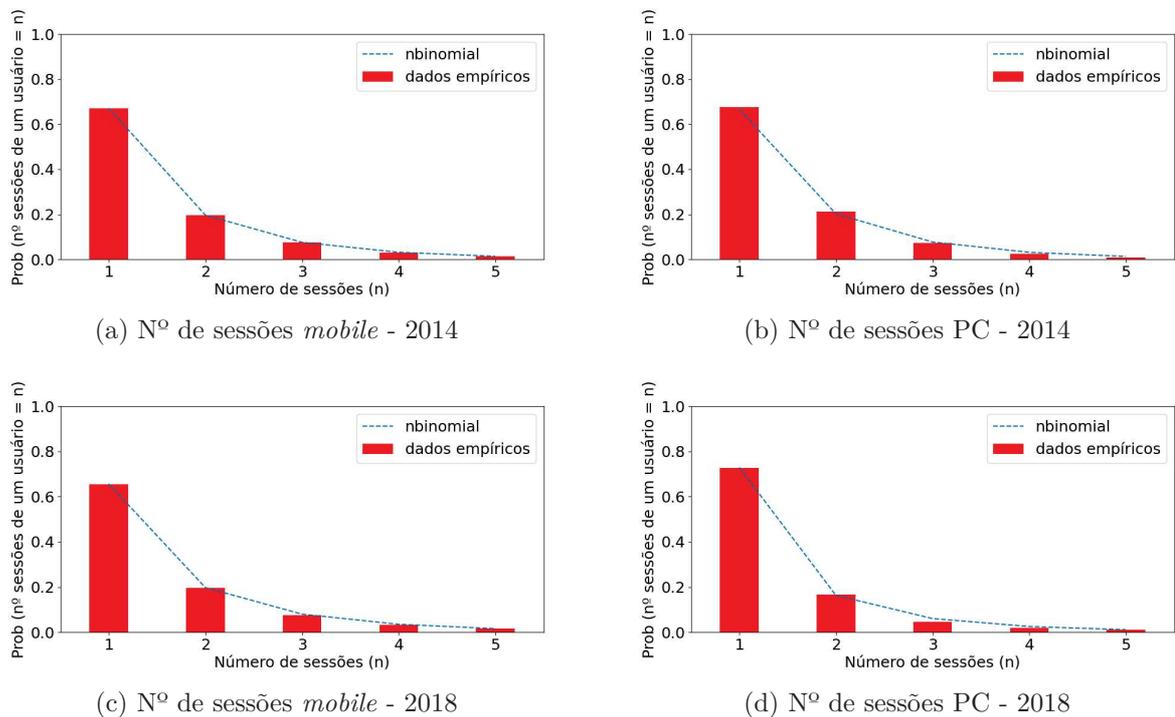
	Ano	Dispositivo	Melhor <i>fitting</i>	1º		Loc	Escala	Kolm. Smir.	Valor-p
				parâmetro	parâmetro				
ON	2014	PC	Gamma	0.5570	-	0	46.1025	0.07	0.1725
ON	2014	Mobile	Exp Weibull	2.0113	0.4010	0	1.8363	0.095	0.328
ON	2018	PC	Beta	0.46226	4.4607	0	414.088	0.075	0.628
ON	2018	Mobile	Gamma	0.25644	-	0	49.6934	0.19	0.001
OFF	2014	PC	Exp Weibull	1.2857	0.6181	3	13.676	0.034	0.1979
OFF	2014	Mobile	Exp Weibull	1.9699	0.4488	3	3.9168	0.0415	0.063
OFF	2018	PC	Exp Weibull	1.9519	0.4638	3	4.8996	0.08	0.908
OFF	2018	Mobile	Exp Weibull	1.8533	0.4874	3	4.5979	0.0185	0.883

Fonte: Elaborado pelo autor. (2020).

sessões que um usuário possui durante a transmissão de um jogo. A figura mostra também que a distribuição estatística que representa melhor os dados empíricos é a binomial negativa para todos os cenários avaliados. Pode-se perceber que a maior parte dos usuários (mais de 65%) possui apenas uma sessão durante a transmissão tanto para os clientes de dispositivos móveis quanto para usuários de computador, independente do torneio avaliado. Um fato interessante é que a porcentagem de clientes de computadores pessoais no torneio de 2018 que têm apenas uma sessão aumentou significativamente se comparado aos demais cenários, com quase 73% dos usuários possuindo apenas uma sessão, contra cerca de 66%

nos demais cenários. Uma possível explicação para esse acontecimento é o fato de clientes de computadores possuírem maior poder computacional atualmente, o que pode levar esses clientes a deixar a transmissão em segundo plano mesmo com menor interesse já que isso não afetará tanto a usabilidade do dispositivo para outros fins como anteriormente. A Tabela 2 mostra com detalhes as informações representadas na Figura 18 com informações dos parâmetros da distribuição binomial negativa em cada cenário e da função massa de probabilidade.

Figura 18 – Modelando o número de sessões dos usuários



Fonte: Elaborado pelo autor. (2020).

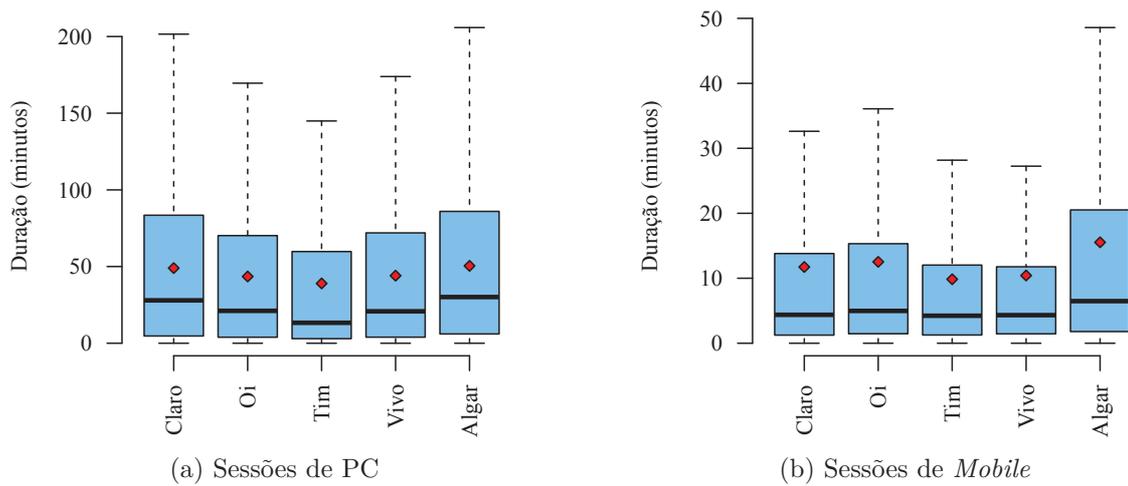
Tabela 2 – Parâmetros dos *fittings* do número de sessões por usuário dos os dez jogos mais acessados em cada torneio. Essa tabela também mostra a porcentagem de clientes que possuem uma, duas ou mais sessões durante a transmissão.

Ano	Dispositivo	Melhor <i>fitting</i>	1 ^o parâmetro	2 ^o parâmetro	1 sessão	2 sessões	3+ sessões
2014	Mobile	Binomial Neg.	0.61	0.52	67.10%	19.64%	13.26%
2014	PC	Binomial Neg.	0.66	0.54	66.58%	20.21%	13.21%
2018	Mobile	Binomial Neg.	0.59	0.49	65.64%	19.75%	14.61%
2018	PC	Binomial Neg.	0.43	0.48	72.93%	16.30%	10.77%

Fonte: Elaborado pelo autor. (2020).

Por fim, avaliamos a duração das sessões dos clientes agrupadas pelo provedor de acesso à Internet utilizado na Figura 19. Vemos que em sessões de *desktop* os provedores Algar e Claro apresentam maior duração, chegando a até 100 minutos para cerca de 80% das sessões.

Figura 19 – Distribuição da duração de sessões por ISP. Fonte: Adaptado de [Guarnieri et al. A ser publicado]



Fonte: Elaborado pelo autor. (2020).

7 QUALIDADE DE EXPERIÊNCIA DO USUÁRIO

Nos últimos anos, o que se tem utilizado para medir qualidade em serviços de *streaming* pela Internet são fatores diretamente percebidos pelos usuários, conhecidos como métricas de qualidade de experiência do usuário (QoE). As seguintes métricas foram avaliadas nesse trabalho:

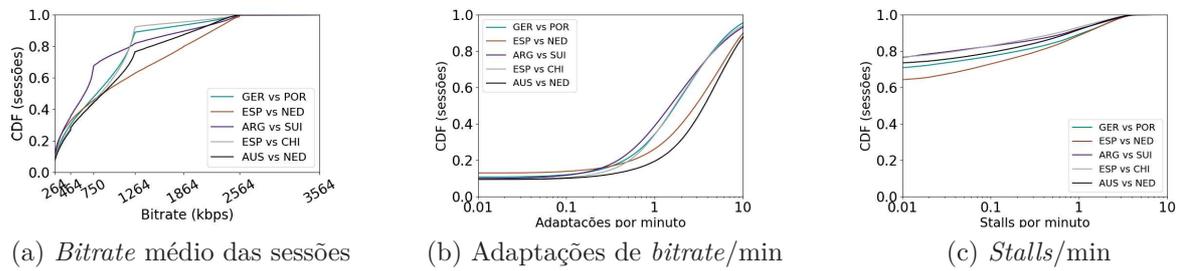
- Atraso na inicialização (*Start-up delay*): O tempo necessário para preencher o *buffer* localizado no navegador utilizado pelo cliente e a reprodução ser iniciada.
- Taxa de reprodução média ao longo de uma sessão (*bitrate* médio).
- Taxa de interrupções (taxa de *stalls*): Frequência de eventos de esvaziamento do *buffer* (e subsequente interrupção da reprodução) durante uma sessão.
- Taxa de adaptações: Frequência de eventos de adaptação da taxa de reprodução do vídeo durante uma sessão.

Vários trabalhos, como [Dobrian et al. 2011, Ahmed et al. 2017, Guarnieri et al. 2017], mostram que o *bitrate* médio, atraso na inicialização e *buffering ratio* são as métricas que mais impactam no engajamento do usuário. Nesse trabalho foi utilizada a duração da sessão como uma estimativa do engajamento. *Buffering ratio* é representada pela divisão do tempo total em que o vídeo ficou pausado aguardando o preenchimento do *buffer* pela duração da sessão. Nesse trabalho, a análise realizada não considera essa métrica porque os dados são provenientes dos *logs* do servidor o que dificulta reconstruir a sessão de tal forma que esses valores sejam fiéis ao que o cliente presenciou. Por conta disso, foi utilizada como alternativa a taxa de interrupções, ou taxa de *stalls*. É considerado que houve uma interrupção sempre que ocorre um esvaziamento do *buffer* e o comportamento do *buffer* é simulado com base em todas as requisições recebidas durante uma sessão. Essa metodologia foi escolhida pois há uma interdependência forte entre a taxa de interrupções e o *buffering ratio* [Ahmed et al. 2017].

O comportamento do usuário varia de acordo com o dispositivo utilizado [Balachandran et al. 2013, Guarnieri et al. 2017]. Por conta disso, as análises foram separadas de acordo com o dispositivo. Além disso, nessa seção foram descartadas sessões com duração menor que 20 segundos para eliminar os chamados *early quitters* [Balachandran et al. 2013]. Esses usuários podem sair por vários motivos, inclusive falta de interesse. Como o objetivo aqui não é avaliar o grau de interesse do usuário no conteúdo, e sim avaliar o impacto das métricas no engajamento, essas sessões não foram levadas em consideração.

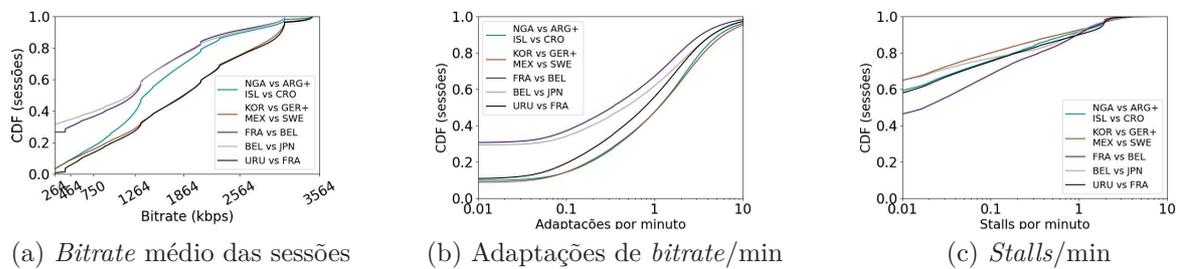
A copa do mundo de 2018 foi transmitida com qualidade de até 4K, no entanto nosso *dataset* contém qualidade de até 1080p (*FULL HD*), isto é, *bitrate* de até 3475 kbps (Figura 22a). Já o tráfego com qualidade 4K era servido por uma CDN externa contratada.

Figura 20 – Caracterização das métricas de QoE — 2014, PC



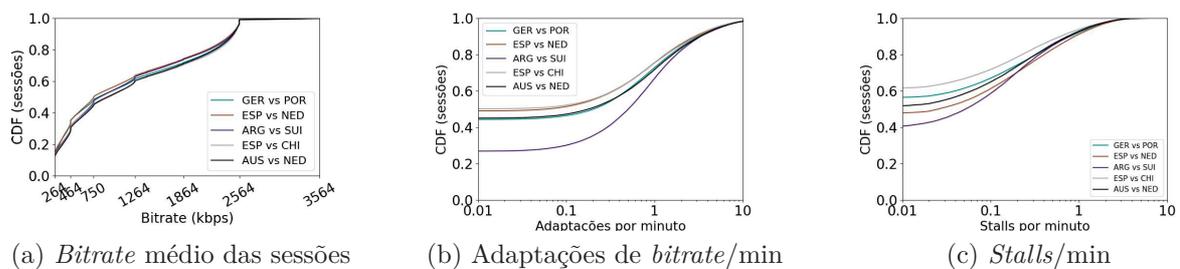
Fonte: Elaborado pelo autor. (2020).

Figura 21 – Caracterização das métricas de QoE — 2018, PC



Fonte: Elaborado pelo autor. (2020).

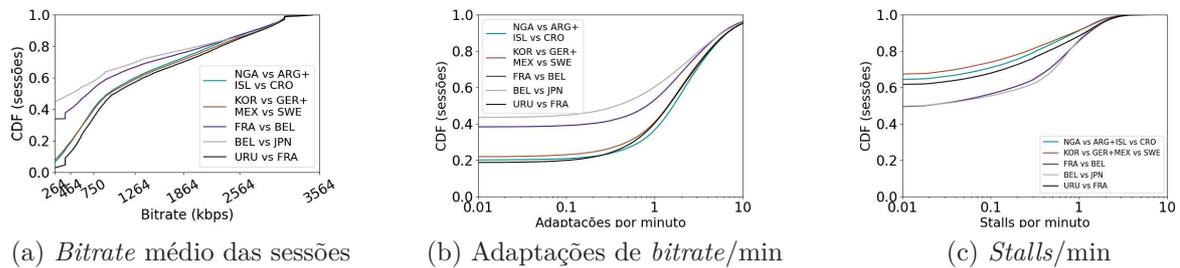
Figura 22 – Caracterização das métricas de QoE — 2014, Mobile



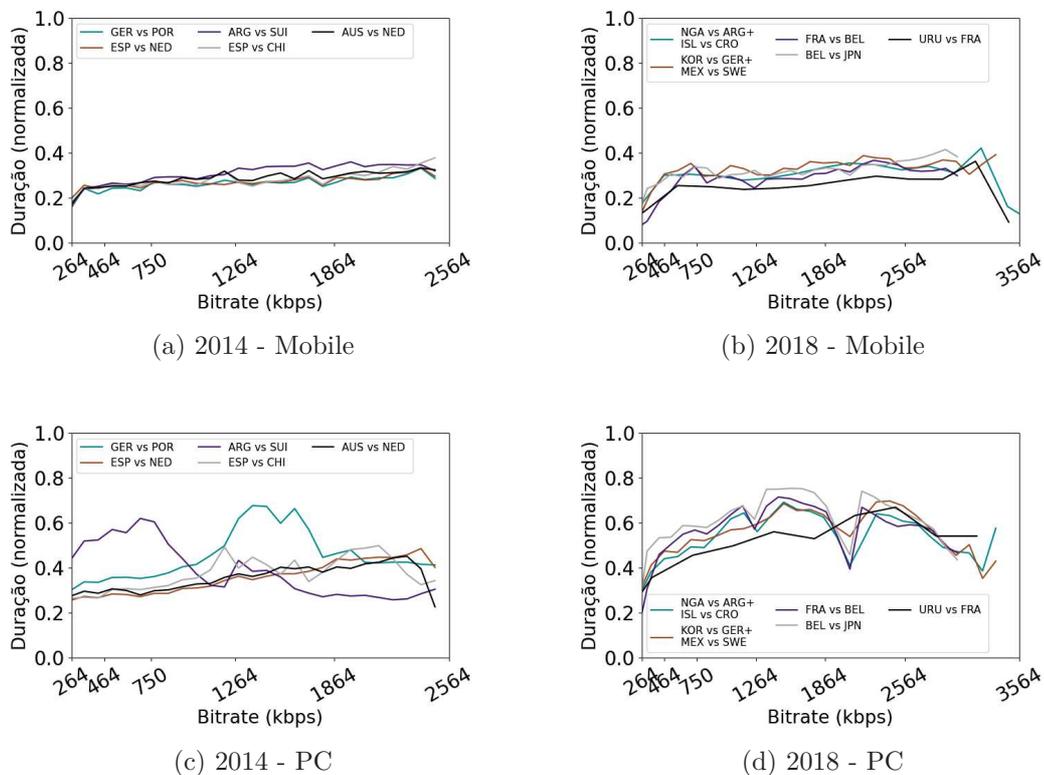
Fonte: Elaborado pelo autor. (2020).

A Figura 21a mostra que para o torneio de 2014, a qualidade máxima chegou a ter uma taxa de *bitrate* de até 2564 kbps (720p - HD). Com isso, vemos um aumento significativo na qualidade do vídeo recebido. Podemos ver também que os usuários de dispositivos móveis possuem qualidade superior aos usuários de PC para o torneio de 2014 (Figuras 21a e 23a), enquanto que em 2018 ela é similar para alguns jogos e apenas um pouco diferente para outros (Figuras 22a e 24a). Essa diferença acentuada que ocorre em 2014 se dá em parte pela limitação de qualidade que existiu em alguns jogos para usuários de PC, mas acreditamos que também seja afetada pela qualidade da rede e poder de processamento dos dispositivos que evoluíram nesse período de quatro anos.

Figura 23 – Caracterização das métricas de QoE — 2018, Mobile



Fonte: Elaborado pelo autor. (2020).

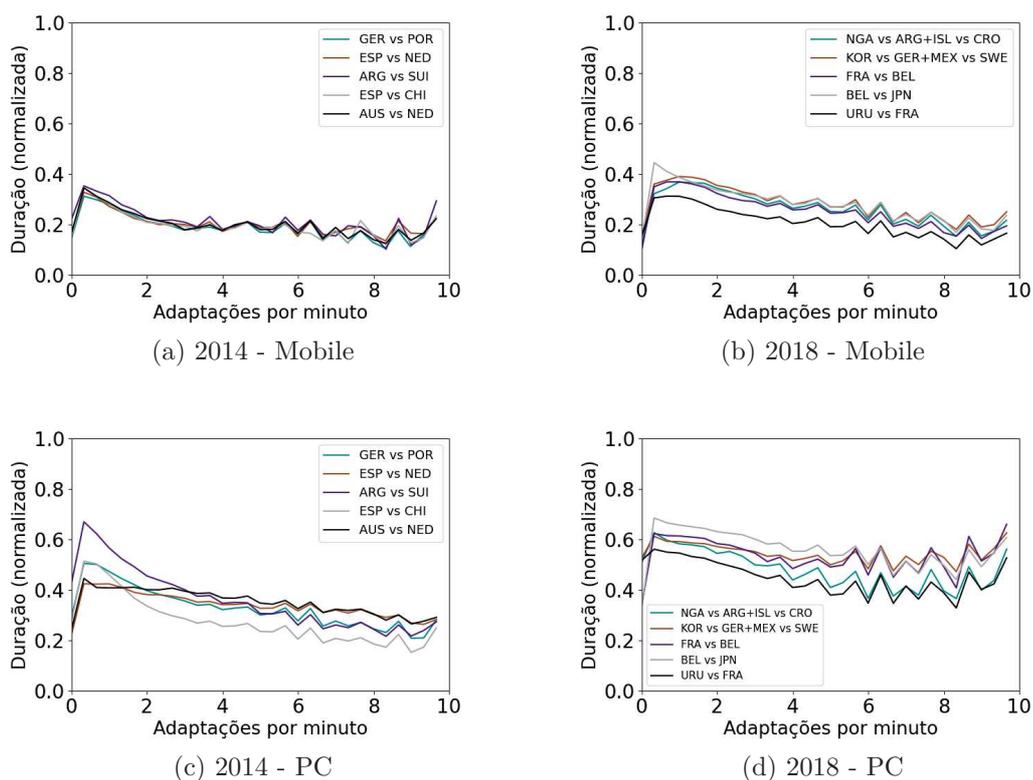
Figura 24 – *Bitrate* x Duração normalizada

Fonte: Elaborado pelo autor. (2020).

Para medir a taxa de adaptações, nós utilizamos todas as mudanças de *bitrate* que ocorreram durante a reprodução, tanto aumento quanto diminuição de *bitrate*. Utilizamos essa abordagem porque em ambos os casos o usuário percebe de forma negativa essa mudança [Nam, Kim e Schulzrinne 2016]. Se compararmos os dois torneios, vemos que a taxa de adaptação caiu para usuários de PC e que uma porcentagem significativa das sessões não possuíram nenhuma adaptação (Figuras 21b e 22b). Vemos, por exemplo, que para o torneio de 2018 quase todas as partidas analisadas mais de 50% das sessões tiveram menos de 1 adaptação por minuto, enquanto que em 2014 menos 40% tiveram esse

comportamento, até mesmo para o jogo com menor número de adaptações. Por outro lado, as sessões dos usuários de dispositivos móveis não apresentaram a mesma característica (Figuras 23b e 24b). A princípio nos pareceu contra intuitivo esse comportamento pois imaginávamos que iria ocorrer menos mudanças de *bitrate* para melhorar a experiência do usuário. Observando com mais atenção notamos que a taxa de *stalls* diminuiu (Figuras 23c e 24c). Como *stalls* impactam mais negativamente no engajamento do que adaptações [Dobrian et al. 2011, Guarnieri et al. 2017], acreditamos que a heurística de adaptação do *player* optou por alterar o *bitrate* para não ocorrer interrupções. Por fim, o número de interrupções aumentou para usuários de computadores, o que não era esperado. Talvez esse comportamento tenha acontecido devido ao usuário escolher qualidade de vídeo superior à sua conexão por não suportar assistir uma transmissão com qualidade baixa em um dispositivo com tela grande, enquanto que em dispositivos móveis os usuários são mais tolerantes com qualidade inferior já que o tamanho da tela do dispositivo é menor.

Figura 25 – Taxa de adaptações de *bitrate* x Duração normalizada



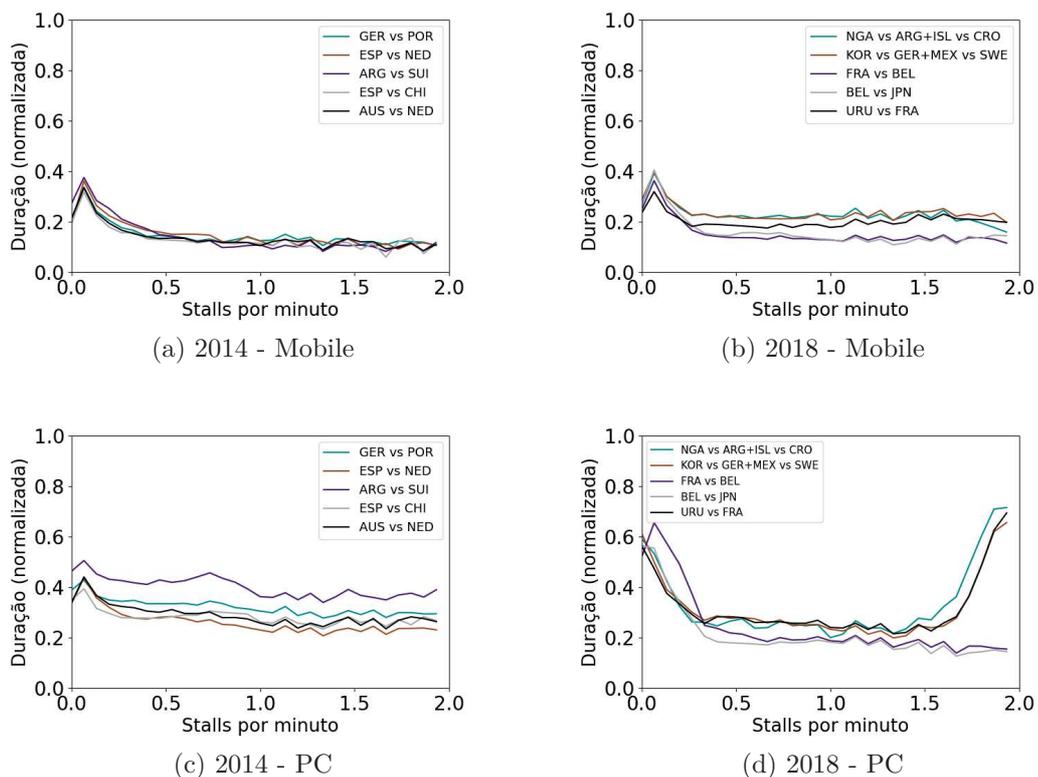
Fonte: Elaborado pelo autor. (2020).

Até o momento, as métricas de QoE avaliadas nos permitiu identificar quantas sessões possuem determinada característica, no entanto não sabemos a influência dessas métricas no engajamento final do usuário. Por conta disso, decidimos avaliar esse impacto. O engajamento foi medido considerando a duração da sessão normalizada, onde a duração foi normalizada considerando o tempo restante para o final do jogo. As sessões que

iniciaram nos 15 minutos finais da partida foram desconsideradas para evitar viés, pois elas tenderiam a ter um engajamento normalizado próximo de 1.

Em primeiro lugar, foi avaliado o impacto do *bitrate* médio da sessão no engajamento que é mostrado na Figura 24, onde o eixo X foi discretizado utilizando 30 grupos. Há bastante variação em relação ao engajamento para usuários de PC, mas no geral sessões com *bitrate* médio maior duram mais. Além disso, em partidas onde há quedas bruscas de engajamento mesmo com *bitrate* elevado, essas quedas ocorrem entre dois valores possíveis de qualidade, por exemplo, entre 1864 e 2564 kbps, indicando que o usuário pode ter presenciado várias mudanças de qualidade ao alternar entre essas duas taxas, e isso ter impactado negativamente e afetado o engajamento. Por fim, o engajamento é maior no torneio de 2018 se comparada com 2014.

Figura 26 – *Stalls* x Duração normalizada



Fonte: Elaborado pelo autor. (2020).

Em seguida, consideramos o número de adaptações de *bitrate* por minuto e o seu impacto no engajamento do usuário, também utilizando 30 grupos para discretizar o eixo X. Cada segmento de vídeo possui 3 ou 4 segundos de vídeo, dependendo do torneio, com isso o máximo de adaptações é 13 ou 18, respectivamente. Optamos então por limitar o eixo X em 10. A Figura 25 mostra a taxa de adaptações de *bitrate* para ambos os dispositivos e torneios, note que o engajamento cresceu em 2018 se comparado com 2014, e sessões com poucas adaptações possuem engajamento maior. No entanto, olhando o

gráfico para sessões de PC para o torneio de 2018 vemos que o engajamento aumentou para valores próximos a 10 adaptações por minuto, o que é estranho e não identificamos a causa desse comportamento.

Por último, a taxa de interrupções é mostrada na Figura 26. Para calcular essa taxa foi dividida a quantidade de interrupções durante a transmissão pela duração da sessão. Para usuários de dispositivos móveis vemos que o engajamento aumentou um pouco no torneio mais recente e que sessões com poucas interrupções possuem maior engajamento. No entanto, usuários de PC no torneio de 2018, em alguns jogos, possuem engajamento alto também em sessões com bastante interrupções, o que não era esperado.

8 CONCLUSÃO

Essa dissertação apresentou uma avaliação de um sistema de *streaming* de vídeo de um grande provedor de conteúdo do Brasil durante duas transmissões de um mesmo tipo de vídeo e conteúdo, as Copas do Mundo da FIFA de 2014 e 2018. Através de caracterizações, comparamos as mesmas métricas para ambos os torneios. Mostramos que o público cresceu bastante chegando a ter cerca de 165% de aumento no público médio, crescimento na taxa de *bitrate* das sessões e aumento de mais de 300% no tráfego, evidenciando que o público do torneio de 2018, além de ter sido maior, presenciou um serviço de qualidade superior. Comparamos também como o comportamento do usuário mudou de um torneio para o outro, avaliando o tamanho de suas sessões, o tempo entre sessões e também as distribuições estatísticas que melhor explicam esse comportamento. Por fim, contrastamos os resultados obtidos de ambos os torneios a cerca da experiência do usuário e seu engajamento. Esses resultados podem ser utilizados para auxiliar na criação de novas infraestruturas de transmissão e entender melhor como os usuários de um grande provedor de conteúdo se comportam durante uma transmissão de vídeo.

É importante ter em mente que esse trabalho foi baseado em um conjunto de dados originado a partir do registro de acesso de requisições HTTP feitas pelo reprodutor de vídeo presente no navegador do usuário, o que exigiu que as sessões dos usuários fossem reconstruídas segundo a metodologia expressa no Capítulo 4. Por isso, caso as sessões geradas não reflitam a realidade por conta de um erro metodológico, o erro será propagado no restante nas avaliações. Sabendo disso, uma natural extensão desse trabalho seria melhorar essa metodologia pois atualmente ela contém um problema. O tamanho do *buffer* considerado foi de 12 segundos, mas segundo relato de uma pessoa responsável pela infraestrutura do sistema estudado, nos foi dito que os navegadores podem tratar de maneira diferente como o *buffer* se comporta, sendo assim, existem navegadores que utilizam um valor fixo em segundos, enquanto outros usam um número fixo de segmentos. Não sabemos qual o impacto disso nos nossos resultados, ou seja, saber a magnitude desse impacto é necessária para futuros trabalhos. Outro ponto importante que pode ser pesquisado é a magnitude da correlação entre as métricas de QoE e o engajamento, além de investigar se há relacionamento causal dessas métricas com o engajamento, como foi identificado em trabalhos similares [Krishnan e Sitaraman 2013].

Com base nos nossos resultados, acreditamos que provedores de conteúdo devam criar suas infraestruturas de transmissão visando diminuir o máximo possível o número de interrupções durante a transmissão para aumentar o engajamento dos seus clientes. Existem algumas alternativas para chegar a esse resultado que varia de acordo com o tipo de vídeo transmitido. Vídeos sob demanda não exigem que o atraso da transmissão seja o menor possível, o que permite configurar o tamanho dos segmentos e do *buffer* com valores maiores. Segmentos maiores permitem que menos requisições sejam feitas durante

uma sessão, economizando processamento dos servidores. Já o *buffer* com tamanho maior proporciona maior estabilidade na reprodução durante momentos de instabilidade da rede do usuário. Por outro lado, vídeos ao vivo precisam manter atraso baixo e, por isso, não é possível seguir essa mesma abordagem durante a criação de sua infraestrutura. Nesse caso, valores pequenos devem ser utilizados para o tamanho dos segmentos de vídeo e do *buffer* e também devem possuir um valor razoável para permitir que haja alguma estabilidade na reprodução mesmo em momentos de instabilidade da rede, mas sem que aumente tanto o atraso final da transmissão. Por fim, além dessas possibilidades já citadas, é interessante avaliar o algoritmo de adaptação de *bitrate* utilizado pois uma regra mais inteligente, adotando técnicas de *machine learning*, podem tentar prever a qualidade mais adequada para aproveitar a rede do usuário, sem prejudicar o número de clientes atendidos pelo provedor.

REFERÊNCIAS

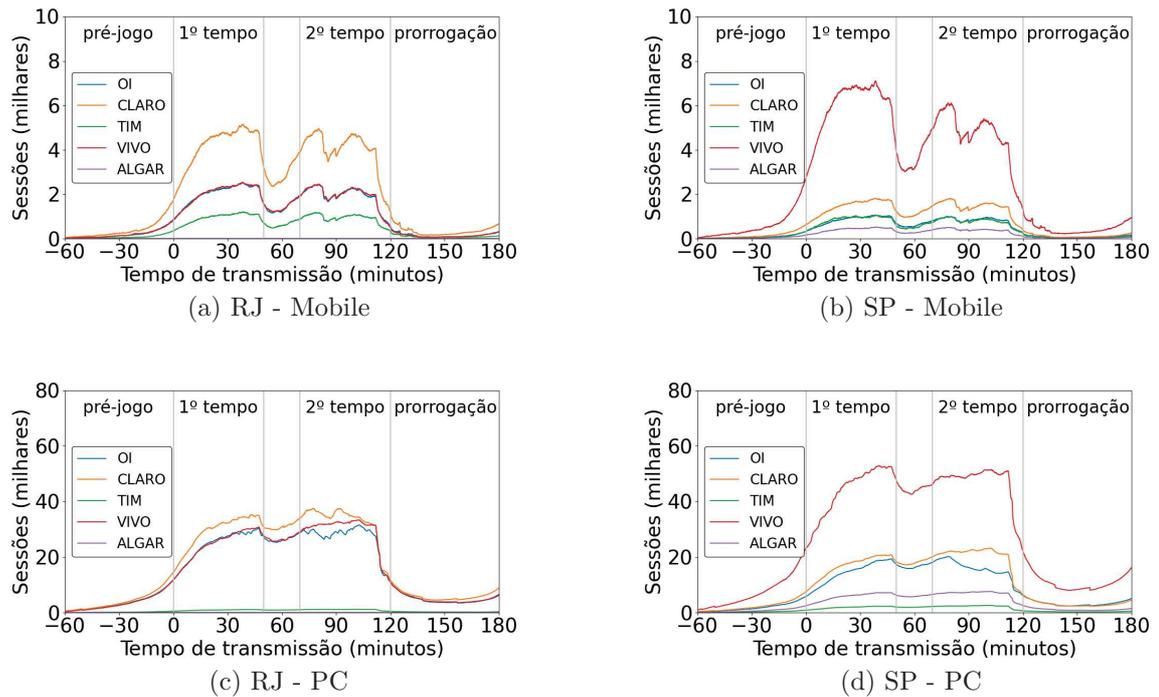
- [Adobe 2009]ADOBE. *HTTP Dynamic Streaming*. 2009.
<https://www.adobe.com/br/products/hds-dynamic-streaming.html>. Acesso em: Agosto, 2020.
- [Ahmed et al. 2017]AHMED et al. Suffering from buffering detecting qoe impairments in live video streams. In: IEEE. *2017 IEEE 25th International Conference on Network Protocols ICNP*. [S.l.], 2017. p. 1–10.
- [Apple 2009]APPLE. *HTTP Live Streaming*. 2009.
https://developer.apple.com/documentation/http_live_streaming. Acesso em: Agosto, 2020.
- [Balachandran et al. 2013]BALACHANDRAN, A. et al. Developing a predictive model of quality of experience for internet video. In: ACM. *ACM SIGCOMM Computer Communication Review*. [S.l.], 2013. v. 43, n. 4, p. 339–350.
- [Bentaleb et al. 2018]BENTALEB, A. et al. A survey on bitrate adaptation schemes for streaming media over http. *IEEE Communications Surveys & Tutorials*, IEEE, v. 21, n. 1, p. 562–585, 2018.
- [Borges et al. 2012]BORGES, A. et al. Characterizing sopcast client behavior. *Computer Communications*, Elsevier, v. 35, n. 8, p. 1004–1016, 2012.
- [Costa et al. 2004]COSTA, C. P. et al. Analyzing client interactivity in streaming media. In: *Proceedings of the 13th international conference on World Wide Web*. [S.l.: s.n.], 2004. p. 534–543.
- [Dobrian et al. 2011]DOBRIAN, F. et al. Understanding the impact of video quality on user engagement. In: ACM. *ACM SIGCOMM Computer Communication Review*. [S.l.], 2011. v. 41, n. 4, p. 362–373.
- [Guarnieri et al. A ser publicado]GUARNIERI, T. et al. Modeling large-scale live video streaming client behavior. *Multimedia Systems*, Springer, A ser publicado.
- [Guarnieri et al. 2017]GUARNIERI, T. et al. Characterizing QoE in large-scale live streaming. In: *IEEE GLOBECOM*. [S.l.: s.n.], 2017.
- [Guarnieri et al. 2018]GUARNIERI, T. et al. Previs ão de engajamento de usuários durante transmiss ão adaptativa de vídeo ao vivo. In: SBC. *Anais Principais do XXXVI Símposio Brasileiro de Redes de Computadores e Sistemas Distribuídos*. [S.l.], 2018.
- [Hands e Wilkins 1999]HANDS, D.; WILKINS, M. A study of the impact of network loss and burst size on video streaming quality and acceptability. In: SPRINGER. *Int. Workshop on Interactive Distributed Multimedia Systems and Telecommunication Services*. [S.l.], 1999. p. 45–57.
- [Krishnan e Sitaraman 2013]KRISHNAN, S. S.; SITARAMAN, R. K. Video stream quality impacts viewer behavior: inferring causality using quasi-experimental designs. *IEEE/ACM Transactions on Networking*, IEEE, v. 21, n. 6, p. 2001–2014, 2013.

- [Liu, Guo e Liang 2008]LIU, Y.; GUO, Y.; LIANG, C. A survey on peer-to-peer video streaming systems. *Peer-to-peer Networking and Applications*, Springer, v. 1, n. 1, p. 18–28, 2008.
- [Machado et al. 2019]MACHADO, B. et al. Evolução do comportamento do usuário em eventos de larga escala na internet. In: SBC. *Anais do XVIII Workshop em Desempenho de Sistemas Computacionais e de Comunicação*. [S.l.], 2019.
- [Merwe, Sen e Kalmanek 2002]MERWE, J. Van der; SEN, S.; KALMANEK, C. Streaming video traffic: Characterization and network impact. In: *Proceedings of the Seventh International Web Content Caching and Distribution Workshop*. [S.l.: s.n.], 2002.
- [Mok, Chan e Chang 2011]MOK, R. K.; CHAN, E. W.; CHANG, R. K. Measuring the quality of experience of http video streaming. In: IEEE. *12th IFIP/IEEE International Symposium on Integrated Network Management (IM 2011) and Workshops*. [S.l.], 2011. p. 485–492.
- [Nam, Kim e Schulzrinne 2016]NAM, H.; KIM, K.-H.; SCHULZRINNE, H. Qoe matters more than qos: Why people stop watching cat videos. In: IEEE. *IEEE INFOCOM 2016-The 35th Annual IEEE International Conference on Computer Communications*. [S.l.], 2016. p. 1–9.
- [Netflix Open Connect 2011]NETFLIX Open Connect. 2011. <https://openconnect.netflix.com/en/>. Acessado em: 11/06/2020.
- [Nonnenmacher e Biersack 1998]NONNENMACHER, J.; BIERSACK, E. W. Optimal multicast feedback. In: IEEE. *Proceedings. IEEE INFOCOM'98, the Conference on Computer Communications. Seventeenth Annual Joint Conference of the IEEE Computer and Communications Societies. Gateway to the 21st Century (Cat. No. 98*. [S.l.], 1998. v. 3, p. 964–971.
- [Robitza et al. 2020]ROBITZA, W. et al. Are you still watching? streaming video quality and engagement assessment in the crowd. In: IEEE. *2020 Twelfth International Conference on Quality of Multimedia Experience (QoMEX)*. [S.l.], 2020. p. 1–6.
- [Sandvine 2020]SANDVINE. *Sandvine The Global Internet Phenomena Report COVID-19 Spotlight*. 2020. https://www.sandvine.com/hubfs/Sandvine_Redesign_2019/Downloads/2020/Phenomena/COVID%20Internet%20Phenomena%20Report%2020200507.pdf. Acessado em: 05/03/2019.
- [Santos et al. 2016]SANTOS, B. et al. Caracterização do comportamento dos clientes de vídeo ao vivo durante um evento de larga escala. In: *Simpósio Brasileiro de Redes de Computadores*. [S.l.: s.n.], 2016.
- [Schlinker et al. 2017]SCHLINKER, B. et al. Engineering egress with edge fabric: Steering oceans of content to the world. In: ACM. *Proceedings of the Conference of the ACM Special Interest Group on Data Communication*. [S.l.], 2017. p. 418–431.
- [Sodagar 2011]SODAGAR, I. The mpeg-dash standard for multimedia streaming over the internet. *IEEE multimedia*, IEEE, v. 18, n. 4, p. 62–67, 2011.

- [Sripanidkulchai, Maggs e Zhang 2004]SRIPANIDKULCHAI, K.; MAGGS, B.; ZHANG, H. An analysis of live streaming workloads on the internet. In: *Proc. of the ACM SIGCOMM conference on Internet measurement*. [S.l.: s.n.], 2004.
- [Stockhammer 2011]STOCKHAMMER, T. Dynamic adaptive streaming over http—standards and design principles. In: *Proceedings of the second annual ACM conference on Multimedia systems*. [S.l.: s.n.], 2011. p. 133–144.
- [Swaminathan 2013]SWAMINATHAN, V. Are we in the middle of a video streaming revolution? *ACM Transactions on Multimedia Computing, Communications, and Applications (TOMM)*, ACM New York, NY, USA, v. 9, n. 1s, p. 1–6, 2013.
- [Velooso et al. 2002]VELOSO, E. et al. A hierarchical characterization of a live streaming media workload. In: *Proc. of the 2nd ACM SIGCOMM Workshop on Internet measurement*. [S.l.: s.n.], 2002.
- [Vieira et al. 2013]VIEIRA, A. B. et al. Sopcast p2p live streaming: Live session traces and analysis. In: *Proceedings of the 4th ACM multimedia systems conference*. [S.l.: s.n.], 2013. p. 125–130.
- [Zambelli 2009]ZAMBELLI, A. Iis smooth streaming technical overview. *Microsoft Corporation*, v. 3, p. 40, 2009.

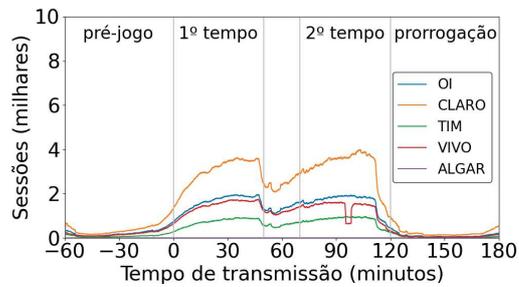
APÊNDICE A – SESSÕES E TRÁFEGO DOS JOGOS MAIS POPULARES

Figura 27 – Sessões ao longo do jogo para os servidores do Rio de Janeiro e São Paulo para o 1º jogo com maior número de endereços IP únicos (Alemanha vs Portugal) do torneio de 2014 agrupadas por provedor de acesso à Internet

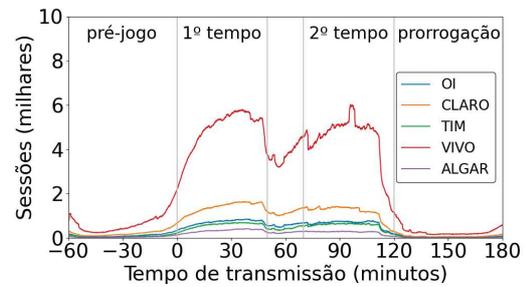


Fonte: Elaborado pelo autor. (2020).

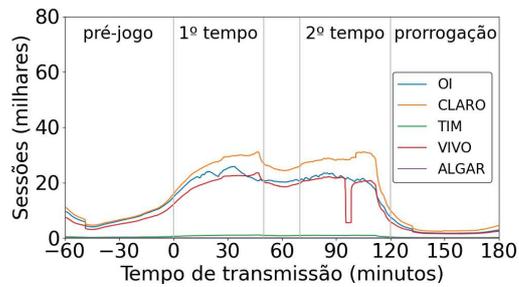
Figura 28 – Sessões ao longo do jogo para os servidores do Rio de Janeiro e São Paulo para o 2º jogo com maior número de endereços IP únicos (Espanha vs Holanda) do torneio de 2014 agrupadas por provedor de acesso à Internet



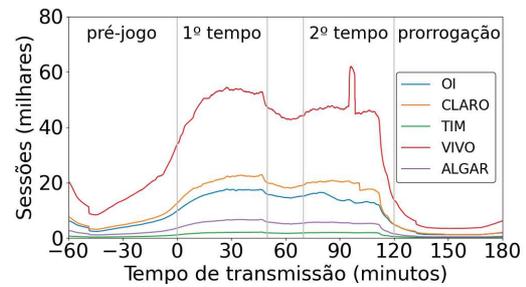
(a) RJ - Mobile



(b) SP - Mobile



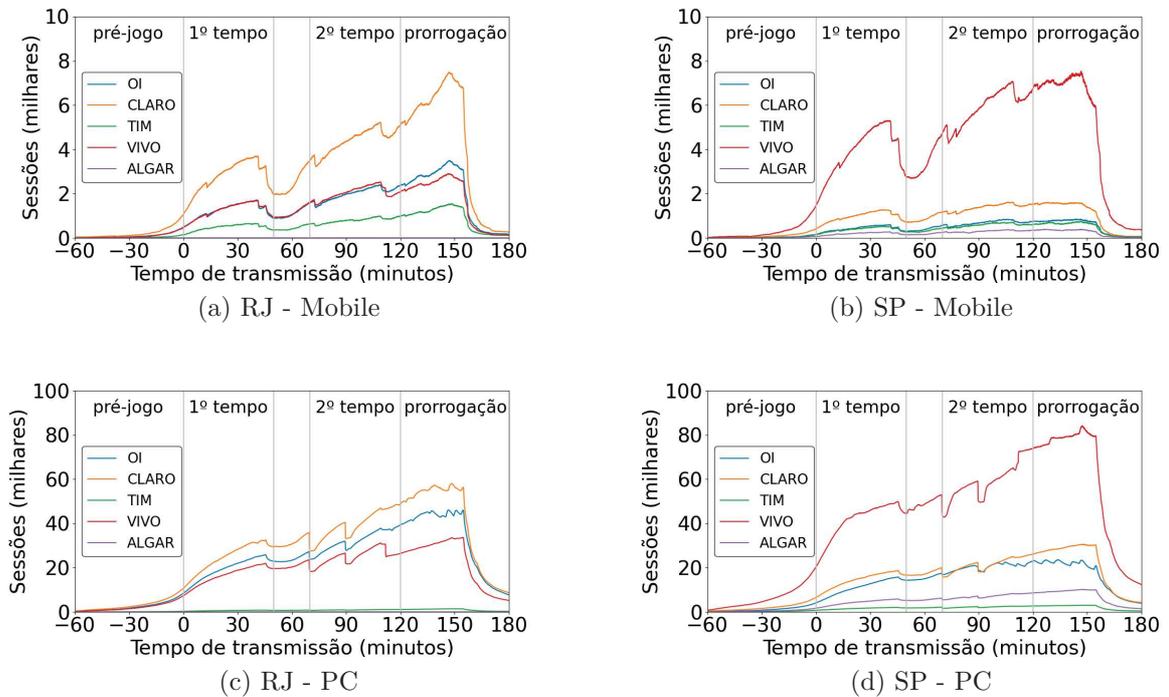
(c) RJ - PC



(d) SP - PC

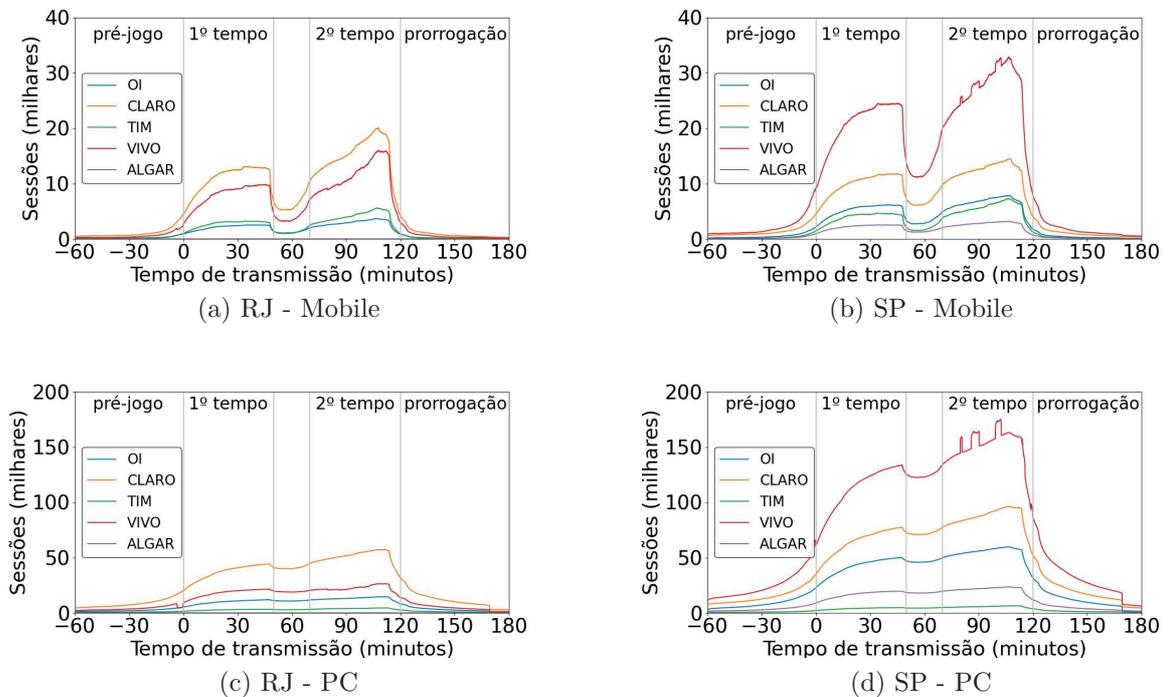
Fonte: Elaborado pelo autor. (2020).

Figura 29 – Sessões ao longo do jogo para os servidores do Rio de Janeiro e São Paulo para o 3º jogo com maior número de endereços IP únicos (Argentina vs Suíça) do torneio de 2014 agrupadas por provedor de acesso à Internet



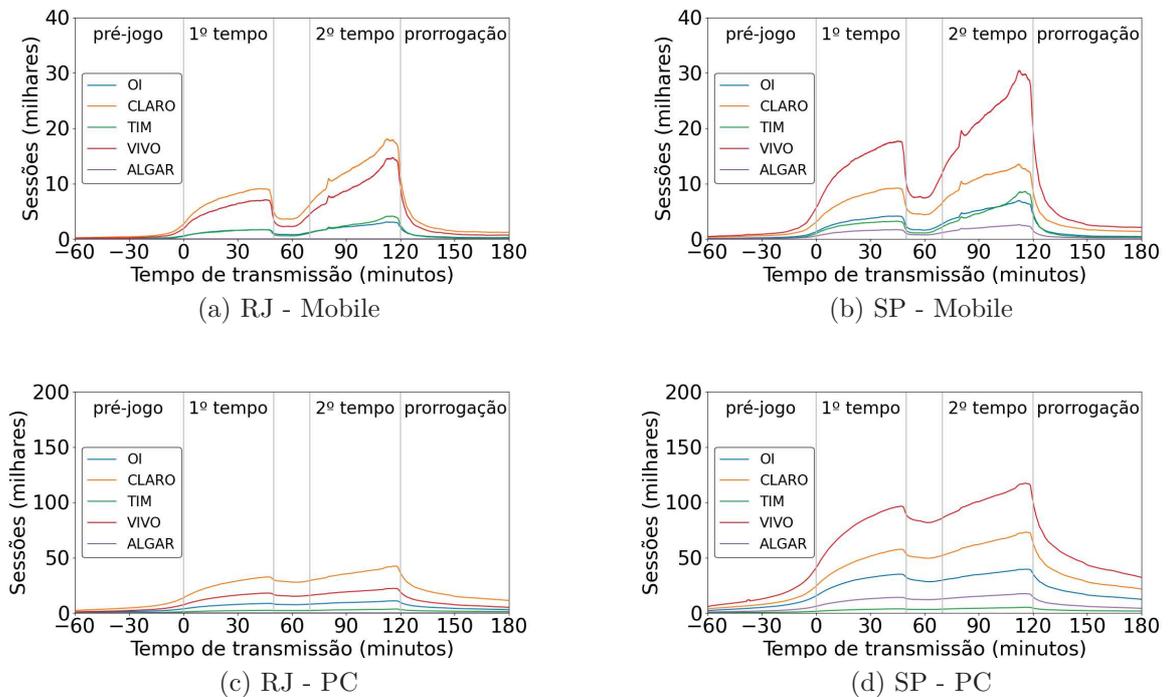
Fonte: Elaborado pelo autor. (2020).

Figura 30 – Sessões ao longo do jogo para os servidores do Rio de Janeiro e São Paulo para o 1º jogo com maior número de endereços IP únicos (Nigéria vs Argentina + Islândia vs Croácia) do torneio de 2018 agrupadas por provedor de acesso à Internet



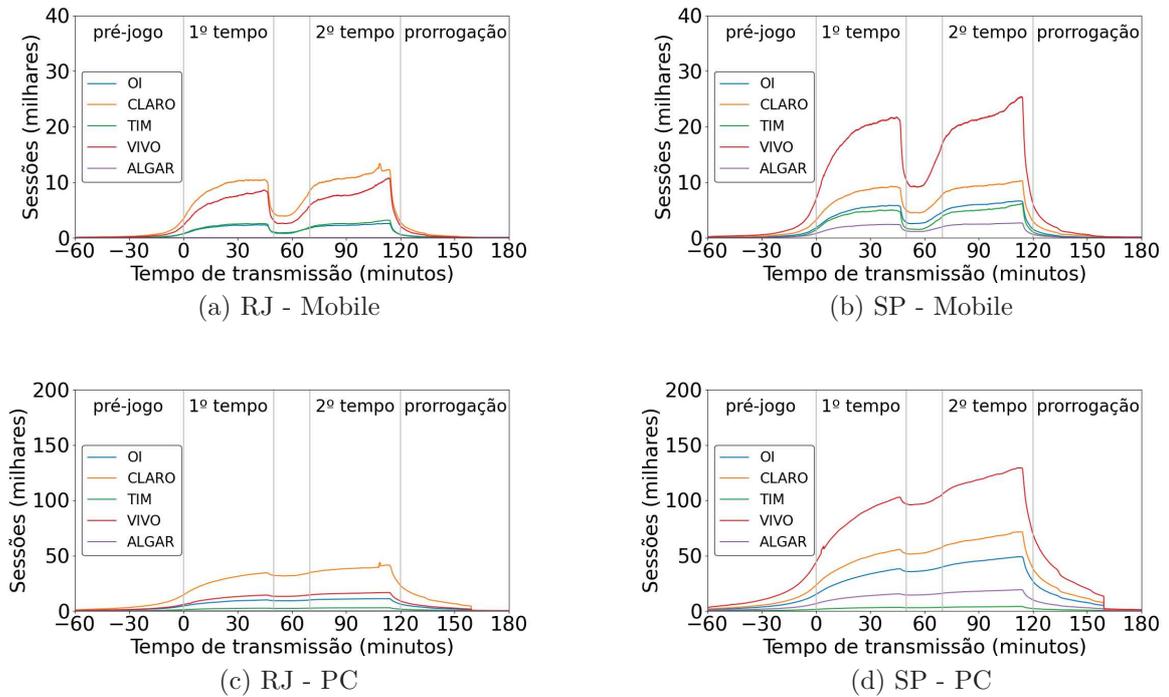
Fonte: Elaborado pelo autor. (2020).

Figura 31 – Sessões ao longo do jogo para os servidores do Rio de Janeiro e São Paulo para o 2º jogo com maior número de endereços IP únicos (Coreia do Sul vs Alemanha + México vs Suécia) do torneio de 2018 agrupadas por provedor de acesso à Internet



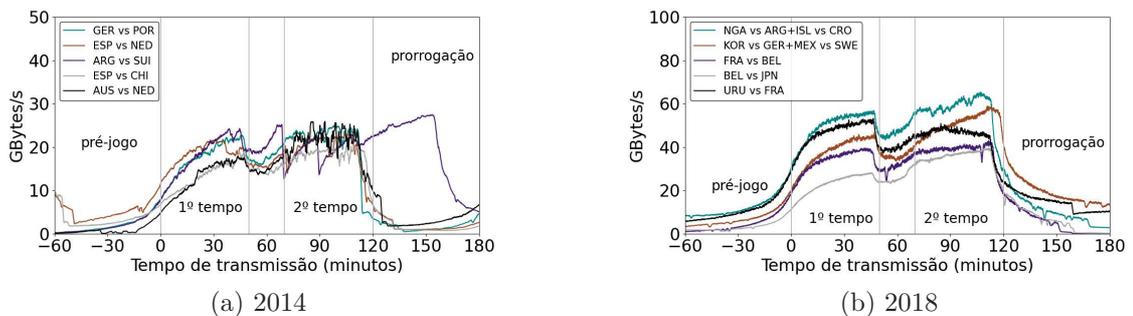
Fonte: Elaborado pelo autor. (2020).

Figura 32 – Sessões ao longo do jogo para os servidores do Rio de Janeiro e São Paulo para o 3º jogo com maior número de endereços IP únicos (França vs Bélgica) do torneio de 2018 agrupadas por provedor de acesso à Internet



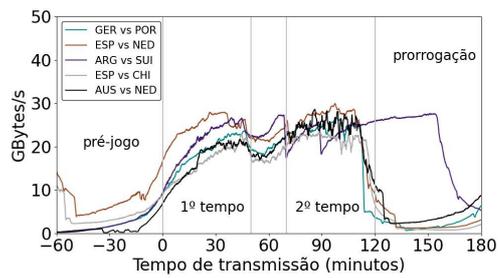
Fonte: Elaborado pelo autor. (2020).

Figura 33 – Tráfego ao longo do tempo para ambos os cinco jogos com maior número de endereços IP únicos servido pelos servidores do Rio de Janeiro

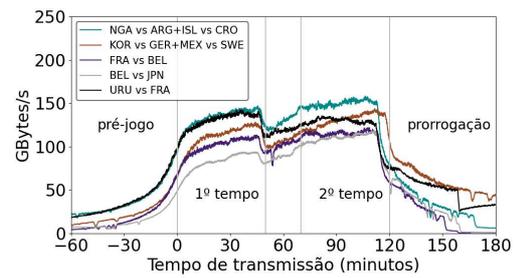


Fonte: Elaborado pelo autor. (2020).

Figura 34 – Tráfego ao longo do tempo para ambos os cinco jogos com maior número de endereços IP únicos servido pelos servidores de São Paulo



(a) 2014



(b) 2018

Fonte: Elaborado pelo autor. (2020).