

# Seminar 1.1 - Evaluacija zadovoljstva korisnika adaptivnog streaminga

Kerim Hodzic

Elektrotehnicki fakultet, Univerzitet Sarajevo  
BiH  
kerim.hodzic@etf.unsa.ba

Dario Raca

Elektrotehnicki fakultet, Univerzitet Sarajevo  
BiH  
draca@etf.unsa.ba

## ABSTRACT

Neprekidan rast dostupnog multimedijalnog sadržaja i njegovo korištenje od strane sve većeg broja korisnika dovodi do sve veće potrebe za kvalitetnom i brzom isporukom kvalitetnog sadržaja putem mreže. Međutim, modeliranje kvalitete takvog korisničkog doživljaja (QoE - engl. - Quality of Experience) predstavlja izazvan zadatak za istraživače koji ulažu napor u bolje razumijevanje i mjerjenje QoE-a. Radi procjene zadovoljstva korisnika, provode se subjektivno ocjenjivanje kvalitete, u kojem ljudi gledaju i ocjenjuju videozapise, i objektivno ocjenjivanje kvalitete, pri kojem se videozapisi automatski ocjenjuju upotrebom jedne ili više objektivnih metrika. Iako postoji veliki broj baza podataka s videozapisima dostupnih za subjektivno i objektivno ocjenjivanje kvalitete, ti se videozapisi, najčešće, ručno modifikuju različitim vremenskim i prostornim degradacijama. Takvi ideozapisi su u najvećem broju slučajeva ručno izmjenjeni da simuliraju kašnjenje pri pokretanju, promjenu kvaliteta (rezolucije) videozapisa kao i zaustavljanje reprodukcije sadržaja zbog nedovoljno brzog stizanja paketa na klijentu. Radi provođenja vjerodostojnije evaluacije kvalitete videozapisa potrebno je simulirati prikaz originalnog korisničkog iskustva dok se gledaju različite vrste snimaka na različitim vrstama i kvalitetama mreže. Vjerujemo da će rezultati našeg istraživanja omogućiti naučnoj zajednici bolje razumijevanje različitih utjecaja kvaliteta adaptivnog streaminga na zadovoljstvo krajnjeg korisnika.

## CCS CONCEPTS

- Information systems → Multimedia streaming; • Networks → Public Internet; Wireless access networks.

## KEYWORDS

Evaluacija zadovoljstva korisnika, Adaptivni streaming, 3G, 4G, WiFi

## ACM Reference Format:

Kerim Hodzic and Dario Raca. 2023. Seminar 1.1 - Evaluacija zadovoljstva korisnika adaptivnog streaminga. In *Proceedings of Seminarski rad 1.1 (ETF 2023)*. ACM, New York, NY, USA, 5 pages. <https://doi.org/10.1145/nnnnnnnnnnnnnn>.

Permission to make digital or hard copies of all or part of this work for personal or classroom use is granted without fee provided that copies are not made or distributed for profit or commercial advantage and that copies bear this notice and the full citation on the first page. Copyrights for components of this work owned by others than ACM must be honored. Abstracting with credit is permitted. To copy otherwise, or republish, to post on servers or to redistribute to lists, requires prior specific permission and/or a fee. Request permissions from [permissions@acm.org](mailto:permissions@acm.org).

ETF 2023, Sarajevo, Bosna i Hercegovina,

© 2023 Association for Computing Machinery.  
ACM ISBN 978-x-xxxx-xxxx-x/YY/MM...\$15.00  
<https://doi.org/10.1145/nnnnnnnnnnnnnn>

## 1 UVOD

Prenos multimedijalnog sadržaja predstavlja dominantnu vrstu saobraćaja koji se odvija na današnjim računarskim mrežama. Video streaming dominira internetom, čineći skoro 66% ukupnog internet saobraćaja u 2022. godini [44]. Streaming sadržaj može varirati od događaja koji se prenose uživo (npr. veliki sportski događaji, video igre ili kulturni događaji) i sadržaja na zahtjev (npr. filmovi i TV emisije), s aplikacijama kao što su YouTube, Netflix, Amazon Prime, Disney+, Tik Tok i Apple+ koji obuhvataju veliki procenat od ukupnog streaming saobraćaja. [44].

Trenutno najpopularniji pristup adaptivnom streamingu je "HTTP adaptive streaming" (HAS) tehnika. HAS omogućava prilagodbu kvaliteta sadržaja različitim mrežnim uslovima dijeljenjem video sadržaja na više segmenata fiksнog trajanja (najčešće 2,4 ili 8 sekund). Svaki segment je kodiran u više kvaliteta (. 200, 500, 1000, 4000 kbps). Na strani klijenta, program za reprodukciju video sadržaja pohranjuje preuzete segmente u međuspremnik (bafer, engl. buffer) za reprodukciju i dekodiranje. Obično je sva inteligencija za odabir kvaliteta segmenta na strani klijenta. Program za reprodukciju video sadržaja procjenjuje dostupnu propusnost mreže i zahtjeva segment s maksimalnim kvalitetom, a u isto vrijeme težeći tome da minimizira događaje zastoja ili ponovnog dobavljanja sadržaja. Tokom godina, implementiran je veliki broj različitih HAS algoritama [6]. Tradicionalno, ovi algoritmi se mogu klasifikovati na osnovu načina na koji se procenjuju raspoloživi mrežni resursi: bazirani na brzini, bazirani na međuspremniku i hibridni. Algoritmi zasnovani na brzini procjenjuju dostupne mrežne resurse mjerjenjem dostupnog protoka te te informacije koriste za odluku o kvalitetu sljedećeg odabranog segmenta [23]. Algoritmi bazirani na međuspremniku (baferu) prate promjene u nivoima međuspremnika (bafera) za reprodukciju te te informacije koriste za odluku o kvalitetu sljedećeg odabranog segmenta [45]. Međutim, većina najsavremenijih algoritama kombinuje oba pristupa prilikom donošenja odluke [13, 22, 51, 67]. Također, mnogi autori koriste i neke drugačije pristupe kada dizajniraju logiku algoritama adaptacije , uključujući mašinsko učenje [32], teoriju upravljanja [13] i optimizaciju [66].

Uz rastuću popularnost streaming servisa, zahtjevi i očekivanja korisnika za kvalitetom iskustva (QoE) visokog nivoa postali su kamen temeljac u dizajnu HAS sistema. Po definiciji, QoE predstavlja metriku mjerjenja pozitivnog ili negativnog korisničkog iskustva u korištenju neke aplikacije ili usluge [8]. Zbog svoje subjektivne komponente, mjerjenje i modeliranje korisničkog QoE-a je težak zadatak. Na ukupnu ocjenu zadovoljstva korisnika u HAS-u utiču različiti negativni faktori uključujući početno kašnjenje, prosječan kvalitet videozapisa, događaje zastoja, učestalost promjene kvaliteta (rezolucije) i trajanje video sadržaja [30]. Minimiziranje i pronaalaženje

optimalne kombinacije ovih faktora predstavlja kompleksan zadatak. Tipičan pristup se sastoji od izvođenja subjektivnih studija koje određuju težinske faktore za svako od oštećenja [14, 30, 39]. Izvedeni QoE modeli postaju ciljna funkcija u dizajniranju logike prilagođavanja adaptivnih algoritama [65, 66]. Na mrežnoj strani, istraživači se obično oslanjam na mrežne metrike, kao što su gubitak paketa i propusnost mreže, te ih mapiraju na QoE korisnika odnosno gledaoca.

Postoje dva glavna pristupa u evaluaciji korisničkog iskustva (QoE): subjektivna i objektivna evaluacija. U objektivnoj evaluaciji video sekvenca se ocjenjuje automatski bez interakcije korisnika. Načini objektivne evaluacije se mogu klasificirati u tri grupe: **Bez reference (NR- engl. no reference)** pristup, gdje originalna video sekvenca nije dostupna za poređenje sa modifikovanom. Neki popularni NR modeli su Video-BLIINDS [43] i metrika zamučenja na ivicama [33]; **Smanjena referenca ( RR - engl. Reduced Reference )** modeli, gdje je originalna video sekvenca djelimično dostupna. Neki popularni RR modeli su SRR [25], ST-RRED [50] i LOW BANDWIDTH RR VQ [38]; **Puna referenca ( FR - engl. Full Reference )** pristup gdje je originalna video sekvenca u potpunosti dostupna za poređenje sa degradiranom video sekvencom. Najpopularniji FR modeli su odnos signal-šum (engl. Signal-to-Noise Ratio - PSNR), indeks strukturne sličnosti (engl. Structural Similarity Index - SSIM) [59], Višenivoski SSIM (engl. Multi-scale SSIM - MS-SSIM) [60] i fuzija višemetodske procjene ( engl. Multimethod Assessment Fusion - VMAF ) [1]. Međutim, subjektivna evaluacija zadovoljstva korisnika (QoE) predstavlja osnovu za bolje razumijevanje i modeliranje korisničkog iskustva. Kako bi procjenili subjektivno iskustvo, istraživači su vremenom kreirali više setova testnih video sekvenci koje sadrže različite tipove tipičnih degradacija. U najvećem broju slučajeva, ova oštećenja se vještački (ručno) dodaju video sekvcencama [30, 53]. Nekoliko studija izvodi i subjektivnu i objektivnu QoE evaluaciju nad istim setom podataka te pored dobivene rezultate (video sekvenci) [14, 19, 30, 47? ].

Glavno ograničenje kod subjektivne evaluacije zadovoljstva korisnika (QoE) predstavlja vještačko (ročno) modifikovani dizajn degradacije video sekvenci koji ne mora da odražava situaciju pri gledanju video sekvence kroz realne mrežne uslove. Postoji raznovrstan skup distorzija koje se mogu pojavit u streaming sesiji, a i same video sekvence mogu biti veoma raznolike u pogledu vrste i kvaliteta sadržaja. Za istraživače je veoma važno kreirati i koristiti skupove podataka (datasetove) o degradiranim video sekvcencama bazirane na realnim uslovima kako bi se omogućio poboljšani dizajn logike algoritama adaptacije. U literaturi postoji mnogo skupova podataka sa logovima propusnosti mreže prikljenim u različitim mobilnim okruženjima pod različitim bežičnim tehnologijama [28, 41]. Generisanje testnih video sekvenci zasnovanih na realističnim video zapisima dopunjuje i proširuje trenutnu literaturu o temi testiranja zadovoljstva korisnika (QoE) adaptivnog streaminga. Koliko nam je poznato, postoji samo nekoliko skupova podataka (datasetova) generisanih na osnovu stvarnih mrežnih logova dostupnih istraživačkoj zajednici [17? , 18]. Međutim, samo neki od njih daju javno dostupne mrežne logove sa kojim su kreirani, a nijedan nije dopunjen video zapisima i video logovima pomoću koji se taj set video zapisa može reproducirati ili proširiti.

## 2 LITERATURA I MOTIVACIJA

Glavni cilj HAS algoritama je maksimiziranje zadovoljstva koje percipira korisnik gledajući video sadržaj. Ovaj izazovan zadatak se bazira na pokušaju što bolje reprezentacije subjektivnog uticaja kroz mapiranje objektivnih QoE metrika na strani klijenta (npr. početno kašnjenje, prosječna brzina prijenosa, zastajkivanje uslijed nedostatka paketa i frekvencija promjene rezolucije) ili metrike mjerene na mreži kao što su iskorištenost mrežnog kanala i precent gubitka paketa. Nadalje, QoE modeli izraženi kao linearna kombinacija degradacija (1), također predstavljaju odgovarajućeg kandidata za dizajniranje HAS algoritma koji maksimizira dati QoE model. Tipičan pristup uključuje modeliranje QoE modela kao funkcije koristi nekog postavljenog optimizacijskog problema [5, 65? ].

Tipična jednačina koja se koristi za izvođenje QoE modela je [14, 30, 39]:

$$QoE_s = w_o \cdot QoE_m - (w_t \cdot I_t + w_v \cdot I_v) + f(I_t, I_v), \quad (1)$$

gdje  $I_t$  predstavlja faktor vremenske degradacije, a  $w_t$  predstavlja njegovu težinu. Vremenska degradacija kvaliteta opisuje degradaciju zbog početnog kašnjenja i zastoja (broj zastoja i trajanje zastoja). Dok početno kašnjenje (do 16 sekundi) ima manji negativan uticaj na QoE, događaji zastoja imaju najveći negativan uticaj na ukupno korisničko iskustvo [48].  $I_v$  i  $w_v$  predstavljaju faktore vizualne degradacije i njegov težinu, respektivno. Slično kao i zastoji, amplituda kvaliteta sadržaja koji se pruža ima značajan uticaj na QoE [21], za razliku od prebacivanja između različitih kvaliteta uz zadržavanje iste rezolucije [21]. Međutim, prebacivanje između različitih rezolucija može uticati na korisničko iskustvo [2].  $QoE_m$  prikazuje maksimalnu (početnu) vrijednost (engl. score) za QoE ili faktor rasta u zavisnosti od QoE modela, a  $w_o$  označava težinu za  $QoE_m$  rezultat. Neki QoE modeli uzimaju u obzir degradacije koje se javljaju istovremeno, ali u ovakvim scenarijima, sumarni subjektivni efekat ne predstavlja direktni zbir svake degradacije pojedinačno [30]. Uloga funkcije  $f(I_t, I_v)$  je da kompenzira ovaj efekat. Međutim, ove degradacije (tj. njihove metrike) su međusobno kontradiktorne. Visoka brzina prijenosa povećava vjerojatnoću nedovoljne napunjenošt međuspremnika (engl. buffer) što rezultira događajima zastoja, dok streaming pri niskom kvalitetu ima ozbiljan negativan utjecaj na percipirano korisničko iskustvo.

Da bi se odredila uzročno posljedična veza između iskustva korisnika i objektivnih metrika, mnoge studije koriste subjektivnu evaluaciju. Ova evaluacija se oslanja na procjenu kvaliteta video snimaka od strane učesnika u kontrolisanom laboratorijskom okruženju [11, 30, 39, 49]. Svaki učesnik ocjenjuje video sekvencu koristeći predefinisanu skalu (označeno kao  $R$ , gdje studije najčešće koriste skalu od 5, 10 ili 100 bodova). Postupak se ponavlja za niz testnih sekvenci. Svaka testna sekvenca je modifikovana sa jednom ili više degradacija. Na kraju se za svaku testnu sekvencu i dati rezultat  $R$ , faktor degradacije računa kao 100- $R$ .

Subjektivna evaluacija je skup i dugotrajan proces koji se izvodi sa ograničenim brojem ljudi (obično do 30) što može da ograničava statističku validnost prikupljenih rezultata. Alternativno, neke studije se opredjeljuju za "crowd-sourcing" pristup, gdje veliki broj korisnika ocjenjuje video sekvence online u nekontrolisanom okruženju [26, 53? ]. Subjektivne studije objavljene do 2014. pregledane su u [19].

Glavni izazov za subjektivnu evaluaciju je način modifikacije testnih video sekvenci sa određenim degradacijama. Obično se one umjetno kreiraju i ručno dodaju video zapisima. Međutim, tako stvorene degradacije ne odražavaju nužno one uočene u stvarnim mrežnim uvjetima, bilo njihovu učestalost (. broj promjena rezolucije, broj zastoja) ili trajanje (. trajanje zastoja). U literaturi postoji velik broj javno objavljenih skupova podataka koji se mogu koristiti za procjenu kvaliteta video sekvenci kroz subjektivnu evaluaciju.

Neki istraživači su sproveli studije sa jako velikim brojem učesnika o uticaju zastoja i promjene kvaliteta videa na zadovoljstvo korisnika. Nažalost, njihovi skupovi podataka nisu dostupni za javnu upotrebu.

U [26], autori koriste analitički dodatak na internet pretraživačima na strani klijenta kako bi prikupili informacije o više od 23 miliona video pregleda od strane 6,7 miliona jedinstvenih korisnika. Sličan pristup sa dodatkom na strani klijenta koristi se i u [16] za prikupljanje informacija od više od 2 miliona jedinstvenih pregleda od preko 1 miliona gledalaca i [29] mjerjenje kašnjenja pokretanja i zastoja u više od 200 miliona video sesija.

Skupovi podataka koji modeliraju adaptivni streaming su: LIVE Mobile Stall, LIVE Mobile Stall II, LIVE-NETFLIX i tu su degradacije sintetički (ručno) ubaćene korištenjem unaprijed definisanih obrazaca (engl. pattern) i, LIVE-NFLX-II, Waterloo SQuE-III i Waterloo SQuE-IV sa autentično dobivenim degradacijama kao što su zastoji i promjene rezolucije. U [54], autori koriste predefinisane obrasce (engl. pattern) događaja zastoja; međutim, skup podataka koji je korišten u radu nije javno dostupan.

Motivisani nedostatkom video sekvenci sa degradacijama zasnovanim na stvarnim mrežnim uslovima, i mnoštvom skupova podataka koji opisuju različite mrežne uslove prikupljene u praksi a koji su dostupni u literaturi [28, 40, 41] planiramo dizajnirati alat za kreiranje video sekvenci sa degradacijama prikupljenim iz video sesija prikupljenih kroz informacije o različitim tipovima mrežnih scenarija prikupljenih u stvarnom svijetu.

Pošto mnogi alati opisani u literaturi koji su dizajnirani za subjektivnu evaluaciju video zapisa. To su, naprimjer, Amazon Mechanical Turk<sup>1</sup>, Microtask<sup>2</sup>, Microworkers<sup>3</sup> i Quadrant of Euphoria [9]. Glavni nedostatak predloženih sistema je njihovo ograničenje na evaluaciju koja se radi samo preko internet pretraživača, time isključujući one koje bi se mogle raditi i na mobilnim uređajima i računarima.

Druzi autori koriste aktivniji pristup, prikupljajući različite objektivne metrike (QoS) na strani klijenta (npr. početno kašnjenje, prosječna brzina prijenosa, zastoji i frekvencija promjene rezolucije) za derivaciju QoE modela [15, 20]. BiQPS je alat zasnovan na mašinskom učenju namijenjen za predviđanje ukupnog kvaliteta HAS sesija [56]. Nam i ostali. [34] opisuju YouSlow, dodatak (engl. plugin) za internet pretraživač Google Chrome dizajniran da detektuje i pamti različite događaje u toku reprodukcije video zapisa (kašnjenje prvog pokretanja, zastope, promjene rezolucije, dio učitanog video zapisa i lokaciju korisnika). Autori su koristili predloženi alat za prikupljanje više od 400.000 YouTube pregleda kako bi procijenili različite QoE metrike analizirajući stope napuštanja videa na YouTubeu.

<sup>1</sup><https://www.mturk.com/>

<sup>2</sup><https://microtask.com/>

<sup>3</sup><https://www.microworkers.com/>

Slično, Chen i ostali. [10] predložili su QoE Doctor, alat koji radi na Android operativnom sistemu za mobilne uređaje i koristi tehnike kontrole korisničkog interfejsa da automatski reproducira ponašanje korisnika, dok prikuplja odgovarajuće QoE podatke za naknadnu analizu. Još jedna aplikacija zasnovana na Androidu, YoMoApp (YouTube Performance Monitoring Application) [58], pasivno prati različite metrike (događaje zastoja i nivo kvaliteta videa) dok se YouTube video gleda na pametnim telefonima krajnjih korisnika. Autori su proširili YoMoApp sa dodatkom u cloudu kako bi otvoreno dijelili potpuna i originalna neobrađena mjerena mjerena koje je YoMoApp snimio na registrovanim uređajima [61].

Za razliku od klijent baziranih rješenja, neki istraživači predlažu server bazirana rješenja za maksimiziranje zadovoljstva korisnika korisnika preporučujući najbolje algoritme kodiranja u zavisnosti od vremena i lokacije korisnika [24]. Sličan sistem zasnovan na oblaku (engl. cloud) je predložen za procjenu performansi HAS-a u različitim mrežnim uslovima, nakon čega slijedi izvođenje MOS (Mean Opinion Score) rezultata iz modela P.1203 [53, 55].

Pored toga, u zadnje vrijeme, su uloženi naporci da se dizajnira konceptualni generički i proširivi alat za treniranje, implementaciju modela i ponovnu evaluaciju u enkriptovanom video streamingu [36, 42]

Zaključujemo da, iako postoji mnogo alata i sistema koji se koriste u području adaptivnog streaminga i mjerena kvaliteta zadovoljstva korisnika, ne postoji sličan alat kao alat koji planiramo implementirati u daljem radu, a to je alat koji omogućava automatsku reprodukciju video zapisa adaptivno streamanog koristeći video logove i logove mreže kreirane u realnom okruženju.

Zatim, u implementaciji alata planiramo omogućiti računanje različitih FR (Full Reference) metrika koji upoređuju originalnu video sekvencu sa degradiranom video sekvencom [52]. Neki popularni modeli FR bi se izračunavali su Peak signal-to-noise ratio (PSNR), jedna od najstarijih metrika za poređenje slike u decibelnoj skali signala koja se obično koristi kao referenca za druge metode procjene kvaliteta videa. PSNR je kasnije nadograden sa structural similarity index (SSIM) metrikom [59], multi-scale structural similarity index (MS-SSIM) metrikom [60] i video multi-method assessment fusion (VMAF) metrikom [1].

Neke od ranijih preglednih radova koji pokrivaju metode objektivne ocjene kvaliteta video snimaka objavili su: Olsson i ostali [35], Winkler i ostali [62, 63], i ostali [64], S. Chikkerur i ostali [12], i Zhou i ostali. [69].

Druge popularne objektivne VQA metode su MOVIE [46] i MOSP [7].

U [37], autori predlažu FR VQA metodu koja analizira "najgorje" rezultate duž prostorne i vremenske dimenzije videa. U [57] autori su objasnili adaptivnu strategiju zasnovanu na distribuciji koja je proširenje indeksa najočiglednijeg izobličenja (most apparent distortion - MAD index ) implementiranog i objašnjenog u [27]. Još neke popularne FR (Full reference) metrike su [3, 4, 31, 68] Vjerujemo da će sistem koji planiramo implementirati i skupovi podataka koje planiramo kreirati pomoći njega biti jedinstveni u postojećoj literaturi i da će pomoći u tekućim istraživanjima kako bi se bolje razumjeli faktori koji utiču na korisničko iskustvo korisnika koji gledaju adaptivne streamove.

## REFERENCES

- [1] 2016. Toward A Practical Perceptual Video Quality Metric. (2016). <https://netflixtechblog.com/toward-a-practical-perceptual-video-quality-metric-653f208b9652>
- [2] A. Asan, W. Robitz, I. h. Mkwawa, L. Sun, E. Ifeachor, and A. Raake. 2017. Impact of video resolution changes on QoE for adaptive video streaming. In *2017 IEEE International Conference on Multimedia and Expo (ICME)*. 499–504. <https://doi.org/10.1109/ICME.2017.8019297>
- [3] Tunç Ozan Aydin, Martin Čadík, Karol Myszkowski, and Hans-Peter Seidel. 2010. Video Quality Assessment for Computer Graphics Applications. *ACM Trans. Graph.* 29, 6, Article 161 (dec 2010), 12 pages. <https://doi.org/10.1145/1882261.1866187>
- [4] Christos G. Bampis, Zhi Li, and Alan C. Bovik. 2019. Spatiotemporal Feature Integration and Model Fusion for Full Reference Video Quality Assessment. *IEEE Transactions on Circuits and Systems for Video Technology* 29, 8 (2019), 2256–2270. <https://doi.org/10.1109/TCST.2018.2868262>
- [5] Abdelhak Bentaleb, Ali C. Begen, Saad Harous, and Roger Zimmermann. 2018. Want to Play DASH? A Game Theoretic Approach for Adaptive Streaming over HTTP. In *Proceedings of the 9th ACM Multimedia Systems Conference* (Amsterdam, Netherlands) (MMSys '18). Association for Computing Machinery, New York, NY, USA, 13–26. <https://doi.org/10.1145/3204949.3204961>
- [6] Abdelhak Bentaleb, Bayan Taani, Ali C. Begen, Christian Timmerer, and Roger Zimmermann. 2019. A Survey on Bitrate Adaptation Schemes for Streaming Media Over HTTP. *IEEE Communications Surveys & Tutorials* 21, 1 (2019), 562–585. <https://doi.org/10.1109/COMST.2018.2862938>
- [7] Abhara Bhat, Sampath Kannangara, Yafai Zhao, and Iain Richardson. 2012. A Full Reference Quality Metric for Compressed Video Based on Mean Squared Error and Video Content. *IEEE Transactions on Circuits and Systems for Video Technology* 22, 2 (2012), 165–173. <https://doi.org/10.1109/TCST.2011.2158465>
- [8] Kjell Brunnström et al. 2013. Qualinet White Paper on Definitions of Quality of Experience. <https://hal.archives-ouvertes.fr/hal-00977812> Qualinet White Paper on Definitions of Quality of Experience Output from the fifth Qualinet meeting, Novi Sad, March 12, 2013.
- [9] Kuan-Ta Chen, Chi-Jui Chang, Chen-Chi Wu, Yu-Chun Chang, and Chin-Laung Lei. 2010. Quadrant of euphoria: crowdsourcing platform for QoE assessment. *IEEE Network* 24, 2 (2010), 28–35. <https://doi.org/10.1109/MNET.2010.5430141>
- [10] Qi Alfred Chen, Haokun Luo, Sanae Rosen, Z. Morley Mao, Karthik Iyer, Jie Hui, Kranthi Sontineni, and Kevin Lau. 2014. QoE Doctor: Diagnosing Mobile App QoE with Automated UI Control and Cross-Layer Analysis. In *Proceedings of the 2014 Conference on Internet Measurement Conference* (Vancouver, BC, Canada) (IMC '14). Association for Computing Machinery, New York, NY, USA, 151–164. <https://doi.org/10.1145/2398776.2663716.2663726>
- [11] Manri Cheon and Jong-Seok Lee. 2018. Subjective and Objective Quality Assessment of Compressed 4K UHD Videos for Immersive Experience. *IEEE Transactions on Circuits and Systems for Video Technology* 28, 7 (2018), 1467–1480. <https://doi.org/10.1109/TCST.2017.2683504>
- [12] Shyamprasad Chikkerur, Vijay Sundaram, Martin Reisslein, and Lina J. Karam. 2011. Objective Video Quality Assessment Methods: A Classification, Review, and Performance Comparison. *IEEE Transactions on Broadcasting* 57, 2 (2011), 165–182. <https://doi.org/10.1109/TBC.2011.2104671>
- [13] L. De Cicco, V. Caldarola, P. Palmisano, and S. Mascolo. 2013. ELASTIC: A Client-Side Controller for Dynamic Adaptive Streaming over HTTP (DASH). In *2013 20th International Packet Video Workshop*. IEEE, 1–8. <https://doi.org/10.1109/PV.2013.6691442>
- [14] J. De Vriendt, D. De Vleeschauwer, and D. Robinson. 2013. Model for estimating QoE of video delivered using HTTP adaptive streaming. In *2013 IFIP/IEEE International Symposium on Integrated Network Management (IM 2013)*. 1288–1293.
- [15] Lam Dinh-Xuan, Michael Seufert, Florian Wamser, and Phuoc Tran-Gia. 2017. Study on the accuracy of QoE monitoring for HTTP adaptive video streaming using VNF. In *2017 IFIP/IEEE Symposium on Integrated Network and Service Management (IM)*. 999–1004. <https://doi.org/10.23919/INM.2017.7987425>
- [16] Florin Dobrian, Vyasa Sekar, Asad Awani, Ion Stoica, Dilip Joseph, Aditya Ganjam, Jibin Zhan, and Hui Zhang. 2011. Understanding the Impact of Video Quality on User Engagement. *SIGCOMM Comput. Commun. Rev.* 41, 4 (aug 2011), 362–373. <https://doi.org/10.1145/2043164.2018478>
- [17] Zhengfang Duanmu, Wentao Liu, Zheruan Li, Diqi Chen, Zhou Wang, Yizhou Wang, and Wen Gao. 2020. The Waterloo Streaming Quality-of-Experience Database-IV. <https://doi.org/10.21227/j15a-8r35>
- [18] Zhengfang Duanmu, Abdul Rehman, and Zhou Wang. 2018. A Quality-of-Experience Database for Adaptive Video Streaming. *IEEE Transactions on Broadcasting* 64, 2 (2018), 474–487. <https://doi.org/10.1109/TBC.2018.2822870>
- [19] Deepthi Ghadiyaram, Janice Pan, and Alan C. Bovik. 2019. A Subjective and Objective Study of Stalling Events in Mobile Streaming Videos. *IEEE Transactions on Circuits and Systems for Video Technology* 29, 1 (2019), 183–197. <https://doi.org/10.1109/TCST.2017.2768542>
- [20] Gerardo Gómez, Lorenzo Hortiguela, Quiliano Perez, Javier Lorca, Raquel Garcia, and Mari Aguayo-Torres. 2014. YouTube QoE Evaluation Tool for Android Wireless Terminals. *EURASIP Journal on Wireless Communications and Networking* 2014 (05 2014). <https://doi.org/10.1186/1687-1499-2014-164>
- [21] T. Hoßfeld, M. Seufert, C. Sieber, and T. Zinner. 2014. Assessing effect sizes of influence factors towards a QoE model for HTTP adaptive streaming. In *2014 Sixth International Workshop on Quality of Multimedia Experience (QoMEX)*. 111–116. <https://doi.org/10.1109/QoMEX.2014.6982305>
- [22] Te-Yuan Huang, Ramesh Johari, Nick McKeown, Matthew Trunnell, and Mark Watson. 2014. A Buffer-based Approach to Rate Adaptation: Evidence from a Large Video Streaming Service. In *Proceedings of the 2014 ACM Conference on SIGCOMM* (Chicago, Illinois, USA) (SIGCOMM '14). ACM, New York, NY, USA, 187–198. <https://doi.org/10.1145/2619239.2626296>
- [23] J. Jiang, V. Sekar, and H. Zhang. 2014. Improving Fairness, Efficiency, and Stability in HTTP-Based Adaptive Video Streaming With Festive. *IEEE/ACM Transactions on Networking* 22, 1 (Feb 2014), 326–340. <https://doi.org/10.1109/TNET.2013.2291681>
- [24] Takuto Kimura, Masahiro Yokota, Arifumi Matsumoto, Kei Takeshita, Taichi Kawano, Kazumichi Sato, Hiroshi Yamamoto, Takanori Hayashi, Kohel Shiomi, and Kenichi Miyazaki. 2017. QUVE: QoE Maximizing Framework for Video-Streaming. *IEEE Journal of Selected Topics in Signal Processing* 11, 1 (2017), 138–153. <https://doi.org/10.1109/JSTSP.2016.2632060>
- [25] Michail-Alexandros Kourtis, Harilaos G. Koumaras, and Fidel Liberal. 2016. Reduced-reference video quality assessment using a static video pattern. *Journal of Electronic Imaging* 25, 4 (2016), 043011. <https://doi.org/10.1117/1.JEI.25.4.043011>
- [26] S. Shunmuga Krishnan and Ramesh K. Sitaraman. 2012. Video Stream Quality Impacts Viewer Behavior: Inferring Causality Using Quasi-Experimental Designs. In *Proceedings of the 2012 Internet Measurement Conference* (Boston, Massachusetts, USA) (IMC '12). Association for Computing Machinery, New York, NY, USA, 211–224. <https://doi.org/10.1145/2398776.2398799>
- [27] Eric Larson and Damon Chandler. 2010. Most apparent distortion: Full-reference image quality assessment and the role of strategy. *J. Electronic Imaging* 19 (01 2010), 011006. <https://doi.org/10.1117/1.3267105>
- [28] Li Li, Ke Xu, Dan Wang, Chunyi Peng, Qingyang Xiao, and Rashid Mijumbi. 2015. A measurement study on TCP behaviors in HSPA+ networks on high-speed rails. In *2015 IEEE Conference on Computer Communications (INFOCOM)*. 2731–2739. <https://doi.org/10.1109/INFOCOM.2015.7218665>
- [29] Xi Liu, Florin Dobrian, Henry Milner, Junchen Jiang, Vyas Sekar, Ion Stoica, and Hui Zhang. 2012. A Case for a Coordinated Internet Video Control Plane. *SIGCOMM Comput. Commun. Rev.* 42, 4 (aug 2012), 359–370. <https://doi.org/10.1145/2377677.2377752>
- [30] Y. Liu, S. Dey, F. Ulupinar, M. Luby, and Y. Mao. 2015. Deriving and Validating User Experience Model for DASH Video Streaming. *IEEE Transactions on Broadcasting* 61, 4 (Dec 2015), 651–665.
- [31] K. Manasa and Sumohana S. Channappayya. 2016. An Optical Flow-Based Full Reference Video Quality Assessment Algorithm. *IEEE Transactions on Image Processing* 25, 6 (2016), 2480–2492. <https://doi.org/10.1109/TIP.2016.2548247>
- [32] Hongzi Mao, Ravi Netravali, and Mohammad Alizadeh. 2017. Neural Adaptive Video Streaming with Pensieve. In *Proceedings of the Conference of the ACM Special Interest Group on Data Communication* (Los Angeles, CA, USA) (SIGCOMM '17). Association for Computing Machinery, New York, NY, USA, 197–210. <https://doi.org/10.1145/3098822.3098843>
- [33] P. Marziliano, F. Dufaux, S. Winkler, and T. Ebrahimi. 2002. A no-reference perceptual blue metric. In *Proceedings. International Conference on Image Processing*, Vol. 3. III–III. <https://doi.org/10.1109/ICIP.2002.1038902>
- [34] Hyunwoo Nam, Kyung-Hwa Kim, and Henning Schulzrinne. 2016. QoE matters more than QoS: Why people stop watching cat videos. In *IEEE INFOCOM 2016 - The 35th Annual IEEE International Conference on Computer Communications*. 1–9. <https://doi.org/10.1109/INFOCOM.2016.7524426>
- [35] Sofie Olson, Mario Stroppiana, and Jamal Bainia. 1997. Objective methods for assessment of video quality: state of the art. *IEEE transactions on broadcasting* 43, 4 (1997), 487–495.
- [36] Irena Orsolic and Lea Skorin-Kapov. 2020. A Framework for in-Network QoE Monitoring of Encrypted Video Streaming. *IEEE Access* 8 (2020), 74691–74706. <https://doi.org/10.1109/ACCESS.2020.2988735>
- [37] Jincheol Park, Kalpana Seshadrinathan, Sanghoon Lee, and Alan Conrad Bovik. 2013. Video Quality Pooling Adaptive to Perceptual Distortion Severity. *IEEE Transactions on Image Processing* 22, 2 (2013), 610–620. <https://doi.org/10.1109/TIP.2012.2219551>
- [38] Margaret H. Pinson. 2005. Low Bandwidth Reduced Reference Video Quality Monitoring System.
- [39] A. Raake, M. Garcia, W. Robitz, P. List, S. Göring, and B. Feitem. 2017. A bitstream-based, scalable video-quality model for HTTP adaptive streaming: ITU-T P.1203.1. In *2017 Ninth International Conference on Quality of Multimedia Experience (QoMEX)*. 1–6. <https://doi.org/10.1109/QoMEX.2017.7965631>
- [40] Darioj Raca, Jason J. Quinlan, Ahmed H. Zahran, and Cormac J. Sreenan. 2018. Beyond Throughput: A 4G LTE Dataset with Channel and Context Metrics. In *Proceedings of the 9th ACM Multimedia Systems Conference* (Amsterdam, Netherlands) (MMSys '18). Association for Computing Machinery, New York, NY, USA, 460–465. <https://doi.org/10.1145/3204949.3208123>

- [41] Haakon Riiser, Paul Vignostad, Carsten Griwodz, and Pål Halvorsen. 2013. Commute Path Bandwidth Traces from 3G Networks: Analysis and Applications. In *Proceedings of the 4th ACM Multimedia Systems Conference* (Oslo, Norway) (*MM-Sys '13*). Association for Computing Machinery, New York, NY, USA, 114–118. <https://doi.org/10.1145/2483977.2483991>
- [42] Piotr Romanik, Mu Muy, Andreas Mauthe, Salvatore D'Antonio, and Mikolaj Leszczuk. 2011. Framework for the Integrated Video Quality Assessment. *Multimedia Tools and Applications* 61 (12 2011). <https://doi.org/10.1007/s11042-011-0946-3>
- [43] Michele A. Saad, Alan C. Bovik, and Christophe Charrier. 2014. Blind Prediction of Natural Video Quality. *IEEE Transactions on Image Processing* 23, 3 (2014), 1352–1365. <https://doi.org/10.1109/TIP.2014.2299154>
- [44] Sandvine. 2023. *The Global Internet Phenomena Report*. Technical Report.
- [45] Y. Sani, A. Mauthe, and C. Edwards. 2015. Modelling Video Rate Evolution in Adaptive Bitrate Selection. In *2015 IEEE International Symposium on Multimedia (ISM)*, 89–94. <https://doi.org/10.1109/ISM.2015.65>
- [46] Kalpana Seshadrinathan and Alan Conrad Bovik. 2010. Motion Tuned Spatio-Temporal Quality Assessment of Natural Videos. *IEEE Transactions on Image Processing* 19, 2 (2010), 335–350. <https://doi.org/10.1109/TIP.2009.2034992>
- [47] Kalpana Seshadrinathan, Rajiv Soundararajan, Alan Conrad Bovik, and Lawrence K. Cormack. 2010. Study of Subjective and Objective Quality Assessment of Video. *IEEE Transactions on Image Processing* 19, 6 (2010), 1427–1441. <https://doi.org/10.1109/TIP.2010.2042111>
- [48] M. Seufert, S. Egger, M. Slanina, T. Zinner, T. Hobfeld, and P. Tran-Gia. 2015. A Survey on Quality of Experience of HTTP Adaptive Streaming. *Communications Surveys Tutorials, IEEE* 17, 1 (Firstquarter 2015), 469–492. <https://doi.org/10.1109/COMST.2014.2360940>
- [49] Zaixi Shang, Joshua P. Ebenezer, Alan C. Bovik, Yongjun Wu, Hai Wei, and Sriram Sethuraman. 2021. Assessment of Subjective and Objective Quality of Live Streaming Sports Videos. *arXiv:2106.08431 [eess.IV]*
- [50] Rajiv Soundararajan and Alan C. Bovik. 2013. Video Quality Assessment by Reduced Reference Spatio-Temporal Entropic Differencing. *IEEE Transactions on Circuits and Systems for Video Technology* 23, 4 (2013), 684–694. <https://doi.org/10.1109/TCSVT.2012.2214933>
- [51] K. Spiteri, R. Uongaonkar, and R. K. Sitaraman. 2016. BOLA: Near-optimal bitrate adaptation for online videos. In *IEEE INFOCOM 2016 - The 35th Annual IEEE International Conference on Computer Communications*, 1–9. <https://doi.org/10.1109/INFOCOM.2016.7524428>
- [52] Akira Takahashi, David Hands, and Vincent Barriac. 2008. Standardization activities in the ITU for a QoE assessment of IPTV. *IEEE Communications Magazine* 46, 2 (2008), 78–84. <https://doi.org/10.1109/MCOM.2008.4473087>
- [53] Babak Taraghi, Abdelhak Bentaleb, Christian Timmerer, Roger Zimmermann, and Hermann Hellwagner. 2021. Understanding Quality of Experience of Heuristic-Based HTTP Adaptive Bitrate Algorithms. In *Proceedings of the 31st ACM Workshop on Network and Operating Systems Support for Digital Audio and Video* (Istanbul, Turkey) (*NOSSDAV '21*). Association for Computing Machinery, New York, NY, USA, 82–89. <https://doi.org/10.1145/3458306.3458875>
- [54] Babak Taraghi, Minh Nguyen, Hadi Amirpour, and Christian Timmerer. 2021. Intense: In-Depth Studies on Stall Events and Quality Switches and Their Impact on the Quality of Experience in HTTP Adaptive Streaming. *IEEE Access* 9 (2021), 118087–118098. <https://doi.org/10.1109/ACCESS.2021.3107619>
- [55] Babak Taraghi, Anatoliy Zabrovskiy, Christian Timmerer, and Hermann Hellwagner. 2020. CADViSE: Cloud-Based Adaptive Video Streaming Evaluation Framework for the Automated Testing of Media Players. In *Proceedings of the 11th ACM Multimedia Systems Conference* (Istanbul, Turkey) (*MMsys '20*). Association for Computing Machinery, New York, NY, USA, 349–352. <https://doi.org/10.1145/3339825.3394581>
- [56] Huyen T. T. Tran, Duc Nguyen, and Truong Cong Thang. 2020. An Open Software for Bitstream-Based Quality Prediction in Adaptive Video Streaming. In *Proceedings of the 11th ACM Multimedia Systems Conference* (Istanbul, Turkey) (*MMsys '20*). Association for Computing Machinery, New York, NY, USA, 225–230. <https://doi.org/10.1145/3339825.3394925>
- [57] Phong V. Vu, Cuong T. Vu, and Damon M. Chandler. 2011. A spatiotemporal most-apparent-distortion model for video quality assessment. In *2011 18th IEEE International Conference on Image Processing*, 2505–2508. <https://doi.org/10.1109/ICIP.2011.6116171>
- [58] Florian Wamser, Michael Seufert, Pedro Casas, Ralf Irmer, Phuoc Tran-Gia, and Raimund Schatz. 2015. YoMoApp: A tool for analyzing QoE of YouTube HTTP adaptive streaming in mobile networks. In *2015 European Conference on Networks and Communications (EuCNC)*, 239–243. <https://doi.org/10.1109/EuCNC.2015.7194076>
- [59] Zhou Wang, A.C. Bovik, H.R. Sheikh, and E.P. Simoncelli. 2004. Image quality assessment: from error visibility to structural similarity. *IEEE Transactions on Image Processing* 13, 4 (2004), 600–612. <https://doi.org/10.1109/TIP.2003.819861>
- [60] Z. Wang, E.P. Simoncelli, and A.C. Bovik. 2003. Multiscale structural similarity for image quality assessment. In *The Thirty-Seventh Asilomar Conference on Signals, Systems & Computers, 2003*, Vol. 2, 1398–1402 Vol.2. <https://doi.org/10.1109/ACSSC.2003.1292216>
- [61] Sarah Wassermann, Pedro Casas, Michael Seufert, and Florian Wamser. 2019. On the Analysis of YouTube QoE in Cellular Networks through in-Smartphone Measurements. In *2019 12th IFIP Wireless and Mobile Networking Conference (WMNC)*, 71–78. <https://doi.org/10.23919/WMNC.2019.8881828>
- [62] Stefan Winkler. 2005. *Digital Video Quality – Vision Models and Metrics*. <https://doi.org/10.1002/9780470024065>
- [63] Stefan Winkler. 2009. Video quality measurement standards – Current status and trends. In *2009 7th International Conference on Information, Communications and Signal Processing (ICICS)*, 1–5. <https://doi.org/10.1109/ICICS.2009.5397585>
- [64] Hong Ren Wu, K. Rao, and Ashraf Kassim. 2007. Digital Video Image Quality and Perceptual Coding. *Journal of Electronic Imaging - J ELECTRON IMAGING* 16 (01 2007). <https://doi.org/10.1117/1.2778686>
- [65] Praveen Kumar Yadav, Abdelhak Bentaleb, May Lim, Junyi Huang, Wei Tsang Ooi, and Roger Zimmermann. 2021. *Playing Chunk-Transferred DASH Segments at Low Latency with QLive*. Association for Computing Machinery, New York, NY, USA, 51–64. <https://doi.org/10.1145/3458305.3463376>
- [66] Xiaoqi Yin, Abhishek Jindal, Vyta Sekar, and Bruno Sinopoli. 2015. A Control-Theoretic Approach for Dynamic Adaptive Video Streaming over HTTP. In *Proceedings of the 2015 ACM Conference on Special Interest Group on Data Communication* (London, United Kingdom) (*SIGCOMM '15*). ACM, New York, NY, USA, 325–338. <https://doi.org/10.1145/2785956.2787486>
- [67] A. H. Zahran, D. Raca, and C. Sreenan. 2018. ARBITER+: Adaptive Rate-Based InTElligent HTTP STreaming Algorithm for Mobile Networks. *IEEE Transactions on Mobile Computing* (2018), 1–1. <https://doi.org/10.1109/TMC.2018.2825384>
- [68] Fan Zhang and David R. Bull. 2016. A Perception-Based Hybrid Model for Video Quality Assessment. *IEEE Transactions on Circuits and Systems for Video Technology* 26, 6 (2016), 1017–1028. <https://doi.org/10.1109/TCSVT.2015.2428551>
- [69] Wei Zhou, Xiongkuo Min, Hong Li, and Qiuping Jiang. 2022. A Brief Survey on Adaptive Video Streaming Quality Assessment. *J. Vis. Comun. Image Represent.* 36, C (jul 2022), 7 pages. <https://doi.org/10.1016/j.jvcir.2022.103526>