



ТЕХНИЧЕСКИ УНИВЕРСИТЕТ – СОФИЯ  
ФАКУЛТЕТ ПО ТЕЛЕКОМУНИКАЦИИ  
КАТЕДРА „КОМУНИКАЦИОННИ МРЕЖИ“

---

маг. инж. Георгиос Василиос Куюмтзидис

ПОДОБРЯВАНЕ КАЧЕСТВОТО НА ВЪЗПРИЯТИЕ В  
БЕЗЖИЧНИ МРЕЖИ ОТ СЛЕДВАЩО ПОКОЛЕНИЕ ЧРЕЗ  
МАШИННО ОБУЧЕНИЕ

**АВТОРЕФЕРАТ**

на дисертация за присъждане на образователна и научна степен  
„ДОКТОР“

Област на висше образование: 5. Технически науки

Професионално направление: 5.3 Комуникационна и компютърна техника

Научна специалност: Комуникационни мрежи и системи

Научни ръководители: проф. д-р инж. Владимир Костадинов Пулков

София, 2024

Дисертационният труд е обсъден и насочен за защита от Катедрения съвет на катедра „Комуникационни Мрежи“ към Факултет по Телекомуникации при Технически Университет – София на редовно заседание, проведено на 26.02.2024 г. (протокол № 8)

Публичната защита на дисертационния труд ще се състои на 09.05.2024г. от 13:00 часа в Конферентната зала на БИЦ на Технически университет – София на открито заседание на научното жури, определено със заповед № ОЖ-5.3-12 / 15.03.2024 г. на Ректора на ТУ-София в състав:

1. Проф. д-р Георги Илиев – председател
2. Доц. д-р Агата Манолова – научен секретар
3. Проф. д-р Розалина Димова
4. Проф. д-р Станимир Садинов
5. Доц. д-р Габриела Атанасова

Рецензенти:

1. Доц. д-р Агата Манолова
2. Проф. д-р Розалина Димова

Материалите по защитата са на разположение на интересувашите се в канцеларията на Факултет по Телекомуникации, блок 1, стая 1439-Б и на Интернет страницата на Технически Университет – София.

Дисертантът е свободен докторант към катедра „Комуникационни Мрежи“, Факултет по Телекомуникации. Изследванията по дисертационният труд са направени от автора, като резултатите от тях са публикувани.

Автор: маг. инж. Георгиос Василиос Куюмтзидис

Заглавие: Подобряване качеството на възприятие в безжични мрежи от следващо поколение чрез машинно обучение

Тираж: 30 броя

Отпечатано в ИПК на Технически университет – София

# **I. ОБЩА ХАРАКТЕРИСТИКА НА ДИСЕРТАЦИОННИЯ ТРУД**

## **Актуалност на проблема**

Бъдещите безжични мрежи (F5N) ще трябва да поддържат непрекъснато развиващите се и разнообразни нужди от свързаност на нововъзникващите вертикални индустрии в областта на медиите и развлеченията, здравеопазването, производството, автомобилостроенето, енергетиката, интернет на нещата (IoT), околната среда и обществената безопасност. Такава широка и хетерогенна гама от услуги и устройства изисква разработването на гъвкави и мащабируеми мобилни мрежи, които са в състояние да отговорят на различните изисквания за качество на услугата (QoS), за да осигурят задоволителни нива на качество на изживяването (QoE).

## **Цел на дисертационния труд, основни задачи и методи за изследване**

Целта на дипломната работа е да предложи цялостна методология за подобряване на QoE в F5N чрез интегриране на изкуствен интелект (AI) в мрежовите операции за оптимизиране на тяхната производителност. Мрежовите операции, базирани на изкуствен интелект, ще бъдат интегрирани в Open RAN архитектурата, за да поддържат различни случаи на употреба с хетерогенни изисквания за QoS по отношение на честотна лента, латентност, загуба на пакети и трептене. По-специално ще бъдат разработени алгоритми за машинно обучение (ML), за да осигурят автоматизирано прогнозиране на мрежовия трафик и оптимално разпределение на ресурсите чрез използване на техники за нарязване на мрежата. Прилагането на автоматизация на оркестрация на ресурсите, подпомагана от ML, ще доведе до оптимално управление на мрежата и ще предостави нова и ефективна методология за намаляване на капиталовите разходи (CAPEX) и оперативните разходи (OPEX) на доставчиците на комуникационни услуги (CSP).

## **Научна новост**

Напредъкът в безжичните комуникационни технологии напълно промени начина, по който хората комуникират и споделят информация и улесни подобренията във всеки аспект от ежедневието, включително предприемачество, образование, развлечения, транспорт, търговия на дребно, сигурност и спешни услуги. 5-то поколение (5G) мобилни мрежови технологии позволява свръхвисокоскоростно предаване на данни, свързва огромен брой устройства и осигурява ултраниска латентност и висока енергийна ефективност. Тези 5G характеристики създават възможности за иновации и нови пазари, като например мрежи с множество наематели, които включват многобройни случаи на употреба с разнообразни мрежови изисквания.

QoE в мобилните мрежи се отнася до мярката за общото ниво на удовлетвореност на крайния потребител от комуникационна услуга, докато QoS е мярка за оценка на производителността

на мрежата. QoS се отнася до техническите показатели, които представляват ключовите показатели за ефективност на мрежата (KPI) и включват параметри като честотна лента, загуба на пакети, латентност и трептене. Въпреки че параметрите на QoS влияят значително върху възприятието на крайния потребител за предоставяните услуги, те не могат директно да изразят възприеманото ниво на качество, както прави QoE, особено в силно разнородната екосистема на FWN.

## **Практическа приложимост**

Всички разработени методи и алгоритми, както и предложените подобрения към вече практически имплементирани такива, са изследвани и анализирани посредством както симулационни експерименти, така и в реална работеща тестова изследователска платформа. Направено е и сравнение с други такива в основата, на които са заложили подобни функционалности и характеристики, или имат сходни цели по отношение на подобрене на работните им параметри. Всичко това прави възможността за внедряване на резултатите от настоящия дисертационен труд непосредствени и лесно реализуеми.

## **Публикуване на резултатите от дисертационното изследване**

Направените анализи, предложените подходи и получените резултати за периода 2021÷2024 са представени в общо **8** авторски публикации индексирани в Scopus и Web of Science: **3** на *международни конференции*; **5** в *международни научни списания*, **3** от които в списания с ранг Q1. Забелязани са 33 цитирания в SCOPUS.

## **Структура и обем на дисертационния труд**

Дисертационният труд е написан на английски език и е в обем от **258** страници формат А4 и съдържа увод, десет глави, заключение с изложени основни приноси, списък на фигурите, списък на таблиците, списък на използваните съкращения, списък с публикациите по дисертацията, списък на използваната литература. Изложението на дисертационния труд съдържа **45** фигури, **32** таблици и **110** математически израза. Използвани са **440** литературни източници като всички са на латиница, над **80%** от които са от последните десет години. Номерата на фигурите и таблиците в автореферата съответстват на тези в дисертационния труд.

## II. СЪДЪРЖАНИЕ НА ДИСЕРТАЦИОННИЯ ТРУД

### 1. QoE-Aware безжични и мобилни мрежи

Нарастващият обем и хетерогенността на достъпните услуги в безжичните и мобилните мрежи налага натиск върху CSPs да разширят капацитета си за мониторинг и оценка на ефективността, по-специално по отношение на разбирането на ефективността на мрежата, както се възприема от крайните потребители. Моделът на проектиране, съобразен с QoE, позволява разбиране и анализиране на работата на мрежи и услуги от гледна точка на крайния потребител. В допълнение, мрежовите измервания, базирани на QoE, представляват ключов източник на знания за цялостната функционалност и управление на мрежата [1]. Концепцията за QoE има капацитета да се превърне в една от ключовите водещи рамки за контрол на качеството на мобилните мрежи. Тясно свързано със субективното изживяване на крайния потребител, QoE позволява по-широко, по-цялостно разбиране на променливите, които влияят на производителността на системата, допълвайки конвенционалните концепции, ориентирани към технологиите, като QoS [2].

### Предизвикателства при управлението на QoE

Дизайнът на FWN с акцент върху QoE ще постигне редица подобрения в сравнение с настоящите мрежи, включително гарантиране на цялостното удовлетворение на крайния потребител, независимо от предоставеното QoS, чрез непрекъснат мониторинг и откриване на всякакви влошавания в субективно възприеманото от крайния потребител качество, които могат да бъдат повлияни от фактори на средата, психологията или контекста. Общият принцип на осъзнаване на QoE при проектирането на мрежата трябва да бъде имплицитно поддържан във всички слоеве на функционалната архитектура и да вземе предвид субективния характер на възприеманото изживяване, като се има предвид, че се предполага, че 5G мрежите са присъщо ориентирани към потребителя. Ето защо е изключително важно за управлението на QoE да интегрира напълно прецизни механизми за мониторинг на QoE, фокусирани върху използването на прозрачно събиране и съхранение на данни в реално време, ефективни техники за големи данни и ML алгоритми за обработка на данни и мрежови функции, които ще осигурят оптимизиране на производителността на мрежата [6].

### Софтуеризиране на мрежата

Внедряването на мрежово софтуеризиране е разрешено от софтуерно дефинираната мрежа (SDN) и технологиите за виртуализация на мрежовите функции (NFV). Използвайки тези технологии, мрежовото софтуеризиране може да осигури програмируемостта, гъвкавостта и модулността, които са от съществено значение за FWN. Софтуерно базираната мобилна мрежова архитектура на 5G системите се очаква да осигури поддръжка на изискванията за мрежови услуги в рамките на предизвикателната среда на нововъзникващите сценарии за използване и освен това да благоприятства развитието на облачните изчисления и техните варианти на мъгла и крайни изчисления [24]. Софтуеризирането на мрежата се отнася до аспектите на проектиране, внедряване, архитектура, внедряване и експлоатация на мрежовата физическа инфраструктура чрез интерградиране и позволяване на пълното използване на софтуерните възможности. Софтуеризираната мрежа е в състояние да осигури необходимата гъвкавост и адаптивност и освен това да осигури развитието на автоматизирана реконфигурация на мрежата чрез прилагане на самоуправление и автоматизирани оперативни процеси [25]. Динамичното преконфигуриране на мрежата е необходимото средство за удовлетворяване на изискванията за QoS на различните случаи на употреба и е жизненоважно да се комбинира с надеждност от край до край (E2E), особено за критични комуникации [26].

### Софтуерно дефинирана мрежа

SDN се отнася до класа техники, който позволява динамичен и мащабируем дизайн, доставка и работа на мрежови услуги чрез директно програмиране, оркестриране, контролиране и управление на мрежовите ресурси. Ключовата характеристика на SDN е разделянето между контролната равнина и мрежовия хардуер и активирането на програмируемо външно мрежово управление чрез специален логически софтуерен компонент, SDN контролера. Архитектурата на SDN поддържа основните елементи на мулти-наем, като позволява обща физическа инфраструктура за ефективна поддръжка на множество клиентски мрежови екземпляри. Програмируемият SDN интерфейс позволява динамичен контрол и автоматизация на неговото създаване и работа и следователно позволява разработването на динамични NS [34].

### **Виртуализация на мрежовата функция**

NFV се отнася до софтуерно базирано внедряване на мрежови функции (NF), които работят върху количество хардуерни и софтуерни ресурси, което се нарича инфраструктура за виртуализация на мрежови функции (NFVI) и включва средата, в която се разработва NFV. NFs могат да бъдат внедрени без усилие и динамично присвоени в NFV среда, а мрежовите ресурси могат да бъдат ефективно разпределени чрез динамично мащабиране към виртуални мрежови функции (VNFs), така че да се реализира верижна функция на услугата (SFC) [42].

### **Мрежово нарязване**

Концепцията за разделяне на мрежи (NS) беше въведена от Алианса за мобилни мрежи от следващо поколение (NGMN) [50] и се състои в принципа за създаване и управление на множество независими логически мобилни мрежи върху обща физическа инфраструктура. Всяка от тези виртуални мрежи се нарича отрязък и е посветена на предоставянето на персонализирана мрежова услуга като независима бизнес операция със специфични изисквания за QoS. NS осигурява гъвкавост и мащабируемост в 5G мрежите и е необходимото средство за позволяване на съвместното съществуване на различни вертикални услуги с различни изисквания за QoS върху споделена физическа инфраструктура. NS може да се реализира чрез разделяне на физическа мрежа на множество логически мрежи, поддържащи персонализирани диференцирани приложения по заявка и използване едновременно на едни и същи физически мрежови ресурси за всяко приложение. Мрежовите ресурси, подпомагани от NS, могат да бъдат динамично и ефективно разпределени към логически мрежови срезове според необходимите изисквания за QoS [51]. Срезът може да се дефинира като изолирана колекция от програмируеми ресурси чрез софтуерни компоненти, които изпълняват отделни мрежови функции и приложни услуги. Жизненоважно за всеки срез е да може да побира отделни мрежови функции и приложни услуги, без да взаимодейства и да се намесва във функциите и мрежовите услуги на съвместно съществуващите срезове [52].

### **Open RAN**

Техниките на виртуализация позволяват логическо разделяне на ресурси като мрежи, изчислителен капацитет и съхранение, докато физическите ресурси се разпределят по динамичен и мащабируем начин. Виртуализацията на мрежата поддържа развитието на гъвкави системи за управление, ефективно използване на ресурсите и рентабилни и разнообразни приложения, чрез разполагане на различни възли и връзки на едно физическо оборудване [96]. Виртуализацията на клетъчна мрежа е насочена към няколко елемента от архитектурата на мрежата, включително инфраструктура, спектър, въздушен интерфейс, технологии за радио достъп и изчислителни ресурси, и осигурява предимства като ефективно използване на ресурсите, оптимизирана мрежова работа, по-проста миграция към нови технологии, по-ниски CAPEX /OPEX, по-високи приходи и създаване на нови пазари. Развитието на отворена RAN (O-RAN) технология, както се препоръчва от O-RAN Alliance, е една от ключовите перспективи във виртуализацията на RAN. O-RAN Alliance е консорциум от важни членове на телекомуникационната индустрия, включително оператори, доставчици, изследователски и академични институции и малки и средни предприятия (МСП), посветени на разработването на O-RAN решения, базирани на виртуализирани RAN елементи, хардуер с бяла кутия, софтуер с отворен код и стандартизирани оперативни съвместими интерфейси, които ефективно интегрират основите на O-RAN за интелигентност и отвореност [98].

### **Оптимизация на машинното обучение за подобряване на QoE**

QoE в безжичните мрежи е метрика, използвана за определяне на удовлетвореността на крайния потребител от производителността на комуникационните услуги и отразява истинското ниво на възприеманото качество. Въпреки че QoE зависи от QoS, конвенционалните методи за мрежово планиране и управление, които разчитат изключително на оптимизирането на KPI на мрежата за подобряване на качеството на услугата, са недостатъчни, за да отговорят на силно различаващите се изисквания на FWN. Конфигурацията и оптимизацията на мрежата, базирана на ML, обратно, има потенциала да увеличи максимално QoE на цялата мрежа, като същевременно отговаря на изискванията за обслужване и капацитета на мрежата [100]. Предложената рамка за подобряване на QoE, базирана на ML, е съсредоточена върху оптимизиране на производителността на мрежата в областите на управление на мрежовия трафик, разпределяне на радиоресурси, нарязване на мрежата, мониторинг на QoS и прогнозиране на QoE.

### **Дефиниране на проблема и формулиране на целта**

Концепцията за QoE е много широка и интердисциплинарна, тъй като се влияе от широк набор от фактори, принадлежащи към различни научни области. Следователно, разработването на ефективна оптимизационна рамка за осигуряване на задоволителни нива на QoE все още е открит изследователски въпрос. За да се справи с

това предизвикателство, тази теза работи за разработването на цялостна методология за подобряване на QoE, ориентирана към приложението, която се фокусира върху използването на предимствата, предлагани от алгоритмите за машинно обучение и Open RAN архитектурата. По-конкретно, целите на дипломната работа са следните:

- Проучване на най-съвременните подходи за интегриране на QoE информираност в безжични и мобилни мрежи.
- Осигуряване на цялостен анализ на управлението на QoE в мултимедийните комуникации и задълбочено изследване на специфичните аспекти за оценка на QoE за приложения за виртуална реалност и видео стрийминг на игри.
- Задълбочено изучаване на методологиите за машинно обучение.
- Предоставяне на цялостен преглед на най-съвременните QoE модели за прогнозиране, базирани на машинно обучение, за видео стрийминг, разширена реалност и приложения за видеоигри.
- Проучване и внедряване на безжични комуникационни мрежи, базирани на технологията Open RAN.
- Разработване на модел за прогнозиране на QoE за безжични приложения за виртуална реалност в Open RAN, използвайки енкодер-декодер дълга краткосрочна памет (LSTM).
- Разработване на модел за прогнозиране на QoE за стрийминг на видео игри в Open RAN, използвайки многоглава конволюционна невронна мрежа (CNN).
- Разработване на модел за прогнозиране на трафика на мобилна мрежа, използващ трансформатор на темпорален синтез (TFT).
- Разработване на модел за разпределение на ресурсите за подобряване на QoE на комуникациите във виртуална реалност, използвайки задълбочено обучение с подсилване.
- Разработване на модел за нарязване на мрежата за подобряване на QoE на мултимедийни комуникации в Open RAN.

## 2. Управление на QoE в мултимедийните комуникации

През последните години QoE привлече много внимание и беше признат за основен елемент при оценката на оперативната ефективност на мрежата. Бяха положени значителни изследователски усилия за разбиране, измерване и моделиране на QoE за редица мултимедийни комуникации. Подходът QoE има за цел да увеличи максимално възприеманото потребителско изживяване, като същевременно намали въздействието върху мрежовите ресурси, както и да подобри нивото на качество на мултимедийните комуникации, като същевременно поддържа ефективни и рентабилни мрежови операции [127].

### Дефиниция на QoE

Оценката на качеството стана все по-сложна, тъй като оперативната сложност на услугите и системите се увеличи, поради експоненциално нарастващия брой включени фактори. Тъй като QoS показателите не са пряко и изрично свързани с възприеманото удовлетворение от крайния потребител и цялостното изживяване с дадена услуга, за оценката на качеството са разгърнати ориентирани към потребителя показатели, наречени ключови индикатори за качество (KQI). По този начин QoE е субективен индикатор, който включва човешки параметри, тъй като свързва възприятието, очакванията и опита на клиентите с ефективността на приложението и мрежата, позволявайки по-цялостно разбиране на качеството, както го изпитват крайните потребители [23]. Според ITU-T [11] и Бялата книга на Qualinet [10] QoE отчита субективното възприятие и очаквания на потребителя към дадена услуга и може да се определи като „степен на удоволствие или раздразнение на потребителя на приложение или услуга. Това е резултат от изпълнението на неговите или нейните очаквания по отношение на полезността и/или удоволствието от приложението или услугата в светлината на личността и текущото състояние на потребителя" [10].

### Фактори, влияещи върху QoE

QoE е качествен индикатор за нивото на удовлетвореност на крайния потребител от мобилни услуги и приложения. QoE фактор на влияние (IF) се предписва като всяка функция на потребител, система, услуга, приложение или контекст, чието фактическо състояние или настройка може да повлияе на качеството на изживяването на потребителя. Факторите, които влияят върху QoE, могат да бъдат класифицирани като свързани с човека, свързани със системата и свързани с контекста [10]. Освен това беше добавена категория на влияещ фактор, свързан със съдържанието, за приложения за видео стрийминг [12].

- **Свързаните с човека IF** се отнасят до всеки вариант на атрибут на човешки потребител като мотивация, ниво на внимание и емоционално състояние или всяка неизменна черта като възраст, пол и острота на зрението и слуха. Демографският и социално-икономическият контекст, физическата и умствена конституция или емоционалното състояние на потребителя могат също да бъдат описани от свързаните с човека IF.
- **Свързаните със системата IF** се отнасят до въздействието на параметрите, които работят на техническо ниво. Те са свързани със свойства като забавяне, предаване, загуба на пакети, кодиране, съхранение, стратегии за буфериране на видео, системен хардуер, изобразяване и възпроизвеждане и показване на медии, които са свързани с мрежата за предаване, крайните устройства и приложението слой на комуникационна връзка.
- **Свързаните с контекста IF** отчитат факторите на околната среда, свързани с потребителя, като местоположението на потребителя, преходна информация като мобилност, социални фактори като присъствието или участието на други лица и целта на използване на услугата, като например за забавление или образование причини.
- **Свързани със съдържанието IF** вземат предвид отличителните характеристики на поточно видео, като скорост на кодиране, формат, разделителна способност, дължина на възпроизвеждане, качество на видеото и възраст, вид и популярност на видеото.

### **Субективна оценка на QoE**

Оценката на QoE може да се извърши с помощта на два метода: субективна и обективна оценка. Методиките за субективна оценка разчитат на получаване на информация от човешки оценители, които са подложени на различни тестове или стимули. По принцип група от оценители е подложена на различни степени на качество, което води до форма на явна или имплицитна реакция от тяхна страна. Обикновено се използват количествени подходи, произхождащи от свързани дисциплини, като психофизика и психометрия, за да се получи информация за оценките на оценителите, като се използват резултати, които характеризират тяхната осведоменост относно степента на качество, което са преживели. Освен това се използват и качествени подходи като фокус групи, интервюта или оценки на профили, особено за определяне кои IF допринасят за QoE и в какво качество. Субективните оценки обикновено се извършват в контролирана лабораторна среда и изискват щателно планиране на това кои променливи и IF трябва да бъдат включени в процедурата за оценка, мониторинг и контрол на качеството [134]. Обикновено оценителите оценяват редица аспекти на възприеманото качество по скала за средно мнение (MOS), числена стойност, варираща от 1 до 5 (т.е. лошо до отлично) [135] и докладват способността си да управляват услуга и нивото си на удовлетворение, чрез методи на проучване като интервюта, фокус групи и въпросници [13]. Стойността на MOS се изчислява чрез осредняване на оценките за качество на възприятието, получени от оценителите. Подходът за субективна оценка дава най-надеждните констатации благодарение на директното събиране на данни от крайните потребители. Основните недостатъци на методите за субективна оценка, от друга страна, произтичат от факта, че те са скъпи, отнемат време, не могат да се използват в реално време и не се повтарят. Поради тези ограничения се появи силна мотивация за внедряването на обективни методи, които предсказват субективното възприемано качество въз основа само на физически атрибути [23].

### **Обективна оценка на QoE**

Обективните модели се описват като метод за оценка на субективното качество само въз основа на обективни измервания на качеството [146]. Тези модели произвеждат оценка, която е близка до оценката, получена чрез субективни методи за оценка. Предимствата на обективния подход включват неговата лекота на прилагане и модифициране, тъй като изследователите трябва да се занимават само с измеримите QoS фактори и свързаните с тях математически модели. Недостатъкът на обективната оценка е нейната неточност, тъй като полученото QoE е приблизително, а не точната стойност на възприеманото качество на крайния потребител.

### **Модели на корелация QoE/QoS**

Оценяването на връзката между параметрите на QoS и техния индивидуален и взаимен ефект върху QoE изисква установяване на модел на корелация между QoE и QoS. Концепцията, залегнала в съпоставянето на QoS/QoE, е да се определят стойностите на QoE от колекция от измерими входни параметри. Обективните параметри на QoS се отнасят до KPI на мрежата. QoE може да бъде получено от тези показатели чрез процес на картографиране на QoS/QoE, който използва подходящи математически модели. Необходима е подходяща функция за картографиране, за да се преобразува обективното видео качество в прогнозирания субективен резултат в стойностите на MOS. Функциите за картографиране се класифицират като линейни и нелинейни. Функциите за



нелинейно картографиране обикновено предоставят значително по-силни корелации от техните линейни еквиваленти [23]. Логистиката, IQX хипотезата, законът на Вебер-Фехнер и степенният закон на Стивън са сред най-често използваните функции за картографиране в литературата [182].

*Таблица II.1: Фактори, влияещи върху QoE на виртуалната реалност*

Human factors	System factors				Context factors
	Content-related	Media/content-related	Network/transmission-related	Hardware-related	
Vision and hearing	Spatial audio	Compression	Delay	Head-mounted display	Physical context
Simulator sickness	Spatial depth (3D)	Video	Bandwidth	Headphones	Temporal context
Immersion	Spatiotemporal complexity	Audio	Loss	Decoder performance	Social context
Expectations and expertise		Storage and transport		Head-tracking	Task context
		Bitrate		Field of view	
		Resolution		Display resolution	
		Frame rate		Refresh rate	
		Audio sample rate			
		Coding delay			

### Специфични аспекти на оценката на QoE за приложения за виртуална реалност

Изобразено представяне на даден визуален и аудио сценарий се нарича VR. Наблюдател или потребител, който се движи в рамките на ограниченията на приложението, получава изобразените имитиращи визуални и слухови сензорни стимули на действителния свят възможно най-естествено. VR приложенията обикновено изискват използването на монтиран на главата дисплей (HMD), за да се замени изцяло зрителното поле на потребителя със симулиран визуален компонент, както и използването на слушалки, за да се предостави на потребителя свързаното аудио. Освен това обикновено се изисква известна степен на проследяване на главата и движението на потребителя, за да се позволи актуализирането на симулираните визуални и аудио функции, като се гарантира, че от гледна точка на потребителя обектите и източниците на звук остават в съответствие с движенията на потребителя. VR QoE IFs се категоризират като фактори за влияние върху човека, фактори за влияние върху системата (свързани със съдържание, свързани с медии/кодек, свързани с мрежа/предаване, свързани с хардуер) и фактори, влияещи върху контекста [212], както е показано в таблица 2.5.

### Специфични аспекти на оценката на QoE за видео приложения за игри

Освен аудио, видео и уеб сърфиране, онлайн видеоигрите, които работят през IP базирани мрежи, набират все по-голямо внимание и популярност. Оценяването на QoE на приложенията за онлайн игри е необходимо условие за управлението на услугите за игри [223] и доставчиците на игри се стремят да подобрят опита на своите потребители, като гарантират повишени нива на платформа и работа на предаване. Трудността при разбирането на QoE на игрите се дължи на това, че видеоигрите могат да се разглеждат като взаимодействие между хора и машини, а не като просто медийно осигуряване, следователно традиционните методологии за измерване на ефекта на предаване върху медийното осигуряване не се прилагат. Освен това, освен съдържанието на играта, бекенд платформата, върху която е изградена играта, потребителският интерфейс относно хардуера и софтуера, включените канали за предаване, както и атрибутите на потребителя, всички оказват влияние върху възприеманото от потребителя QoE. QoE IFs за видеоигри се категоризират като фактори за влияние върху човека, фактори за влияние върху системата (свързани с играта, свързани с устройство за игра, свързани с мрежа/предаване, свързани с компресия) и фактори, влияещи върху контекста [229], както е показано в таблица 2.6.

*Таблица II.2: Фактори, влияещи върху QoE на видеоигрите*

Human factors	System factors			Context factors
	Game-related	Playing device-related	Network/transmission-related	
			Compression-related	

Experience	Game genre	Device portability	Delay	Frame rate	Physical environment factors
Intrinsic and extrinsic motivation	Game mechanics and rules	Handheld device size	Jitter	Resolution	Social context
Static and dynamic human factors	Temporal and spatial accuracy	Input modalities	Bandwidth	Rate controller modes	Service factors
Human vision	Temporal and spatial video complexity	Output modalities	Packet loss	Group of pictures	Novelty
	Pace	Display		Motion range search	
	Visual perspective of the player			Audio compression	
	Aesthetics and design characteristics				
	Learning difficulty				

### 3. Машинно обучение в безжични комуникационни мрежи

ML се отнася до областта на компютърната теория, която позволява на алгоритмите да извличат модели директно от данни, без да се налага изрично да ги конструират, като правят изводи и оценки от входни проби [244]. ML е клон на изкуствения интелект (AI), който през последните години отбелязва несравнимо нарастване на използването му в приложения, които решават сложни проблеми и позволяват автоматизация в широк спектър от домейни, включително телекомуникационни мрежи. Това се дължи най-вече на огромните обеми налични данни, големия напредък в методите за машинно обучение и последния напредък в капацитета на изчислителните ресурси [245]. ML се използва в широк набор от изчислителни приложения, включително ефективни решения на проблеми, при които традиционните подходи изискват обширна фина настройка или дълги списъци с правила. Освен това, поради капацитета на ML алгоритмите да се адаптират към нови данни, ML методите могат да адресират серия от много сложни проблеми, които се намират в променливи изчислителни среди, за които традиционните подходи не предлагат жизнеспособни решения, а също и да придобият представа за огромни обеми от данни.

#### Учене под надзор, без надзор и за укрепване

Методите на ML се разделят въз основа на количеството и типа супервизия, която получават по време на обучението, както и дали обучаващият сигнал или обратната връзка са достъпни за учебната система в три категории, контролирано, неконтролирано и обучение с подсилване [246]:

- **Обучение под надзор (SL)**, където алгоритъмът предоставя примери за входните данни и очакваните от тях резултати. Предвидените отговори, наречени етикети, са част от набора от данни за обучение, подхранван от алгоритъм.
- **Неконтролирано обучение (UL)**, където алгоритъмът не включва никакви етикети, позволявайки моделът, възлътен във входните данни, да бъде открит сам, тъй като системата се опитва да се научи без помощта на инструктор.
- **Обучение с подсилване (RL)**, където се предоставя само обратна връзка за ефективността на алгоритъма в динамична настройка, по отношение на награди и наказания. Системата за обучение, наречена агент, след това трябва да научи за себе си оптималния метод, известен като политика, за да увеличи максимално възнаграждението с течение на времето.

#### Изкуствени невронни мрежи

Изкуствените невронни мрежи (ANN) се отнасят до техниките за изчислително моделиране, които са получили широко признание за моделиране на трудни проблеми от реалния свят в много области на приложение. ANN могат да бъдат определени като изчислителни структури, съставени от плътно свързани помежду си основни компоненти за обработка, известни като изкуствени неврони или възли, които могат да извършват огромен брой паралелни изчисления за прилагане на обработка на данни и представяне на знания [266]. ANN наподобяват взаимодействието между невроните в човешкия мозък по два начина: 1) мрежата получава знанията си от околната среда чрез процес на обучение и 2) силата на междуневронните връзки, а именно синаптичните тегла, се използват за запазване на придобитите знания [267].

#### Дълбоки невронни мрежи

Дълбоките невронни мрежи (DNN) са ANN с множество скрити слоеве между входния и изходния слой, за разлика от ANN само с един скрит слой, които се наричат плитки ANN [272]. Основната цел на DNN е да

апроксимират сложни функции чрез комбиниране на основни и специфични действия на единици или неврони. В зависимост от структурата на модела, функциите обикновено се определят чрез претеглена комбинация от определена колекция от скрити единици, които имат нелинейна функция за активиране. Тези процедури, в допълнение към единиците в изхода, се наричат слоеве. Следователно, DNN научава множество нива на представяне и абстракция чрез моделиране на абстракции на данни от високо ниво чрез множество нелинейни трансформации. Скорошният напредък в изчислителните възможности, широкото разполагане на данни за обучение на DNN и появата на ефективни методи за обучение на DNN са основните стимули, които улесниха преминаването от традиционни плитки ANN към DNN [274].

#### **4. Преглед на най-съвременните модели за прогнозиране на QoE за мултимедийни комуникации**

В тази глава е включен анализ и класификация на базирани на ML мултимедийни комуникационни подходи за прогнозиране на QoE. Процесът на прогнозиране на QoE на крайните потребители се състои от първия етап от оптимизирането на мултимедийната услуга за стрийминг. Освен това прогнозирането на QoE предлага по-задълбочен поглед върху начина, по който техническите параметри на комуникационната мрежа влияят върху качеството на услугата, както се възприема от крайните потребители. Класификацията на най-съвременните прогнозни модели е ориентирана към приложението, тъй като включва решения, включващи видео стрийминг, виртуална реалност и приложения за видео игри. Осигурен е задълбочен сравнителен анализ за всеки жанр на приложение, целящ да очертае разликата между конвенционалните услуги за видео стрийминг и нововъзникващите приложения за виртуална реалност и видеоигри, по отношение на диференциацията във факторите, които имат значително влияние върху QoE, както и както в показателите, използвани за оценка на QoE. Резултатите от този анализ показват, че прилагането на моделите за прогнозиране на QoE е разделено между използване на ANN и ML алгоритми. Точността на прогнозиране обаче се подобрява с използването на ANN и по-специално на DNN.

#### **5. Разработване на отворени мрежи за радиодостъп с отчитане на QoE**

Концепцията за отворена мрежа за радио достъп (O-RAN), въведена от алианса O-RAN, може да се счита за технология, променяща играта, показваща силни възможности за превръщане на мобилния RAN домейн към персонализирани решения, за да отговори на гореспоменатите разнообразни изисквания за използване на услуги случаи на FWN. O-RAN alliance е консорциум, оформен от сливането на cloud-RAN (C-RAN) съюза и xRAN форума. Целта му е да развие настоящите RAN топологии и да разгърне виртуализиран и напълно оперативно съвместим NG-RAN, базиран на два основни стълба: отвореност и интелигентност [98]. Основните принципи, върху които се основава O-RAN, включват виртуализирани RAN елементи, хардуер с бяла кутия, софтуер с отворен код, стандартизирани оперативно съвместими интерфейси, специфични API и използване на комерсиални хардуерни компоненти извън себе си (COTS). Съответно ползите от приемането на решения, базирани на O-RAN, включват ефективно използване на мрежови ресурси, оптимизирана работа на мрежата, по-проста и по-бърза миграция към нови технологии, по-ниски CAPEX и OPEX, по-високи приходи и създаване на нови пазари и бизнес модели.

##### **Архитектура на O-RAN**

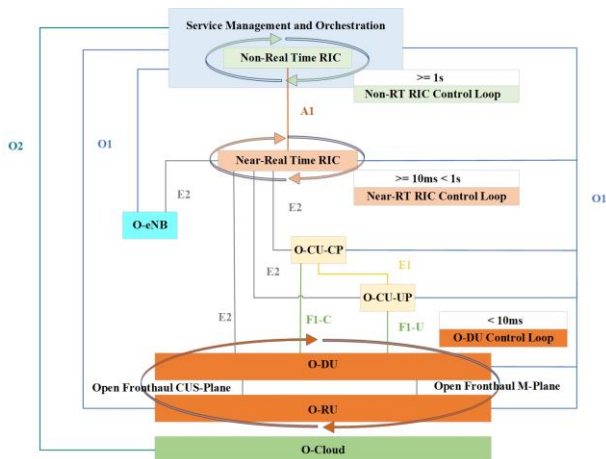
Както е показано на Фиг. 5.1, O-RAN архитектурата е структурирана около четири основни принципа: дезагрегиране на RAN елементи, интелигентно и затворено управление чрез управлявани интелигентни контролери (RIC), виртуализация и отворени интерфейси [341].

**Дезагрегацията** на RAN елементи разделя базовите станции (BS) на отделни функционални компоненти. Следващото поколение възел B (gNB) е разделен на три компонента: централно устройство (CU), разпределено устройство (DU) и радио устройство (RU), които се наричат O-CU, O-DU и O-RU в спецификациите на O-RAN. CU е подразделен на два логически компонента, един за контролната равнина (CP) и един за потребителската равнина (UP), съответно като O-CU-CP и O-CU-UP. Това логическо разделяне позволява различни операции да бъдат изпълнявани в отделни части на мрежата и на различни хардуерни платформи.

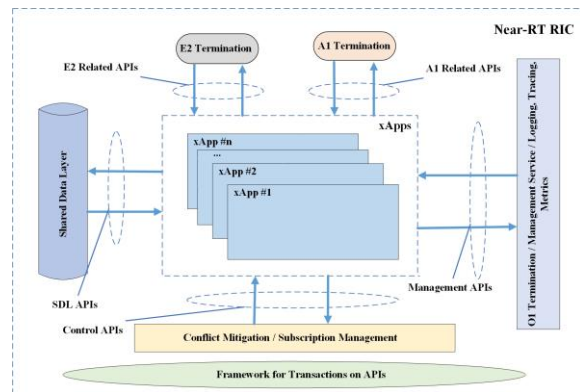
**RAN интелигентните контролери** са програмируеми елементи, способни да изпълняват рутинни процедури за оптимизация при затворен цикъл на управление и да организират RAN операциите. O-RAN Alliance разработи

спецификации за RIC в нереално време (non-RT RIC), който взаимодейства с мрежовия оркестратор и функционира във времева скала, по-голяма от 1 s, както и RIC в почти реално време (близо до -RT RIC), който изпълнява контролни вериги във времева скала, варираща от 10ms до 1s. Не-RT RIC е съставна част на единицата за управление и оркестрация на услугата (SMO) и поддържа почти RT RIC за интелигентно управление на RAN и функции за оптимизация. Не-RT RIC използва контролната верига не в реално време, за да управлява и обучава ML моделите, които ще бъдат изпълнени в почти RT RIC. Освен това RIC, който не е RT, може да повлияе на SMO операциите, позволявайки на почти RT RIC индиректно да администрира всички елементи на O-RAN архитектурата, свързани с SMO, като предприема действия и налага политики. Почти RT RIC е внедрен на ръба на мрежата и взаимодейства с DU и CU, заедно с наследени O-RAN-съвместими дългосрочно развитие (LTE) еволюирани възлови бази (eNB). Почти RT RIC се състои от няколко приложения, наречени xApps, както и услугите, необходими за активиране на изпълнението и оркестрацията на xApps. xApp е микроуслуга, която може да управлява радио ресурси, използвайки стандартизирани интерфейси и модели на услуги [346].

**Виртуализацията** представя нови елементи за управление и оптимизиране на мрежовите операции и инфраструктура. Виртуализацията позволява платформи с отворен облак (O-Cloud) и техники за изчисления в облак да бъдат използвани за инсталиране на компонентите на O-RAN архитектурата. Физическите възли, софтуерните елементи, включително операционната система и хипервайзорите на виртуалната машина, както и операциите за управление и оркестрация, могат да бъдат комбинирани и виртуално внедрени за O-RAN в O-Cloud платформа [348]. По-специално, виртуализацията дава възможност за: 1) отделяне на хардуерни и софтуерни компоненти; 2) стандартизиране на хардуерните възможности за O-RAN инфраструктурата; 3) споделяне на хардуер между различни наематели; и 4) автоматизиране внедряването и конфигурацията на RAN операции.



**Фигура II.1:** O-RAN логическа архитектура и контролни вериги [345].



**Фигура II.2:** Вграждане на xApps в почти RT RIC [354].

**Отворените интерфейси** насърчават иновациите, позволяват по-бързи цикли на актуализиране и надграждане и улесняват изграждането и интегрирането на нови виртуализирани елементи в RAN екосистемата [345]. Техническите спецификации за отворени интерфейси, свързващи множество части на O-RAN архитектура, са издадени от O-RAN Alliance. Стандартизирането на тези интерфейси е решаваща първа стъпка в разрешаването на оперативната съвместимост на CU, DU и RU от различни производители, както и позволяването на почти RT RIC от един доставчик да комуникира с BS от друг доставчик. Освен това O-RAN архитектурата може да бъде внедрена чрез избиране на няколко мрежови местоположения, включително облачни, крайни и клетъчни сайтове за различни видове оборудване и използване на различни конфигурации, поради отворените интерфейси.

### QoE-Awareness за O-RAN

Предвидените сценарии за използване на 5G на подобрена мобилна широколентова връзка (eMBB) и свръхнадеждни комуникации с ниска латентност (uRLLC) са съответно особено изразходващи честотна лента и чувствителни към латентност. Текущите високотелни интерактивни приложения, като онлайн видео стрийминг, мултиплейър игри и свързани превозни средства, обикновено се обслужват по най-добрия начин, без оптимизация, ориентирана към приложението. За да могат тези приложения да отговарят на различни изисквания за QoE, е необходимо да се разработи по-холистичен подход в работата на мрежата. Ориентираното към приложения прогнозиране на QoE и управляваната от QoE проактивна мрежова оптимизация в затворен цикъл в реално време могат да помогнат за подобряване на QoE. AI/ML моделите могат да бъдат разработени за

оптимизиране на QoE, като се възползват от софтуерно дефинирания RIC и отворените интерфейси на O-RAN. Тези модели могат да събират и обработват многоизмерни данни, за да поддържат операции като управление на трафика и прогнозиране на QoE и да налагат QoS решения в близък цикъл [9]. Разработването на автоматизиран контрол на правилата за QoS/QoE поведение позволява на мрежовите оператори да настройват фино поведението в реално време. Подходящата мрежова конфигурация в отговор на изискванията за QoE може да бъде постигната чрез диктуване на политика и контрол от не-RT RIC и почти RT RIC съответно, под формата на gApps и xApps [344].

### **Вграждане на AI/ML в O-RAN с xApps**

Използването на AI и ML техники се очаква да бъде катализатор в дизайна на FWN, като предоставя решения на много сложни проблеми на широк диапазон от нива, включително PHY слой, MAC слой, RRM и RAN OSS [352]. Подпомаганите от AI/ML решения в O-RAN попадат в трите типа контролни вериги, както е показано на Фиг. 5.1 [345]: 1) верига 1 контролира планирането на нивото на времеви интервал на предаване (TTI) и работи в TTI времева скала (< 10 ms); 2) контур 2 е позициониран в почти RT RIC, работи в диапазона от 10-500 ms и извършва оптимизация на ресурса; и 3) контур 3 е позициониран в не-RT RIC, работи във времева скала, по-голяма от 500 ms, и управлява политики и оркестрация. Операциите, свързани с AI/ML, могат да бъдат разпределени в трите цикъла и да се изпълняват паралелно. Съгласно конкретния сценарий на използване, мястото за обучение на ML модел зависи от изчислителната сложност, наличността на данни, изискванията за време за реакция и типа на ML модела.

Почти RT RIC може да хоства множество xApps, работещи паралелно на API, както е показано на фиг. 5.2. xApps могат да се свързват през интерфейсите A1 и E2 и да управляват RAN операции с помощта на ML модели. Резултатите от xApps се координират чрез използване на смекчаване на конфликти и управление на абонаменти. Работата на xApps изисква координация за изискванията за време и мониторинг за правилна конфигурация, балансирана обработка на ресурси и обработка на съобщения. Използването на xApps позволява на не-RT RIC да приеме модулен подход, тъй като всяко xApp съдържа различен ML модел. xApps може или да събира данни за по-нататъшна обработка, или да прилага промени в мрежовата функция [354].

## **6. QoE прогнозиране за приложения за виртуална реалност в Open RAN**

В тази глава се предлага обективен модел за прогнозиране на QoE за VR 360-градусов видео стрийминг, поддържан от методологии за дълбоко обучение. По-конкретно, моделът за прогнозиране се основава на енкодер-декодер LSTM DNN, който се прилага към Open RAN безжична мрежа, базирана на O-RAN архитектурата и спецификациите. Целта на модела за прогнозиране е да определи количествено в реално време ефекта от работата на безжичната мрежа върху качеството на VR услугата, както се възприема от крайните потребители. Оценката на QoE може да се класифицира като обективен метод, тъй като моделът за прогнозиране е в състояние да предскаже общата стойност на QoE, използвайки само измерими параметри на QoS. Тези параметри на QoS, които са KPI на мрежата, се събират и записват с помощта на система за мониторинг на QoS, базирана на инструменти за мониторинг с отворен код. Моделът за прогнозиране картографира събраните стойности на KPI на мрежата, а именно честотна лента, забавяне и загуба на пакети, към MOS стойности, а мрежата на енкодер-декодер LSTM изследва взаимозависимостите между тях, за да определи общата стойност на QoE за VR 360-градусово видео стрийминг услуга.

### **QoE оценка на виртуалната реалност**

Възприеманото качество на приложение или услуга от крайните потребители се определя от мярката QoE. Следователно, в контекста на мобилните и безжичните мрежи, QoE изразява как работата на мрежата влияе върху възприеманото качество на комуникационните услуги. Оценката на QoE се основава на съпоставянето на планираните качествени характеристики, които определят очакванията на потребителя с възприеманите характеристики, произтичащи от естествен стимул. Потопящите приложения представят някои особености в оценката на QoE, които се фокусират главно върху самото изживяване, както и върху IFs [10]. В потопящите приложения следното може да има важно въздействие върху QoE: 1) „усещането за присъствие“, което се отнася до усещането за въплъщение във VR среда; 2) „мястото на илюзията“, което позволява на потребителите да възприемат виртуалните обекти като реални; и 3) взаимодействието между потребителя и VR средата [356]. В литературата се споменават два метода за оценка на QoE: субективна и обективна оценка. Субективните модели използват човешки оценители, които оценяват качеството на услугата, след като са били изложени на серия от

тестове или стимули. Обратно, обективните модели улавят възприеманото от крайните потребители качество, като използват само обективни показатели за качество.

### **Фактори, влияещи върху QoE на мрежата/преноса**

Услугата за безжично VR 360-градусово видео стрийминг изисква предаване на огромно количество многопосочно видео съдържание с изключително ниска латентност. Също така, за да създадете наистина завладяващи VR изживявания, способността за плавно предаване на VR видео с висока разделителна способност и хаптична обратна връзка е от решаващо значение. Следователно параметрите на мрежата/предаване на латентност, честотна лента и загуба на пакети играят важна роля за поддържане на завладяващи преживявания [212].

- 1) **Забавяне:** VR приложенията трябва да отговарят на строги изисквания за латентност, за да предоставят наистина завладяващо изживяване. Най-често срещаните форми на латентност включват забавяне на опашката, забавяне по въздуха, забавяне на буфера и забавяне на движение към фотон. Забавянето засяга атрибути като начално време за зареждане и забавяне, причинявайки лошо качество на представяне. Тъй като човешкото възприятие изисква точни и безпроблемни визуални стимули, VR трябва да се третира като приложение с критично значение за латентността, като латентността е най-важното IF, тъй като води до дисоциирани VR преживявания и може да влоши болестта на симулатора [363].
- 2) **Широчина на честотната лента:** Количеството необходими данни за създаване на завладяващи изживявания в VR 360-градусова среда за поточно видео е значително. Следователно, ако необходимата честотна лента не бъде осигурена по време на предаване, качеството на настройката на VR ще се влоши. Следователно претоварването може да доведе до значителна загуба на пакети и прекомерно забавяне, понижавайки възприеманото качество на услугата VR [212]. Мрежовата честотна лента се определя като пропускателната способност, необходима за предаване на VR 360-градусово видео и може да се разглежда като един от най-важните аспекти, засягащи VR приложение [363].
- 3) **Загуба на пакети:** Схемата за предаване определя как загубата на пакети влияе върху създаването на завладяващи VR изживявания. При надеждни режими на предаване необходимите повторни предавания на пакети поради загуба на пакети увеличават общото забавяне. При ненадеждни режими на предаване, аудиовизуалното качество се влошава поради загуба на пакети, което причинява замръзване на видеото и артефакти на плочки [212].

### **Картографиране на QoS/QoE**

Идеята зад картографирането на QoS/QoE е да се извлекат стойности на QoE въз основа на измерими входни параметри. За да се определи връзката между параметрите на QoS и тяхното различно и реципрочно влияние върху QoE, трябва да се създаде модел на корелация. Параметрите на QoS са свързани с оперативното качество на комуникационната мрежа и се отнасят до KPI на мрежата. В процеса на картографиране на QoS/QoE стойността на QoE може да бъде изчислена от тези параметри, като се използват подходящи математически модели, както е анализирано в параграф 2.5.

### **Модел за прогнозиране на QoE**

Предложеният модел за прогнозиране на QoE се основава на енкодер-декодер LSTM DNN, приложен към експериментална безжична мрежа в малък мащаб, изградена на Open RAN технология. Системата за мониторинг на QoS е разработена от страна на потребителя с помощта на инструменти за мониторинг с отворен код. Уловените атрибути на QoS за честотна лента, латентност и загуба на пакети се подават в модела за картографиране на QoS/QoE, който ги картографира към MOS стойности. И накрая, моделът за прогнозиране на енкодер-декодер LSTM изследва взаимозависимостите между картографираните входни стойности, за да определи общата стойност на QoE.

### **Тестова платформа Open RAN**

Експерименталната мрежа Open RAN е изградена върху малък тестов стенд, поддържащ 4G архитектурата, както и 5G non-standalone (NSA) архитектура, която използва комбинация от наследената 4G инфраструктура за дългосрочно развитие (LTE) с 5G RAN. Базиран е на OpenAirInterface (OAI), софтуерен пакет с отворен код, който поддържа 3GPP архитектури на многофункционално x86 компютърно оборудване и COTS софтуерно дефинирани радио (SDR) системи като универсални софтуерни радио периферни устройства (USRP) [364]. Тестовият стенд поддържа три типа eNB архитектури (монолитна, разделена опция 2 и разделена опция 7.2), един тип gNB архитектура (монолитна) и еволюирало пакетно ядро (EPC) [99]. EPC е контейнеризиран с помощта на

докер технология, докато RAN е разположен на голо метално ниво. Всички мрежови елементи обаче са разположени на един и същ физически хардуер, персонален компютър (PC), оборудван с 64 GB RAM и процесор Intel i9 3,6 GHz. За eNB архитектура предаването е конфигурирано в режим на дуплексиране с разделяне на честотата (FDD) с 20 MHz честотна лента в лента 7, докато за архитектура gNB предаването е конфигурирано в режим на дуплексиране с разделяне на времето (TDD) с 40 MHz честотна лента в лента n78.

#### **Наблюдение на QoS и генериране на набор от данни**

Системата за мониторинг на QoS за улавяне на параметрите на мрежата/предаване на честотна лента, латентност и загуба на пакети е изградена върху инструментите за мониторинг на Prometheus, Telegraf и Grafana. Наборът от данни за обучение на невронната мрежа е генериран чрез наблюдение на параметрите на QoS за честотна лента, латентност и загуба на пакети по време на безжично предаване на VR 360-градусови видеоклипове в YouTube. Системата за мониторинг на QoS събра данни от ноември 2022 г. до януари 2023 г., използвайки различни натоварвания за поточно видео. Периодът на наблюдение продължи общо 8 седмици и стойностите на честотната лента на мрежата, забавянето и загубата на пакети бяха събрани с 1-минутен интервал на измерване, давайки общо 80 640 проби от данни за всеки QoS параметър. 360-градусовите VR видеоклипове на YouTube, подобно на повечето днешни комерсиални VR приложения, принадлежат към фазата преди VR и имат съответните мрежови изисквания [367]. За да създадем представителен набор от данни, използвахме комбинация от 360-градусови VR видеоклипове с ниско, средно и силно движение. Техническите спецификации на тези видеоклипове са както следва: резолюция 3840x2160 пиксела (4K UHD), кадрова честота 30 FPS, битрейт на видео 45 Mbps, MP4 контейнер и H.264 видео кодиране.

#### **Модел на картографиране на QoS/QoE**

За да се създаде моделът за картографиране на QoS/QoE, методите за картографиране на логистиката, IQX, WFL и SPL бяха приложени към измерванията на мрежовите QoS параметри. Да се построи приблизителна крива  $y = f(x)$  който най-добре пасва на дискретния набор от точки за измерване  $(x_i, y_i)$ , където  $i = 1, 2, 3, \dots, n$ , беше използвана методологията за напасване на кривата. По-конкретно, беше използван методът на най-малките квадрати, който е един от най-широко използваните методи за намиране на кривата на най-добро прилягане към даден набор от данни [368]. Метриците MSE и  $R^2$  бяха използвани за оценка на точността на напасване на кривата.

#### **Модел за прогнозиране на задълбочено обучение**

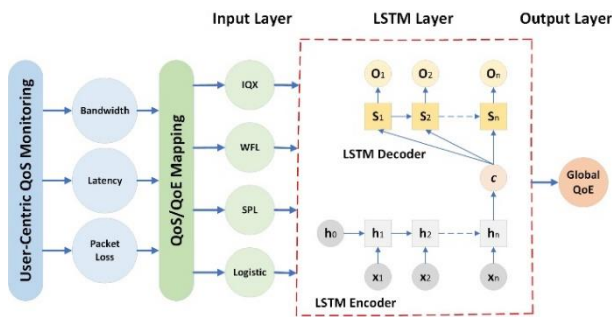
За разработване на модела за предсказване на задълбочено обучение бяха използвани TensorFlow и Keras. Реализацията на предложения модел използва многостъпков енкoдер-декодер LSTM с многовариантен вход. Както е показано на фиг. 6.6, многовариантният вход се състои от картографираните стойности на честотната лента, латентността и загубата на пакети. Скрытият слой е изграден върху енкoдер-декодер LSTM, подкатегория на LSTM, предназначена за решаване на проблеми с последователност. В този случай измерванията на QoS от предходните 2 дни се използват за прогнозиране на QoE на следващия ден. Мрежата на енкoдер-декодер LSTM изследва взаимозависимостите между входните стойности, за да определи глобалната стойност на QoE в изходния слой. Фиг. 6.7 показва диаграма на пълната архитектура на тестовата среда в малък мащаб, включително мрежата Open RAN, системата за мониторинг на QoS и модела за прогнозиране.

#### **Оценка на модела за прогнозиране**

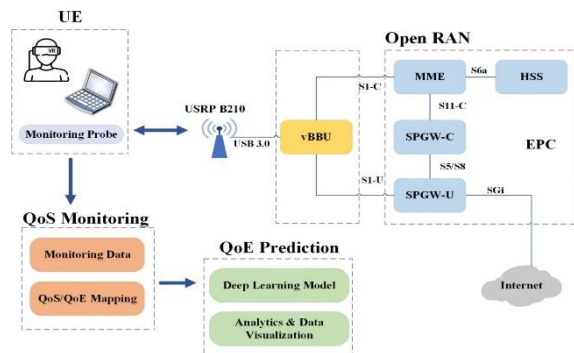
Предложеният модел за предсказване на енкoдер-декодер LSTM се сравнява с най-значимите и широко използвани невронни мрежи в категорията RNN, включително SimpleRNN, LSTM, автоенкодер LSTM, двупосочен LSTM и затворена рекурентна единица (GRU). При подготовката на данните наборът от данни беше повторно изваден, тъй като невронните мрежи, принадлежащи към класа LSTM, са най-ефективни, когато обработват проби като единични последователности от наблюдения, които не надвишават 400 времеви стъпки. Следователно входните данни за минута бяха повторно взети като почасови проби, като се получи общо 1344 проби. Моделът за прогнозиране е оформен като многовариантен, многостъпков модел за прогнозиране на времеви серии, който прогнозира стойностите на QoE за следващия ден въз основа на наблюденията от последните 2 дни. По-конкретно, 48-часови проби (2 дни  $\times$  24 часа) се използват като времеви стъпки назад за прогнозиране на QoE на следващите 24 времеви стъпки (1 ден  $\times$  24 часа). Моделът за прогнозиране има 12 входни последователности, които съответстват на картографираните параметри на QoS и 1 изход, който дава глобалната стойност на QoE на безжичната мрежа.

### Сравнителна оценка на моделите за прогнозиране

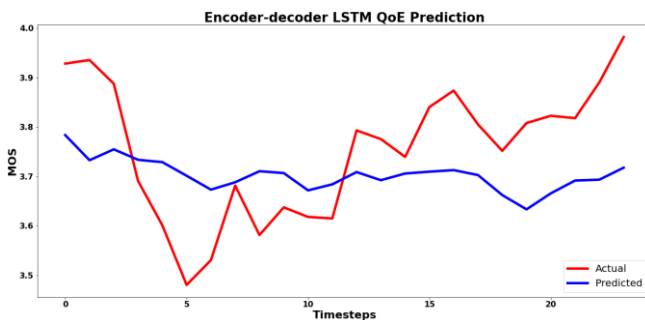
8-те седмици на мониторинг на QoS дадоха общо 56 дни наблюдения. Тези 56 дни бяха разделени, както следва: 38 дни бяха използвани като набор от данни за обучение, 9 дни като набор от данни за тест и 9 дни бяха запазени като набор от данни за валидиране. По време на компилирането на моделите бяха използвани обратните извиквания на Keras за подобряване на ефективността на обучението. По-специално, ModelCheckpoint бяха използвани за запазване на теглата на модела на конкретни времеви стъпки, EarlyStopping за спиране на процеса, когато наблюдаваният показател за оценка спре да се подобрява, и ReduceLROnPlateau за минимизиране на скоростта на обучение, след като наблюдаваният показател вече не се подобрява. За да се оцени точността на моделите за прогнозиране, бяха използвани показателите RMSE, MAE, MAPE, MSE и MedAE. Резултатите от показателите за точност на прогнозата са представени в таблица 6.4. Можем да забележим, че предложеният енкодер-декодер LSTM модел превъзхожда останалите модели, като постига по-добри резултати във всички показатели за точност. Струва си да се отбележи, че всички модели за прогнозиране се представят значително по-добре от наивния модел и че разликите между тях са малки, като по този начин потвърждават ефективността на моделите от клас RNN при обработката на приложения за данни от времеви серии. Резултатите от прогнозата на QoE за следващия ден спрямо стойностите на набора от данни за валидиране от предходните 2 дни са изобразени на Фиг. 6.9. Прогнозата за следващия ден съответства на 24 стъпки напред във времето, а базата за валидиране на предходните 2 дни съответства на 48 стъпки назад.



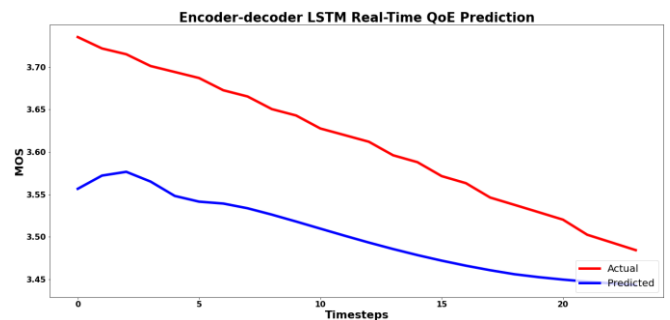
Фигура II.3: Архитектура на модела за прогнозиране на QoE за дълбоко обучение.



Фигура II.4: Пълна архитектура на тестовия стенд.



Фигура 6.9: Представяне на действителна спрямо прогнозирана стойност на VR QoE.



Фигура II.5: Представяне на прогнозиране на VR QoE в реално време спрямо действителни стойности.

Таблица II.3: Оценка на прогнозния модел на VR QoE.

	MSE	RMSE	MAE	MAPE (%)	MedAE
Naive	0.29636	0.54439	0.49610	15.2277	0.46343
Simple RNN	0.04126	0.20312	0.17529	4.68265	0.17242
LSTM	0.03383	0.18395	0.15186	4.08651	0.13727
Autoencoder LSTM	0.03134	0.17704	0.14987	4.05443	0.14518
Bidirectional LSTM	0.029015	0.17033	0.13958	3.81615	0.12350
Encoder-decoder LSTM	<b>0.02541</b>	<b>0.15943</b>	<b>0.12491</b>	<b>3.42698</b>	<b>0.09981</b>
GRU	0.02767	0.16361	0.13198	3.63324	0.10320



### Прогноза за QoE в реално време

Обучените модели се използват за прогнозиране на QoE в реално време, както е показано на Фиг. 6.10, където можем да наблюдаваме прогнозирането на стойностите на QoE за 24 напредващи времеви стъпки. Предсказаните стойности на QoE са изобразени спрямо действителните стойности на QoE, които се основават на мониторинг на QoS в реално време и картографиране на QoS/QoE. По-конкретно, експерименталното събиране на данни обхваща 4-часов период от време на наблюдение на параметрите на QoS на VR 360-градусов видео поток през Open RAN testbed, давайки общо 240-минутни проби. Тези проби се използват като стъпки назад във времето за оценка на точността на прогнозата за QoE в реално време и са наборът от данни, спрямо който се потвърждава способността на модела да се обобщава добре към нови данни. Както е показано в таблица 6.6, предложеният модел LSTM на енкoder-декодер превъзхожда моделите за прогнозиране на SimpleRNN, LSTM, автоенкодер LSTM, двупосочен LSTM и GRU, като постига най-добрия резултат във всички показатели за точност. Можем да наблюдаваме, че резултатите за точността на прогнозиране на QoE в реално време за всички модели са намалени в сравнение с резултатите по време на оценката на модела. Това се дължи на малкия размер на експерименталния набор от данни в реално време, който влияе върху присъщата вариация на входните данни, което води до по-голяма вътрешна вариация на набора от данни за обучение в сравнение с набора от данни за валидиране. Моделът на енкoder-декодер LSTM превъзхожда останалите модели за прогнозиране, тъй като показва по-голяма способност да работи с малки набори от данни. Точността на прогнозиране на моделите се подобрява с увеличаване на размера на набора от данни, но ние искахме експериментално да тестваме ефективността на моделите в условията на приложение в реалния свят.

Таблица II.4: Оценка на прогнозния модел на VR QoE в реално време.

	MSE	RMSE	MAE	MAPE (%)	MedAE
Simple RNN	0.54320	0.73702	0.50636	21.9287	0.32311
LSTM	0.47626	0.69011	0.46084	20.1354	0.26658
Autoencoder LSTM	0.52514	0.72466	0.53395	22.3827	0.40065
Bidirectional LSTM	0.56478	0.75152	0.55616	23.2374	0.43710
Encoder-decoder LSTM	<b>0.43370</b>	<b>0.65856</b>	<b>0.42022</b>	<b>18.7329</b>	<b>0.24058</b>
GRU	0.51687	0.71894	0.48108	20.9888	0.26736

## 7. Прогнозиране на QoE за видео стрийминг на игри в Open RAN

В тази глава е представен базиран на задълбочено обучение обективен модел за прогнозиране на QoE за приложения за стрийминг на видео игри. Моделът за прогнозиране се основава на персонализирана многоглава конволюционна невронна мрежа (многоглава CNN), приложена към O-RAN-съвместима безжична комуникационна мрежа. Целта на модела за прогнозиране е да се измери влиянието на работата на безжичната мрежа върху качеството на игралното видео, както се възприема от крайните потребители в реално време. Тъй като моделът за прогнозиране може да прогнозира стойността на QoE, свързана с мрежата/преноса, като използва чисто количествено измерими QoS фактори, оценката на QoE може да бъде категоризирана като обективна. Параметрите на QoS за честотна лента, лагентност, загуба на пакети и трептене се улавят и записват от система за наблюдение на QoS, проектирана с инструменти за наблюдение с отворен код. Моделът за прогнозиране първо преобразува събраните параметри на QoS в MOS стойности, а след това многоглавата мрежа на CNN анализира взаимозависимостите между тях, за да извлече общата стойност на QoE за услугата за безжично видео стрийминг на игри. Доколкото е известно на автора, това е първото проучване за измерване и прогнозиране на QoE на поточно видео от игри през Open RAN. Освен това, той дава за първи път сравнителен анализ на DNN алгоритми за този вид приложение.

### Оценка на QoE за видео игри

Фактор, допринасящ за трудността при разбирането на механизма за QoE на видео игрите, е, че игрите, за разлика от конвенционалните медийни приложения, могат да се разглеждат като взаимодействие човек-машина. Следователно типичните подходи за оценка на влиянието на предаването върху медийното разпространение не са приложими. Освен това, в допълнение към съдържанието, бекенд платформата, на която е разработена играта, потребителските интерфейси, безжичният комуникационен канал и потребителските функции, могат значително да повлияят на QoE [224].

## Фактори, влияещи върху QoE на мрежата/преноса

Безжично видео поточно предаване на игри и по-специално приложенията за игри в облак изискват обширни интернет ресурси при свързване между клиент и сървър. Поради необходимостта от обмен на огромно количество мултимедийни данни със сървър, безжичната връзка на потребителя трябва да може да изпраща тези данни с възможно най-малко забавяне [377]. Следователно, тези типове приложения са по-податливи на параметрите на QoS на мрежата, което налага осигуряването на набор от изисквания за латентност, трептене, честотна лента и загуба на пакети, за да се постигне оптимално QoE.

- 1) **Забавянето**, възприемано от крайния потребител, е свързано с интервала от време от изпълнението на командите на потребителя до появата на последващото игрово събитие на екрана. Следователно въздействието на забавянето върху QoE е силно повлияно от характеристиките на играта.
- 2) **Трептене** има забележимо влияние върху QoE на приложенията за онлайн и облачни игри. Наличието на трептене предизвиква неравномерно визуално впечатление от играта, тъй като поради ефекта му показването на видео кадри се случва с променлива латентност.
- 3) Въздействието на **ограничението на честотната лента** върху QoE се оказва особено важно за приложенията за облачни игри, тъй като те разчитат на стрийминг на съдържание за игри в реално време. Това изисква последователен и високоскоростен трансфер на данни, за да се осигури плавен геймплей. Ограниченията на честотната лента могат да доведат до буфериране, по-ниска разделителна способност и повишена латентност, което оказва отрицателно въздействие върху QoE.
- 4) **Загубата на пакети** оказва значително влияние върху QoE в приложенията за игри, обикновено с нива от едва 1%, което води до важен спад в изживяването на крайния потребител. Прекомерната загуба на пакети намалява визуалното качество, което води до по-ниска честота на кадрите и лошо игрово изживяване.

## Картографиране на QoS/QoE

Принципът на работа на съпоставянето на QoS/QoE е да се изчисли QoE, като се използват само преброими стойности на мрежовите QoS параметри. За да се определи връзката между тези параметри и нивото на QoE, е важно да се създаде модел на корелация. Целта на този модел е да изчисли стойностите на QoE с помощта на подходящи математически модели, както е анализирано в параграф 2.5.

## Модел за прогнозиране на QoE

Предложеният модел за прогнозиране на QoE се основава на многоглава CNN и се прилага към експериментална безжична мрежа в малък мащаб, създадена с помощта на технологията Open RAN. Системата за наблюдение на QoS от страна на потребителя е изградена с инструменти за наблюдение с отворен код. Събраните атрибути на QoS за честотна лента, забавяне, загуба на пакети и трептене се предоставят на модела за картографиране на QoS/QoE, който ги картографира към MOS стойности. И накрая, за да изчисли общата стойност на QoE, многоглавият модел за прогнозиране на CNN анализира взаимозависимостите между картографираните входни стойности.

## Тестова платформа Open RAN

Реализацията на Open RAN работи в малък тестов стенд, както е описано в 6.4.1.

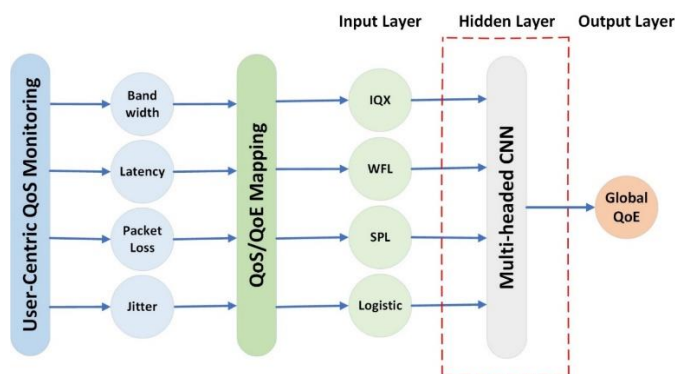
## Наблюдение на QoS и генериране на набор от данни

Системата за мониторинг на QoS използва инструментите за мониторинг с отворен код на Prometheus, Telegraf и Grafana за събиране на мрежови/предавателни показатели за честотна лента, трептене, латентност и загуба на пакети. Тя може да бъде класифицирана като система за наблюдение на QoS, ориентирана към потребителя, тъй като параметрите на мрежата/преноса се събират от страна на потребителя, като се използват сонди на устройството на крайния потребител, за да се осигурят показатели на ниво приложение. Наборът от данни за обучение на невронната мрежа беше генериран чрез наблюдение на параметрите на QoS по време на безжично предаване на видеоклипове за игри в YouTube. Данните бяха събрани с помощта на различни зареждания на поточно видео от ноември 2022 г. до януари 2023 г. Периодът на наблюдение беше общо 8 седмици и данните бяха събрани с интервал на измерване от 1 минута, което доведе до общо 80640 проби от данни за всеки QoS параметър. Използвани са видеоклипове с резолюция 1440p / 60fps.

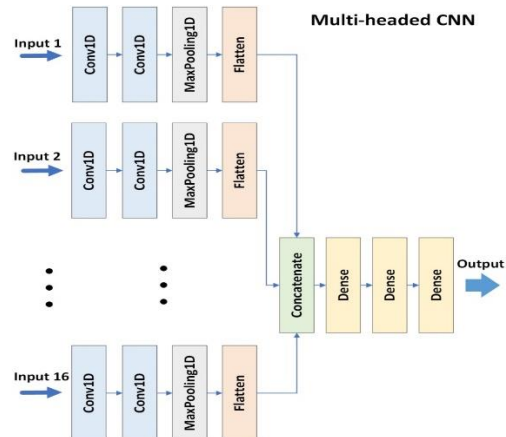
## Модел на картографиране на QoS/QoE

За да се изгради моделът за картографиране на QoS/QoE, методите за картографиране на логистиката, IQX, WFL и SPL се прилагат към измерванията на мрежовите QoS параметри. За получаване на приблизителна крива  $y =$

$f(x)$  който най-добре пасва на дискретния набор от точки за измерване  $(x_i, y_i)$ , където  $i = 1, 2, 3, \dots, n$ , използван е методът за напасване на кривата. По-специално беше възприет методът на най-малките квадрати.



**Фигура II.6:** Архитектура на модела за прогнозиране на QoE за задълбочено обучение.



**Фигура II.7:** Структура на многоглавата CNN.

### Модел за прогнозиране на задълбочено обучение

Разработването на модела за прогнозиране на QoE се основава на CNN. Подклас на CNN архитектурата е CNN моделът с множество глави, в който отделен CNN подмодел или отделна глава се използва за всяка входна променлива. В многоглавата архитектура е необходима адаптация при проектирането на модела и при предварителната обработка на наборите от данни за обучение и тестване. По отношение на дизайна на модела, трябва да се дефинира отделен CNN модел за всяка от входните променливи, с подходящи модификации на броя на слоевете и настройката на хиперпараметрите. По-конкретно, трябва да се разработи подмодел за всяка входна променлива, която приема едномерна последователност от входни данни и извежда планарен вектор, съдържащ обобщение на обучението на характеристиките. Наборът от тези вектори може да бъде обединен чрез конкатенация, за да се разработи голям вектор, който преди прогнозирането се интерпретира от редица напълно свързани слоеве.

За разработване на модела за предсказване на задълбочено обучение бяха използвани TensorFlow и Keras. Предложеният модел за прогнозиране на QoE е изграден с помощта на многоетапна многоглава CNN с многовариантен вход. Многовариантният вход, както е илюстриран на Фиг. 7.4, включва картографираните стойности на честотна лента, трептене, забавяне и загуба на пакети. Скрытият слой се основава на многоглава CNN, предназначена да разрешава проблеми с последователността. Тези видове приложения обикновено се оформят като проблеми с прогнозиране на една или повече входни времеви стъпки към една изходна времева стъпка. В този случай измерванията на QoS от предходните 2 дни бяха използвани за прогнозиране на QoE на следващия ден.

При подготовката на данните наборът от данни беше преобразуван в неприпокриващи се 60-минутни последователности. Следователно входните данни от 80 640 минути бяха повторно семплирани в почасови проби, като се получиха общо 1344 проби. Многоглавият CNN е проектиран като многоетапен многовариантен модел за прогнозиране на времеви серии, който прогнозира стойностите на QoE за следващия ден въз основа на данните от предишните два дни. По-специално, за да предскаже QoE на 24 напредващи времеви стъпки (1 ден x 24 часа), той използва 48 часови проби (2 дни x 24 часа) като назад времеви стъпки. Моделът за прогнозиране има 16 входни последователности, съответстващи на картографираните стойности на параметрите на QoS и 1 изход, който дава общата стойност на QoE.

Структурата на многоглавия CNN модел е показана на фиг. 7.5. Моделът не счита, че данните имат времеви стъпки; вместо това, той го третира като последователност, върху която конволюционните слоеве могат да прилагат филтри, подобни на 1D изображение. По време на разработването на модела входните и плоските слоеве се съхраняват в списъци, за да се определят входовете на модела и функцията на слоя за максимално обединяване. Моделът очаква 16 масива като вход, по един за всеки от подмоделите. Това се изисква на всички етапи от

процеса, включително обучение, оценка и прогнозиране с краен модел. Поради тази причина, списък от 16 3D матрици [*samples, time steps, features*] е създадена, където колоната от характеристики е равна на единица, тъй като представлява едномерните входни последователности.

### Оценка на модела за прогнозиране

Моделът за прогнозиране използва всяка от 16-те входни променливи за времеви серии, за да прогнозира общата стойност на QoE за следващите 24 времеви стъпки. Това се постига чрез включване на всеки едномерен времеви ред като отделна входна последователност, към която вътрешно представяне след това се интерпретира от изхода. Това е така, защото вместо да предвижда една единствена характеристика, предложеният подход изисква многовариантни входове, тъй като изходната последователност е продукт от наблюдения на предишни времеви стъпки, засегнати от множество независими характеристики.

8-седмичното наблюдение на QoS доведе до 56 дни събиране на данни. Тези 56 дни бяха разпределени, както следва: наборът от данни за обучение се състои от 42 дни, наборът от тестови данни се състои от 7 дни, а наборът от данни за валидиране се състои от 7 дни. Използвахме обратни извиквания на Keras, за да увеличим ефективността на обучението при сглобяване на моделите. По-специално, ModelCheckpoint се използва за съхраняване на теглата на модела на ключови времеви стъпки, EarlyStopping за прекратяване на процеса, когато наблюдаваният показател за оценка вече не се подобрява, и ReduceLROnPlateau за минимизиране на скоростта на обучение, когато наблюдаваният показател вече не се подобрява.

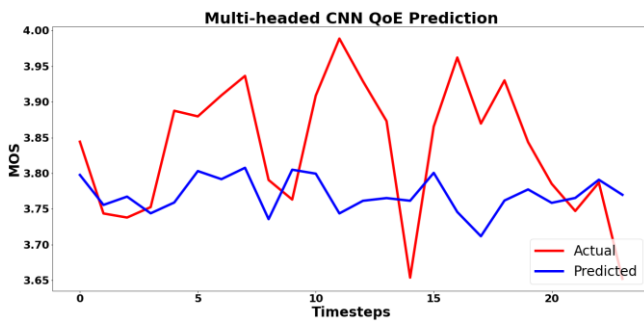
Метриците MSE, RMSE, MAE, MAPE и MedAE бяха използвани за оценка на точността на моделите за прогнозиране. Таблица 7.2 представя резултатите от показателите за точност на прогнозата. Можем да видим, че предложеният многоглав модел на CNN преобладава над другите модели, като ги превъзхожда във всички резултати за точност. Важно е да се подчертае, че всички модели за прогнозиране показват умерени несъответствия между тях, което потвърждава пригодността на моделите от клас CNN и RNN за справяне с проблеми с моделирането на данни от времеви редове. Резултатите от прогнозата на QoE за следващия ден спрямо стойностите на набора от данни за валидиране от предходните 2 дни са изобразени на Фиг. 7.6. Прогнозата за следващия ден съответства на 24 стъпки напред във времето, а базата за валидиране на предходните 2 дни съответства на 48 стъпки назад във времето.

**Таблица II.5:** Оценка на модела за прогнозиране на QoE за видео игри.


	MSE	RMSE	MAE	MAPE (%)	MedAE
CNN	0.03241	0.18005	0.14492	3.92163	0.13820
Multi-channel CNN	0.03432	0.18527	0.14835	4.03715	0.13218
Multi-headed CNN	<b>0.01342</b>	<b>0.11588</b>	<b>0.09786</b>	<b>2.52839</b>	<b>0.09664</b>
TCN	0.03581	0.18924	0.15303	4.14064	0.13052
LSTM	0.03250	0.18029	0.14196	3.85048	0.13774
ResCNN-LSTM	0.03245	0.18016	0.14317	3.87785	0.13492
RNN	0.03450	0.18576	0.14212	3.88562	0.11938
GRU	0.03232	0.17978	0.14060	3.82902	0.12912

### Прогноза за QoE в реално време

Обучените модели, използвани за прогнозиране на QoE в реално време, както е показано на Фиг. 7.7, където стойностите на QoE са прогнозирани за 24 времеви стъпки напред. Представени са прогнозирани спрямо действителните стойности на QoE, базирани на мониторинг на QoS в реално време и картографиране на QoS/QoE. Експерименталното събиране на данни беше извършено за период от 4 часа и се основаваше на мониторинг на QoS на стрийминг на игрално видео чрез Open RAN testbed, предоставяйки общо 240 минути проби. Тези проби се използват за оценка на точността на прогнозата за QoE в реално време в стъпки назад във времето и са наборът от данни, спрямо който се потвърждава способността на модела да се обобщава добре към нови данни.



**Фигура II.8:** Представяне на действителна спрямо прогнозирана стойност на QoE за видео игри.



**Фигура II.9:** Представяне на прогнозиране на QoE за видео игри в реално време спрямо действителни стойности.

Предложеният многоканален модел на CNN превъзхожда моделите за прогнозиране на CNN, многоканален CNN, TCN, LSTM, ResCNN-LSTM, RNN и GRU във всички мерки за точност, както е показано в таблица 7.4. Можем също така да видим, че резултатите за точността на прогнозиране на QoE в реално време за всички модели са по-ниски от стойностите, получени при оценката на моделите. Това се дължи на факта, че експерименталният набор от данни в реално време е ограничен по размер, което засяга присъщата вариация на входните данни, което води до по-голяма присъща вариация на набора от данни за обучение в сравнение с набора от данни за валидиране. Поради по-голямата си способност да обработва малки набори от данни, многоглавият модел на CNN постига по-висока точност от останалите модели за прогнозиране. Точността на прогнозата се подобрява, когато обемът на набора от данни се увеличи чрез дълги часове събиране на данни, но ние се интересуваме да проверим полезността на модела за прогнозиране в реални ситуации, където моделът трябва да може да предоставя прогнози в ограничено количество от време.

**Таблица II.6:** Оценка на модела за прогнозиране на QoE за видео игри в реално време.

	MSE	RMSE	MAE	MAPE (%)	MedAE
CNN	0.23826	0.48811	0.48011	15.1477	0.47310
Multi-channel CNN	0.01761	0.13272	0.10765	3.43980	0.09638
Multi-headed CNN	<b>0.01362</b>	<b>0.11674</b>	<b>0.09386</b>	<b>3.00307</b>	<b>0.07228</b>
TCN	0.56402	0.75101	0.72555	22.8735	0.72082
LSTM	0.23745	0.48729	0.48058	15.1615	0.47333
ResCNN-LSTM	0.31307	0.55952	0.54857	17.2956	0.54257
RNN	0.11620	0.34089	0.32962	10.4182	0.32056
GRU	0.30079	0.54844	0.54065	17.0485	0.53445

## 8. Прогнозиране на трафика в мобилна мрежа

Тази глава представя разработването на персонализиран модел на трансформатор за времеви синтез (TFT) за прогнозиране на трафика на мобилна мрежа. Както показват резултатите от това проучване, TFT архитектурата представя редица предимства пред установения статистически анализ и конвенционалните техники за машинно обучение в контекста на прогнозиране на трафика в мобилната мрежа, което позволява ефективно моделиране на времеви модели в колебанията на обема на трафика. TFT се справя с предизвикателствата, свързани с динамичния и сложен характер на данните в мобилната мрежа, като успешно използва предимствата на трансформаторната архитектура и предоставя по-точни и интерпретируеми прогнози в сравнение с конвенционалните модели за дълбоко обучение. Освен това, в сравнение с конвенционалните методи за статистически анализ, способността на TFT да моделира сложни нелинейни връзки и зависимости в данните му дава предимство по отношение на точността на прогнозиране.

### Прогноза за мрежовия трафик

Прогнозирането на мрежовия трафик обикновено се моделира като проблем с времеви серии, представляващ набор от характеристики на трафика в даден интервал от време. Това представяне може да се използва за наблюдение на развитието във времето както на общия, така и на индивидуалния потребителски трафик. Изследването на пространствено-времевата динамика на потребителския трафик позволява изследване на


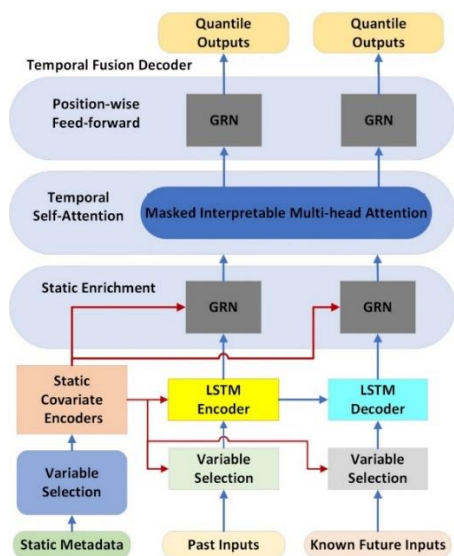
вариациите на изискванията за свързаност в комуникационната мрежа и идентифициране на повтарящи се модели [389].

### Модел на прогнозиране

Моделът за прогнозиране се основава на TFT алгоритъм. Компонентите на неговата архитектура включват стробиращи механизми, мрежи за избор на променливи, статични ковариантни енкодери, интерпретируемо многоглаво внимание, декодер за времево сливане и квантилни изходи, както е показано на Фиг. 8.1 [389]. Дизайнът на TFT модела беше реализиран с помощта на библиотеките на Python с отворен код Darts, PyTorch и Scikit-Learn.

### Оценка на изпълнението

Обхватът на тази глава е да представи използването на TFT алгоритъма за реални приложения за прогнозиране на трафика в мобилната мрежа. Поради тази причина се използва набор от данни от реалния свят за обучение на модела за прогнозиране. Оперативната ефективност и точността на прогнозиране на предложения модел за прогнозиране се оценяват спрямо най-съвременните бенчмарк модели, принадлежащи към статистическия анализ и конвенционалното машинно обучение и задълбочено обучение.




Фигура II.10: Архитектура на прогнозния модел [389].

Фигура II.11: Ежедневен интернет трафик на мобилна мрежа.

Таблица II.7: Точност на прогнозиране на интернет активността.

City Center Internet Activity				
	MSE	MAE	RMSSE	MASE
ARIMA	$1.54195 \cdot 10^7$	$3.46461 \cdot 10^3$	2.66817	3.82501
ETS	$7.63048 \cdot 10^6$	$1.72292 \cdot 10^3$	1.87695	1.90215
XGBoost	$4.10692 \cdot 10^6$	$1.24746 \cdot 10^3$	1.12720	0.91770
LightGBM	$1.53723 \cdot 10^7$	$3.29035 \cdot 10^3$	2.66408	3.63263
LSTM	$1.51959 \cdot 10^7$	$3.13241 \cdot 10^3$	2.23939	2.46421
GRU	$1.40681 \cdot 10^7$	$2.94717 \cdot 10^3$	2.15468	2.31849
TFT	$1.92636 \cdot 10^6$	$9.09198 \cdot 10^2$	<b>0.65580</b>	<b>0.67146</b>
University District Internet Activity				
	MSE	MAE	RMSSE	MASE
ARIMA	$3.01491 \cdot 10^5$	$3.94071 \cdot 10^2$	2.51411	2.84059
ETS	$3.88283 \cdot 10^6$	$1.48816 \cdot 10^3$	9.02237	10.72781
XGBoost	$1.28479 \cdot 10^5$	$2.39373 \cdot 10^2$	0.18350	0.21740
LightGBM	$1.88029 \cdot 10^6$	$1.30092 \cdot 10^3$	6.27855	9.37745
LSTM	$6.68215 \cdot 10^6$	$2.45283 \cdot 10^3$	1.45173	2.62971
GRU	$6.83891 \cdot 10^6$	$2.53369 \cdot 10^3$	1.46865	2.71639
TFT	$1.24178 \cdot 10^4$	$9.23070 \cdot 10^1$	<b>0.03010</b>	<b>0.05017</b>
Residential District Internet Activity				
	MSE	MAE	RMSSE	MASE
ARIMA	$2.76414 \cdot 10^5$	$3.94662 \cdot 10^2$	1.78296	2.16668
ETS	$1.67901 \cdot 10^5$	$2.87261 \cdot 10^2$	1.38959	1.57705
XGBoost	$2.84468 \cdot 10^5$	$4.35321 \cdot 10^2$	1.61630	1.77331
LightGBM	$4.58411 \cdot 10^5$	$5.61319 \cdot 10^2$	2.29609	3.08162
LSTM	$4.24438 \cdot 10^5$	$5.21678 \cdot 10^2$	1.94511	2.18453

GRU	$2.76161 \cdot 10^5$	$4.23030 \cdot 10^2$	1.56893	1.77146
TFT	$4.59134 \cdot 10^4$	$1.72452 \cdot 10^2$	0.40490	0.46434



Фигура 11.12: Прогноза за интернет активността.

### Описание на набора от данни

Наборът от данни, използван за обучение на моделите за прогнозиране, идва от набора от данни, предоставен от Telecom Italia, основен италиански доставчик на телекомуникационни услуги [410]. Наборът от данни се състои от подробен запис на обаждания (CDR) на телефонни услуги, SMS услуги и интернет активност в град Милано и провинция Трентино. Трафикът е записан в периода между 1 ноември 2013 г. и 1 януари 2014 г. Интервалът от време на запис беше 10 минути, генерирайки общо 62 дни наблюдения и 500 милиона записа. Интернет активността се записва всеки път, когато потребител се свърже или прекъсне връзката с мрежата или се осъществи трансфер на данни. CDR се генерира и събира на всеки 60 минути за всички докладвани дейности, ако взаимодействието или дейността надвишава 15 минути или се консумират повече от 5 MB интернет данни.

### Оценка на модела за прогнозиране

По време на проектирането на модела за прогнозиране бяха положени специални грижи, за да се гарантира, че той ще може ефективно да улавя разликите в моделите на трафика и сезонността в цялата зона на покритие. За тази цел се демонстрира прогнозирането на трафика върху клетките, покриващи три района на градската зона на град Милано с различни характеристики. По-специално се използват клетките, съответстващи на центъра на града (площад Дуото), университетски квартал (университет Воссони) и жилищен квартал (квартал Fiera). По този начин се тества способността на модела за прогнозиране да предоставя точни прогнози при различни условия, тъй като разликите в моделите на трафик между тези области са особено очевидни. Както се наблюдава на фиг. 8.2, тенденцията на мрежовия трафик в центъра на града показва постоянно високи стойности през деня както през делничните дни, така и през почивните дни. За разлика от това университетската зона показва високи стойности през целия ден и значително по-ниски стойности през нощта и през почивните дни, достигайки своя връх през периода на коледните празници. В жилищния район има постоянен модел на търсене на трафик както през делничните дни, така и през уикендите, с умерени колебания между дневните и вечерните часове. Резултатите от бенчмаркинга на моделите за прогнозиране на интернет активността са представени в таблица 8.1. Може да се отбележи, че предложеният модел за прогнозиране превъзхожда моделите за сравнение и в трите региона. Фигура 8.3 показва 24-часовата прогноза за интернет активността в трите района на град Милано.

## 9. Разпределение на ресурси за подобряване на QoE

В тази глава се предлага нов модел за разпределение на ресурси, който предлага стабилно решение на предизвикателствата на оптимизацията на QoE в безжичните мрежи. По-конкретно, това изследване е пионерско

усилие за подобряване на QoE на безжични VR комуникации чрез включване на техники за задълбочено обучение (DRL) в рамката за разпределение на ресурсите. Предложеният модел за разпределение на ресурсите динамично се адаптира към развиващите се характеристики на безжичния канал и потребителските взаимодействия, оптимизирайки QoE на видео стрийминг на VR конференции в реално време. Иновацията на нашия подход към подобряването на QoE се крие в цялостното разглеждане на свързаните с предаването параметри, влияещи върху QoE, критичен аспект, често пренебрегван в традиционните стратегии за оптимизиране на QoE. По-конкретно, персонализиранят DRL алгоритъм изследва политиката за разпределение на ресурсите, която максимизира свързаната с предаването стойност на QoE, като същевременно удовлетворява мрежовите изисквания за QoS на безжичните VR приложения. Предложеният модел за разпределение на ресурсите установява нова парадигма за QoE оптимизация в безжичните VR комуникации, уникално подходяща за справяне с динамичния и непредвидим характер на безжичните среди.

### **Задълбочено обучение за укрепване за разпределяне на ресурси**

DRL е подмножество от полето за машинно обучение, което съчетава RL с възможностите на DNN. В RL автономните агенти се научават да вземат решения чрез взаимодействието си с околната среда. В контекста на безжичните комуникационни мрежи, DRL се очертава като мощен инструмент за оптимизиране на стратегии за разпределение на ресурси. По-специално, DRL може да се приложи за справяне с предизвикателствата, свързани с динамични и сложни безжични среди, където ефективното разпределение на ресурсите става първостепенно. Чрез възможностите за адаптивно обучение на DRL, моделите могат динамично да коригират параметри като разпределение на мощността, използване на честотата и политики за планиране, за да подобрят производителността на мрежата. Това се оказва безценно в сценарии, при които традиционните подходи може да се борят да се адаптират бързо към променящите се условия [434].

### **Модел за подобряване на QoE**

В тази глава се предлага усъвършенстван модел за подобряване на QoE, който използва разпределение на радиочестотен ресурс, базирано на DRL. Моделът е проектиран да оптимизира VR конференнтното видео предаване през 5G gNB BS. Основната цел на модела е да оптимизира производителността на мрежата, за да отговори на строгите изисквания за QoS, присъщи на безжичните VR приложения, чрез управлявано от AI динамично регулиране на разпределението на спектъра.

### **Видео поточно предаване на конференция за виртуална реалност**

VR конференнтно видео поточно предаване е трансформиращо приложение, което бързо набира популярност в нарастващата VR екосистема. Тази иновативна технология революционизира традиционната парадигма на видеоконференнтната връзка, като предлага завладяващо и интерактивно изживяване. VR конференциите надхвърлят ограниченията на физическото разстояние, тъй като участниците могат да участват във виртуални срещи, сякаш присъстват физически. Присъщата интерактивност на тези приложения улеснява динамичното и ангажиращо потребителско изживяване, позволявайки пространствено осъзнаване и усещане за присъствие. За този експеримент се разглежда приложение, принадлежащо към фазата преди VR [367]. По-конкретно, мрежовият трафик се симулира за предаване на VR конференнтно видео с разделителна способност 3840x1920 пиксела, честота на кадрите 30 FPS, битрейт на видео 16 Mbps и дълбочина на цвета 8 бита. Предполага се, че видеото е компресирано с помощта на кодека за компресиране на видео H.264.

### **QoE оценка на виртуалната реалност**

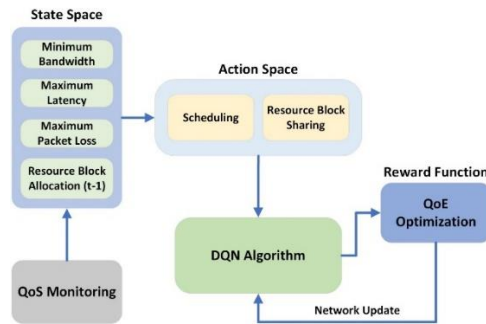
QoE е критичен елемент в оценката на VR приложенията, тъй като осигурява цялостна мярка за цялостната удовлетвореност на потребителите от завладяващия характер на VR изживяването. Това става особено важно, когато се обмисля видео стрийминг на VR конференция, тъй като включва взаимодействие в реално време между участниците. Процесът на оценка на QoE гарантира, че завладяващите качества на видео стрийминг на VR конференция са съобразени с очакванията на потребителите. В това изследване е осигурен задълбочен анализ на въздействието на влияещите фактори, свързани с мрежата/преноса, върху QoE на приложенията за безжична виртуална реалност. Следователно ефектът от мрежовите QoS параметри на честотната лента, латентността и загубата на пакети е разбираемо изследван, тъй като те имат най-значително влияние върху QoE [212].

### **Картографиране на QoS/QoE**

Предложеният модел за оптимизация включва механизми за мониторинг на QoS в реално време за наблюдение и оценка на ключовите параметри на QoS на честотната лента, забавянето и загубата на пакети, които са критични за VR приложенията. Това картографиране свързва техническите аспекти на QoS с емпиричните измерения на



QoE. За да се идентифицира връзката между параметрите на QoS и техния индивидуален и комбиниран ефект върху QoE, трябва да се установи модел на корелация. За тази цел се използва хипотезата IQX, както е анализирано в параграф 2.5.



**Фигура II.13:** Архитектура за разпределение на ресурсите на DRL.

### Разпределение на ресурси, базирано на DRL

Предложеният оптимизационен модел, както е показано на Фиг. 9.2, се основава на DRL, за да позволи динамично разпределение на ресурсите, отговаряйки в реално време на непрекъснато променящите се условия на безжичните мрежи. Целта на DRL агента е да оптимизира QoS параметрите на мрежата, а именно честотна лента, латентност и загуба на пакети, за да подобри QoE на крайните потребители. Тази стратегия за динамично разпределение има за цел да гарантира, че мрежовите ресурси са непрекъснато фино настроени към специфични изисквания, особено в контекста на изискващото ресурси VR конферентно видео стрийминг приложение. Адаптивният характер на DRL позволява на модела за разпределение на ресурсите да реагира в реално време на промените в мрежовите условия. Тази динамична адаптация позволява на мрежата ефективно да се справя с променящите се изисквания и условия, което в крайна сметка води до подобро QoE за крайните потребители.

### Оценка на разпределението на ресурсите

Оценката на предложената методология за разпределение на ресурсите се основава на сравнителното изследване на DRL алгоритъма на DQN спрямо установените модели за планиране на кръгов режим (RR), индикатор за най-добро качество на канала (BCQI) и пропорционално справедливо (PF).

### Сравнителна оценка

За създаване на симулациите се използва платформата за програмиране MATLAB. В този сценарий се приемат gNB и четири UE с произволна мобилност на пътни точки. За предаванията е възприет моделът на загуба на пътя на свободното пространство. Параметрите на gNB включват честотна лента на канала от 20 MHz, разстояние между подносителите от 30 KHz, дуплексно предаване с разделяне по време (TDD), мощност на предаване от 32 dBm и усилване на приема от 11 dB, докато UE също имат усилване на получаване от 11 dB. И четирите UE получават един и същ трафик, симулация на VR конферентен видео стрийминг. В този сценарий целта е да се даде висок приоритет на едно от четирите UE и да се оптимизират неговите мрежови QoS параметри за честотна лента, забавяне и загуба на пакети, за да се подобри неговата QoE стойност.

Стратегията за разпределение на ресурсите на DQN агента се основава на оптимизиране на QoE на UE с висок приоритет. По-специално, агентът проучва оптималното разпределение на ресурсните блокове, за да постигне условието за прекратяване, което изисква задоволяване на мрежовите изисквания на UE с висок приоритет. Те са настроени на скорост на предаване от 30 Mbps, латентност от 10 ms и загуба на пакети от 0%. Мрежовите изисквания за фазата преди VR бяха използвани като базови стойности, за които се предполагаше, че съответстват на QoE от 3 при стойността на MOS. Параметрите на QoS бяха съпоставени с QoE MOS стойности, като се използва предположението IQX, както е описано в раздел 9.3.3. Резултатите от сравнителния анализ между алгоритъма DQN и кръговия, BCQI и пропорционалния справедлив модел са представени в таблица 9.2. Очевидно е, че DQN агентът превъзхожда конвенционалните модели за планиране, постигайки подобрене на QoE и доказвайки, че е в състояние да изпълни предварително дефинирани мрежови изисквания, съответстващи на конкретни SLA.

**Таблица II.8:** Сравнение на моделите за разпределение на ресурсите.

	Round Robin	BCQI	Proportional Fair	DQN
Bandwidth (Mbps)	19.6416	18.6464	20.4755	29.3721
Latency (ms)	15.0147	16.011	14.1427	10.0405
Packet Loss (%)	0.0001	0.0002	0.0001	0
QoE (MOS)	2.9323	2.8875	3.0457	3.3137

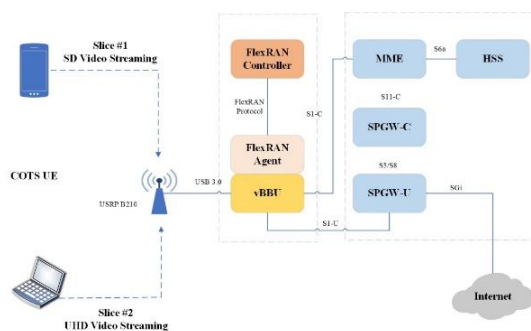
## 10. Срязване на мрежата за подобряване на QoE

Концепцията за NS се състои от принципа за създаване и управление на множество независими логически мобилни мрежи върху обща физическа инфраструктура [50]. Всяка от тези виртуални мрежи се нарича срез и е предназначена за предоставяне на персонализирани мрежови услуги със специфични QoS атрибути за различни сценарии на използване. NS осигурява гъвкавост и мащабируемост в мобилните мрежи и е необходимото средство за развитието на мрежи с множество наематели, като позволява различни вертикални услуги с диференцирани изисквания за QoS да съществуват съвместно в споделена физическа инфраструктура.

Внедряването на NS се основава на разделянето на физическата мрежа на множество логически мрежи с цел използване на общите физически мрежови ресурси за едновременна поддръжка на хетерогенни, персонализирани и приложения по заявка. Мрежовите ресурси, подпомагани от NS, могат да бъдат динамично и ефективно разпределени към логически мрежови срезове според изискванията на QoS [51]. Срезът може да се дефинира като изолирана колекция от програмируеми ресурси чрез софтуерни компоненти, която изпълнява отделни мрежови функции и приложни услуги. От решаващо значение е всеки срез да може да хоства отделни мрежови функции и приложни услуги, без да взаимодейства и да се намесва в съвместно съществуващи срезове [52].

### Експериментална настройка

Настройката на тестовия стенд за експеримента за оптимизиране на мрежата за висококачествени мултимедийни комуникации (MMC) се основава на конфигурацията, изобразена на Фиг. 10.1. По отношение на UE е използван лаптоп Lenovo Legion Y520, свързан към мрежата чрез LTE донгъл Huawei E3372. Обхватът на нашия експеримент е да приложим NS върху нашата мрежова архитектура и да анализираме приноса му в ефективното използване на радиоресурси и, следователно, в оптимизираната производителност на мрежата и подобреното качество на MMC.



Фигура 10.14: Експериментална настройка.

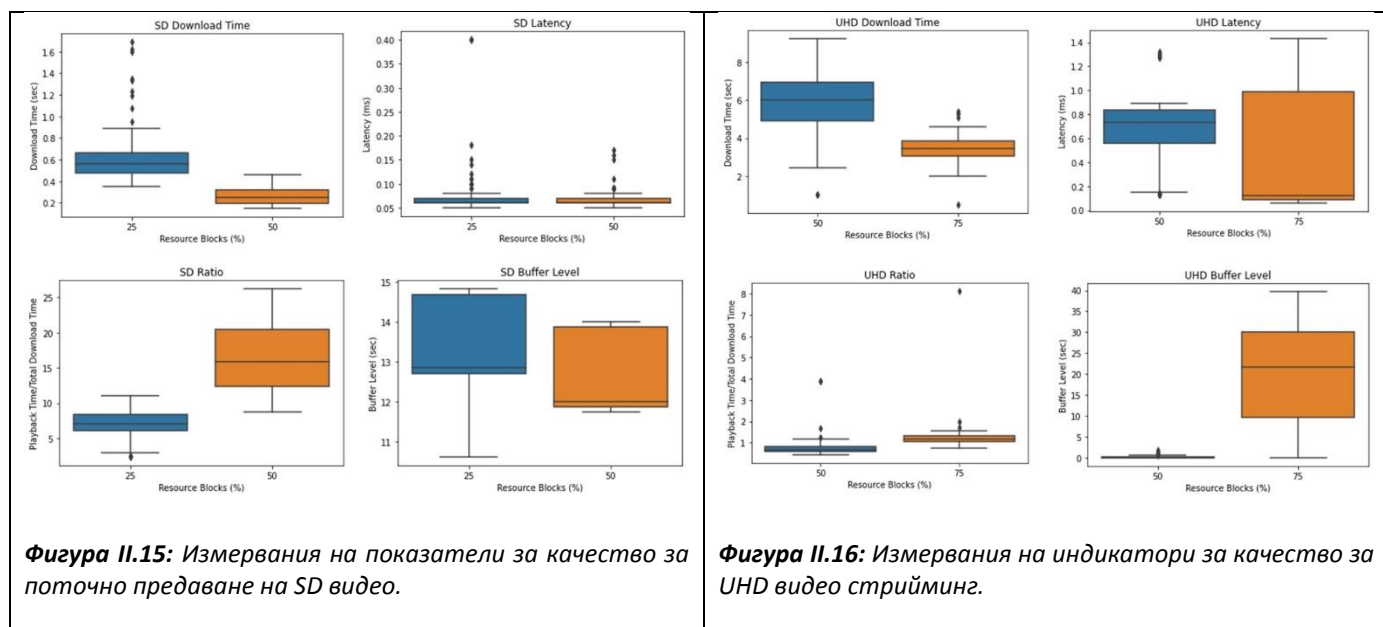
За създаването на срезове е използвана платформата FlexRAN с отворен код, както е показано на фиг. 10.1. FlexRAN е гъвкава и програмируема софтуерно дефинирана RAN (SD-RAN) платформа, която осигурява разделяне между контролната равнина и данните на RAN архитектурата чрез южно насочен API. FlexRAN поддържа функции за управление на RAN в реално време, подпомогнати от виртуализирани контролни функции и програмируемост, следвайки принципите на мрежовото софтуериране и неговите два основни компонента: SDN и NFV [24].

Беше проведен експеримент в малък мащаб в контекста на мобилно видео стрийминг. В експерименталния сценарий използвахме услугата за динамично адаптивно поточно предаване през HTTP (DASH) и проучихме ефекта на NS върху качеството на видеото, което крайният потребител изпитва в референтния клиент DASH 4.3.0. Изследвахме мобилното поточно предаване на приблизително 10-минутно DASH видео в две резолюции: 1) DASH видео със стандартна разделителна способност (SD), т.е. резолюция 720x480 пиксела; и 2) ултра-висока разделителна способност (UHD) DASH видео, т.е. резолюция 3840x2160 пиксела. Измерванията на индикаторите за качество бяха проведени от страна на клиента и включват времето за изтегляне на видео в секунди,

латентността в ms, съотношението на времето за възпроизвеждане към общото време за изтегляне, нивото на буфера в секунди и броя на пропуснатите кадри.

### Експериментални резултати

За да се изследва функционалността на NS, бяха създадени два среза. Първият срез беше използван за поточно предаване на SD видео, а вторият срез за поточно предаване на UHD видео. Първоначално на двата сегмента бяха разпределени приблизително 50% от наличните RB в опит да се проучи производителността на мрежата и нейното въздействие върху качеството на видеото, когато работи по най-добрия начин за доставка. Както е показано на Фиг. 10.2, разпределението на 50% от RB е прекалено достатъчно за поточно предаване на SD видео, тъй като осигурява изключително ниски времена на изтегляне и латентност, както и оптимални стойности за съотношението и нивото на буфера. Тази забележка се подсилва, ако наблюдаваме таблица 10.1, където изпуснатите кадри за този конкретен случай са нула. Напротив, в случай на UHD, 50% от наличните ресурси в нашата мрежова конфигурация са недостатъчни, за да поддържат стрийминг и да осигурят висококачествено видео за крайните потребители. Това е очевидно, ако наблюдаваме Фигура 10.3, където можем да отбележим непосилно високите времена на изтегляне и латентност, както и лошите резултати в характеристиките на съотношението и нивото на буфера. Недостатъчността на 50% от мрежовите ресурси за поточно предаване на UHD видео е очевидна и в таблица 10.1, тъй като броят на пропуснатите кадри е изключително голям, компрометирайки сериозно качеството на видеото, което крайният потребител изпитва.



**Таблица 11.9:** Изпуснати кадри за SD и UHD видео стрийминг.

SD (25% RBs)	SD (50% RBs)	UHD (50% RBs)	UHD (75% RBs)
7	0	6897	158

Впоследствие приблизително 25% от RB бяха разпределени за SD стрийминг, а 75% от RB за UHD стрийминг. Както можем да видим на Фиг. 10.2, тази промяна в мрежовата конфигурация, която намалява броя на RB, налични за SD видео поточно предаване, има минимално въздействие върху неговото качество. Както времето за изтегляне, така и времето за забавяне се увеличават, но остават в приетите граници, както е случаят със стойностите на съотношението и нивото на буфера. Това е очевидно и в таблица 10.1, тъй като броят на пропуснатите кадри е само 7, което предполага повече от ефективни нива на видео качество за крайните потребители. По отношение на UHD стрийминг, както можем да видим на фиг. 10.3, разпределението на увеличени радио ресурси, което достига около 75% от наличните RB, значително допринесе за подобряването на качеството на видеото. Очевидно е, че както времето за изтегляне, така и времето за забавяне са значително намалени, а стойностите на съотношението и нивото на буфера са в рамките на приетите нива. Освен това, както

е показано в Таблица 10.1, броят на пропуснатите кадри е драстично намален, осигурявайки задоволителни нива на качество на видеото за крайните потребители.

## Изводи

Концепцията за QoE надхвърля традиционните научни граници, черпейки влияние от широк набор от фактори, обхващащи различни научни области. Тази интердисциплинарна метрика подчертава сложността, присъща на оптимизирането на потребителското удовлетворение в безжичните мултимедийни комуникации. Следователно проектирането на стабилна рамка за оптимизация, която е в състояние да осигури постоянно задоволителни нива на QoE, остава продължаващо изследователско усилие.

В отговор на това предизвикателство, тази теза се стреми да бъде пионер, като предлага цялостна методология, ориентирана към приложението, за подобряване на QoE. В центъра на предложения подход е използването на ML алгоритми и иновативната Open RAN архитектура. Чрез използване на възможностите на ML техниките и възползване от гъвкавостта и мащабируемостта, осигурени от Open RAN, е разработена холистична рамка за оптимизация, която адресира многостранната динамика на управлението на QoE в мултимедийни комуникационни среди. В обобщение, тази дипломна работа свързва теорията и практиката, като допринася за безпроблемната доставка на висококачествени безжични мултимедийни комуникации.

Приносите на дисертационният труд се отнасят до:

- Цялостно проучване на най-съвременните подходи за интегриране на QoE информираност в безжични и мобилни мрежи. Различните техники и методологии, използвани за включване на съображенията за QoE в процесите на мрежово управление и оптимизация, са подробно проучени.
- Задълбочен анализ на управлението на QoE в мултимедийните комуникации и задълбочено изследване на специфичните аспекти за оценка на QoE за VR и приложения за стрийминг на видео игри.
- Проучване на ML методологии в контекста на безжичните комуникационни мрежи и анализ на различни ML техники и алгоритми, свързани с прогнозирането и оптимизирането на QoE в мултимедийните комуникации.
- Изчерпателен преглед на най-съвременните базирани на ML QoE модели за прогнозиране за видео стрийминг, разширена реалност и приложения за видеоигри. Анализ на ефективността и приложимостта на различни ML подходи при прогнозиране и оптимизиране на QoE в различни мултимедийни сценарии.
- Проучване и внедряване на безжични комуникационни мрежи, базирани на технологията Open RAN. Анализ на архитектурата и функционалността на Open RAN системи и изследване на техния потенциал за подобряване на QoE в безжични комуникационни мрежи.
- Разработване на модел за прогнозиране на QoE за безжични VR приложения в Open RAN. Предлага се нов модел LSTM на енкодер-декодер, предназначен да предскаже точно стойностите на QoE за VR 360-градусов видео стрийминг през Open RAN.
- Разработване на модел за прогнозиране на QoE за стрийминг на видео игри в Open RAN. Предлага се нов модел на CNN с множество глави, пригоден да предскаже стойности на QoE за приложения за стрийминг на видео игри през Open RAN.
- Разработване на модел за прогнозиране на трафика в мобилната мрежа с помощта на TFT архитектура. Предлага се нов подход за прогнозиране на трафика в мобилната мрежа и оптимизиране на разпределението на ресурсите за подобро QoE, базирано на TFT.
- Разработване на модел за разпределение на ресурси, базиран на DRL, за подобряване на QoE на безжичните VR комуникации. Предлага се нов подход за динамично разпределяне на мрежови ресурси въз основа на QoE оптимизация.
- Разработване на модел за нарязване на мрежата, предназначен да подобри QoE на мултимедийни комуникации в Open RAN. Предлага се нов подход за нарязване на мрежата за оптимизиране на QoE чрез разпределяне на ресурси за мултимедийни комуникации.

## Литература

- [1] S. Wassermann, P. Casas, M. Seufert and F. Wamser, "On the analysis of of YouTube QoE in Cellular Networks through in-Smartphone Measurements," in *12th IFIP Wireless and Mobile Networking Conference (WMNC)*, Paris, 2019.

- [2] P. Casas, M. Seufert, F. Wamser, B. Gardlo, A. Sackl and R. Schatz, "Next to You: Monitoring Quality of Experience in Cellular Networks from the End-Devices," *IEEE Transactions on Network and Service Management*, vol. 13, no. 2, pp. 181 - 196, 2016.
- [6] C. Tselios and G. Tsolios, "On QoE-awareness through virtualized probes in 5G networks," in *IEEE 21st International Workshop on Computer Aided Modelling and Design of Communication Links and Networks (CAMAD)*, Toronto, 2016.
- [10] K. Brunnström et al., "Qualinet White Paper on Definitions of Quality of Experience," 2013.
- [11] ITU-T, "Vocabulary for performance, quality of service and quality of experience," Rec. ITU-T P.10/G.100, Nov. 2017.
- [12] P. Juluri, V. Tamarapalli and D. Medhi, "Measurement of Quality of Experience of Video-on-Demand Services: A Survey," *IEEE Communications Surveys & Tutorials*, vol. 18, no. 1, pp. 401 - 418, 2016.
- [13] ETSI TR 102 643, "Human Factors (HF); Quality of Experience (QoE) requirements for real-time communication services," 2009.
- [23] M. A. Alreshoodi and J. C. Woods, "Survey on QoE/QoS Correlation Models for Multimedia Services," *International Journal of Distributed and Parallel Systems*, vol. 4, no. 3, 2013.
- [34] ONF TR-526, "Applying SDN Architecture to 5G Slicing," 2016.
- [42] A. Barakabitze, A. Ahmad, R. Mijumbi and A. Hines, "5G Network Slicing using SDN and NFV: A Survey of Taxonomy, Architectures and Future Challenges," *Computer Networks*, vol. 167, 2020.
- [50] NGMN Alliance, "NGMN 5G White Paper," 2015.
- [51] H. Zhang, N. Liu, X. Chu, K. Long, A.-H. Aghvami and V. C. Leung, "Network Slicing Based 5G and Future Mobile Networks: Mobility, Resource Management, and Challenges," *IEEE Communications Magazine*, vol. 55, no. 8, pp. 138 - 145, 2017.
- [52] A. Nakao et al., "End-to-end Network Slicing for 5G Mobile Networks," *Journal of Information Processing*, vol. 25, pp. 153-163, 2017.
- [63] ITU-R, "IMT Vision - Framework and overall objectives of the future development of IMT for 2020 and beyond," Recommendation ITU-R M.2083-0, Sep. 2015.
- [64] ITU-T Y.3112, "Framework for the support of network slicing in the IMT-2020 network," 2018.
- [96] M. Hoffmann and M. Staufer, "Network Virtualization for Future Mobile Networks: General Architecture and Applications," in *In Proc. IEEE ICC 2011*, Kyoto, Japan, Jun. 5-9, 2011.
- [98] O-RAN Alliance, "O-RAN: Towards an Open and Smart RAN," Oct. 2018.
- [100] ITU-T Y.3170, "Machine learning in future networks including IMT-2020: Use cases," 2019.
- [127] L. Skorin-Kapov, M. Varela, T. Höbfeld and K.-T. Chen, "A Survey of Emerging Concepts and Challenges for QoE Management of Multimedia Services," *ACM Transactions on Multimedia Computing, Communications, and Applications*, vol. 14, no. 2s, p. 1-29, May 2018.
- [134] R. Schatz, T. Höbfeld, L. Janowski and S. Egger, "From packets to people: Quality of experience as a new measurement challenge," in *Data Traffic Monitoring and Analysis*, Berlin, Heidelberg, Germany: Springer, 2013, pp. 219-263.
- [135] ITU-T, "Mean Opinion Score (MOS) Terminology," Rec. ITU-T P.800.1, Jul. 2006.
- [146] A. Takahashi, "Framework and Standardization of Quality of Experience (QoE) Design and Management for Audiovisual Communication Services," *NTT Technical Review*, 2009.
- [182] J. Korhonen, N. Burini, J. You and E. Nadernejad, "How to evaluate objective video quality metrics reliably," in *Proc. 5th Int. Workshop on Quality of Multimedia Experience*, Melbourne, VIC, Australia, Jul. 5-7, 2012.
- [212] ITU-T, "Influencing factors on quality of experience for virtual reality services," Rec. ITU-T G.1035, May 2020.
- [223] S. Moller, S. Schmidt and S. Zadttooghaj, "New ITU-T Standards for Gaming QoE Evaluation and Management," in *Proc. QoMEX 2018*, Cagliari, Italy, May 29-Jun. 1, 2018.
- [224] S. Möller, S. Schmidt and J. Beyer, "Gaming taxonomy: An overview of concepts and evaluation methods for computer gaming QoE," in *Proc. QoMEX 2013*, Klagenfurt am Wörthersee, Austria, Jul. 3-5, 2013.
- [244] C. M. Bishop, in *Pattern Recognition and Machine Learning (Information Science and Statistics)*, New York, NY, USA: Springer, Aug. 2006.
- [245] R. Boutaba, M. A. Salahuddin, N. Limam, S. Ayoubi, N. Shahriar, F. Estrada-Solano and O. M. Caicedo, "A comprehensive survey on machine learning for networking: evolution, applications and research opportunities," *Journal of Internet Services and Applications*, vol. 9, Jun. 2018.
- [246] A. Géron, in *Hands-on machine learning with Scikit-Learn, Keras and TensorFlow: concepts, tools, and techniques to build intelligent systems (2nd ed.)*, Gravenstein Highway North, Sebastopol, CA, USA: O'Reilly Media, Sep. 2019.
- [266] I. A. Basheer and M. Hajmeer, "Artificial Neural Networks: Fundamentals, Computing, Design, and Application," *Journal of Microbiological Methods*, vol. 43, no. 1, pp. 3-31, Jan. 2001.
- [267] S. Haykin, in *Neural Networks and Learning Machines (3rd edition)*, Upper Saddle River, NJ, USA: Pearson Prentice Hall, 2009.
- [272] I. Goodfellow, Y. Bengio and A. Courville, in *Deep Learning*, Cambridge, MA, USA: MIT Press, 2016.
- [274] X. Glorot, A. Bordes and Y. Bengio, "Deep sparse rectifier networks," in *Proc. AISTATS 2011*, Fort Lauderdale, FL, USA, Apr. 11-13, 2011.
- [341] M. Polese, L. Bonati, S. D'Oro, S. Basagni and T. Melodia, "Understanding O-RAN: Architecture, Interfaces, Algorithms, Security, and Research Challenges," [Online] Available: [arXiv:2202.01032](https://arxiv.org/abs/2202.01032), Feb. 2022, Feb. 2022.
- [344] O-RAN Alliance, "O-RAN Minimum Viable Plan and Acceleration towards Commercialization," Jun. 2021.
- [345] O-RAN Alliance, "AI/ML workflow description and requirements," Oct. 2020.
- [346] B. Brik, K. Boutiba and A. Ksentini, "Deep Learning for B5G Open Radio Access Network: Evolution, Survey, Case Studies, and Challenges," *IEEE Open Journal of the Communications Society*, vol. 3, pp. 228-250, Jan. 2022.
- [348] M. S. Hossain and G. Muhammad, "A Deep-Tree-Model-Based Radio Resource Distribution for 5G Networks," *IEEE Wireless Communications*, vol. 27, no. 1, pp. 62-67, Feb. 2020.
- [352] R. Ferrús, O. Sallent, J. Pérez-Romero and R. Agustí, "Applicability Domains of Machine Learning in Next Generation Radio Access Networks," in *In Proc. 2019 Int. Conf. on Computational Science and Computational Intelligence (CSCI)*, Las Vegas, NV, USA, Dec. 5-7, 2019.
- [354] P. H. Masur and J. H. Reed, "Artificial Intelligence in Open Radio Access Network," [Online] Available: [arXiv:2104.09445](https://arxiv.org/abs/2104.09445), Apr. 2021.
- [356] A. Perkis et al., "Qualinet white paper on definitions of Immersive Media Experience (IMEx)," [Online] Available: [arXiv:2007.07032](https://arxiv.org/abs/2007.07032), Jun. 2020, Jun. 2020.
- [363] S. Mangiante, G. Klas, A. Navon, Z. GuanHua, J. Ran and M. D. Silva, "VR is on the Edge: How to Deliver 360° Videos in Mobile Networks," in *Proc. VR/AR Network '17*, Aug. 2017.
- [364] F. Kaltenberger, A. P. Silva, A. Gosain, L. Wang and T.-T. Nguyen, "OpenAirInterface: Democratizing innovation in the 5G Era," *Computer Networks*, vol. 176, Jul. 2020.
- [367] Huawei, "Whitepaper on the VR-Oriented Bearer Network Requirement," Sep. 2016.

- [368] R. D. Levie, "Curve Fitting with Least Squares," *Critical Reviews in Analytical Chemistry*, vol. 30, no. 1, pp. 59-74, Jun. 2010.
- [377] O. S. Peñaherrera-Pulla, C. Baena, S. Fortes, E. Baena and R. Barco, "Measuring key quality indicators in cloud gaming: Framework and assessment over wireless networks," *Sensors*, vol. 21, no. 4, Feb. 2021.
- [389] B. Lim, S. Ö. Arık, N. Loeff and T. Pfister, "Temporal Fusion Transformers for interpretable multi-horizon time series forecasting," *International Journal of Forecasting*, vol. 37, no. 4, pp. 1748-1764, Oct.- Dec. 2021.
- [410] G. Barlacchi et al., "A multi-source dataset of urban life in the city of Milan and the Province of Trentino," *Scientific data*, vol. 2, no. 1, pp. 1-15, Oct. 2015.
- [434] Y. Huang, C. Xu, C. Zhang, M. Hua, and Z. Zhang, "An Overview of Intelligent Wireless Communications using Deep Reinforcement Learning," *Journal of Communications and Information Networks*, vol. 4, no. 2, pp. 15–29, Jun. 2019.
- [438] X. Foukas, N. Nikaen, M. M. Kassem and M. K. K. Marina, "FlexRAN: A Flexible and Programmable Platform for Software-Defined Radio Access Networks," in *In Proc. 12th Int. Conf. on emerging Networking EXperiments and Technologies (CoNEXT 2016)*, Irvine, California, Dec. 12-15, 2016.

## Списък на публикациите по дисертационния труд

1. G. Kougoumtzidis, V. Poulkov, Z. Zaharis, and P. Lazaridis, "Machine Learning for QoE Management in Future Wireless Networks," in *2021 XXXIVth General Assembly and Scientific Symposium of the International Union of Radio Science (URSI GASS)*, Aug. 2021, pp. 1–4. doi: 10.23919/URSIGASS51995.2021.9560226.
2. G. Kougoumtzidis, V. Poulkov, Z. D. Zaharis, and P. I. Lazaridis, "A Survey on Multimedia Services QoE Assessment and Machine Learning-Based Prediction," *IEEE Access*, vol. 10, pp. 19507–19538, 2022, doi: 10.1109/ACCESS.2022.3149592.
3. G. Kougoumtzidis, V. Poulkov, Z. Zaharis, and P. Lazaridis, "QoE Assessment Aspects for Virtual Reality and Holographic Telepresence Applications," in *Future Access Enablers for Ubiquitous and Intelligent Infrastructures*, D. Perakovic and L. Knapcikova, Eds., in *Lecture Notes of the Institute for Computer Sciences, Social Informatics and Telecommunications Engineering*. Cham: Springer International Publishing, 2022, pp. 171–180. doi: 10.1007/978-3-031-15101-9\_12.
4. G. Kougoumtzidis, V. Poulkov, Z. D. Zaharis, and P. I. Lazaridis, "Intelligent and QoE-aware Open Radio Access Networks," in *2022 3rd URSI Atlantic and Asia Pacific Radio Science Meeting (AT-AP-RASC)*, May 2022, pp. 1–4. doi: 10.23919/AT-AP-RASC54737.2022.9814435.
5. A. Vlahov, G. Kougoumtzidis, A. Mihovska, and V. Poulkov, "Performance Analysis of Evolved RAN Architectures with Open Interfaces," *Journal of Mobile Multimedia*, pp. 239–262, 2023, doi: 10.13052/jmm1550-4646.19112.
6. G. Kougoumtzidis, A. Vlahov, V. Poulkov, Z. Zaharis, and P. Lazaridis, "QoE-Oriented Open Radio Access Networks for Virtual Reality Applications," in *2022 25th International Symposium on Wireless Personal Multimedia Communications (WPMC)*, Oct. 2022, pp. 491–496. doi: 10.1109/WPMC55625.2022.10014946.
7. G. Kougoumtzidis, A. Vlahov, V. K. Poulkov, P. I. Lazaridis, and Z. D. Zaharis, "Deep Learning-Aided QoE Prediction for Virtual Reality Applications Over Open Radio Access Networks," *IEEE Access*, vol. 11, pp. 143514–143529, 2023, doi: 10.1109/ACCESS.2023.3343846.
8. G. Kougoumtzidis, A. Vlahov, V. K. Poulkov, P. I. Lazaridis, and Z. D. Zaharis, "QoE Prediction for Gaming Video Streaming in ORAN Using Convolutional Neural Networks," *IEEE Open Journal of the Communications Society*, vol. 5, pp. 1167 - 1181, 2024, doi: 10.1109/OJCOMS.2024.3362275.



TECHNICAL UNIVERSITY OF SOFIA  
FACULTY OF TELECOMMUNICATIONS  
DEPARTMENT “COMMUNICATION NETWORKS”

---

**Georgios Kougioumtzidis, M.Sc.**

**Machine Learning for QoE Enhancement in Future Wireless Networks**

**ABSTRACT of Ph.D. THESIS**

Future wireless networks (FWNs) are expected to support the diversified network service requirements of emerging multimedia applications such as virtual reality (VR) and gaming video streaming, as well as innovative markets and business models such as vertical industries and multi-tenancy networks. Such a wide and heterogeneous range of services and devices requires the development of flexible, scalable and programmable user-centric wireless networks that provide connectivity according to demanding quality of service (QoS) requirements and ensure satisfactory levels of quality of experience (QoE) for end-users.

The objective of this thesis is to propose a comprehensive application-oriented methodology for QoE enhancement in FWNs. The implementation is based on exploiting the advantages of machine learning and the open radio access network (Open RAN) architecture with respect to improving network efficiency and operation, as well as reducing overall capital and operational costs through automation, network virtualization, the use of open-source software, and embedded intelligence. More specifically, the proposed optimization framework is focused on the development of machine learning algorithms that will provide automation in the areas of network traffic management, radio resource allocation, network slicing, QoS monitoring, and QoE prediction, ensuring high levels of QoE for the considered scenarios of wireless VR applications and gaming video streaming.