Vysoká škola báňská - Technická univerzita Ostrava
Fakulta elektrotechniky a informatiky
Katedra telekomunikační techniky

Nový způsob hodnocení kvality videa

Ing. Jaroslav Frnda

Doktorský program: Informatika, komunikační technologie a aplikovaná matematika
Studijní obor: Komunikační technologie

Ostrava, 2017

Prehlásenie

Prehlasujem, že som túto dizertačnú prácu vypracoval samostatne. Uviedol som všetky literárne pramene a publikácie, z ktorých som čerpal.

V Ostrave 6.12.2017 _____

Poďakovanie

Týmto by som chcel poďakovať môjmu školiteľovi doc. Ing. Miroslavovi Vozňákovi, Ph.D. za jeho cenné rady a pripomienky počas môjho doktorského štúdia.

Ďakujem aj kolegom na katedre a Miroslavovi Uhrinovi zo Žilinskej Univerzity za odborné konzultácie a námety.

Veľké poďakovanie patrí mojej snúbenici a rodine, bez ktorých by táto práca pravdepodobne nevznikla.

Abstrakt

Cieľom dizertačnej práce je priniesť novú metódu hodnotenia kvality videa, ktorá bude využívať prvky umelej inteligencie a umožní prepojiť výsledky objektívneho a subjektívneho spôsobu hodnotenia kvality. V súčasnosti je problematické interpretovať objektívne skóre (QoS) z pohľadu subjektívneho vnímania koncového zákazníka (QoE). Dodnes neexistuje jednotná hodnotiaca škála pre oba spôsoby, a preto je zložité určiť hranicu dostačujúcej kvality pre koncového užívateľa z objektívneho merania. Výskum v tejto oblasti sa zameriava na tvorbu nových hybridných metrík, avšak zatiaľ bez uspokojivých výsledkov. Preto sa snaha o prepojenie existujúcich metrík oboch kategórií javí ako momentálne chýbajúci krok k efektívnemu hodnoteniu kvality videa.

Kľúčové slová

ACR, Kvalita videa, Objektívne a subjektívne hodnotenie, SSIM, neurónová sieť

Abstract

The aim of this thesis is to bring a new method for video quality evaluation, that will use elements of artificial intelligence and allows to interconnect results obtained from video objective and subjective assessment methods. Nowadays, it is problematic how to interpret objective score (QoS) from the subjective point of view (QoE) of end-users. No unified interpretation scale has existed so far for both approaches so it is difficult to determine the satisfactory level for end-users obtained from objective assesment. Research in this field is focused on creating of hybrid metrics, however no adequate outputs can be expected in near future. The interconnection between nowadays the most used metrics of both categories seems to be a missing step toward effective video quality evaluation.

Keywords

ACR, Objective and Subjective Assessment, SSIM, Neural Network, Video Quality

Obsah

1 Úvod 15
2 Digitálne vysielanie pomocou IP (IPTV) 17
2.1 Prenosové protokoly v IPTV 17
2.1.1 Real Time Transport Protocol 17
2.1.2 RTP Control Protocol 18
2.2 Kódovanie videa pre digitálne vysielanie 18
2.2.1 Kodek H.264 part 10 19
2.2.2 Kodek H.265 20
2.2.3 Typy snímok a ich predikcie u MPEG štandardov 21
2.2.4 GOP (Group of Pictures) schéma 23
2.2.5 Dekódovanie 23
2.3 Parametre ovplyvňujúce kvalitu videa 24
2.4 Ľudský vizuálny systém 27
3 Určovanie kvality videa 29
3.1 Subjektívne metriky hodnotenia kvality videa 30
3.2 Objektívne metriky hodnotenia kvality videa 31
4 Neurónová sieť 35
4.1 Viacvrstvové neurónové siete 36
4.1.1 Metóda Backpropagation 38
5 Súčasný stav skúmanej problematiky 41
6 Ciele dizertačnej práce 45
7 Návrh modelu, metodika práce a príprava dát 47
7.1 Vytvorenie databázy ohodnotených videosekvencií 47
7.1.1 Definícia parametrov testovacích videosekvencií a ich tvorba 48
7.1.2 Výber videosekvencií a priebeh testovania 51
7.2 Štatistické metódy vyhodnotenia 52
8 Analýza vplyvu stratovosti v sieti na kvalitu videosekvencií 55
8.1 Výsledky vykonaných testov 55
8.2 Využitie databázy na modelovanie neurónovej siete 62
9 Návrh klasifikátora založeného na neurónovej sieti 63
9.1 Využitie možností programovacieho jazyka Python 63
9.1.1 Príprava prostredia pre implementáciu klasifikátora 63

9.2 Vplyv voľby topológie na presnosť odhadu neurónovej siete 64
9.2.1 Namerané dáta 65
9.3 Vplyv voľby aktivačnej funkcie na presnosť odhadu MOS 66
9.3.1 Namerané dáta 67
9.4 Eliminovanie pretrénovanosti neurónovej siete 67
9.5 Spôsob použitia navrhnutého modelu pri predikcii 69
9.6 Štatistické vyhodnotenie úspešnosti predikcie navrhnutého modelu 70
9.7 Zhrnutie a porovnanie s už publikovanými predikčnými modelmi 73
10 Prínosy dizertačnej práce 77
Záver 79
Referencie 81
Citované príspevky autora 85
Publikačná a projektová činnosť autora 87
Príloha A Databáza ohodnotených videosekvencií 91
Príloha B Experimentálne overenie dát 97
B.1 Export výsledkov predikcie pre jednotlivé topológie neurónovej siete 97
B.2 Užívateľské rozhranie predikčného modelu 100
Príloha C Obsah priloženej SD karty 101

Zoznam použitých skratiek

ACR	Absolute Category Rating	Absolútne kategorické hodnotenie
BPNN	Back Propagation Neural Network	Neurónová sieť založená na metóde spätného šírenia chýb
CPU	Central Processing Unit,	Procesor základnej jednotky
CSRC	Contributing Source Identificator	Identifikátor prispievajúcich zdrojov
CTU	Coding Tree Unit	Jednotka kódovacieho stromu
DBN	Deep Belief Network	Typ hlbokej neurónovej siete
DCR	Degradation Category Rating	Kategorické hodnotenie degradácie
DSIS	Double Stimulus Impairement Scale	Dvojnásobne stimulovaná mierka zhoršenia
DTS	Decoding Timestamps	Dekódovacia časová pečiatka
DVD	Digital Versatile Disc	Digitálny viacúčelový disk
FPS	Frames per second	Počet snímok za sekundu
GOP	Group of Pictures	Súbor snímok v MPEG
GPU	Graphics Processing Unit	Grafický procesor
HD	High Definition	Vysoké rozlíšenie
HEVC	High Efficiency Video Coding	Vysoko efektívne kódovanie videa
IP	Internet Protocol	Internetový protokol
ITU	International Telecommunication Union	Medzinárodná telekomunikačná únia
MOS	Mean Opinion Score	Hodnotiaca stupnica MOS
MPEG	Motion Picture Experts Group	Skupina expertov pre pohyblivý obraz
NN	Neural network	Neurónová sieť (NS)
OS	Operation System	Operačný systém
PAL	Phase Alternating Line	Kódovací štandard farebnej televízie
PSNR	Peak Signal to Noise Ratio	Špičkový pomer signálu k šumu
PTS	Presentation TimeStamp	Prezentačná časová pečiatka
RNN	Random Neural Network	Typ rekurentnej neurónovej siete
QoE	Quality of Experience	Kvalita vnímania
QoS	Quality of Service	Kvalita služby
SCSF	Spatial Contrast Sensitivity Function	Blok výpočtu metriky VQM
SQL	Structured Query Language	Štruktúrovaný vyhľadávací jazyk
SSIM	Structural Similarity Index	Index štrukturálnej podobnosti
UDP	User Datagram Protocol	Používateľský datagramový protokol
UHD	Ultra High Definition	Ultra vysoké rozlíšenie
VLC	Video Lan Client	Video LAN klient
VoIP	Voice over IP	Hlas prenášaný cez IP protokol
VQM	Video Quality Metric	Metrika video kvality

Zoznam tabuliek

8.1 Výsledky objektívneho a subjektívneho testovania pre scénu Campfire. 56
8.2 Výsledky objektívneho a subjektívneho testovania pre scénu Construction. 56
8.3 Výsledky objektívneho a subjektívneho testovania pre scénu Runners. 57
8.4 Výsledky objektívneho a subjektívneho testovania pre scénu Wood. 57
9.1 Výsledky nameraných hodnôt pre jednotlivé topológie. 65
9.2 Výsledky nameraných hodnôt pre jednotlivé aktivačné funkcie. 67
9.3 Výsledky štatistických veličín referenčných a modelových vzoriek. 71
9.4 Výsledky Mann-Whitney-Wilcoxonovho testu o zhodnosti mediánov. 71
9.5 Porovnanie navrhnutého modelu s publikovanými algoritmami. 75
A.1 Výsledky dotazníkového šetrenia. 91

Zoznam obrázkov

Obr. 2.1: Hlavička protokolu RTP [39]. Pole CSRC je nepovinné a používa sa hlavne pri prenose viacerých streamov súčasne napríklad počas videokonferencie [40]..... 18
Obr. 2.2: Štruktúra kodeku H.264 [19]..... 19
Obr. 2.4: Porovnanie veľkosti blokov medzi H.264 a H.265 [7]. 21
Obr. 2.5: Typy snímok a ich pomerová veľkosť [5]..... 22
Obr. 2.6: Dekódovanie GOPu = 8 – H.265 kodek [7]..... 22
Obr. 2.7: Rôzne typy GOPu - editačný (N=1, M=1), krátky (N=6, M=2) a štandardný GOP (N=12, M=3) [5]. 23
Obr. 2.8: Rozdiel poradia snímok dekódovania voči kódovaciemu procesu [5]..... 24
Obr. 2.9: Šírenie chyby v GOPe [42]. 24
Obr. 2.10: Podvzorkovanie 4:4:4, nedochádza k redukcii irelevancie [18]. 26
Obr. 2.11: Podvzorkovanie 4:2:2, z chrominančných makroblokov sa prenáša hodnota každého druhého stĺpca, mierna redukcia irelevancie [18]..... 26
Obr. 2.12: Podvzorkovanie 4:2:0 tzv. obriadok podvzorkovanie. Prenáša sa spriemerovaná hodnota okolitých pixelov, výrazná redukcia irelevancie [18]..... 26
Obr. 2.13: Pomer citlivosti ľudského oka pre spektrum farieb [45]..... 28
Obr. 3.1: Priebeh hodnotenia kvality videa metódou ACR [8]. 30
Obr. 3.2: Priebeh hodnotenia kvality videa metódou DCR [8], [9]. 30
Obr. 3.3: Schéma SSIM metriky [11]..... 32
Obr. 3.4: Schéma VQM metriky [20]..... 33
Obr. 4.1: Schematické zobrazenie neurónu [46]. 35
Obr. 4.2: Graf priebehu funkcie sigmoid a hyperbolický tangens (tanh) [16]. 36
Obr. 4.3: Štruktúra neurónovej siete [15]..... 37
Obr. 5.1: Základná stupnica MOS [17]. 41
Obr. 7.1: SI a TI indexy pre 4K videosekvencie [31]..... 48
Obr. 7.2: Schéma vytvárania videosekvencií. 49
Obr. 7.3: Postup hodnotenia videosekvencií. 50
Obr. 7.4: Prehľad použitých videosekvencii [22]..... 52
Obr. 8.1: Názvoslovie testovacích videosekvencií..... 55
Obr. 8.2: Porovnanie detailnosti snímky pri zachovaní bitového toku 5 Mbit/s pre UHD (hore) a Full HD (dole)..... 59
Obr. 8.3: Porovnanie výsledkov objektívneho a subjektívneho testovania pre scénu Campfire s bitovým tokom 5 Mbit/s..... 60

Obr. 8.4: Porovnanie výsledkov objektívneho a subjektívneho testovania pre scénu Campfire s bitovým tokom 15 Mbit/s. 61
Obr. 8.5: Zaznamenané artefakty v obraze pre HD rozlíšenie s 5 Mbit/s bitovým tokom. Stratovosť 0,1 % reprezentuje prvý riadok a 0,5 % druhý riadok, kodek H.264 je naľavo a H.265 napravo. 61
Obr. 9.1: Graf rozloženia absolútnych hodnôt relatívnej odchýlky. 66
Obr. 9.2: Graf predikcií neurónovej siete v stave pretrénovania (vľavo) a po jeho eliminovaní pomocou Dropout techniky (vpravo). 68
Obr. 9.3: Schéma priebehu výpočtu predikovanej hodnoty MOS navrhnutým modelom. 69
Obr. 9.4: Graf hustoty rozdelenia pre referenčnú a modelovú sadu. 72
Obr. 9.5: Korelačný diagram pre kodek H.264 (hore) a H.265 (dole). 73
Obr. B.1: Výsledok predikcie v závislosti na zadaných vstupoch. 100

1 Úvod

Konvergencia a s ňou spojená digitalizácia sietí, ktorá prebehla začiatkom 90-tych rokov, priniesla integráciu dovtedy separátnych prenosových systémov do jednej sieťovej infraštruktúry založenej na internetovom protokole IP. Vďaka tomuto procesu sa oddelené služby ako hlas, video a dáta mohli začať prenášať spoločnou prenosovou infraštruktúrou. Otvorila sa cesta k väčšej konkurencii na trhu, poskytovatelia pripojenia do siete Internet preberajú zákazníkov telekomunikačným a káblovým operátorom.

Na druhej strane treba spomenúť, že konvergencia priniesla so sebou nové problémy a potrebu nájsť nové riešenia. Architektúra siete založenej na IP nebola pripravená na real-time služby, ako je prenos hlasu a videa. Pri dátovom prenose je najdôležitejšie, aby nedochádzalo k stratám doručených informácií, ktoré môžu vzniknúť počas prenosu sieťou.

Interaktívna komunikácia dvoch a viac koncových strán si ale vyžaduje veľmi malé hodnoty celkového oneskorenia, inak je pocit interaktivity v reálnom čase narušený. Preto boli vytvorené nové protokoly pre prenos služieb reálneho času, ktoré tolerovali stratovosť dát, teda neprebiehalo overovanie doručenia a znovupreposielania stratených častí, čím sa znížila časová réžia prenosu a celkové oneskorenie. Ľudský zrak aj sluch nie je dokonalý a istá stratovosť dát (sluch je viac tolerantný na stratovosť ako zrak) je dokonca nepostrehnuteľná.

Okrem nových protokolov pre chod týchto služieb bolo nevyhnutné sa viac zamerať aj na monitorovanie výkonnosti siete. Celkové vyťaženie siete hrá významnú rolu pri vzniku oneskorenia a stratovosti v sieti a to z dôvodu čakania paketov v zásobníkoch smerovačov na ich spracovanie. Vznikli preto nové politiky prioritizovania dát, ktoré uprednostňovali časovo citlivé multimediálne dáta a vybavovali ich v smerovačoch prednostne.

S monitorovaním ide ruka v ruke vyhodnocovanie úrovne poskytovania služieb. Tu existujú dva rozličné prístupy k hodnoteniu kvality. Prvá skupina zahŕňa subjektívne hodnotenia, ktoré vychádzajú z pozorovania jednotlivých užívateľov. Tieto metódy vyjadrujú vnímanie poskytovanej kvality priamo koncovým používateľom a určujú, kde sa nachádza hranica pre akceptovateľnú kvalitu. Tieto testy sú ale náročné na čas a ľudské zdroje a generujú väčšie rozpätie výsledkov z dôvodu veľkej miery subjektivity hodnotiaceho človeka.

Objektívne metódy vychádzajú z matematických modelov snažiacich sa simulovať ľudské vnímanie, čo významne redukuje náklady na čas a ľudí. Zároveň pri rovnako nastavených podmienkach testovania dosahujú rovnaké výsledky, ktoré je možné medzi sebou jednoduchšie porovnávať a analyzovať. Tieto výpočtové modely pracujú s parametrami ako stratovosť, oneskorenie v sieti alebo typ kodeku a podľa matematických funkcií určia skóre vyjadrujúce kvalitu služieb.

Aj keď sú objektívne hodnotiace metriky preferované, v posledných rokoch nastáva opätovný odklon smerom ku subjektívnym testom. Dôvodom je rozmach poskytovateľov IPTV služieb, kde objektívne hodnotiace metriky nedostatočne poukazujú na vnímanie poskytovanej kvality služby ich zákazníkmi. To je aj jeden z dôvodov vzniku združenia QUALINET (s

podporou Európskej únie), ktoré zastrešuje výskumné organizácie naprieč celou Európou. Najaktuálnejšia otázka, ktorou sa toto združenie v oblasti kvality služby zaoberá, je nájsť spôsob prepojenia objektívnych a subjektívnych metrík, respektíve vznik novej hybridnej metodiky. Osobná účasť na výročnom stretnutí v Berlíne v roku 2015 mi umožnila získať nové poznatky a hlavne kontakty na výskumné tímy zaoberajúce sa touto problematikou.

Jeden zo spôsobov, akým by to bolo možné prepojiť oba spôsoby hodnotenia kvality popisuje aj predkladaná dizertačná práca. Úvodné kapitoly popisujú aktuálny stav skúmanej problematiky a prezentujú čiastkové výsledky vedeckých pracovníkov v tejto oblasti. Pomocou nich bude možné navrhnutý model a dosiahnuté výsledky porovnať a určiť reálny prínos tejto práce. Po nich nasleduje praktická časť, ktorá popisuje nevyhnutné kroky na vytvorenie databázy videosekvencií a výsledného modelu. Každá použitá testovacia videosekvencia bola ohodnotená subjektívnou aj objektívnou metrikou a výsledky umožnili nájsť prepojenie medzi týmito metrikami za pomoci vhodne navrhnutých prvkov umelej inteligencie. Posledná časť predkladanej práce sa venuje verifikácii navrhnutej metódy, analýze využitia v praxi a možnostiam ďalšieho výskumu.

2 Digitálne vysielanie pomocou IP (IPTV)

Systém šírenia digitálneho vysielania pomocou protokolu IP predstavuje v súčasnosti konkurencieschopný koncept pre prenos televízneho vysielania koncovému zákazníkovi. Spoločne s poskytovaním pripojenia do siete Internet a hlasovou telefóniou (VoIP) tvorí marketingovo pomenovaný balík služieb s názvom Triple play. Tento koncept priniesol konkurenciu do dovtedy často monopolného trhu poskytovateľov obrazových alebo hlasových služieb. Významne tomu pomohla konvergencia a digitalizácia sietí, protokol IP a paketové siete dosiahli dominantné postavenie pri prenose digitálnych služieb.

2.1 Prenosové protokoly v IPTV

Okrem transportného protokolu UDP, ktorý zabezpečuje prenos paketovou sieťou je de facto jediným všeobecne využívaným protokolom RTP protokol. Ten do seba zapuzdrí užívateľsky užitočné informácie (obrazovú alebo hlasovú vzorku) a na prijímacej strane zabezpečí doručenie v správnom poradí. Pri prenose môže byť využívaný aj podporný protokol RTCP, ktorý analyzuje a poskytuje kvalitatívne parametre prenosovej trasy (napríklad stratovosť alebo kolísanie oneskorenia - jitter) koncovým staniciam za účelom lepšej adaptácie na podmienky prenosovej sústavy. Tie vďaka týmto informáciám môžu meniť parametre prenosového toku a dosahovať tak čo najlepšiu možnú kvalitu multimediálnych služieb.

2.1.1 Real Time Transport Protocol

Protokol RTP je definovaný v odporučení RFC 3550 [39]. Tento protokol je z pohľadu referenčného modelu OSI zaradený na 5., čiže relačnú vrstvu. Najčastejšie je využívaný s protokolom UDP a umožňuje detekciu straty paketov a časové zoradenie paketov. Schéma RTP hlavičky je zobrazená na obrázku 2.1. Medzi jej významné polia patri [39], [40]:

- PT – Payload Type identifikuje formát prenášaných užitočných dát, zjednodušene povedané typ použitého kodeku.
- Sequence Number – Sekvenčné číslo, určujúce poradie daného RTP paketu vo vnútri dátového toku. Počiatočná hodnota je generovaná náhodne, každý nasledujúci RTP paket zvýši túto hodnotu o 1. Pomocou tohto čísla je možné detekovať stratu paketov.
- Timestamp – časová pečiatka používa sa na určenie poradia, v ktorom boli doručené údaje z média. Počiatočná hodnota je náhodne vybrané číslo odvodené od času média a následne je monotónne navyšovaná pre každý nasledujúci paket tak, aby zachytil časový rozostup vzniku dvoch za sebou idúcich paketov. Časová pečiatka slúži k synchronizácií zdroja a cieľa a k detekovaniu a výpočtu kolísania oneskorenia (Jitter).

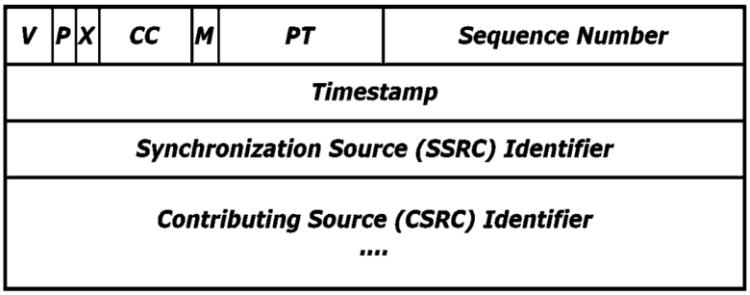

Obr. 2.1: Hlavička protokolu RTP [39]. Pole CSRC je nepovinné a používa sa hlavne pri prenose viacerých streamov súčasne napríklad počas videokonferencie [40].

2.1.2 RTP Control Protocol

Protokol je založený na pravidelnej výmene kontrolných paketov medzi všetkými účastníkmi RTP relácie, pričom taktiež využíva UDP protokol. Hlavnou úlohou RTCP je poskytovanie spätnej väzby na kvalitu služieb (QoS) poskytované RTP protokolom. Funkcia spätnej odozvy je realizovaná prostredníctvom RTCP sender a receiver reports (správy odosielateľa a prijímateľa). RTCP pakety obsahujú informácie (forma štatistiky), podľa ktorých môže vysielajúca strana dynamicky meniť multimediálny tok, ako rýchlosť prenosu alebo typ záťaže. RTCP tak poskytuje služby riadenia toku a kontrolu zahltenia siete. RTCP používa UDP port o jednotku vyšší ako používa RTP [39].

2.2 Kódovanie videa pre digitálne vysielanie

Dominantné postavenie pri prenose videa v digitálnej forme majú kodeky pracovnej skupiny MPEG. Pri spracovaní obrazu dochádza ku stratovej kompresii, pričom sa využíva nedokonalosť ľudského sluchu a zraku. Odstraňujú sa nepodstatné informácie z pohľadu ľudského vnímania [5], [12].

Ich kodek MPEG-2 predstavený v roku 1995 sa stal štandardom pre kódovanie videa pre DVD nosiče a pre rozbiehajúce sa digitálne televízne vysielanie. O niekoľko rokov neskôr bol uvedený jeho nástupca MPEG-4. Tento kodek má viacero verzií a pre prenos TV vysielania a kódovania filmov na digitálne nosiče vo vysokom rozlíšení (HD a Full HD rozlíšenie) sa ujal PART 10 využívajúci kodek H.264. Voči svojmu predchodcovi poskytuje výraznú úsporu prenosového pásma [3], [12]. Tento kodek v súčasnosti kóduje televízne vysielanie v digitálnej forme pre veľkú časť krajín Európy. V roku 2013 vychádza nový štandard pre uchovávanie videa v digitálnej podobe a to MPEG-HEVC využívajúci kodek H.265. Opäť poskytuje výraznejší kompresný pomer ako jeho predchodca, ale pre svoju náročnosť na výpočtový výkon sa ním počíta až pre kódovanie vo veľmi vysokom rozlíšení UHD, teda 3840 x 2160 a vyššie.

Okrem týchto kodekov existujú aj iné video formáty, ako VP8 a VP9 od spoločnosti Google, ale pre digitálne kódovanie televíznych staníc a uchovávanie na nosičoch sa doteraz nepresadili.

2.2.1 Kodek H.264 part 10

Tento kodek bol vytvorený v spolupráci vývojového tímu expertov Medzinárodnej Telekomunikačnej Únie (ITU-T Video Coding Experts Group) a skupiny MPEG. Tento kodek sa stal nástupcom kodeku MPEG-2. H.264 prislúcha k video štandardu ITU-T H.26x a zároveň skupine MPEG, ktorá používa značenie pre tento kodek ako MPEG-4/AVC [4].

Úmyslom pri návrhu H.264/AVC bolo vytvoriť štandard, ktorý by bol schopný pracovať s výhradne dobrou obrazovou kvalitou v bitových rýchlostiach, ktoré sú podstatne nižšie ako tie, ktoré boli potrebné pri predošlých normách. A mal by to tiež vykonávať bez zvýšenia zložitosti, ktorá robí realizáciu návrhu nadmieru drahou. Ďalším cieľom bolo vytvoriť štandard tak, aby bol flexibilný v použití väčšieho množstva aplikácií (podpora pre široký rozsah bitových tokov aj rozlíšení), aby pracoval v širokom spektre sietí a systémov (napríklad pre DVB-T, záznam na digitálne nosiče, streamovanie cez RTP/IP paketové siete). Základné aspekty H.264/AVC [4], [19]:

- Blok - pole pixelov s rozmerom 8 x 8.
- Makroblok - pozostáva zo skupiny štyroch blokov, čiže jeho rozmery sú 16 x 16 pixelov.
- Jas - komponent, ktorý kóduje informáciu jasu daného obrázku.
- Farebnosť - komponent, ktorý obsahuje informáciu o farbe.
- YCbCr model - definuje farebný priestor ako pomer jeden jas ku dvom farebným komponentom. YCbCr je bližšie k ľudskému vnímaniu farieb ako model RGB používaný štandardne pre zobrazovaciu techniku. Komponent jasu je značený ako Y, Cb a Cr sú farebné komponenty. Konkrétne, Cb je rozdiel modrého jasu a Cr je rozdiel červeného jasu.

Makrobloky sú usporiadané do segmentov. Pri H.264/AVC snímka pozostáva z jedného, alebo viacerých segmentov. Do kódovaných videí sú vkladané sekvenčné jednotky, aby boli vysielané pakety menšie. Myslí sa tým vysielanie nie celých snímok ako paketov.

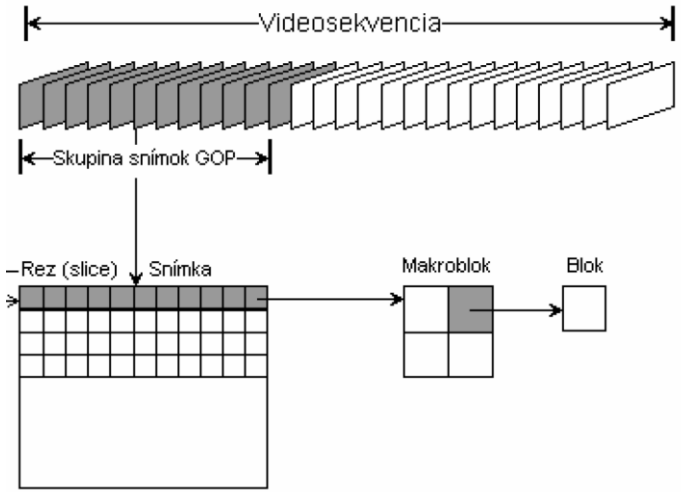

Obr. 2.2: Štruktúra kodeku H.264 [19].

Pravdepodobnosť výskytu bitových chýb je u malých paketov oveľa menšia ako u veľkých paketov. Navyše malé pakety redukujú množstvo stratenej informácie spôsobenej chybou, takže metódy na maskovanie chýb môžu byť využívané omnoho efektívnejšie. Na obrázku 2.3 je vidieť príklad, ktorý poukazuje na výhody používania segmentov. Ak nastane chyba, namiesto maskovania celého rámca sa musí maskovať len segment, kde nastala chyba [41], [42].

Medzi jednoznačné výhody kodeku H.264 patrí lepší kompresný pomer (50 % úspora voči MPEG-2), lepšia kvalita obrazu a synchronizácia zvuku. Popularitu kodeku umocnila aj narastajúca vlna zdieľania a ukladania videí na webové portály, napríklad najznámejší videoserver YouTube odporúča používať H.264 pre nahrávanie videí.

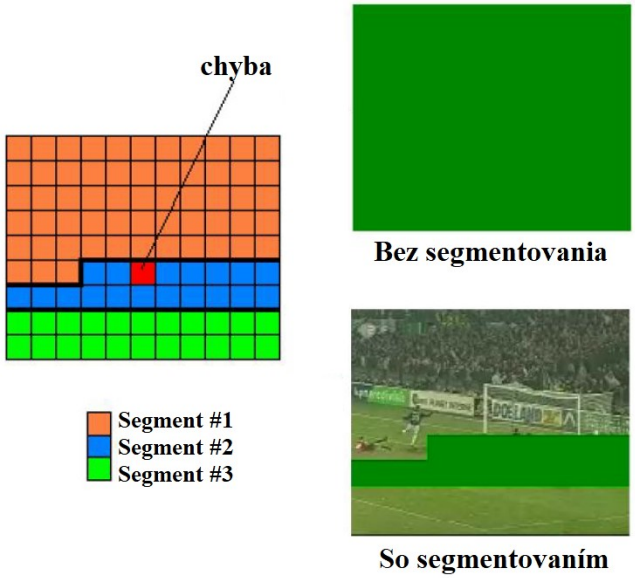

Obr. 2.3: Zobrazenie chyby s použitím segmentovania a bez neho [41].

2.2.2 Kodek H.265

H.265/HEVC (High Efficiency Video Coding) je nový štandard pre kompresiu videa. Bol štandardizovaný v 2013. Opäť sa jedná o spoluprácu medzi ITU a MPEG a je považovaný za nástupcu H.264. Efektivita kompresie je znovu navýšená o 50 %, ale na úkor vyššej výpočtovej náročnosti. Preto sa predpokladá jeho postupné nasadenie pre televízne vysielanie vo veľmi vysokom rozlíšení.

Slovenská televízia vysielala skúšobne v HEVC olympiádu v Riu v roku 2016, v ČR pre rok 2017 prechodová (testovacia) sieť má pokrývať už približne 70 % územia [14], [43].

Aby HEVC dosiahol maximálny kompresný pomer a zároveň zachoval veľký počet detailov, používa H.265 kodek nový spôsob rozdeľovania obrazu. Riadiaci prvok tvorí kódovací strom CTU, ktorý nahrádza predošlú štruktúru makroblokov. Dokáže makroblok rozšíriť až na 64 x 64 pixelov a dynamicky meniť jeho veľkosť (obr. 2.4). Tento fakt výrazne napomáha efektívnosti kompresie, najmä na veľkých homogénnych plochách.

Postup stromového kódovania začína rozdelením obrazu na jasové a chrominančné bloky CB s veľkosťou 64 x 64, 32 x 32 alebo 16 x 16 pixelov. Daný počet CB tvorí jednu kódovaciu jednotku CU. CU sa ďalej delia na predikčné bloky (PB) s rôznymi veľkosťami a

tvarmi pre medzisnímkovú a vnútrosnímkovú predikciu. Pri predikcii je možné vytvoriť dva druhy pohybových vektorov. Pre vypočítanie pokročilého pohybového vektora sú nevyhnutné údaje z referenčnej snímky a okolitých predikčných blokov. Mód zlúčenia pohybových vektorov zas umožňuje prebrať pohybové vektory zo susedných PB [7], [41].

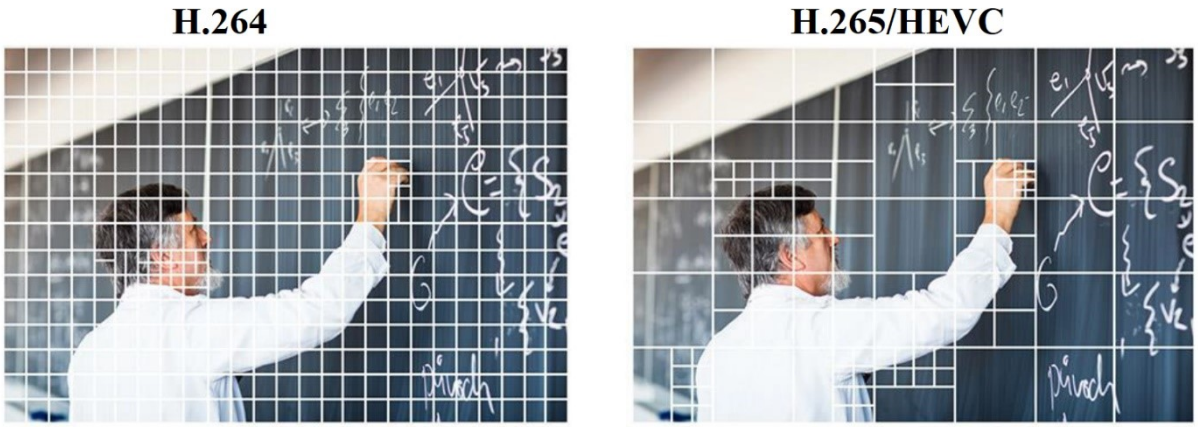

Obr. 2.4: Porovnanie veľkosti blokov medzi H.264 a H.265 [7].

2.2.3 Typy snímok a ich predikcie u MPEG štandardov

Snímka predstavuje hlavnú kódovaciu jednotku videosekvencií, ktorá využíva priestorovú alebo časovú koreláciu (podobnosť) informácií. Štandard definuje tri typy snímok zobrazených na obrázku 2.5 [3], [4], [5]:

- **I (Intraframe) - referenčné.**
  - Neobsahujú žiadnu väzbu na nasledujúce ani predchádzajúce snímky.
  - Obsahujú 100 % vykresľovaných informácií.
- **P (Predicted) - predikčné (smerom dopredu).**
  - Využívajú väzbu s predchádzajúcou **I** alebo **P** snímkou, ktorú následne použijú ako referenčnú. Predikcia je jednosmerná, smerom dopredu a prenáša sa len rozdiel medzi snímkami.
  - Úspora na dátový tok je približne 50 %.
- **B (Bidirectional predicted) - predikčné (obojsmerné).**
  - Využíva sa väzba na predchádzajúce **I** alebo **P** snímky. Predikcia je obojsmerná.
  - Úspora na dátový tok je približne 80 %.

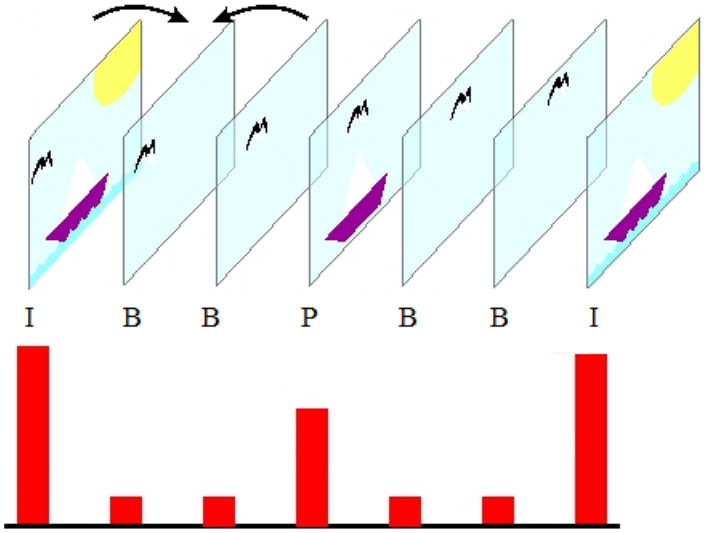

Obr. 2.5: Typy snímok a ich pomerová veľkosť [5].

Hierarchia u H.264 je obdobná ako pri MPEG-2. Prináša ale mnoho vylepšení a režimov. Zásadné rozdiely sú pri veľkosti transformovaného bloku a využívaní predikcií už aj pri vnútrosnímkovom kódovaní (intraframe). Predchádzajúce generácie využívali pohybové vektory len pri medzisnímkovom kódovaní (interframe). Predikcie sa využívajú už pri type snímok I a aplikujú sa v priestorovej oblasti. H.264 využíva pre predikciu informácie zo susedných okrajových nefiltrovaných pixelov makrobloku s najvhodnejšími informáciami. Lepšia predikcia v intraframe móde vedie k lepšej predikcii v interframe móde a teda aj k účinnejšej kompresii [6].

HEVC definuje novú hierarchickú štruktúru. Tá umožňuje B snímkam odkazovať na ďalšie B snímky pre vytvorenie hierarchickej odkazovej štruktúry, kde GOP tvorí skupinu snímok, v ktorej sa počet B snímok rovná dĺžke GOPu–1. Napríklad pre GOP = 8 by sekvencia mohla byť zakódovaná ako na obr. 2.6, kde v prvej fáze snímka B1 využíva dve P snímky. V druhej fáze dve B2 snímky využívajú P a B1 snímky ako referenčné. Z tohto dôvodu môžu byť tieto dve B2 snímky spracované paralelne. V tretej fáze môžu štyri snímky B3 využiť ako referenčné snímky P a B2 alebo B1 a B2 snímky. Vďaka tomu môžu byť všetky štyri snímky spracované paralelne [7].

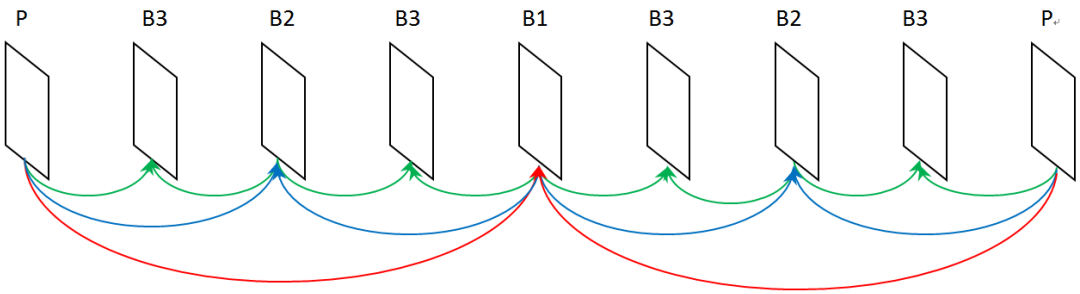

Obr. 2.6: Dekódovanie GOPu = 8 – H.265 kodek [7].

2.2.4 GOP (Group of Pictures) schéma

Predstavuje skupinu obrázkov tvorenú z P a B snímok umiestnených medzi dvomi I snímkami. Pri nedefinovanom type GOPu rozhoduje o type snímky kodér na základe predikcie a pohybových vektorov. GOP sa štandardne definuje dvomi premennými, N a M. N predstavuje počet snímok medzi dvomi referenčnými (I) snímkami (vrátane koncovej I snímky) a M definuje počet B snímok medzi dvomi P snímkami (vrátane koncovej P snímky). Pri využívaní predikčných snímok je potrebná vyrovnávacia pamäť pre spracovanie v dekodéri. Minimálna veľkosť počtu predikčných snímok uchovaných v pamäti zodpovedá:

$$P = \frac{1}{fps} \times N \tag{2.1}$$

Pri poškodení referenčnej snímky dôjde k poškodeniu aj predikčných snímok alebo až k strate celého GOPu. GOP zložený len z I snímok sa využíva len na editačné účely, pre prenos je nevhodný. Dôležitá je optimálna dĺžka GOPu [3], [5]:

- **Krátky GOP**:
  - vysoký objem dát,
  - nízke oneskorenie,
  - malá vyrovnávacia pamäť.

- **Dlhý GOP**:
  - menšia kvalita, nižší objem dát,
  - väčšie oneskorenie.

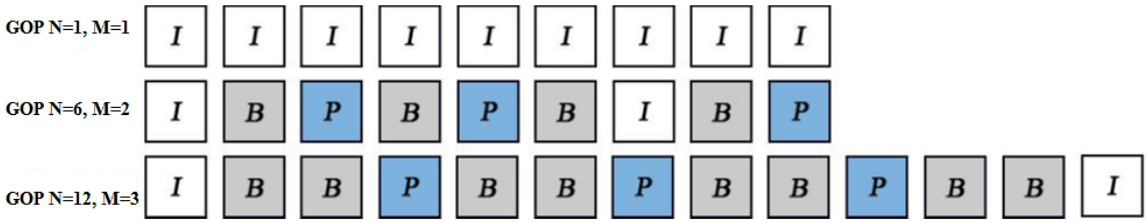

Obr. 2.7: Rôzne typy GOPu - editačný (N=1, M=1), krátky (N=6, M=2) a štandardný GOP (N=12, M=3) [5].

2.2.5 Dekódovanie

Poradie snímok pri vysielaní a dekódovaní je rozdielne ako pri ich zobrazovaní na zobrazovacej ploche. Na obrázku 2.8 vidieť, že pri prenose a dekódovaní dochádza k preusporiadaniu snímok. Pre dekódovanie B snímky potrebuje mať dekodér už vo svojej pamäti uložené jej predchádzajúce I a P snímky. Pre korektné poradie dekódovania v správnom čase slúži časová pečiatka DTS. DTS spolu s PTS sa prenáša v paketoch elementárneho toku [3], [5].

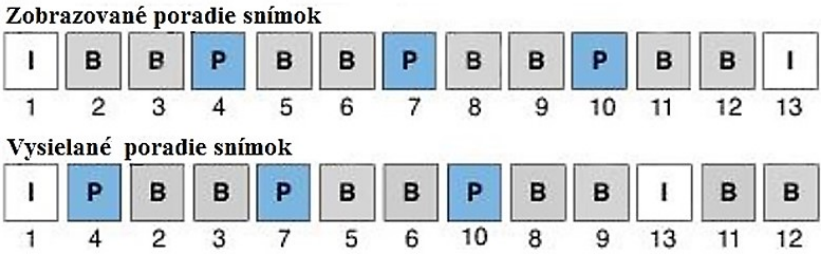

Obr. 2.8: Rozdiel poradia snímok dekódovania voči kódovaciemu procesu [5].

Vizuálne chyby obrazu spôsobené chybou dátového toku majú rozdielny profil v širokej závislosti na tom, ktorá časť video dátového toku je ovplyvnená prenosovou chybou a ako je nastavený kóder. Nevýhodou časovo-priestorovej predikcie je skreslenie obrazu spôsobené stratou makrobloku tým, že nie je obmedzená len na samotný stratený makroblok. Od momentu, keď sú priestorovo, alebo časovo susedné makrobloky závislé na predošlom poškodenom makrobloku, sa chyba obrazu (zelený makroblok) šíri do časovo susedných makroblokov vo vnútri celej videosekvencie až po dekódovanie ďalšej I snímky. To znamená, že až do príchodu nového GOPu budú priestorovo susedné makrobloky vo vnútri sekvencie poškodené. Ak sa použije veľké GOP, zlepší sa kompresia, ale chyba sa šíri do ďalších snímok (ako je vidieť z obrázku 2.9).

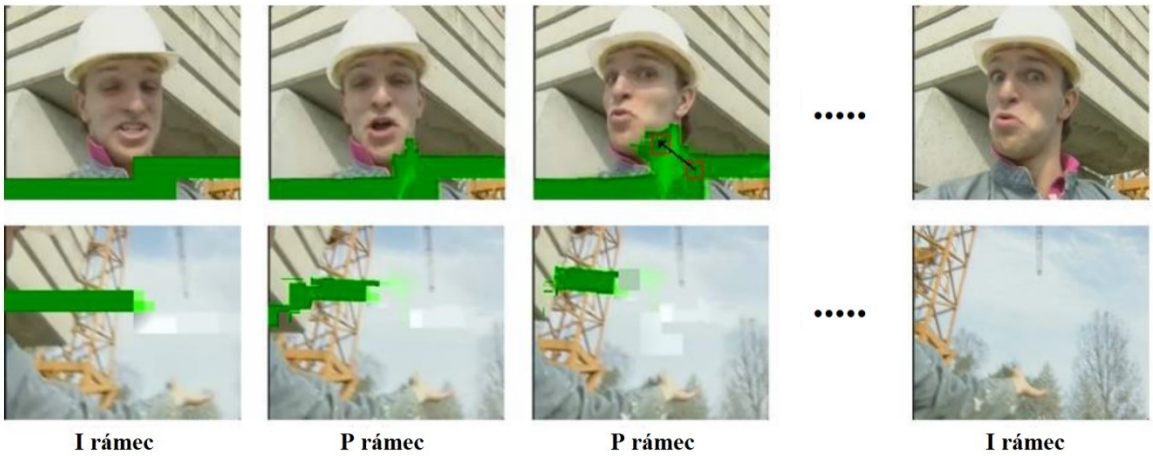

Obr. 2.9: Šírenie chyby v GOPe [42].

2.3 Parametre ovplyvňujúce kvalitu videa

Na to, aby bolo možné modelovať a predpovedať kvalitu videa je dôležité poznať hlavné parametre ovplyvňujúce jeho výslednú kvalitu. Vlastnosti podieľajúce sa na kvalite videosekvencií sú okrem typu kodeku nasledujúce [4], [5], [12]:

- rozlíšenie
- bitový tok
- bitová hĺbka RGB kanálov
- luminančná a chromatická zložka

Rozlíšenie vyjadruje počet pixelov, ktoré môžu byť zobrazené na obrazovke. Pixel predstavuje jeden bod obrazu zadaný svojou farbou podľa použitého modelu, napr. RGB. Preto s narastajúcim rozlíšením je potrebné kódovať viac informácií, čo zvyšuje dátový tok videa.
Bitový tok vyjadruje počet prenesených dát za určitú časovú jednotku, najčastejšie vyjadrený v megabitoch za sekundu (Mbit/s). Čím je bitový tok vyšší, tým môže byť kompresia obrazu menšia.
Bitová hĺbka a RGB model. RGB farebný model reprezentuje základný, aditívny farebný model troch primárnych farieb a to: červená (**R**ed), zelená (**G**reen) a modrá (**B**lue). Tento základný model však presne nedefinuje parametre jednotlivých troch RGB farieb. Rôznymi transformáciami tohto modelu a presne definovanými RGB zložkami vznikli kódovacie štandardy farebného signálu pre zobrazovaciu techniku v analógovej podobe (napr. PAL, NTSC,...). V súčasnosti je snaha normalizovať a využívať jeden farebný priestor viacerými zariadeniami pre odstránenie transformácií z jedného farebného priestoru na iný pri prenose signálu medzi rôznymi zariadeniami. Každý obrazový bod (pixel) je tvorený sústavou troch, ešte menších RGB subbodov. Pri aditívnom, súčtovom miešaní farieb, ktoré sa využíva v zobrazovacej technike, dostaneme vysvietením všetkých troch RGB subbodov s rovnakým jasom biele svetlo. Na obdobnom princípe pracuje aj vykresľovanie farieb v ľudskom oku. Vysvietením rôznych kombinácií RGB kanálov získame rôzne farby. Počet kvantovacích hladín alebo paleta farieb pre jeden RGB kanál je $2n$, kde n predstavuje bitovú hĺbku. Pri 10 bitovom videu by dokázal jeden kanál zobraziť 1024 hladín svojej farby.
Luminančná a chromatická zložka - Pred prenosom signálu cez prenosové médium dochádza k rozloženiu signálu na luminančnú a chrominančnú zložku. Takýto signál sa vo všeobecnosti označuje ako YUV, pri analógovom signáli hovoríme o YPbPr a pri digitálnom o YCbCr. Luminančná zložka (Y) reprezentuje jasovú informáciu a dve chrominančné zložky (UV) farbonosnú (červená a modrá). Takéto komponentné rozdelenie signálu vychádza z vlastnosti ľudského oka, ktoré je citlivejšie na zmeny v jasovej oblasti [2], [11]. Z tohto dôvodu sa kompresia dát a šetrenie dátového toku realizuje na chrominančnej zložke pomocou jej podvzorkovania. Podvzorkovanie chrominančnej zložky videa, čiže farbonosnej informácie, je veľmi dôležitým parametrom kompresie. Vzorka je najmenšia elementárna časť videa. Vzorka **Y** nesie informáciu o úrovni jasu a vzorky **Cb**, **Cr** informácie o hodnotách modrej a červenej farby pre jednotlivý pixel.

Blok, ako už bolo spomenuté, tvorí skupina 64 vzoriek usporiadaných do matice 8 x 8 vzoriek. Blok môže niesť informácie o jase a farbe [19]. Makroblok predstavuje základnú kódovaciu jednotku o veľkosti 16 x 16 pixelov. Vždy obsahuje štyri bloky jasovej informácie a podľa stupňa podvzorkovania chrominančnej informácie sa mení počet blokov farby. Podľa zloženia makrobloku z luminančných a chrominančných blokov rozlišujeme štyri základné typy podvzorkovania- 4:4:4, 4:2:2, 4:1:1, 4:2:0 [12], [18].

Pri názorných výpočtoch vyjadrujúcich ovplyvňovanie výsledného dátového toku, sa bude pracovať s referenčným videom v rozlíšení 1920 x 1080 pixelov, bitovou hĺbkou 10 bitov pre jeden kanál a snímkovou frekvenciou 30 fps.

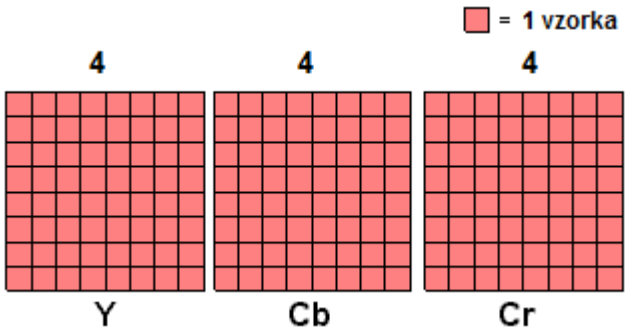

Obr. 2.10: Podvzorkovanie 4:4:4, nedochádza k redukcii irelevancie [18].

$$1920 \times 1080 \times 10 \times 30 \times 3 = 1\ 866\ 240\ 000 \text{ bit/s} = 1{,}86 \text{ Gbit/s} \quad (2.2)$$

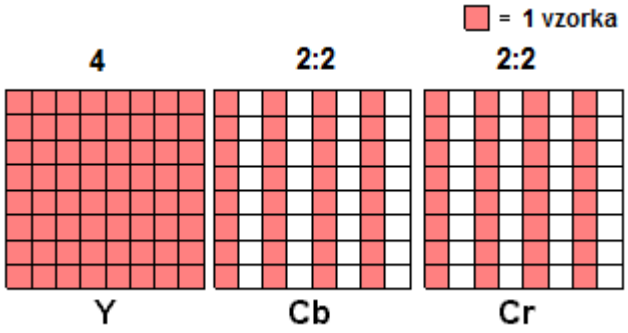

Obr. 2.11: Podvzorkovanie 4:2:2, z chrominančných makroblokov sa prenáša hodnota každého druhého stĺpca, mierna redukcia irelevancie [18].

Y: $1920 \times 1080\ x\ 10 \times 30 = 622\ 080\ 000$ bit/s = 622,08 Mbit/s (2.3)

Cb, Cr: $(1920/2) \times 1080 \times 10 \times 30 \times 2 = 622\ 080\ 000$ bit/s = 622,08 Mbit/s

Celkový dátový tok: 1 244 160 000 bit/s = 1,24 Gbit/s

Úspora na dátovom toku: 33%

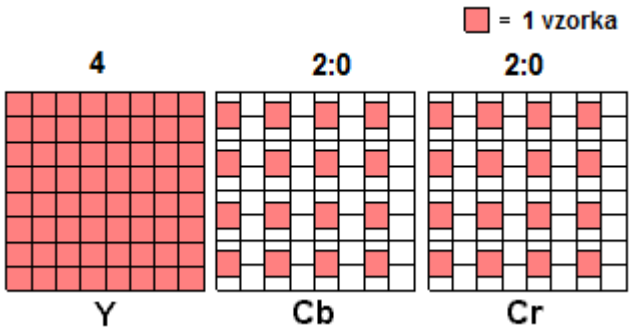

Obr. 2.12: Podvzorkovanie 4:2:0 tzv. obriadok podvzorkovanie. Prenáša sa spriemerovaná hodnota okolitých pixelov, výrazná redukcia irelevancie [18].

Y: $1920 \times 1080 \times 10 \times 30 = 622\ 080\ 000$ bit/s = 622,08 Mbit/s (2.4)

Cb, Cr: $(1920/2) \times (1080/2) \times 10 \times 30 \times 2 = 311\ 040\ 000$ bit/s = 311,04 Mbit/s

Celkový dátový tok: 933 120 000 bit/s = 933,12 Mbit/s

Úspora na dátovom toku: 50 %

Za profil poskytujúci vysokú kvalitu sa považuje 4:2:2 s 10 bitovou farebnou hĺbkou. Najčastejšie však dekódovacie zariadenia zákazníkov disponujú výkonom umožňujúcim profil 4:2:0 a 8 bitovú farebnú hĺbku. Tento profil je ale stále plne postačujúci pre kvalitné televízne vysielanie, a preto bol použitý pre tvorbu testovacích videosekvencií. Podľa uskutočnených kvalitatívnych testov sa výsledky medzi profilmi pohybujú rádovo v jednotkách percent [18].

2.4 Ľudský vizuálny systém

Zrak sa právom považuje za najdôležitejší zmysel každého človeka umožňujúci vnímať okolitý svet. Z pohľadu spracovania obrazu oči fungujú ako senzory (kamery), optický nerv ako prenosová cesta a ľudský mozog miesto, kde je obraz spracovaný.

Na sietnici ľudského oka sa nachádzajú dva typy fotoreceptorov, ktoré sú zodpovedné za premenu svetla na elektrický signál, pomenované podľa tvaru – tyčinky a čapíky. Tyčinky množstvom výrazne prevyšujú čapíky, na sietnici sa ich nachádza približne 100-140 miliónov. Sú rozmiestnené pravidelne po celej sietnici, okrem miesta v okolí fovey – stredovej jamky. Tyčinky sú zodpovedné za tzv. skotopické videnie, teda videnie za šera, kedy už nerozoznávame farby ale obrysy áno. Dokážu rozpoznávať iba jasovú zložku svetla, ale sú približne 200 000 krát citlivejšie ako čapíky.

Čapíkov v ľudskom oku nájdeme len 4 - 7 miliónov hlavne v oblasti stredovej jamky sietnice, v menšej hustote sú ale rozmiestnené po celej sietnici. Najaktívnejšie sú za denného svetla, s ubúdajúcim svetlom klesá aj ich citlivosť. Sú zodpovedné za farebné, denné, tzv. fotopické videnie. Pri miernom šere alebo slabom osvetlení sú aktívne tyčinky aj čapíky – tento jav sa nazýva mezopické videnie. Čapíky ďalej rozdeľujeme na tri druhy, ktoré sa od seba líšia vnímanou vlnovou dĺžkou svetla (krátke, stredné a dlhé vlnové dĺžky). Spolu dokáže ľudské oko rozoznať zhruba 150 odtieňov farieb [44].

Ľudské oko je zároveň odlišne citlivé na rôzne vlnové dĺžky svetla. Najvyššia citlivosť (spektrálna účinnosť) sa prejavuje pri vlnovej dĺžke 555 nm a celkovo pri odtieňoch zelenej – zelenožltej farby. Naopak, najmenej je oko citlivé na farby v okolí fialovej a modrej ako znázorňuje graf na obrázku 2.13 [44], [45].

Postupne nadobudnuté znalosti o vlastnostiach a nedokonalostiach ľudského videnia sa používajú na vytváranie a zdokonaľovanie rôznych technológií a postupov súvisiacich so spracovaním obrazu. Typickým príkladom je využitie pri tvorbe zobrazovacích zariadení a pri kompresii obrazového signálu. Vychádzajú z nich a objektívne hodnotiace metriky snažiace sa pri posudzovaní kvality obrazu čo najviac priblížiť ľudskému vnímaniu a tým eliminovať potrebu subjektívnych testov náročných na ľudské zdroje a čas. Tieto modely sú založené práve na psychologických a psychofyzických štúdiách, o niektorých vlastnostiach videnia ako spomenuté jasové prispôsobenie oka, vnímanie kontrastu, maskovanie atď.

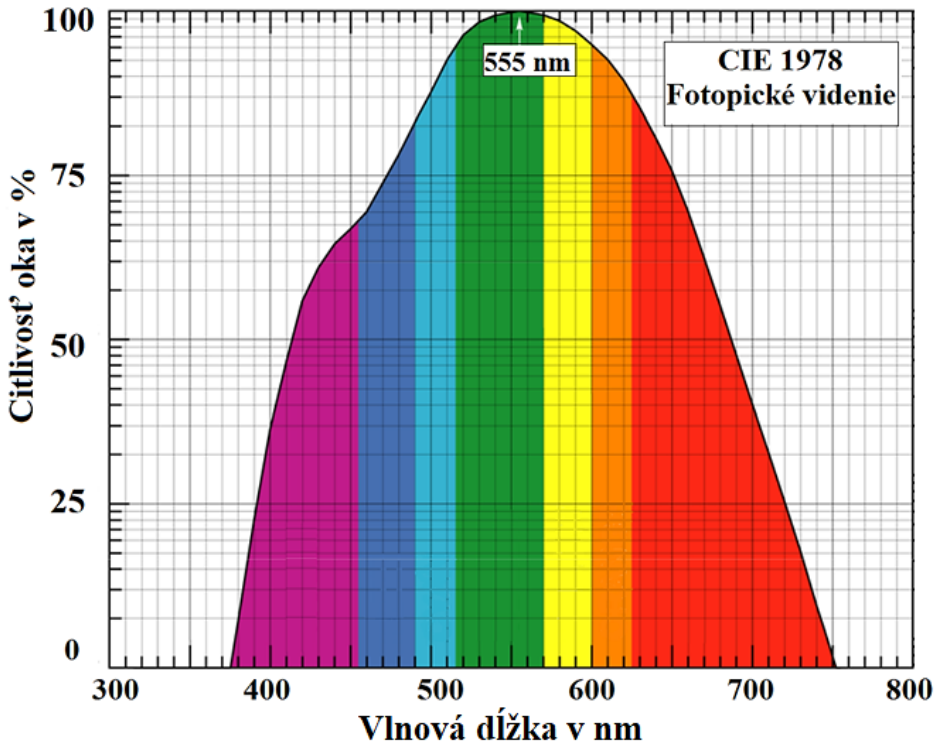

Obr. 2.13: Pomer citlivosti ľudského oka pre spektrum farieb [45].

S každým novým poznatkom dochádza k zdokonaľovaniu a približovaniu sa modelov k vnímaniu obrazu ľudským okom, nedá sa však očakávať, že by dokázali úplne nahradiť skutočného človeka a jeho subjektívne hodnotenie.

Parametrov, z ktorých modely vychádzajú, je pomerne veľké množstvo, tu sú spomenuté tie najdôležitejšie [44], [45].

- **Jasové prispôsobenie oka**

Človek dokáže vnímať veľký rozsah hodnôt jasu, avšak nikdy nie súčasne. Oko sa vie prispôsobiť jasu v rozsahu až 12 rádov, ak zohľadníme fotopické aj skotopické videnie. V skutočnosti to znamená, že dokážeme vidieť aj za bezmesačnej noci, aj pri priamom slnečnom svetle. O prispôsobení hovoríme, pretože ľudské oko sa adaptuje na strednú hodnotu momentálnej intenzity svetla a dokáže vnímať iba 2-3 rády hodnôt jasu v jej okolí. Citlivosť na ostatné, vyššie i nižšie intenzity svetla je len veľmi malá, v podstate zanedbateľná [44]. Adaptácia na momentálnu strednú hodnotu jasu v okolí nie je okamžitá, rýchlejšie sa ľudské oko dokáže prispôsobiť na zvýšenie intenzity svetla ako na jej pokles.

- **Citlivosť oka na kontrast**

Kontrast je možné definovať ako rozdiel jasov dvoch susedných bodov obrazu, pričom maximálny kontrast vyjadruje rozdiel medzi bielou a čiernou farbou. Zistilo sa, že zrakový vnem závisí viac na vzťahu medzi jasom konkrétneho bodu alebo miesta a intenzitou jasu v okolí, než na samotnom absolútnom jase. Kontrastom sa teda dá nazvať aj táto miera relatívneho jasu [44], [45].

3 Určovanie kvality videa

Prechod z analógového na digitálnu formu spracovania videa a jeho následný prenos paketovou sieťou založenou na protokole IP priniesol okrem pozitív aj niekoľko negatívnych vlastností. Takáto prenosová infraštruktúra nebola pôvodne navrhnutá na transfer multimediálneho obsahu v „reálnom čase“, ale na spoľahlivé doručovanie informácií. Vplyvom vyťaženia prenosovej cesty môže dochádzať k stratám paketov alebo k navyšovaniu prenosového času. Pre služby ako e-mail alebo web nemá celkové oneskorenie veľký vplyv na funkčnosť a stratovosť počas prenosu je vyriešená opätovným preposielaným chýbajúcich dát transportným protokolom TCP. Kontrola doručenia a ich prípadné chýbajúce znovu preposielanie však významne navyšuje časovú réžiu prenosu a nemôže byť použité pre služby vyžadujúcu vzájomnú interakciu ako hovor (VoIP) alebo videokonferencia. Preto sa používa prenosový protokol UDP, v ktorom absentuje kontrola doručenia dát a ľudské zmysly, zrak a sluch tolerujú istú mieru straty informácie.

Z pohľadu obrazovej služby je významný parameter ovplyvňujúci jej kvalitu práve stratovosť v sieti. IPTV alebo video streamovacie služby je možné pokladať za jednosmerné služby (prenos obsahu od videoservera smerom ku koncovému zákazníkovi) a pre účely tejto práce môžeme celkové oneskorenie v sieti pokladať za nepodstatné.

Na to, aby bolo možné hodnotiť kvalitu poskytovanej služby, ako napríklad degradačný vplyv stratovosti alebo výkonnosť a efektivitu samotných kodekov bolo vytvorených niekoľko hodnotiacich metrík, ktoré sa radia do dvoch hlavných skupín:

- Subjektívne hodnotiace metódy,
- Objektívne hodnotiace metódy.

Kým prvá skupina metód využíva reálnych pozorovateľov, druhá skupina využíva matematické modely snažiace sa adaptovať vnímanie ľudským okom. Na rozdiel od určovania kvality hlasu, neexistuje jednotná hodnotiaca škála. Subjektívne metódy využívajú spravidla stupnicu MOS (Mean Opinion Score) zadefinovanú v odporučení P.800 od ITU-T, ktorá bola prvotne určená pre hodnotenie hlasu. Objektívne metódy nanešťastie využívajú svoje separátne stupnice, príkladom môže byť staršia metóda PSNR (0 - ∞ dB) alebo dnes frekventovane využívaná metóda SSIM (0 - 1). Pre testovanie kvality videa sa vo veľkej miere využívajú testy subjektívne ako aj objektívne. Problémom ostáva interpretácia výsledkov objektívnych metrík a ich modelovanie na subjektívne vnímanie ľudským zrakom. Preto je hlavný cieľ tejto práce nájsť spôsob ako tieto rozdielne metriky medzi sebou prepojiť a správne interpretovať.

3.1 Subjektívne metriky hodnotenia kvality videa

Subjektívne metódy pre vyhodnotenie celkovej obrazovej kvality popisuje odporučenie ITU-T P.910. Tieto metódy môžu byť použité na rôzne účely ako hodnotenie kvality kódovacích algoritmov alebo úroveň kvality videa prenášaného cez sieťovú infraštruktúru. Toto odporučenie popisuje vlastnosti použitých zdrojových sekvencií ako dĺžka, typ obsahu (rozdelenie do kategórií podľa dynamiky pohybu) alebo doba na hodnotenie [8]. Toto odporučenie nadväzuje na [9], v ktorom sú podrobne popísané testovacie podmienky, napríklad svietivosť a kontrast obrazovky, uhol sledovania, či štatistické vyhodnotenie výsledkov.

- **ACR – Úplné kategorické hodnotenie**
  ACR je jedna z najpoužívanejších metód pre analyzovanie kvality videosekvencií. Testovacie sekvencie majú mať dĺžku do 10 sekúnd a po každej vzorke nasleduje rovnako dlhá pauza 10 sekúnd na ohodnotenie videnej sekvencie. Metóda patrí medzi nereferenčné metriky. Výsledky sú vyjadrené ako priemerné skóre na stupnici MOS [8].

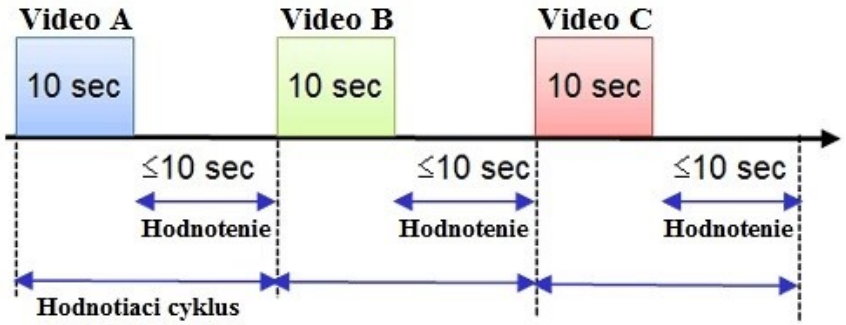

Obr. 3.1: Priebeh hodnotenia kvality videa metódou ACR [8].

- **DCR – Kategorické hodnotenie degradácie**
  Táto metóda známa tiež ako DSIS patrí medzi referenčné metriky. Sekvencie sú prezentované v pároch, po referenčnej sekvencii nasleduje sekvencia testovacia, čas na hodnotenie je rovnaký ako pri ACR. Výsledky sa udávajú ako skóre na stupnici MOS, ale v tomto prípade sa stupnica nazýva DMOS (degradácia MOS) [8], [9].

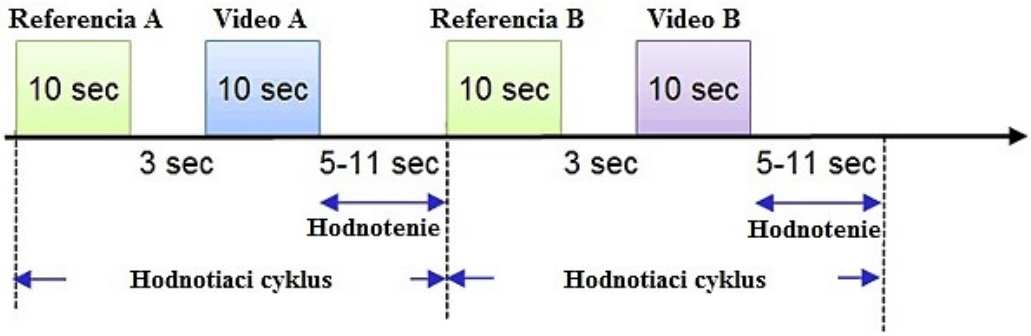

Obr. 3.2: Priebeh hodnotenia kvality videa metódou DCR [8], [9].

3.2 Objektívne metriky hodnotenia kvality videa

Objektívne hodnotiace metriky sú matematické metódy bez účasti pozorovateľov. Jedná sa o referenčné metriky vyhodnocujúce degradáciu testovacej sekvencie voči referenčnej vzorke. Objektívne metriky môžu byť nasadené priamo u poskytovateľov služieb a priebežne vyhodnocovať poskytovanú kvalitu s ohľadom na parametre a vplyvy prenosovej infraštruktúry. To umožňuje dynamicky reagovať a upravovať prenosové a kvalitatívne parametre tak, aby koncový užívateľ disponoval príjmom v čo najlepšej možnej kvalite. Dôležité je preto docieliť čo najpresnejšiu interpretáciu výsledkov objektívneho vyhodnotenia z pohľadu subjektívneho skóre, teda zabezpečiť prepojenie objektívnych a subjektívnych metrík v oblasti posudzovania kvality videa.

- **PSNR – Odstup signálu od šumu**
  Táto metrika je založená na princípe porovnávania pixelov z originálneho videa odpovedajúcim pixelom v testovacej sekvencii. Výhoda je rýchlosť a nenáročnosť výpočtu, nevýhoda je nedostatočné zohľadnenie vnímania kvality a skreslenia videa ľudským vnímaním [10], [11], [12]. Vychádza zo strednej kvadratickej chyby (MSE), ktorá predstavuje kvadratickú odchýlku medzi testovanou a originálnou vzorkou. PSNR potom určuje pomer medzi maximálnou hodnotou signálu voči MSE v decibeloch.

$$\mathrm{PSNR} = 10\log_{10}\left(\frac{\mathrm{MAX}_I^2}{\mathrm{MSE}}\right), [\mathrm{dB}] \tag{3.1}$$

  V podstate sa dá povedať, že zatiaľ čo MSE meria rozdiel medzi obrázkami, PSNR zisťuje, ako verne sa testovaný obrázok podobá na referenčný originál [10]. Metriky MSE a PSNR sú dobre definované iba pre informáciu, ktorá závisí od svietivosti, sily jasu, obrazu. Ak sa jedná o informáciu o farbe, resp. ak nastala zmena farby v obrazoch, neexistuje žiadna dohoda o vyhodnocovaní týchto metrík. Pretože sú založené na porovnávaní obrazu pixel po pixeli, majú len obmedzený, približný vzťah so skreslením, alebo s vnemom kvality ľudského zraku.

- **SSIM – Index štrukturálnej podobnosti**
  Metóda zohľadňuje vnímanie obrazu ľudským okom. Vyhodnocuje vizuálny dopad posunov jasu v obraze, zmien v kontraste a iné zaznamenané chyby porovnávaného obrazu voči originálu. Na rozdiel od PSNR porovnáva väčšie okolie bodu, čo umožňuje lepšie vnímanie rozdielov ľudského oka. Za okolie je možné považovať napr. štvorec s rozmermi 8 x 8. SSIM metóda je určená predovšetkým na počítanie kvality obrazu pre jas a kontrast snímky. Referenčné hodnoty SSIM sú v rozmedzí 0 až 1, kde nula znamená nulovú podobnosť s originálom a jeden dva úplne totožné obrazy.

Výsledná hodnota SSIM je kombináciou troch parametrov, keď pre originálny signál *x* a kódovaný signál *y* platí [11]:

$$\mathrm{SSIM}(x,y) = [l(x,y)]^{\alpha}[c(x,y)]^{\beta}[s(x,y)]^{\gamma} \tag{3.2}$$

- Člen ($l(x,y)$) porovnáva jas signálu.
- Člen ($c(x,y)$) porovnáva kontrast signálu.
- Člen ($s(x,y)$) meria štruktúru korelácie.
- $\alpha > 0$, $\beta > 0$, $\gamma > 0$ riadi váhu jednotlivých častí.

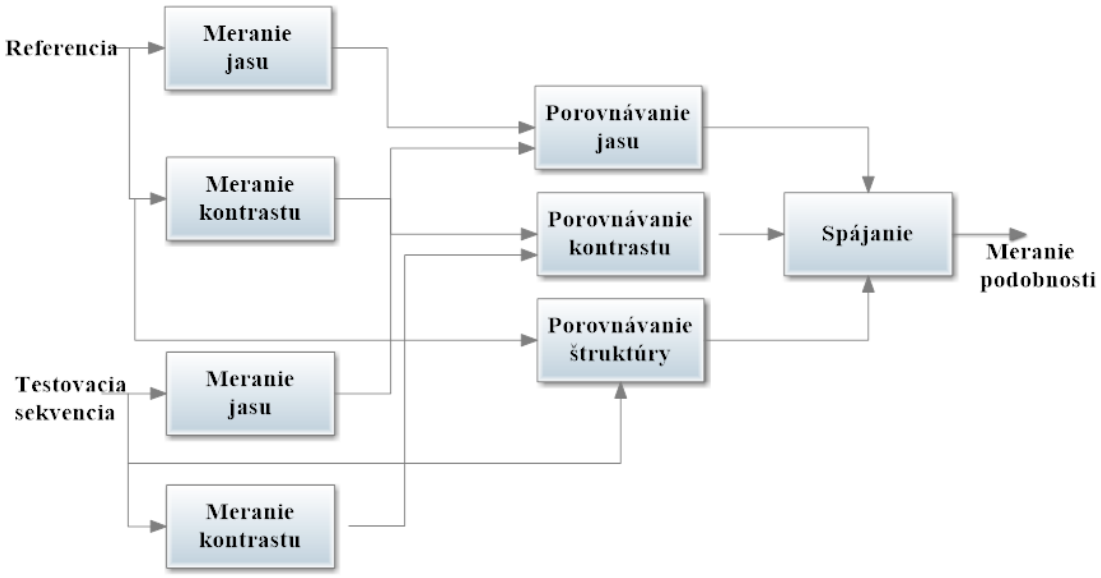

Obr. 3.3: Schéma SSIM metriky [11].

Pre správnosť výpočtu je veľmi dôležité, aby sa všetky tri komponenty l(x,y), c(x,y) a s(s,y) navzájom neovplyvňovali. Napríklad, aby zmena jasu, alebo kontrastu, nemala žiadny vplyv na štruktúru obrazu. V praxi sa zvyčajne vyžaduje hodnotenie kvality celého obrazu. Preto sa používa vzťah pre priemernú hodnotu SSIM tzv. MSSIM [35]:

$$\mathrm{MSSIM}(X,Y) = \frac{1}{M}\sum_{j=1}^{M} SSIM\ (x_j,\ y_j) \tag{3.3}$$

Kde X a Y sú originál a prislúchajúci skreslený obraz. x_j a y_j sú elementárne časti obrazu nachádzajúce sa na rovnakých pozíciách a M je množstvo elementárnych častí obrazu.

- **VQM – Metrika video kvality**
  Metrika, ktorá podobne ako SSIM bola vyvinutá, aby poskytovala merania vnímanej kvality videa. Hodnotí poškodenie videa, vrátane rozmazania obrazu, trhavý a neprirodzený pohyb, globálny šum, skreslenie a blok skreslenia farieb a spája ich do jednej metriky. Využíva pritom rozklad každej snímky na bloky, ktoré sú podrobené diskrétnej kosínusovej transformácii (DCT). Následne sú tieto koeficienty spracované a porovná sa rozdiel medzi referenčnou a testovacou snímkou [20].

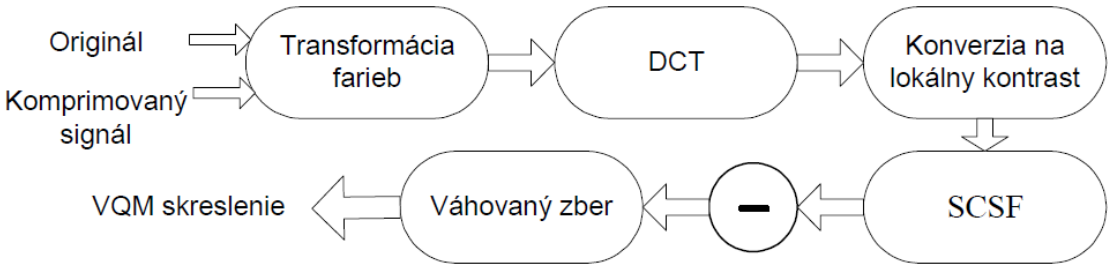

Obr. 3.4: Schéma VQM metriky [20].

Na obrázku 3.4 vidieť algoritmus pre výpočet VQM metriky. Originál a komprimovaný signál vstupujú do nasledovných blokov, pomocou ktorých sú potom tieto dva signály, respektíve obrazy, porovnávané a vyhodnotené. Blok SCSF koncentruje iba nápadné priestorové rozdiely DCT komponentov a následne ich konvertuje do lokálneho kontrastu (LC), čo má za následok, že pri výpočte nie sú také vysoké nároky na pamäť. DCT koeficienty sa prevedú do LC tak, že sa každý DCT koeficient vynásobí so zodpovedajúcou zložkou v SCFS matici. Váhový zber je posledný krok, kde sa vypočítava veľkosť stredného a maximálneho skreslenia. Potom sa začlení maskovanie kontrastu do operácie jednoduchého určenia maximálnej váhy a porovná so stredným skreslením. To odráža skutočnosť, že veľké skreslenie v jednej časti potlačí našu citlivosť na ďalšie skreslenie [20].

SSIM metrika je využívaná častejšie pre analýzu kvality videa ako VQM. Z mnohých testov vyplýva, že dosahuje dobrú koreláciu s ľudským vnímaním, pretože porovnáva testovaciu a referenčnú vzorku spôsobom odzrkadľujúcim vplyv degradácie jasu alebo kontrastu na ľudský zrak [3], [11], [20], [23]. Preto bola táto metrika zvolená pre objektívne testovanie kvality na účely realizácie zámerov dizertačnej práce. Problémom ale ostáva správne podanie výsledkov. Ak je SSIM výsledok napríklad 0,855, môže sa daný výsledok interpretovať ako pokles kvality o takmer 15 %. Neexistuje ale zadefinovaný exaktný prevod medzi stupnicou SSIM a subjektívnym vnímaným napríklad v podobe stupnice MOS, a preto dochádza k rozporom, ako výsledky metriky SSIM správne interpretovať.

4 Neurónová sieť

Neurónová sieť (NS) je výpočtový systém, ktorý má schopnosť uchovávania informácií a umožňuje ich ďalšie spracovanie, pričom napodobňuje ľudský mozog v zbieraní poznatkov v procese učenia a uchovávaní týchto poznatkov s využitím medzineurónových spojení [15]. Modely neurónových sietí do značnej miery zjednodušujú procesy, ktoré vnútri v mozgu prebiehajú.

Základným prvkom NS je neurón. Obecný model neurónu s vektorom vstupov x_i a váh w_i je zobrazený na obrázku 4.1.

Operácia, ktorou neurón transformuje svoje vstupy na výstup je spravidla veľmi jednoduchá a skladá sa z dvoch krokov:

- výpočet post-synaptického potenciálu,
- výpočet výstupnej hodnoty.

Zložitá činnosť NS spočíva v spojení mnohých takýchto jednoduchých elementov do celku. Prvý proces sa zaoberá vstupmi do neurónu a nastavenými váhami a výsledok tohto procesu je postúpený aktivačnej funkcii, ktorá ho spracuje na výstup z neurónu. Aktivačná funkcia buď zosilňuje alebo utlmuje vstupný potenciál neurónu. Zvyčajne, hlavne v začiatkoch strojového učenia, hromadne využívanou aktivačnou funkciou bola skoková funkcia, ktorá je typická pre model neurónu nazývajúci sa perceptron. Výstup tohto modelu neurónu závisí od zvolenej hodnoty prahu θ a je definovaný rovnicou 4.1 [15]:

$$y = Sgn\left(\sum_{i=1}^{n} w_i x_i - \theta\right) \tag{4.1}$$

kde

$Sgn(x) = 1, \quad x > 0,$

$Sgn(x) = 0, \quad x \leq 0,$

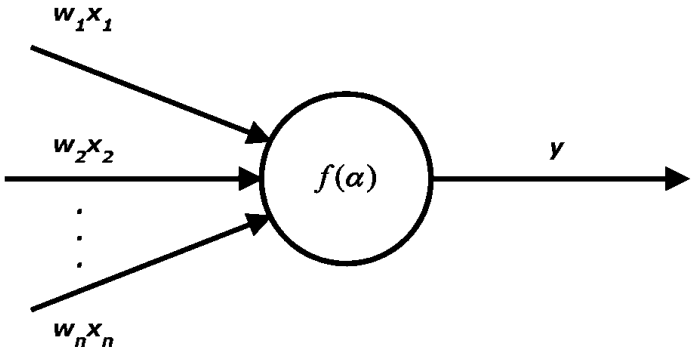

Obr. 4.1: Schematické zobrazenie neurónu [46].

Perceptron funguje výborne ako tzv. binárny klasifikátor, teda je schopný vstupy rozdeľovať do dvoch základných skupín. Pre potreby zložitejších úloh je vhodné mať aktivačnú funkciu, ktorá by zachovávala možnosť binárnej klasifikácie a zároveň poskytovala komplexnejšiu škálovateľnosť pri rozhodovaní o zaradení do konkrétnej skupiny. Nepoužije sa skoková funkcia, ale napríklad funkcia nazývaná sigmoid, ktorá je v prípade neurónových sietí najčastejšie používaná. Spôsob nastavovania sigmoidnej funkcie je daný jej požadovanou strmosťou [15], [16].

$$y = f\left(\sum_{i=1}^{n} w_i x_i - \theta\right) \qquad f(x) = \frac{1}{1+e^{-x}} \tag{4.2}$$

Pre rôzne prípady sa používajú aj iné funkcie ako Elliotova funkcia, lineárna funkcia, hyperbolický tangens (tanh), Rectified linear unit (ReLu) a podobne [46]. V závislosti od použitej funkcie je obor hodnôt a definičný obor <0,1> (napr. Sigmoid) alebo <-1,1> (napr. tanh). V prípade spojitej funkcie hovoríme o spojitom perceptrone.

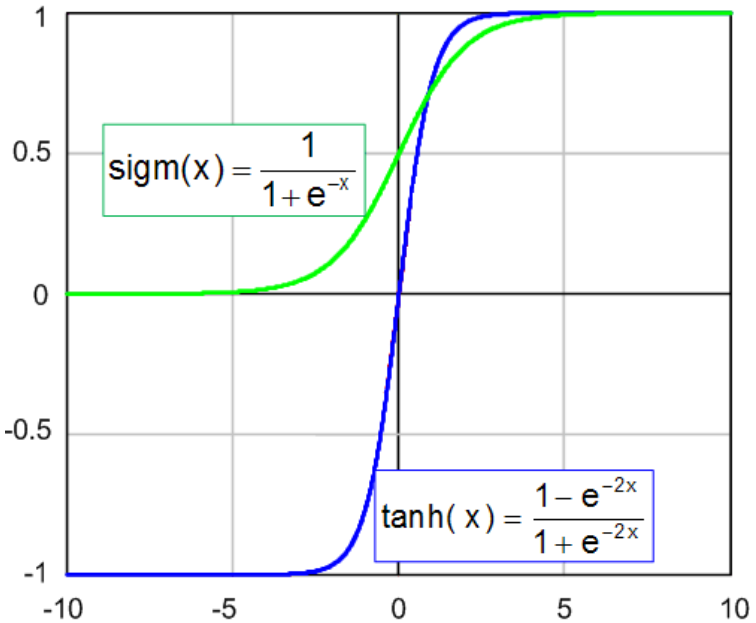

Obr. 4.2: Graf priebehu funkcie sigmoid a hyperbolický tangens (tanh) [16].

4.1 Viacvrstvové neurónové siete

Modely neurónových sietí sa snažia napodobniť správanie ľudského mozgu. Hoci je samotný neurón schopný plniť rôznorodé funkcie podobne ako v našom mozgu, na plné rozvinutie jeho potenciálu je potrebná spolupráca viacerých medzi sebou pospájaných neurónov. Vzájomným

prepojením neurónov je sieť schopná riešiť komplexnejšie problémy (rozoznávať viac skupín resp. z pohľadu grafu viac rovín) a zároveň nadobúda schopnosť generalizovať, teda s určitou presnosťou odhadovať výstupy aj pre tie vstupy, s ktorými sa dovtedy sieť ešte nestretla [16].

V prevažnej väčšine sietí sú neuróny usporiadané do vrstiev. Tento prístup značne uľahčuje programovú implementáciu a umožňuje matematický popis činnosti NS. Opäť tu možno nájsť aj podobnosť s ľudským mozgom: „vrstvy“ neurónov sa nachádzajú aj v niektorých jeho častiach.

Ako je vidieť z obrázku 4.3 obecná neurónová sieť sa skladá aspoň z troch vrstiev. Medzi dvomi susednými vrstvami sa nachádza tzv. úplne prepojenie neurónov, každý neurón nižšej vrstvy je spojený s každým neurónom vrstvy vyššej.

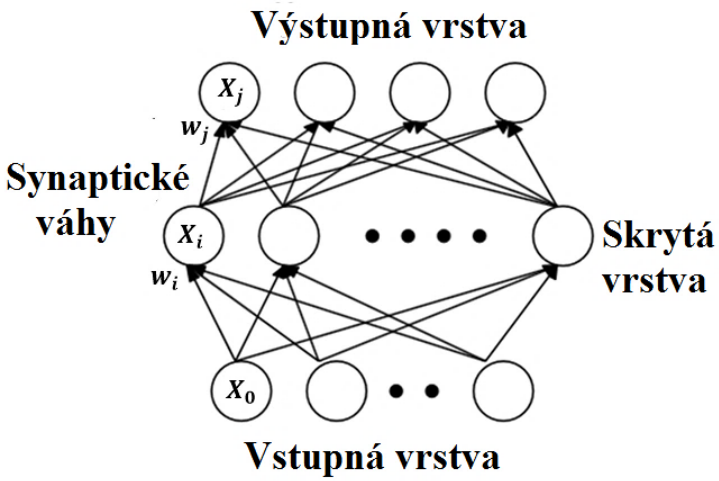

Obr. 4.3: Štruktúra neurónovej siete [15].

Počty neurónov v jednotlivých vrstvách závisia na niekoľkých faktoroch. V prípade vstupnej vrstvy musí počet neurónov odpovedať počtu elementov vo vstupnom vektore. V prípade výstupnej vrstvy platí obdobné pravidlo, s tým rozdielom, že niekoľko hodnôt (typicky 2) môže byť interpretované jedným neurónom. Správnemu určeniu počtu neurónov v skrytých vrstvách predchádza často „experimentovanie“ a hľadanie najlepšieho výsledku pomocou testovania mnohých topológií siete. Obecne však platí, že tvar neurónovej siete by mal mať tvar trojuholníka alebo lichobežníka, teda zužovať sa smerom k výstupnej vrstve, aby mal schopnosť generalizácie.

Podľa smeru, ktorým sa šíria signály v NS ich rozdeľujeme do dvoch hlavných skupín. Dopredné (angl. feed-forward) NS sú také, v ktorých sa signál šíri iba od vstupných neurónov (neuróny, ktorých vstupmi sú signály z prostredia) cez skryté neuróny (neuróny, ktoré sú vstupmi aj výstupmi spojené s inými neurónmi; tieto sa v niektorých typoch NS nemusia vôbec nachádzať) k výstupným neurónom (neuróny, ktorých výstup vedie do prostredia). Rekurentné NS sú také, v ktorých sa signál môže pohybovať aj smerom od výstupov ku skrytým častiam alebo dokonca až k vstupom. Využívajú sa hlavne v oblastiach, kde sú sledované javy závislé na svojej predchádzajúcej hodnote.

4.1.1 Metóda Backpropagation

Ako bolo uvedené na začiatku kapitoly, jednou zo základných vlastností NS je schopnosť učiť sa. Zjednodušený priebeh neurónovej siete, kde sa informácia propaguje dopredným šírením, je daný tým, že sa najprv excitujú neuróny na vstupnej vrstve. Ich excitácia sa prenáša do vyššej vrstvy, kde bude signál pomocou synaptických váh upravený. Každý neurón vyššej vrstvy spraví sumu takýchto signálov od všetkých pripojených neurónov nižšej vrstvy a podľa výsledku a svojej aktivačnej funkcie excituje na 0 alebo 1. Tento proces prebieha celou sieťou až kým nie sú všetky neutróny excitované. To, ako správne nastaviť synaptické váhy, je dané procesom učenia.

Schopnosť viacvrstvovej siete poskytovať čo najrelevantnejšie výsledky závisí na tom, ako presne sú nastavené váhy prepojení medzi jednotlivými neurónmi (synapsiami). Podľa toho na akom princípe sa využíva schopnosť učenia, rozoznávame dva typy učenia sa NS.
Kontrolované učenie (angl. supervised learning) je založené na tom, že sieť má pri svojom učení k dispozícii množinu vstupov a k nim požadovaných výstupov. V procese učenia sa upravujú parametre siete (tzv. váhy spojení) tak, aby sa minimalizoval rozdiel medzi získanou odozvou siete na dané vstupy a výstupmi požadovanými pre tieto vstupy.
Nekontrolované učenie (angl. unsupervised learning) je také, pri ktorom má sieť k dispozícii iba vstupy; k nim prislúchajúce výstupy sieť generuje na základe vlastností samotných vstupných údajov. Tieto výstupy nie sú vopred známe.

Metóda využitá pri trénovaní neurónovej siete sa nazýva Backpropagation. Tá spočíva v použití vektora vstupov a náhodnom generovaní váh spojení. Potom sa nechá spočítať odozva NS. Porovnaním výsledku odozvy s požadovaným stavom sa zistí chybovosť neurónovej siete. Následne smerom od najvyššej vrstvy k najnižšej dôjde k úprave synaptických váh tak, aby chyba pri následnej odozve NS bola čo najnižšia [16].

Dá sa povedať, že podstata tejto metódy učenia spočíva v hľadaní minima chybovej funkcie E, ktorá je definovaná v rovnici 4.3 [15]:

$$E = \frac{1}{2} \times \sum_{i=1}^{p} \sum_{j=1}^{m} (y_j - o_j)^2 \tag{4.3}$$

kde y_j je skutočná odozva neurónu výstupnej vrstvy, o_j je požadovaná odozva j-tého neurónu výstupnej vrstvy, p je celkový počet vzorov trénovacej množiny a m je počet neurónov výstupnej vrstvy.

Minimalizácia chybovosti prebieha vhodnou úpravou váhového vektoru, pričom jeho zmena je daná rovnicou 4.4:

$$\Delta w_{ij} = -\eta \times \frac{\partial E}{\partial w_{ij}} + \mu \times \Delta w'_{ij} \tag{4.4}$$

kde η je koeficient učenia, μ je koeficient vplyvu zmeny váh z predchádzajúceho kroku a $\Delta w'_{ij}$ zmena váhy z predchádzajúceho kroku.

Parciálna derivácia chybovej funkcie E podľa synaptickej váhy w_{ij} je vynásobená koeficientom učenia preto, aby chybová funkcia nemala tendenciu divergovať od svojho minima. Záporné znamienko potom otáča smer posunu chybovej funkcie od maxima k minimu. Druhý člen nesie informáciu o vplyve predchádzajúcej zmeny váh a v mnohých implementáciách sa vôbec nevyužíva, uvedený je tu z obecného hľadiska [46].

Pre proces učenia NS je potrebné vytvoriť trénovaciu množinu (z tej sa ešte vyčlení validačná sada) a testovaciu množinu pre verifikáciu modelu. Trénovacia množina obsahuje prvky (vzory) pri ktorých sa vie nielen vstup ale aj aký výstup (odozvu) by NS mala poskytnúť. Porovnaním vzorov a výsledkov odozvy NS sa určí prvotná chybovosť, ktorá sa následne pomocou vyššie uvedenej metódy postupne znižuje až na požadovanú úroveň. Natrénovaná neurónová sieť sa otestuje pomocou validačnej množiny, ktorá obsahuje dáta (vzory), ktoré neboli použité pre trénovanie NS. Počas priebehu trénovania môže dochádzať k javu, že chybovosť trénovacej množiny klesá, ale u validačnej množiny narastá. Tento jav sa nazýva pretrénovanie a je preto potrebné nehľadieť len na klesajúcu chybovosť trénovacej množiny, ale hľadať najvhodnejší kompromis pri nastavovaní váh a výberu topológie.

5 Súčasný stav skúmanej problematiky

Oblasť výskumu, ktorá je popísaná v tejto práci, hľadá prienik medzi dvomi veľkými oblasťami prístupu k hodnoteniu kvality, a to kvalita služby (QoS) a kvalita vnímania (QoE). Rozvoj týchto celkov nadväzoval na rozmach využívania hlasovej a obrazovej služby. Prvý stret týchto prístupov nastal pri hodnotení kvality hlasu. Subjektívne hodnotenia pozostávajú z konverzačných a posluchových testov, kde užívatelia hodnotia čistotu hlasu a celkovú kvalitu interaktívneho pocitu z obojstrannej komunikácie. Objektívne metriky priniesli zefektívnenie testovacieho procesu na základe algoritmov snažiacich sa odhadnúť kvalitu hlasu porovnávaním referenčného a testovacieho vzorku. Obe kategórie pritom využívajú hodnotiacu stupnicu zvanú MOS, ktorá je definovaná v odporučení ITU-T P. 800 [17]. Táto stupnica nadobúda hodnoty od 1 do 5, kde 5 znamená najlepšiu kvalitu. Stupnica je rozdelená do piatich kategórií ako ukazuje obrázok 5.1.

Obr. 5.1: Základná stupnica MOS [17].

Ako príklad štandardizácie objektívnych testov slúži odporučenie P.861 od ITU-T, ktoré popisuje ako objektívne matematicky hodnotiť kvalitu reči poskytovanú jednotlivými hlasovými kodekmi. Výsledok vyjadroval mieru zhoršenia signálu a bol pretransformovaný na stupnicu MOS. Prielom nastal vydaním odporučenia G.107 známe ako E-Model. Toto odporučenie prinieslo objektívny spôsob ako vyhodnotiť kvalitu hlasovej služby pričom berie do úvahy vplyvy, ktoré môžu nastať na prenosovej trase. Novšie vydanie tohto odporučenia umožnilo jeho využitie aj pre paketové siete, a teda používa sa aj pre hodnotenie hlasu prenášaného cez IP sieť tzv. VoIP. Hoci táto metrika pôvodne využívala hodnotiacu škálu od 0-100, odporučenie však uvádza aj prevod na stupnicu MOS. Výhoda MOS spočíva v jej presne zadefinovaných hraniciach, ktoré popisujú poskytovanú kvalitu. Z hľadiska objektívneho a subjektívneho testovania kvality hlasovej služby teda existuje prepojenie v podobe využívania jednotnej interpretačnej škály MOS.

Ďalší výskum sa sústredí najmä na hľadanie nových modelov, ktoré by boli schopné vylepšiť E-Model prostredníctvom využitia neurónových sietí alebo regresných rovníc [46] [frn1], [frn2].

Oproti tomu je situácia v oblasti hodnotiacich techník videa odlišná. Existuje viacero subjektívnych aj objektívnych metrík, každá však používa rozličnú výsledkovú škálu. Subjektívne testy zastrešujú odporúčania ITU-T P.910 a ITU-R BT.500 určené pre referenčné aj nereferenčné testovanie.

Objektívne hodnotiace metódy podobne ako pri hlase pozostávajú z matematických modelov schopných vyjadriť mieru podobnosti testovacieho vzorku s referenčným. Medzi výpočtovo nenáročnú a stále používanú metriku sa radí PSNR, v súčasnosti asi najpreferovanejšia objektívna metrika na ohodnotenie kvality video snímok je SSIM [2], [3], [10].

Výskum spravidla zahŕňa niekoľko oblastí. Tou prvou je účinnosť kodekov. Porovnáva sa dosiahnutá kvalita obrazu novo vydaného kodeku s predchodcami a jeho výpočtová náročnosť. Druhá oblasť sa zaoberá analýzou vplyvu sieťových parametrov na kvalitu obrazu. Pretože v prípade prenosu videa, ktorý je spravidla jednosmerný, berie sa do pozornosti ako dôležitý fenomén stratovosť v sieti. Táto oblasť výskumu prináša výsledky robustnosti videokodekov na stratovosť [frn3], [frn4].

Posledná oblasť sa zameriava na spôsoby hodnotenia kvality videa. Jedno z prvých zapojení neurónových sietí do hodnotenia kvality videa je neintrusívna (nereferenčná) metóda z oblasti QoS s názvom PSQA (Pseudo Subjective Quality Assessment). Tento model je založený na vytrénovanej neurónovej sieti, ktorá sa snaží čo najlepšie simulovať výsledky subjektívneho testovania DCR v závislosti na kvalite videa a výkonnosti prenosovej siete. Ako vektor vstupov slúžili parametre videa ako bitový tok, kodek, alebo stratovosť v sieti. Autori však použili primárne dnes už zastaralý kodek MPEG-2, nízke rozlíšenie CIF (352 x 288) a bitové toky do 1 Mbit/s. Hoci výsledky dosahovali dobré parametre (Pearsonov korelačný koeficient viac ako 0,98), boli dosiahnuté s použitím databázy s nízkym počtom vzorov (trénovacia sada 80 vzoriek, testovacia množina obsahovala iba 14 vzoriek) [25]. Táto práca však poslúžila ako základná metodika aj pre túto dizertačnú prácu.

Autori v [26] sa zamerali pri tvorbe modelu na odlišné príznaky popisujúce vlastnosti videa alebo siete ako rôznu dĺžku GOPu, rôzne nastavenia prioritizácie dát v sieti (BestEffort a DiffServ) či vytvárania úzkeho hrdla siete. Bolo použité iba jedno rozlíšenie (720 x 480) a veľké krokovanie stratovosti dát v sieti (1, 5, 10 %). Výsledný korelačný koeficient bol mierne cez 0,94 a RMSE 0,27.

Mapovanie hodnôt SSIM na škálu MOS pomocou regresnej rovnice je popísané v [27], výsledky korelácie však kolíšu v závislosti na použitom type videosekvencie od 0,65 do 0,91.

Technika strojového učenia v podobe lineárnej regresnej funkcie (Elastic Net) bola použitá pre tri dostupné online databázy videosekvencií v [28]. Pokiaľ bola sieť vytrénovaná pre každú databázu samostatne, výsledky korelácie boli uspokojivé, no ak bola natrénovaná sieť použitá pre zvyšné databázy, korelačný koeficient klesol pod 0,85. Autori preto sami priznávajú výhodnosť tejto techniky pre testovacie databázy, kde absentuje rôznorodosť obsahu (dynamiky scén) a vlastnosti sekvencií (typ kodeku, bitrate,...).

Práca [29] sa zaoberá dosiahnutými výsledkami v oblasti využitia strojového učenia a umelej inteligencie pre hodnotenie kvality videa. Autori zhrnuli v niekoľkých bodoch najväčšie obmedzenia skúmaných metód:

- Spoliehanie sa na MOS, pri malom množstve pozorovateľov výsledný priemer nekorešponduje s jednotlivými subjektívnymi hodnoteniami užívateľov (vysoká smerodajná odchýlka).
- Používanie limitovanej sady videosekvencií, nezohľadňujúce rôznorodosť obsahu videosekvencií v reálnych podmienkach (dynamika scén, nočné a denné scény,...).
- Zameranie sa iba na videokompresiu, pričom vplyv na subjektívne hodnotenie majú aj iné vlastnosti (príznaky) videa ako rozlíšenie, stratovosť alebo bitový tok.

Autori na databáze 400 videosekvencií, ktoré zohľadňovali spomenuté pripomienky, otestovali viaceré nástroje strojového učenia od lineárnej regresie a techniky rozhodovacieho stromu založenom na regresii (Decision Tree based Regression) až po neurónové siete, a dospeli k názoru, že práve neurónové siete poskytujú najpresnejšie výsledky korelujúce na úrovni 0,9 [29].

Zaujímavou alternatívou k posudzovaniu a odhadu kvality videa je práca [30] zaoberajúca sa extrakciou špecifických informácií pre každú testovaciu sekvenciu. Jedná sa o tzv. časovú a priestorovú informáciu (anglicky Temporal Information - TI a Spatial Information - SI). Časová informácia vyjadruje dynamiku pohybu v obraze. Nepohybujúci predmet má nulovú hodnotu a čím dochádza k väčšej dynamike pohybu, TI index nadobúda vyššie hodnoty. Priestorová informácia popisuje množstvo priestorových detailov a ich zmenu na snímke. Zjednodušene povedané, pokiaľ kamera sníma krajinu a prvý je záber na les a potom plynulá zmena na zasnežené pohorie, SI index dosahuje vyššie hodnoty v porovnaní so snímaním pohybujúceho bagra na stavbe, kde pozadie okolo bagra ostáva nemenné [8]. Výsledky práce v podobe regresnej funkcie schopnej pomocou SI a TI indexov odhadovať subjektívne vnímanie kvality korelovali (opäť Pearsonov koeficient) podľa typu videodatabázy medzi 0,7 - 0,92.

Z tohto prehľadu kľúčových prác venujúcich sa skúmanej problematike predkladanej dizertačnej práce je viditeľný odklon od QoS smerom k QoE. Hoci je stále dôležitý monitoring prenosovej cesty (stratovosť, kolísanie oneskorenia, vyťaženosť siete,...) komerční poskytovatelia služieb potrebujú poznať ako negatívne vplýva výkonnosť siete na užívateľské vnímanie, a či je potrebné vykonať zásahy do topológie, prioritizačných politík či kapacít prenosových sietí. Jednoducho potrebujú vedieť, či vzniknutá degradácia kvality je ešte akceptovateľná koncovými zákazníkmi. Dodnes nie je stanovená jednotná hodnotiaca stupnica, prípadne prepojenie výsledkov medzi subjektívnymi a objektívnymi metrikami. Neexistujúce prepojenie spôsobuje problém v interpretácii nameraných hodnôt a tým pádom k správnemu posudzovaniu kvality obrazovej služby. Vzniknutá výskumná európska organizácia Qualinet, ktorá zastrešovala univerzitné vedecké tímy si dala za cieľ priniesť úplne novú tzv. hybridnú metriku, ale ich súčasný stav sa nachádza v experimentálnej vývojovej rovine [1], [2]. Aj to je dôvod, prečo sa táto predkladaná práca zaoberá návrhom prepojenia oboch spôsobov hodnotenia pomocou strojového učenia a umožniť tak priradenie výsledkov objektívnych metrík ku subjektívnemu vnímaniu kvality koncovými užívateľmi.

6 Ciele dizertačnej práce

Ciele dizertačnej práce vychádzajú z popisu súčasného stavu a odrážajú smerovanie výskumu v oblasti hodnotenia kvality videa. Uvedené body, ktoré boli schválené študijnou komisiou, predstavujú jednotlivé kroky, ako bude praktická časť dizertačnej práce spracovaná.

- **Metodika tvorby videosekvencií**
  Vytvorenie testovacích videosekvencií spĺňajúce náležité odporúčania ITU-T s rôznou dynamikou scén a kvalitatívnych parametrov ako typ kodeku, rozlíšenie a bitový tok. Tieto parametre budú nastavené tak, aby odrážali reálny stav, s ktorým sa môže užívateľ služby stretnúť.

- **Vytvorenie databázy tréningových a testovacích dát**
  Ohodnotené videosekvencie poslúžia na vytvorenie väzby medzi subjektívnym a objektívnym hodnotením. Z referenčných videosekvencií budú vytvorené testovacie vzorky, ktorých kvalita bude degradovaná pomocou nastavenej stratovosti v sieti.

- **Návrh nového prístupu k hodnoteniu kvality videa**
  Nový prístup bude založený na modelovaní kvality videa pomocou neurónových sietí, teda podstata dizertačnej práce spočíva v návrhu nového parametrického modelu a jeho následnom overení. Tento model bude určovať subjektívnu kvalitu na základe kvalitatívnych parametrov použitých pri tvorbe videosekvencií, doplnených o objektívny výsledok metriky SSIM. V rámci dizertácie bude vybraný vhodný typ neurónovej siete a prenosovej funkcie a bude navrhnutá jej optimálna štruktúra z pohľadu efektivity, tzn. doba učenia verzus dosiahnutá presnosť klasifikácie.

- **Verifikácia navrhnutého modelu**
  Testovacia sada videosekvencií poslúži na prvotné otestovanie miery presnosti modelu. Automatizované pretrénovanie na základe rozširovania sady, ktorá bude voľne dostupná, umožní za podmienky dodržania stanovenej testovacej metodiky neustále vylepšovať navrhnutý parametrický model.

7 Návrh modelu, metodika práce a príprava dát

Cieľom dizertačnej práce je vytvoriť nový prístup k hodnoteniu kvality videa založenom na parametrickom modeli využívajúci pritom umelú neurónovú sieť a ktorý bude schopný z určených vstupov pozostávajúcich z informácií o prenášanom videu a SSIM hodnoty sa výsledkovo čo najviac približovať k subjektívnemu hodnoteniu.

Vznikol by tak nástroj, ktorý by vedel poskytovateľom Triple-play služieb v reálnom čase priblížiť vnímanie kvality prenášaného videa z pohľadu ich zákazníkov. To by im umožnilo plynulo reagovať na stav ich siete a podľa potreby ovplyvňovať parametre siete a prenášaného videa tak, aby koncový zákazník dostával pre neho akceptovateľnú kvalitu služby.

Nasledujúca kapitola popisuje použité prostriedky a postupy, pomocou ktorých bola vytvorená praktická časť tejto dizertačnej práce.

7.1 Vytvorenie databázy ohodnotených videosekvencií

V predchádzajúcej kapitole bolo spomenutých niekoľko prác využívajúcich dostupné databázy videosekvencií vhodné na evaluáciu kvality pomocou subjektívnych alebo objektívnych testov. Predovšetkým výskumné tímy patriace do organizácie Qualinet vytvorili viaceré databázy ohodnotených videí. Tieto databázy však zahŕňajú videá prevažne s nižšími rozlíšeniami a UHD rozlíšenie absentuje úplne, rovnako tak ako aj kodek H.265 [21]. Pre tvorbu databázy je dôležité, aby bola videosekvencia v nekomprimovanom .yuv formáte, ktorý následne bude prekódovaný na požadovaný formát, rozlíšenie a bitový tok. Videosekvencie, ktoré sú dostupné v nekomprimovanom formáte vo vysokom rozlíšení a boli už použité pre analýzu kvality [3], [20], ale neposkytovali dostatočnú rôznorodosť zameranú na dynamiku zmeny scén a typu prostredia. Tento problém vyriešila skupina výskumníkov zo Shanghai Jiao Tong University, keď zverejnila svoju databázu 15 videosekvencií v nekomprimovanom .yuv formáte [22]. Videosekvencie sú v rozlíšení UHD s rýchlosťou zobrazenia 30 snímok za sekundu a celkovej dĺžke 10 sekúnd, teda dokopy obsahuje každá 300 snímok. Tvorcovia sa zamerali na časový a priestorový index SI a TI, a ako dokazuje obrázok 7.1, podarilo sa im docieliť rôznorodosť v dynamike scén a aj v ich priestorovej oblasti [31]. Aj keď sa 10 sekundová dĺžka testovacieho videa môže zdať málo, autori v práci [24] ukázali, že dlhšie sekvencie (20 alebo 30 sekúnd) nemajú vplyv na subjektívne hodnotenie.

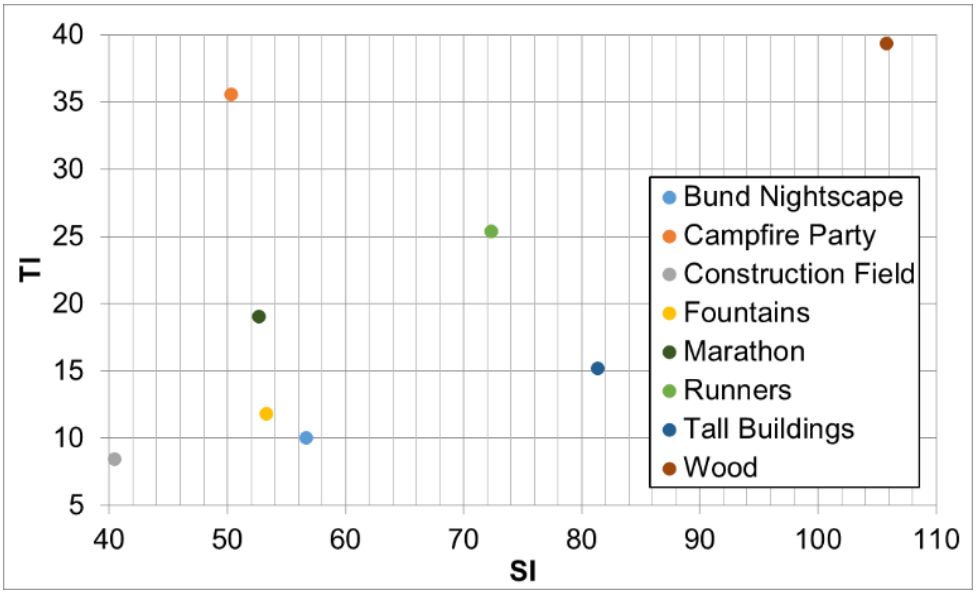

Obr. 7.1: SI a TI indexy pre 4K videosekvencie [31].

7.1.1 Definícia parametrov testovacích videosekvencií a ich tvorba

Televízne vysielanie v dnešnej dobe používa HD (720p), FullHD (1080p) a UHD (2160p) rozlíšenie. Rozlíšenie 4K ponúka na šírku viac pixelov ako UHD, ale komerčne sa nepresadilo z dôvodu preferovaného pomeru strán 16:9, ktoré ponúka UHD (niekedy označované aj ako 3,75K).

Testovacie vzorky musia zahŕňať rôzne typy scén tak, aby reprezentovali každý kvadrant grafu na obrázku 7.1. Zároveň budú reflektovať na odporúčanie P.910, ktoré tiež pomocou SI a TI indexov definuje rôzne typy scén [8].

Bitový tok videosekvencií bol zvolený s ohľadom na ich reálne používanie, teda 5, 10 a 15 Mbit/s. Pri dnešnom využívaní kodeku H.264 sa štandardne používa 10 Mbit/s, prémiové filmové stanice sa blížia k hodnote 15 Mbit/s [13]. S dátovým tokom 15 Mbit/s sa počíta aj pri nasadzovaní H.265 (DVB-T2) s plánovanou riadnou prevádzkou po roku 2020 [14].

Pre digitálne kódovanie televíznych staníc sa používa prevažne H.264, ale v mnohých krajinách je stále nasadený aj jeho predchodca MPEG-2. Využívanie H.265 je v súčasnosti len v testovacej prevádzke a pre príjem je potrebné mať televízor alebo set top box podporujúci tento najnovší štandard. Do plného nasadenia H.265 ostáva síce ešte niekoľko rokov, treba však byť pripravený na budúci vývoj a preto je aj tento kodek zaradený pre tvorbu databázy.

Na prenos sieťou sa využíva transportný protokol UDP, ktorý neposkytuje mechanizmus potvrdzovania prijatých dát (z dôvodu zvyšovania časovej réžie a tým narušeniu kontinuálneho prenosu), preto môže v dôsledku vysokej vyťaženosti dochádzať k zahadzovaniu dát na smerovačoch. Objektívny sieťový parameter, ktorý môže významne degradovať kvalitu prenášaného videa je stratovosť, obvykle vyjadrená v percentuálnom pomere k celkovému množstvu prenesených dát.

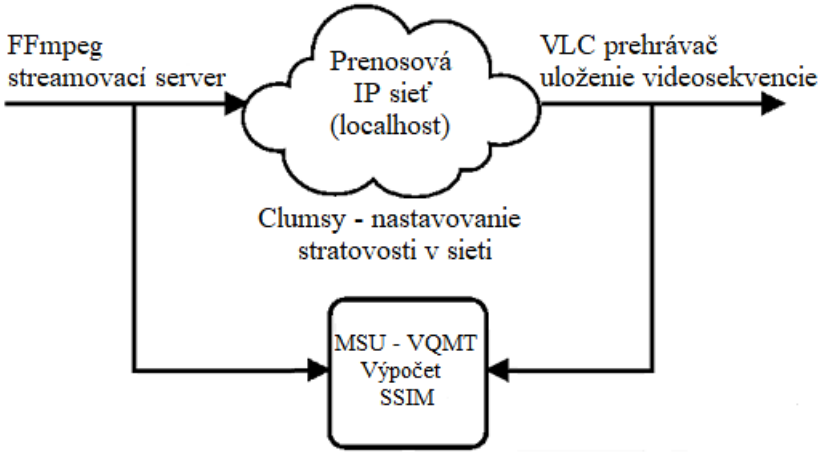

Obr. 7.2: Schéma vytvárania videosekvencií.

Preto je nevyhnutné pri tvorbe databázy počítať s týmto javom a každý typ sekvencie kvalitatívne degradovať zahadzovaním náhodne vybraných dát. Pomocou nástroja FFmpeg boli sekvencie streamované (v rámci localhost slučky na ethernetovom rozhraní) a nástroj VLC umožnil zachytávanie a uloženie streamu. O zahadzovanie paketov počas streamovania sa postaral program Clumsy 0.2 [32]. Otestovaný bol aj známejší linuxový nástroj NetEm, ktorý ale pri testovaní nedokázal zahadzovať pakety s takou požadovanou presnosťou ako program Clumsy. Takto degradované video bolo uložené a podrobené procesu hodnotenia. Hodnoty stratovosti boli nastavené zo zreteľom na výsledky už publikovaných prác, ktoré jasne poukázali na hranice možnej akceptácie takto degradovanej kvality videa. Zvolené boli hodnoty 0,1 %, 0,2 %, 0,3 %, 0,5 %, 0,75 % a 1 %. Stratovosť nad jedno percento výrazne degraduje kvalitu videa a pre potreby modelu nemá zmysel sa ešte vyššími hodnotami zaoberať [frn3], [frn5].

Videá boli stiahnuté vo formáte YUV s podvzorkovaním 4:2:0 a bitovou hĺbkou 8 bit na kanál (16,7 milióna odtieňov farieb), čo zodpovedá bežnému profilu digitálneho vysielania [uhr1].

Pre potreby prekódovania nekomprimovaného formátu .yuv na kodek H.264 a H.265 bol použitý už spomenutý nástroj FFmpeg, ktorý pracuje s open source softwarovými kodérmi x264 a x265. Tie sú síce pomalšie v kódovaní ako ich komerční súperi, ale efektivitu kódovania dosahujú na porovnateľných úrovniach [33], [34]. Nekomprimované videosekvencie s UHD rozlíšeným boli postupne prekódované na kompresné formáty H.264 a H.265, dodatočné rozlíšenia HD a FullHD a tri bitové toky 5, 10 a 15 Mbit/s. Použitá direktíva na prekódovanie videa pomocou nástroja FFmpeg vyzerá nasledovne:

```
ffmpeg -f rawvideo -video_size 3840x2160 -pix_fmt yuv420p -framerate 30 -i
NAZOV_SUBORU.yuv -vcodec libx264 -x264-params keyint=15:min-
keyint=15:bframes=3:b-adapt=1:bitrate=5000:vbv-maxrate=5000:vbv-
bufsize=5000 -vf scale=3840x2160 NAZOV_SUBORU.ts
```

kde vstup predstavoval názov nekomprimovaného videa, x264 použitý kodér, následne je definovaná veľkosť GOPu v podobe počtu B snímok za sebou, bitový tok 5 Mbit/s,

prekódovaná veľkosť rozlíšenia, názov a formát výsledného súboru. Formát .ts (MPEG-TS, transport stream) predstavuje digitálny kontajner na prenos a uloženie videosúborov, a je používaný pre prenos digitálneho vysielania [frn3], [uhr1]. Zároveň program FFmpeg dokáže simulovať streamovací server a streamovať videosekvencie po sieti vo formáte .ts (metodika tvorby je znázornená na obrázku 7.2):

```
ffmpeg -re -i NAZOV_SUBORU.ts -c copy -f mpegts udp://127.0.0.1:1234
```

kde parameter –re značí, že streamovacia rýchlosť bude rovnaká ako je bitový tok videa. Z príkazu vidieť použitie kontajnera MEPG-TS na streamovanie s transportným protokolom UDP. Dôležité je označiť, aby program (prehrávač) VLC ukladal streamovací tok vo formáte „tak ako príde“ a nevykonával žiadne vlastné prekódovanie. Celý proces tvorby videosekvencií je znázornený na obrázku 7.3.

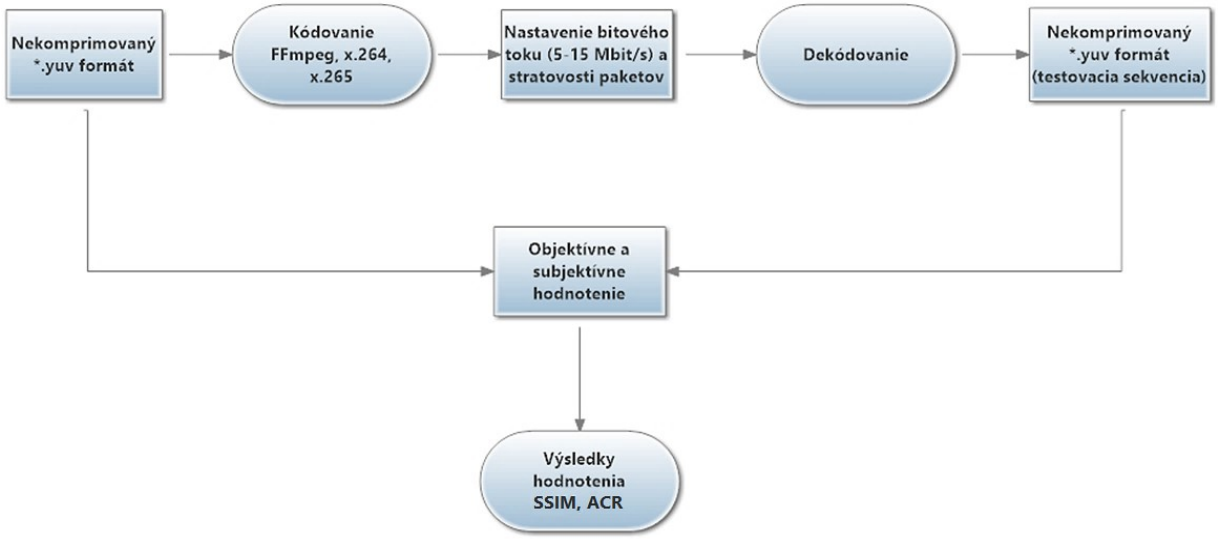

Obr. 7.3: Postup hodnotenia videosekvencií.

Pre objektívne ohodnotenie všetkých videosekvencií bol použitý nástroj MSU VQMT, ktorý dokáže porovnať referenčnú a testovaciu vzorku a vypočítať hodnotu pre metriku SSIM [frn6], [35].

Aj keď zahadzovanie paketov bolo generované náhodne, v najhoršom prípade mohla nastať situácia, že by sa zahadzovali práve referenčné I snímky, ktoré by výrazne ovplyvnili kvalitu videosekvencie. Práve z tohto dôvodu pre každú videosekvenciu bolo vykonaných 10 meraní. Po prípadnom vyradení odľahlých pozorovaní (pravidlo 3σ) bola vybraná videosekvencia s takou hodnotou SSIM, ktorá sa najviac približovala vypočítanej priemernej hodnote.

Pre subjektívne testovanie boli zaobstarané monitory spĺňajúce odporúčanie ITU-R BT.500 (24" Dell P2415Q UHD) a vytvorená testovacia miestnosť tak, aby boli splnené podmienky regulárnosti testovania (svetelné podmienky, vzdialenosť od monitora, vytvorenie úvodných tréningových sekvencií a pod.) [8], [9].

Technika subjektívneho hodnotenia ACR bola zvolená na základe odporúčania komisie reflektujúc tak reálnu situáciu, keď koncoví zákazníci posudzujú kvalitu videa bez možnosti vzhliadnutia referenčného nepoškodeného obrazu.

7.1.2 Výber videosekvencií a priebeh testovania

Videosekvencie určené k testovaniu bolo potrebné zvoliť tak, aby čo najlepšie reflektovali na typy scén s ktorými sa najčastejšie stretávame. Preto po zrelej úvahe a analýze SI a TI indexov boli vybrané nasledujúce scény (zobrazené na obrázku 7.4 v smere zľava doprava) zo zvolenej databázy [22], [31]:

- **Construction Field –** (nízka hodnota indexov TI a SI)
  Scéna s pohybom bagra uprostred, statická poloha kamery, pozadie rozostavanej budovy. Reprezentuje typ vysielania ako sú diskusné relácie alebo moderovanie TV správ s miernym pohybom moderátora alebo hostí a stálym pozadím za nimi.

- **Runners –** (stredná hodnota indexov SI a TI)
  Záznam maratónskeho behu. Reprezentuje športový prenos s dynamickým pohybom účastníkov.

- **Campfire Party** (nízka hodnota indexu SI a vysoká hodnota indexu TI)
  Zoskupenie väčšieho počtu osôb pred plameňom ohňa v noci. Reprezentuje akčné a filmové nočné scény s ohňom ako sú napríklad výbuchy.

- **Wood** (vysoké hodnoty indexov SI a TI)
  Rýchly pohyb kamery dookola v lese. Reprezentuje dynamické pohyby, rýchlo meniace sa objekty na scéne.

Hoci v odporúčaní ITU-R BT.500 je uvedené, že minimálny počet pozorovateľov je 15 [9], pre korektné štatistické spracovanie, teda aby priemer hodnôt mal reprezentatívnu funkciu, testovania sa zúčastnilo 60 pozorovateľov vo veku od 18 – 35. Muži prevládali v pomere 38:22.

Hodnotiaci proces dodržiaval metodiku ACR [8], testovacie sekvencie boli zoradené tak, aby sa nenachádzali za sebou dve rovnaké scény. Počas 10 sekundovej pauzy medzi prehrávaním, ktorá je určená na hodnotenie, pozorovatelia zaznačili svoje hodnotenie do vopred pripraveného dotazníka podľa poradového čísla sekvencie. Pred samotným začiatkom hodnotenia boli účastníci oboznámení s hodnotiacou škálou a boli im prehrávané viaceré trénovacie sekvencie, ktoré ale nepatrili medzi 4 testované scény. Maximálna doba testovania v rámci jedného bloku, bola podľa odporúčania stanovená na 30 minút. Zamedzilo sa tým poklesu sústredenia pozorovateľov na jednotlivé sekvencie z dôvodu veľkého množstva prehrávaných sekvencií.

Obr. 7.4: Prehľad použitých videosekvencii [22].

Dohromady bola vytvorená databáza obsahujúca 432 videosekvencií, z ktorej bude náhodne vyčlenená približne štvrtina ako referenčná testovacia sada. Každá videosekvencia bola ohodnotená 60 krát, teda kompletná databáza obsahuje 25 920 vzoriek určených pre trénovanie a validáciu navrhnutého modelu. Pre každú videosekvenciu bola programom MSU VQMT vypočítaná aj hodnota objektívnej metriky SSIM.

7.2 Štatistické metódy vyhodnotenia

Pre vyhodnotenie nameraných výsledkov a ich vzájomné porovnanie uverejnenými modelmi boli definované tieto základné štatistické veličiny:

- *Výberový priemer* ($\bar{x}$) - súčet všetkých hodnôt, delený počtom všetkých hodnôt, definovaný vzťahom:

$$\bar{x} = \frac{1}{n} \cdot \sum_{i=1}^{n} x_i \tag{7.1}$$

kde x_i sú jednotlivé hodnoty a n je celkový počet hodnôt výberu.

- *Výberová smerodajná odchýlka (s)* vyjadruje, ako sa hodnoty líšia od priemernej hodnoty. Je definovaná ako druhá odmocnina z výberového rozptylu. Vo vzorci musíme uvažovať $n - 1$ (pretože 1 meranie je už závislé s výpočtom strednej hodnoty).

V prípade, že sú všetky dáta rovnaké, smerodajná odchýlka je rovná nule. Počíta sa podľa vzorca:

$$s = \frac{1}{n-1} \cdot \sum_{i=1}^{n} (x_i - \bar{x}\,)^2 \tag{7.2}$$

- *Variačný koeficient (v)* - predstavuje relatívnu mieru variability. Vypočíta sa ako podiel smerodajnej odchýlky a priemeru. Variačný koeficient sa definuje vzťahom:

$$v = \frac{s}{\bar{x}} \cdot 100 \tag{7.3}$$

Ak je hodnota variačného koeficientu väčšia ako 50 %, aritmetický priemer stráca význam, pretože štatistický súbor je heterogénny, nesúrodý a aritmetický priemer ho nemôže reprezentovať.

- *Pearsonov korelačný koeficient (r)* – udáva mieru lineárnej závislosti dvoch premenných a nadobúda hodnoty od -1 do 1, pričom čím viac sú veličiny priamo úmerné, tým viac sa hodnota približuje 1. Nevýhodou Pearsonovho korelačného koeficientu je fakt, že výskyt extrému v súbore hodnôt vedie k ovplyvneniu jeho celkovej hodnoty (v pozitívnom aj negatívnom smere). Je definovaný vzťahom:

$$r_{x,y} = \frac{\sum_{i=1}^{n}(x_i - \bar{x}\,) \cdot (y_i - \bar{y})}{\sqrt{\sum_{i=1}^{n}(x_i - \bar{x})^2} \cdot \sqrt{\sum_{i=1}^{n}(y_i - \bar{y})^2}} \tag{7.4}$$

kde i predstavuje konkrétne jedno hodnotenie videosekvencie, x_i reprezentuje hodnotu na stupnici MOS získanú pozorovateľom a y_i reprezentuje hodnotu MOS predpovedanú popisovaným modelom, hodnoty $\bar{x}$ a $\bar{y}$ sú priemery príslušných veličín.

- *Stredná kvadratická chyba (RMSE)* – je ekvivalentom smerodajnej odchýlky, vyjadruje rozloženie jednotlivých nameraných dát okolo referenčnej hodnoty. Výpočet RMSE vychádza z absolútnej chyby merania (Δ_i), definovanej nižšie.

$$\Delta_i = x_i - y_i$$
$$RMSE = \sqrt{\frac{1}{n-1}} \cdot \sum_{i=1}^{n} {\Delta_i}^2 \tag{7.5}$$

8 Analýza vplyvu stratovosti v sieti na kvalitu videosekvencií

Vykonanie subjektívneho aj objektívneho testovania poukázalo ako zahadzovanie paketov v sieti degraduje kvalitu videosekvencií pre videokodeky H.264 a H.265. Nasledujúce podkapitoly prinášajú dosiahnuté výsledky a ich zhodnotenie.

8.1 Výsledky vykonaných testov

Ako bolo uvedené v predchádzajúcej kapitole, testovania sa zúčastnilo 60 pozorovateľov, čo umožnilo vznik dostatočne veľkej databázy subjektívnych ohodnotení. Kvôli interpretácii výsledkov pomocou priemeru (slúžiaci ako referenčná hodnota pre tvorbu a verifikáciu navrhnutého modelu neurónovej siete) je ale potrebné overiť jeho štatistickú relevantnosť. To, či pozorovatelia zastávali podobný názor na jednotlivé testovacie sekvencie, alebo dochádzalo k výrazným rozporom (a tým pádom priemer nemá výpovednú hodnotu) prezradil variačný koeficient. Pokiaľ jeho hodnota nepresiahne 50 %, má priemer reprezentatívnu funkciu. Pri pohľade na dosiahnuté výsledky z dotazníkov je možné prehlásiť, že vypočítaný priemer má silnú výpovednú hodnotu. Variačný koeficient vyšší ako 40 % nebol zaznamenaný a hodnota vyššia ako 35 % bola prítomná len u 50 z celkového počtu 432 testovacích videosekvencií. Inak povedané, len čosi viac ako 11 % testovaných videosekvencií dosiahlo variačný koeficient vyšší ako 35 %.

Ku skompletizovaniu vytvorenej databázy pre účely tvorby nového klasifikátora založeného na neurónovej sieti bolo ešte potrebné priradiť pre každú videosekvenciu aj hodnotu objektívnej metriky SSIM podľa postupu popísaného v predchádzajúcej kapitole.

Tabuľka testovacích videosekvencií s ich štatistickým vyhodnotením je uvedená v prílohe A, kompletný prepis všetkých subjektívnych hodnotení je dostupný v elektronickej forme prílohy s názvom *Testovanie ACR*. Spolu s tým je ako súčasť prílohy aj zložka obsahujúca všetky použité videosekvencie aj s ich nepoškodenými originálmi pre prípadné ďalšie využitie.

Obrázok 8.1 zobrazuje názvoslovie jednotlivých videosekvencií. Vďaka skúsenostiam nadobudnutým počas spolupráce na vzniku databázy pre rozpoznávanie emócií v hlase [uhr2], je možné použiť už vytvorený SQL nástroj na prepojenie s databázou a ako možné použitie sa javí napríklad rozširovanie navrhnutého modelu pomocou crowdsourcingu. Sumár výsledkov v podobe tabuliek je uvedený nižšie.

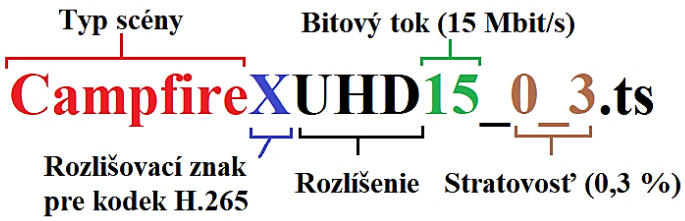

Obr. 8.1: Názvoslovie testovacích videosekvencií.

Tab. 8.1: Výsledky objektívneho a subjektívneho testovania pre scénu Campfire.

Bitový tok	Strata Paketov	Campfire - H264						Campfire - H265 (HEVC)					
		HD		FullHD		UHD		HD		FullHD		UHD	
	%	SSIM/ACR		SSIM/ACR		SSIM/ACR		SSIM/ACR		SSIM/ACR		SSIM/ACR	
5 Mbit/s	0,1	0,997	4,017	0,985	3,117	0,992	2,617	0,986	3,050	0,990	2,817	0,991	3,633
	0,2	0,995	3,700	0,981	2,900	0,990	2,417	0,977	3,100	0,975	2,333	0,966	2,700
	0,3	0,991	3,500	0,978	2,850	0,982	1,667	0,892	2,433	0,922	1,500	0,962	2,517
	0,5	0,984	3,150	0,964	2,083	0,964	1,450	0,869	1,800	0,913	1,267	0,941	2,017
	0,75	0,974	3,133	0,959	2,067	0,962	1,317	0,837	1,467	0,905	1,150	0,932	1,917
	1	0,959	2,883	0,922	1,683	0,946	1,167	0,808	1,333	0,881	1,100	0,853	1,467
10 Mbit/s	0,1	0,987	4,083	0,985	2,867	0,990	3,250	0,964	3,233	0,968	2,150	0,984	3,200
	0,2	0,973	3,533	0,975	2,417	0,981	3,133	0,937	3,117	0,946	2,033	0,981	3,000
	0,3	0,927	3,033	0,961	2,200	0,929	2,950	0,918	2,700	0,917	1,450	0,919	2,583
	0,5	0,906	2,967	0,945	2,000	0,903	2,700	0,873	1,933	0,906	1,167	0,862	1,833
	0,75	0,887	2,217	0,92	1,700	0,900	2,633	0,852	1,733	0,886	1,167	0,855	1,700
	1	0,886	1,517	0,904	1,367	0,884	1,933	0,771	1,417	0,859	1,200	0,835	1,400
15 Mbit/s	0,1	0,944	4,233	0,971	3,117	0,971	2,583	0,9214	2,533	0,967	2,117	0,979	2,967
	0,2	0,912	3,600	0,954	2,517	0,919	2,183	0,919	2,417	0,966	2,067	0,951	2,533
	0,3	0,904	2,900	0,937	2,400	0,893	2,100	0,891	2,067	0,913	1,467	0,946	2,417
	0,5	0,869	2,650	0,89	1,700	0,863	1,317	0,760	1,450	0,898	1,200	0,898	2,100
	0,75	0,812	2,467	0,884	1,600	0,853	1,250	0,753	1,267	0,873	1,200	0,829	1,400
	1	0,768	2,067	0,861	1,333	0,842	1,100	0,733	1,233	0,808	1,033	0,763	1,067

Tab. 8.2: Výsledky objektívneho a subjektívneho testovania pre scénu Construction.

Bitový tok	Strata Paketov	Construction - H264						Construction - H265 (HEVC)					
		HD		FullHD		UHD		HD		FullHD		UHD	
	%	SSIM/ACR		SSIM/ACR		SSIM/ACR		SSIM/ACR		SSIM/ACR		SSIM/ACR	
5 Mbit/s	0,1	0,995	4,667	0,978	3,317	0,995	4,133	0,985	2,733	0,969	2,400	0,973	3,300
	0,2	0,986	4,133	0,974	3,033	0,989	4,117	0,965	2,617	0,962	2,200	0,969	2,767
	0,3	0,980	3,217	0,952	2,817	0,984	3,917	0,949	2,400	0,924	1,567	0,953	2,483
	0,5	0,970	3,133	0,912	2,083	0,965	3,683	0,901	1,817	0,897	1,200	0,928	2,350
	0,75	0,962	2,950	0,907	1,633	0,949	2,700	0,873	1,283	0,877	1,250	0,884	1,500
	1	0,922	2,783	0,892	1,350	0,941	2,217	0,809	1,150	0,827	1,200	0,850	1,400
10 Mbit/s	0,1	0,987	3,800	0,990	3,400	0,993	4,217	0,961	2,367	0,939	1,900	0,985	3,533
	0,2	0,973	3,567	0,982	3,167	0,992	4,150	0,918	2,000	0,925	1,833	0,981	3,300
	0,3	0,962	3,217	0,951	2,500	0,964	3,617	0,874	1,433	0,852	1,500	0,945	2,467
	0,5	0,936	3,100	0,894	2,117	0,943	3,150	0,821	1,317	0,808	1,333	0,885	1,683
	0,75	0,901	2,850	0,852	1,767	0,921	2,867	0,770	1,083	0,751	1,133	0,844	1,467
	1	0,893	2,767	0,795	1,133	0,887	2,650	0,751	1,017	0,710	1,067	0,841	1,483
15 Mbit/s	0,1	0,978	3,783	0,963	3,000	0,980	3,633	0,875	1,283	0,866	1,750	0,938	2,467
	0,2	0,977	3,450	0,892	2,200	0,971	3,400	0,857	1,200	0,851	1,583	0,936	2,233
	0,3	0,962	3,267	0,863	2,383	0,964	3,300	0,805	1,217	0,778	1,750	0,919	2,067
	0,5	0,922	2,617	0,844	1,483	0,927	3,117	0,787	1,250	0,744	1,200	0,867	1,567
	0,75	0,919	2,500	0,785	1,733	0,873	2,567	0,740	1,000	0,682	1,033	0,777	1,300
	1	0,881	2,067	0,720	1,117	0,857	2,300	0,662	1,000	0,668	1,050	0,726	1,000

Tab. 8.3: Výsledky objektívneho a subjektívneho testovania pre scénu Runners.

Bitový tok	Strata Paketov	Runners - H264						Runners - H265 (HEVC)					
		HD		FullHD		UHD		HD		FullHD		UHD	
	%	SSIM/ACR		SSIM/ACR		SSIM/ACR		SSIM/ACR		SSIM/ACR		SSIM/ACR	
5 Mbit/s	0,1	0,976	3,567	0,983	2,833	0,987	3,233	0,955	2,400	0,979	2,350	0,964	2,483
	0,2	0,975	3,217	0,972	2,850	0,982	3,050	0,948	2,067	0,956	2,150	0,942	2,117
	0,3	0,935	2,917	0,902	2,250	0,958	2,533	0,940	2,033	0,896	1,783	0,930	2,067
	0,5	0,900	2,333	0,858	1,867	0,938	2,067	0,854	1,767	0,804	1,567	0,888	1,833
	0,75	0,873	1,767	0,835	1,683	0,918	1,600	0,751	1,333	0,800	1,267	0,858	1,367
	1	0,747	1,267	0,815	1,283	0,864	1,000	0,659	1,000	0,742	1,000	0,845	1,000
10 Mbit/s	0,1	0,979	3,217	0,980	3,083	0,974	2,983	0,912	2,033	0,902	1,400	0,951	2,250
	0,2	0,979	3,133	0,943	2,900	0,969	2,733	0,868	1,767	0,875	1,167	0,929	1,817
	0,3	0,931	2,333	0,893	2,433	0,948	2,583	0,805	1,400	0,834	1,167	0,896	1,700
	0,5	0,878	2,000	0,763	1,797	0,856	1,533	0,688	1,100	0,768	1,133	0,841	1,733
	0,75	0,849	1,667	0,725	1,167	0,820	1,300	0,646	1,150	0,668	1,100	0,712	1,167
	1	0,786	1,017	0,716	1,017	0,795	1,000	0,577	1,017	0,619	1,050	0,635	1,000
15 Mbit/s	0,1	0,973	3,233	0,951	2,500	0,931	2,250	0,867	1,817	0,896	1,633	0,903	1,867
	0,2	0,971	3,267	0,903	2,267	0,896	1,950	0,797	1,617	0,840	1,500	0,857	1,517
	0,3	0,894	2,133	0,908	1,567	0,851	1,567	0,744	1,317	0,772	1,333	0,835	1,283
	0,5	0,865	1,950	0,833	1,350	0,792	1,133	0,684	1,183	0,663	1,400	0,734	1,033
	0,75	0,740	1,433	0,789	1,067	0,729	1,033	0,629	1,050	0,628	1,017	0,677	1,033
	1	0,718	1,017	0,634	1,000	0,675	1,000	0,532	1,000	0,560	1,017	0,656	1,000

Tab. 8.4: Výsledky objektívneho a subjektívneho testovania pre scénu Wood.

Bitový tok	Strata Paketov	Wood - H264						Wood - H265 (HEVC)					
		HD		FullHD		UHD		HD		FullHD		UHD	
	%	SSIM/ACR		SSIM/ACR		SSIM/ACR		SSIM/ACR		SSIM/ACR		SSIM/ACR	
5 Mbit/s	0,1	0,946	3,750	0,954	2,350	0,965	3,100	0,939	2,367	0,930	2,633	0,912	2,817
	0,2	0,942	3,733	0,933	1,917	0,951	2,867	0,929	2,333	0,881	2,333	0,910	2,467
	0,3	0,840	2,783	0,873	1,567	0,921	2,417	0,857	2,250	0,886	1,833	0,867	2,367
	0,5	0,732	2,833	0,780	1,317	0,898	1,917	0,732	1,583	0,812	1,550	0,720	2,050
	0,75	0,625	2,583	0,761	1,133	0,859	1,650	0,555	1,267	0,709	1,133	0,654	1,667
	1	0,620	2,300	0,721	1,033	0,816	1,583	0,346	1,000	0,638	1,067	0,639	1,100
10 Mbit/s	0,1	0,935	3,783	0,956	3,667	0,926	3,200	0,927	2,083	0,912	1,933	0,898	2,467
	0,2	0,900	3,583	0,912	3,117	0,919	3,233	0,789	2,033	0,862	1,767	0,894	2,450
	0,3	0,751	3,017	0,860	2,783	0,855	2,067	0,700	1,667	0,830	1,467	0,848	1,900
	0,5	0,715	2,983	0,763	1,450	0,771	1,467	0,625	1,500	0,742	1,200	0,752	1,467
	0,75	0,619	2,300	0,725	1,300	0,718	1,267	0,395	1,050	0,643	1,133	0,624	1,050
	1	0,602	2,150	0,716	1,150	0,661	1,000	0,333	1,050	0,584	1,083	0,592	1,033
15 Mbit/s	0,1	0,927	3,583	0,950	2,917	0,911	2,417	0,907	2,283	0,853	1,817	0,837	2,450
	0,2	0,887	3,233	0,836	2,267	0,907	2,367	0,806	2,067	0,840	1,867	0,760	2,217
	0,3	0,743	2,867	0,775	1,950	0,843	1,900	0,565	1,367	0,778	1,500	0,715	1,800
	0,5	0,714	2,550	0,761	1,667	0,749	1,467	0,477	1,233	0,638	1,167	0,472	1,200
	0,75	0,604	2,067	0,735	1,033	0,596	1,233	0,376	1,067	0,587	1,067	0,421	1,033
	1	0,591	1,967	0,699	1,033	0,560	1,050	0,314	1,000	0,524	1,000	0,362	1,033

Z dosiahnutých výsledkov uvedených v tabuľkách 8.1 - 8.4 môžeme vyvodiť nasledujúce závery:

- Novší kodek H.265 (HEVC) dosahuje horšie výsledky pri zaznamenanej stratovosti v sieti ako jeho predchodca H.264. Je to spôsobené najmä vyššou kompresiou, ktorá má za následok výraznejšiu stratu kvality snímok v prípade chýbajúcich dát.

- Čím vyšší je bitový tok, tým horšiu má odolnosť na stratovosť, zapríčinenú celkovo väčším objemom chýbajúcich dát ako pri nižších tokoch.

- Hodnota minimálne 4 v škále MOS (kvalita je dobrá) bola dosiahnutá pri najnižšej vypočítanej hodnote SSIM 0,945. Hodnota aspoň 3 (kvalita je priemerná) bola prvýkrát dosiahnutá pri najnižšej hodnote SSIM 0,887. Korešponduje to s výsledkami uverejnenými v práci [36].

- Lepšie výsledky zaznamenali scény Construction (statická scéna) a Campfire (tmavé nočné pozadie) ako dynamické scény Runners a Wood. Pri scénach kde nedochádza k dynamickej zmene vykreslených farieb medzi nasledujúcimi snímkami, algoritmy dokážu efektívnejšie maskovať chýbajúce dáta a pri zachovaní konštantného bitového toku podliehajú tieto snímky menšej kompresii [37].

Tieto závery potvrdzujú aj doposiaľ uvedené práce autora, ktoré sa venovali testovaniu efektívnosti kodekov simulujúc rôzne parametre videosekvencií a rozličné prenosové prostredia [frn3], [frn4], [uhr3], [sev1].

Napriek možnému očakávaniu, že rozlíšenie bude mať priamy vplyv na kvalitu videosekvencie, nedá sa jednoznačne určiť, že vyššie rozlíšenie prináša lepšiu alebo horšiu kvalitu sekvencie v závislosti na stratovosti v sieti. V prípade streamovania najviac paketov pripadá práve I snímkam, teda je predpoklad, že aj najväčšie percento chýb postihuje práve I snímky. Na druhej strane ak ostáva nemenný bitový tok a zvyšuje sa len rozlíšenie, dochádza k výraznejšej kompresii hlavne referenčného I snímku čo môže voči nižšiemu rozlíšeniu priniesť istú stratu detailnosti obrazu. Na obrázku 8.2 je zobrazená nočná scéna, kde vrchná snímka má bitový tok 5 Mbit/s pre UHD rozlíšenie a pod ňou pre Full HD, obe pre kodek H.264. Z obrázku je evidentné, že pre UHD je daný bitový tok už na hranici pozerateľnosti s rozmazanými detailmi oproti rozlíšeniu Full HD.

Pri konštantnom bitovom toku a vysokom rozlíšení zároveň dochádza k navýšeniu veľkosti I snímky z dôvodu vykreslenia násobne viac bodov (UHD voči Full HD potrebuje vykresliť 4 násobne viac bodov). Typicky pri prenose MPEG-TS, sa zabalí do jedného UDP paketu 7 tzv. PES (Packetized Elementary Stream) paketov o maximálnej veľkosti 188 B. Preto sa v rámci jedného PES paketu pri vyššom rozlíšení prenesie menej informácií zo snímky a jeho prípadná strata menej ovplyvní vytvorené makrobloky, čo zmierni propagovanie chyby v GOPe. Teda to, ako bude vyzerať výsledný pokles kvality, ktorý vznikne ako dôsledok stratovosti dát počas prenosu sieťou je oveľa viac ovplyvnený bitovým tokom a typom (dynamikou) scény [36], [37], [38], [frn1], [frn3], [frn4].

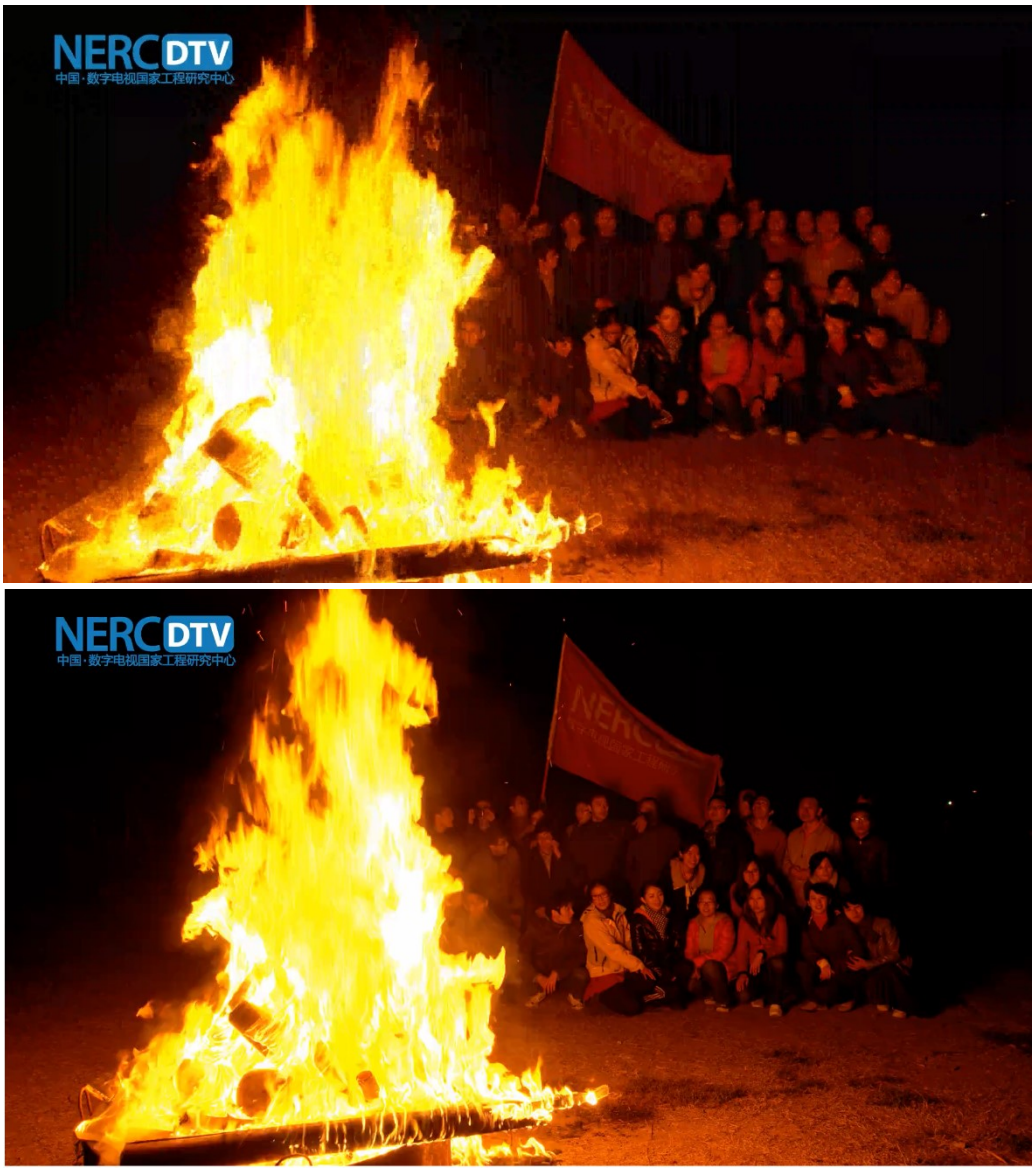

Obr. 8.2: Porovnanie detailnosti snímky pri zachovaní bitového toku 5 Mbit/s pre UHD (hore) a Full HD (dole).

Pomocou grafov zobrazených na obrázkoch 8.3 a 8.4 je názornejšie vidieť porovnanie oboch typov vykonaných testov. Stĺpcový graf vyjadruje namerané hodnoty objektívnou metrikou SSIM a na pravej osi sú vynesené výsledky subjektívneho testovania. Pre 5 aj 15 Mbit/s bitový tok dosahuje rozlíšenie HD kodeku H.264 najlepšie subjektívne výsledky. Pre toto najnižšie testované rozlíšenie je aj 5 Mbit/s dostatočný bitový tok, nie je potrebná tak výrazná kompresia obrazu a zahadzovanie paketov sa prejavilo v strate aj „nadbytočných“ dát, nepostrehnuteľných pre ľudské oko. Rovnako tak na obrazové artefakty v menšom rozlíšení je ľudské oko menej citlivé ako pri vysokých rozlíšeniach [uhr3], [45].

Na druhej strane novší kodek H.265 pracuje s výraznejším kompresným pomerom, a preto aj malá stratovosť dôležitých informácií má signifikantnejší vplyv aj na subjektívne posudzovanú kvalitu. Pri porovnaní oboch bitových tokov je zreteľné, ako nízky tok degraduje subjektívnu kvalitu kodeku H.264 pri UHD rozlíšení v porovnaní s najvyšším tokom dát. Sila nového kodeku sa naplno prejavila pri najvyššom rozlíšení a bitovom toku, kde pri nízkej strate

dát poskytol lepší a detailnejší obraz z hľadiska subjektívneho testovania ako jeho predchodca. To, že kodek H.265 je stavaný hlavne na veľmi vysoké rozlíšenie (UHD/4K) potvrdzuje porovnanie subjektívnych testov a výrazný prepad hodnotenia pre rozlíšenie Full HD voči UHD. Pri Full HD starší kodek dosahoval spravidla lepšie hodnotenie pri subjektívnom aj objektívnom testovaní, a po započítaní náročnosti pre kódovanie a prehrávanie kodeku H.265 má v súčasnosti význam nasadzovať nový kodek na UHD a vyššie rozlíšenia.

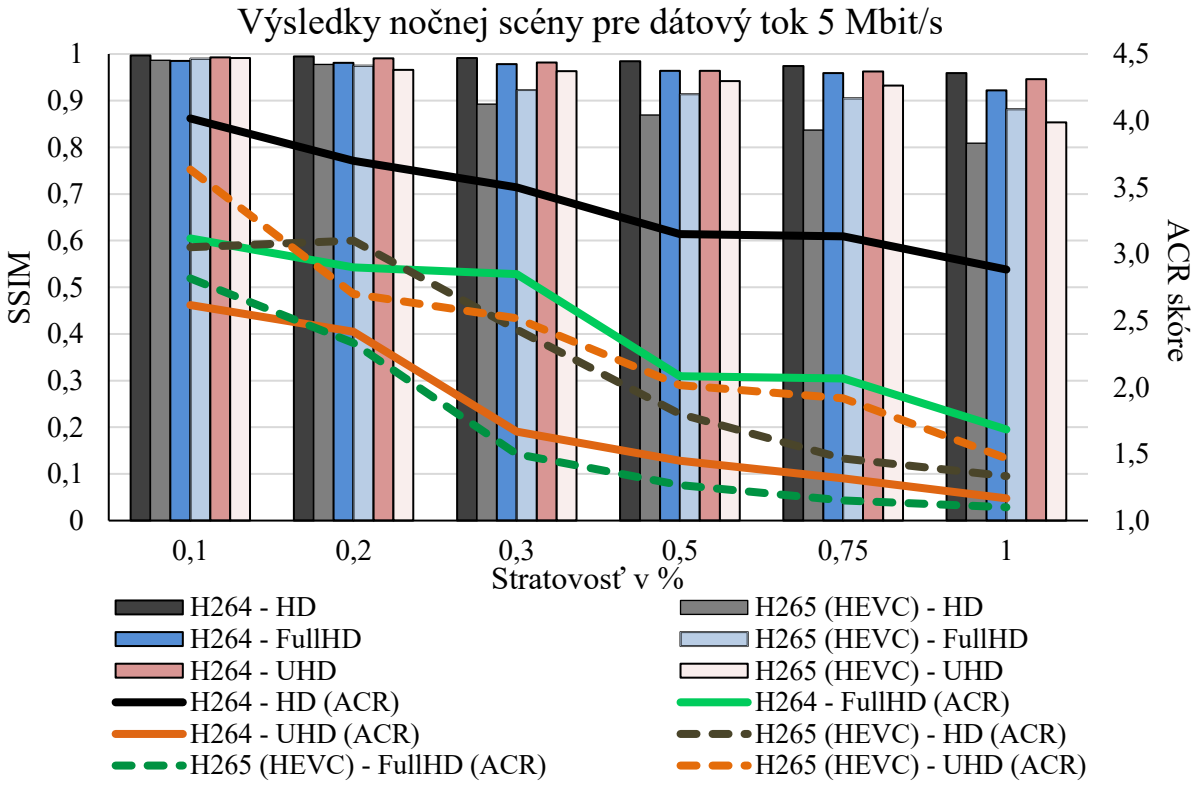

Obr. 8.3: Porovnanie výsledkov objektívneho a subjektívneho testovania pre scénu Campfire s bitovým tokom 5 Mbit/s.

Obrázok 8.5 znázorňuje najvýraznejšie artefakty v obraze zaznamenané pre oba kodeky pri stratovosti 0,1 a 0,5 % so zhodným rozlíšením (HD) a bitovým tokom (5 Mbit/s). Pri vyššej stratovosti sa v dynamicky meniacej oblasti scény zakódovanej pomocou H.265 vytvárajú výrazne chyby v obraze, pričom horná časť reprezentujúca relatívne jednofarebné tmavé pozadie je bez viditeľných chýb. Aj na tomto príklade vidieť, ako chýbajúce dáta pri vyššej kompresii ovplyvňujú schopnosť maskovania chyby. Pri nemeniacom sa tmavom pozadí je jeho prenášaná zmena pomocou snímok B a P minimálna a predpoveď chýbajúcich častí vo vytvorených blokoch je oveľa jednoduchšia a presnejšia.

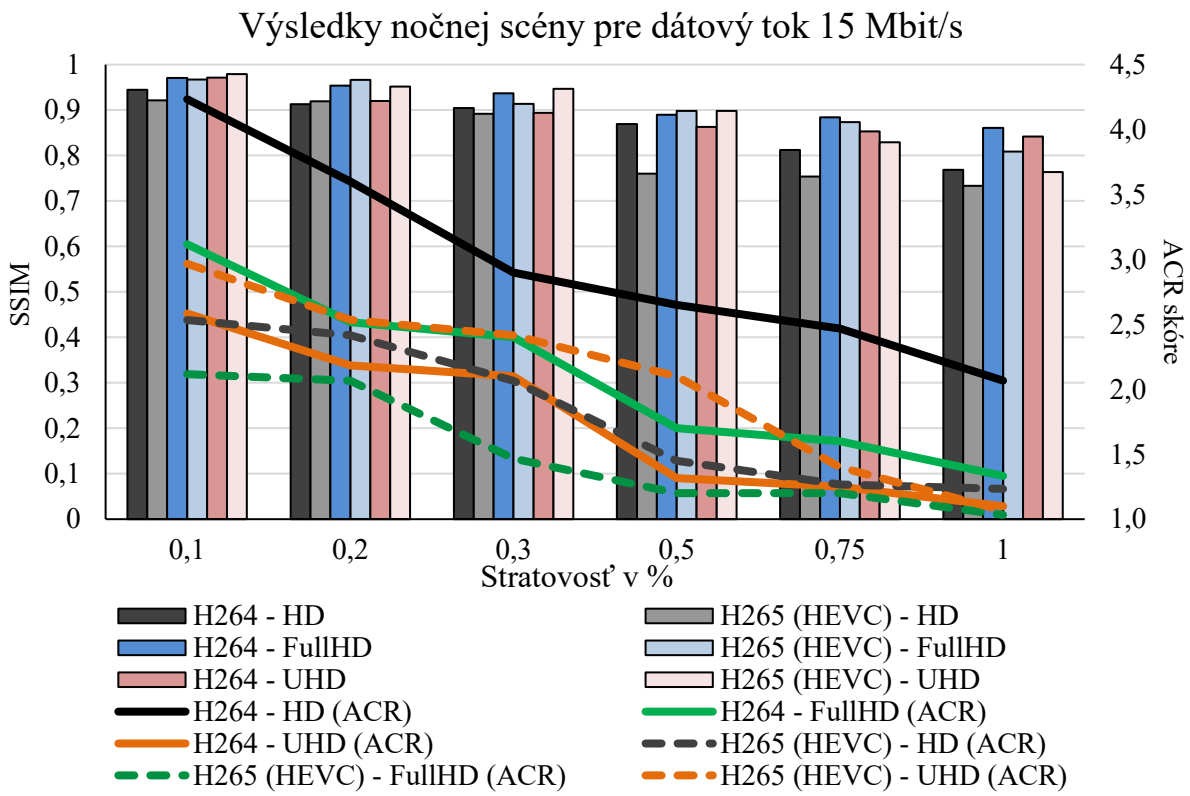

Obr. 8.4: Porovnanie výsledkov objektívneho a subjektívneho testovania pre scénu Campfire s bitovým tokom 15 Mbit/s.

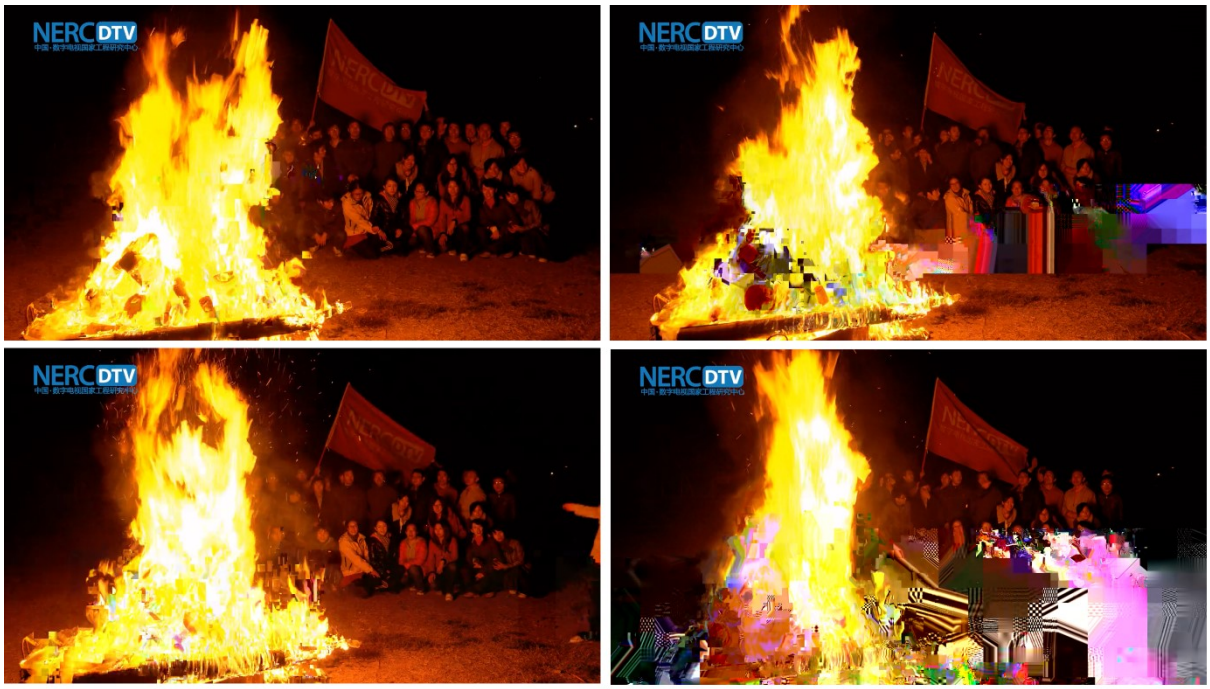

Obr. 8.5: Zaznamenané artefakty v obraze pre HD rozlíšenie s 5 Mbit/s bitovým tokom. Stratovosť 0,1 % reprezentuje prvý riadok a 0,5 % druhý riadok, kodek H.264 je naľavo a H.265 napravo.

8.2 Využitie databázy na modelovanie neurónovej siete

Databáza ohodnotených videí je využitá ako vstup a referencia pre trénovanie a testovanie rôznych modelov neurónovej siete. Proces hľadania správnej konfigurácie s cieľom minimalizovať predikčnú chybu zahŕňal potrebu nájsť:

- optimálnu topológiu,
- aktivačnú funkciu neurónu.

Počíta sa s predikciou pre dva rôzne kodeky, ktoré majú mierne odlišné výsledky, teda vektory vstupov tieto kodeky delia na dve fundamentálne skupiny. Každá konfigurácia neurónovej siete bola natrénovaná na vstupných dátach z rovnakej množiny 10-krát. Každá trénovacia množina bola rozdelená náhodne v pomere 7:3 na trénovaciu a validačnú sadu, pričom trénovanie prebehne s trénovacou sadou a presnosť natrénovania je overená validačnou sadou.

Náhodné delenie sa opakuje pre každé jedno modelovanie siete, čiže pre 10 opakovaní je 10-krát náhodne vytvorená trénovacia a validačná sada. Zvolené číslo 10 vychádzalo z vlastných skúseností, výsledkov autorov prác [frn6], [26], [46] a skúšobných testov tak, aby obmedzilo vplyv náhodne generovaných inicializačných váh, náhodného delenia na trénovaciu a validačnú sadu aby sa zvýšila štatistická významnosť celého procesu. Počet epoch trénovania bol najprv experimentálne nastavený na 3000, ale pri niektorých topológiách dochádzalo k pretrénovaniu neurónovej siete. Otestované boli aj hodnoty 1000 a 300, pričom až hodnota 300 reprezentovala stav, kde nedochádzalo k pretrénovaniu a zároveň je to bod, keď je hodnota chybovej funkcie modelu neurónovej siete veľmi blízko svojho minima. To, ako sa správala pretrénovaná neurónová sieť pri prekročení počtu epoch je popísané v nasledujúcej kapitole.

Okrem výstupu siete v podobe predikovanej hodnoty MOS skóre bol pre každú konfiguráciu sledovaný aj čas nutný k úspešnému natrénovaniu neurónovej siete. Tento údaj slúži ako jedna z metrík pre výber optimálneho navrhnutého modelu.

9 Návrh klasifikátora založeného na neurónovej sieti

Nasledujúce podkapitoly detailne popisujú jednotlivé kroky vedúce k vytvoreniu funkčného predikčného modelu. Ako vstupy sú brané parametre videosekvencií popísané v predchádzajúcich kapitolách. Ako referenčná hodnota vystupuje spriemerované subjektívne hodnotenie získané metódou ACR, interpretované pomocou stupnice MOS, získané vykonanými subjektívnymi testami. Do neurónovej siete teda vstupuje 6 hodnôt popisujúcich charakter videa a jeho odolnosť na stratovosť s tým, že očakávaným výstupom je predikovaná hodnota subjektívneho hodnotenia v škále MOS.

9.1 Využitie možností programovacieho jazyka Python

Začiatok vývoja programovacieho jazyka Python sa datuje od roku 1991. Pôvodne bol vyvíjaný ako skriptovací jazyk, dnes je však využívaný aj na tvorbu veľkých softwarových projektov ako aplikačné servery alebo systémy na zdieľanie súborov. Je voľne dostupný ako open source projekt, podporuje objektovo-orientované programovanie a jednoduché rozširovanie pomocou modulov napísaných v C alebo C++. Výhodou je aj automatická prítomnosť tohto jazyka pre OS Linux, a to v dvoch verziách – staršiu verziu predstavuje interpreter Python 2.X a novšiu Python 3.X. Pre účely tejto práce bola použitá novšia verzia Python 3.5.1+ (súčasť OS Linux Mint 18, kernel 4.4.0-21, x86_64), pričom funkčnosť implementácie bola odskúšaná aj na nasledujúcej verzii Python 3.5.2. Použité vývojové prostredia sú pycharm a Subline text 2.

9.1.1 Príprava prostredia pre implementáciu klasifikátora

Prídavné moduly a balíčky sa jednoducho inštalujú pomocou správcu balíčkov *pip* a správne kompilovanie kódu zabezpečuje *setuptools*. Pokiaľ nie sú súčasťou predinštalovanej verzie Pythonu v Linuxe, dajú sa dodatočne pridať pomocou známej direktívy apt-get install.

Samotná knižnica určená pre modelovanie neurónových sietí s vysokou úrovňou abstrakcie pre Python sa vola *Keras* [47]. Je vyvíjaná s ohľadom na jednoduché používanie a vysoký výpočtový výkon. Podporuje prácu na frameworku Tensorflow alebo Theano. Dokáže vykonávať výpočty so zapojením CPU aj grafického procesoru. Bola vybraná pre jej užívateľské prostredie a rozsiahlu dokumentáciu. Podporuje rozsiahlu škálu neurónových sietí. Použitá verzia bola 1.2.0. Inštalácia je podrobne popísaná v dokumentácii [47].

Inštalácia zabezpečí aj pridanie dodatočných modulov potrebných pre modelovanie a výpočty a to konkrétne numpy, scipy, pyyaml a theano.

NumPy je základná knižnica pre prácu s maticami, tabuľami a poliami. Scipy obsahuje základné algoritmy pre interpoláciu alebo integrovanie.

Theano je výpočtová knižnica napísaná v jazyku Python. Pri výpočtoch dokáže pracovať s CPU aj GPU. Theano podporuje modelovanie a výpočty neurónových sietí, ale jedná sa o veľmi nízko úrovňový framework. Preto je používaný v spolupráci s knižnicami ponúkajúcimi vyššiu mieru abstrakcie a jednoduchšie modelovanie neurónových sietí.

Tensorflow je open source výpočtová knižnica vyvíjaná pod záštitou Google. Je to kombinácia nízkoúrovňového výpočtového frameworku typu Theano s možnosťou využitia vyššej miery abstrakcie ako napríklad v knižnici Keras. Obrovská užívateľská základňa a podpora spoločnosti Google, z nej spravili jeden z najväčších projektov pre prácu s neurónovými sieťami.

Keras dokáže pracovať s obomi implementáciami pre spracovanie dát – tzv. Keras backend – Tensorflow a Theano (aj keď samozrejme nie súčasne). Otestované boli obe riešenia a z pohľadu potrebného času nebol pri tomto type neurónovej siete zaznamenaný výrazný rozdiel. Pokiaľ sú nainštalované obe knižnice, jednoducho sa dá medzi nimi vyberať a odskúšať. Stačí nájsť konfiguračný súbor keras.json a zmeniť položku *backend* z `theano` na `tensorflow` alebo opačne [47]. Tieto všetky spomenuté knižnice sú potrebné pre spustenie a predikciu modelu v podobe neurónovej siete.

Pre samotnú tvorbu je potrebné ešte podľa potreby doinštalovať knižnicu Pandas, ktorá pracuje s 2D tabuľkami, ktoré sa objavujú v SQL databázach a hlavne v podobe CSV formátu. Pretože ako vstup slúžila upravená databáza výsledkov, táto knižnica bola nevyhnutná pre prácu na neurónovej sieti. Spôsob načítania výsledkov uložených v CSV formáte vyzerá nasledovne:

```
def load_data():
    # načítanie CSV súboru s výsledkami
    dataframe = pandas.read_csv("working_data_clean.csv", header=1)
    dataset = dataframe.values

    # pozícia vstupov a načítanie hodnoty pre každé zo 60-tich hodnotení
    train_dataset = []
    validation_dataset = []
    for i in dataset:
        vstupy = i[0:6]
        hodnotenia = i[7:67]
```

Na trénovanie neurónovej siete bola použitá knižnica Scikit-learn využívajúca knižnice Numpy a Scipy. Pre ukladanie konfigurácie testovaných modelov v podobe .h5f súborov (topológia, aktivačná funkcia, nastavenie váh pre neuróny) bol využívaný backend theano [48], a to pomocou nasledujúcej konfigurácie:

```
  def save_model(self, name):
        print('model saved')
        self.model.save_weights('weights_new_{}.h5f'.format(name))
```

9.2 Vplyv voľby topológie na presnosť odhadu neurónovej siete

Vzhľadom k charakteru viacvrstvových neurónových sietí je správna topológia veľmi dôležitá pre dosiahnutie optimálneho výsledku. Príliš malý počet neurónov vedie k neschopnosti neurónovej siete naučiť sa predkladané vzory a príliš veľké množstvo neurónov vedie sieť

k presnému reprodukovaniu naučených vzorov, čím stráca svoju schopnosť generalizovať. Pomocou popísaných knižníc pre Python bol postupne generovaný počet neurónov a vrstiev pre neurónovú sieť. Generovanie a hľadanie správnej topológie prebehlo od 3 po 8 vrstiev s maximom 230 neurónov pre jednu vrstvu:

```
base_list = range(50,130,5)
multi_list = range(4,20)
print(len(base_list)*len(multi_list))
neurons = []
for b in base_list:
    for m in multi_list:
        layers = []
        for c in range(1,m+1):
           layers.append(b-int((b/m)*(m-c)))
        neurons.append(layers[::-1])
```

Koeficient učenia η bol po počiatočných experimentálnych pokusoch nastavený na hodnotu 0,0013. Vstupná vrstva z dátami nemanipuluje, bola tu využitá lineárna aktivačná funkcia. Dohromady bolo otestovaných 140 topológií neurónovej siete.

9.2.1 Namerané dáta

Výsledky uskutočnených meraní na validačnej sade sú zobrazené v tabuľke 9.1. Uvedená topológia (každý riadok tabuľky) je pre daný počet vrstiev najlepšia z hľadiska Pearsonovho korelačného koeficientu. Podrobnejšie informácie o výsledkoch všetkých preskúmaných topológií sa nachádzajú v prílohe B a v elektronickej podobe na priloženej pamäťovej karte.

Tab. 9.1: Výsledky nameraných hodnôt pre jednotlivé topológie.

Topológia siete	$r_{x,y}$[-]	RMSE [-]	Čas [s]
230-154-77	0,990	0,2183	162
230-173-115-58	0,991	0,2149	207
131-105-79-53-27	0,994	0,2155	141
98-79-59-40-20	**0,989**	**0,2155**	**97**
175-146-117-88-59-30	0,996	0,2122	236

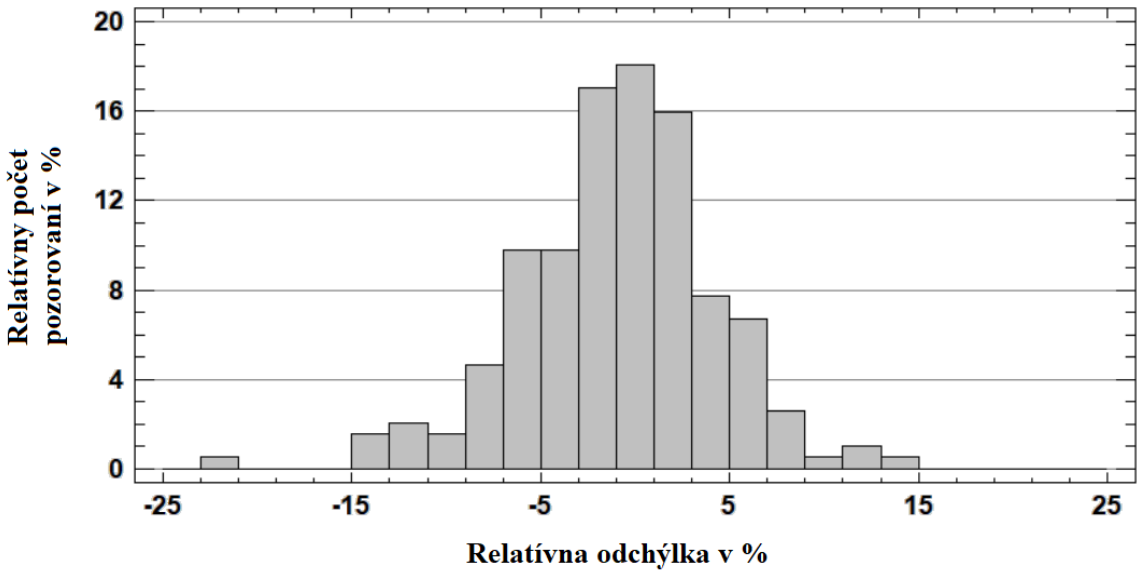

Obr. 9.1: Graf rozloženia absolútnych hodnôt relatívnej odchýlky.

V tabuľke okrem topológií s najlepším hodnotením je uvedená a zvýraznená topológia 98-79-59-40-20. Táto topológia síce nedosahuje najlepšiu koreláciu, ale má výrazne nižší čas vytrénovania siete. Dosahuje najlepší pomer aproximácie voči časovej náročnosti, a preto bola vyhodnotená ako najlepšia topológia. Siete s vyšším počtom neurónov a vrstiev sa výraznejšie prispôsobili svojím vzorom a dochádzalo k rýchlejšiemu a častejšiemu pretrénovaniu. Trénovanie prebiehalo na HW s procesorom AMD Opteron so 4-mi modulmi po 8 jadier, dokopy 32 jadier. Hodnota RMSE mierne nad 0,2 korešponduje s variačným koeficientom subjektívnych testov, ktorá až na pár prípadov neprekročila hodnotu 35 %. Táto hodnota odpovedá približne 7 % chybovosti vo vzťahu k stredu stupnice MOS. Ako poukazuje graf na obrázku 9.1, vysoká podobnosť s referenčnými hodnotami je aj daná tým, že do 10 % odchýlky (relatívna chyba) leží 73,2 % (< 5 % sa nachádza 39,69 %) všetkých pozorovaní. Z ostatných modelov žiadny neprekročil hodnotu 72 % pre tento sledovaný parameter. Kompletné štatistiky sú uvedené v elektronickej podobe v súbore *correlations_pearson_rmse*. Model je teda porovnateľný s modelmi popísanými v kapitole 5.

9.3 Vplyv voľby aktivačnej funkcie na presnosť odhadu MOS

Voľba aktivačnej funkcie ovplyvňuje nielen schopnosť jednotlivých neurónov modifikovať vstupný potenciál, ale jej samotný predpis (resp. zložitosť) má výrazný vplyv na dobu výpočtu vo fáze trénovania neurónovej siete. Testovací proces prebiehal za rovnakých podmienok, ako tomu bolo pri hľadaní vhodnej topológie neurónovej siete. Experimentálne meranie bolo vykonané 10 krát, topológia neurónovej siete bola 98-79-59-40-20, počet epoch obmedzený na 300 a koeficient učenia η rovný hodnote 0,0013.

Knižnica Keras vie pracovať s viacerými typmi aktivačnej funkcie a pomocou nasledujúceho predpisu bola otestovaná ich miera presnosti predikcie. Vzorky pre aktivačnú funkciu tanh sú totožné s tými zo sekcie venovanej jednotlivým topológiám.

```
    X, Y = load_data()
     layers = ['relu', 'tanh', 'sigmoid', 'hard_sigmoid', 'linear']
     for l in layers:
         learnObj = Learner(X, Y, layers=n, activation=l, save=True,
epoch=300, verbose=0)
         learnObj.train_cross_validate()
```

9.3.1 Namerané dáta

Výsledky v tabuľke 9.2 poukazujú na minimálne rozdiely z pohľadu dosiahnutej korelácie a chybovosti. Funkcia ReLu má mierne lepší výpočtový čas, ale dosahuje horšie výsledky aproximácie. Pri pohľade na výsledky je možné prehlásiť, že funkcia tanh predstavuje kompromis medzi výslednou mierou predikcie a výpočtového času potrebného na trénovanie.

Tab. 9.2: Výsledky nameraných hodnôt pre jednotlivé aktivačné funkcie.

Aktivačná funkcia	$r_{x,y}$[-]	RMSE [-]	Čas [s]
Tanh	0,989	0,2155	97
ReLu	0,980	0,2199	91
Sigmoid	0,974	0,2259	113
Hard Sigmoid	0,973	0,2294	106
Linear	0,885	0,4474	78

Okrem lineárnej aktivačnej funkcie mali zvyšné otestované funkcie výrazne horší výpočtový čas (tretia najlepšia aktivačná funkcia Hard Sigmoid o 9 %). Lineárna aktivačná funkcia dosiahla síce najlepší čas, ale z hľadiska možnosti aproximácie najhoršie výsledky.

9.4 Eliminovanie pretrénovanosti neurónovej siete

Pri prílišnej snahe o dosiahnutie čo najnižšej chybovosti modelu pre trénovaciu sadu môže dôjsť k situácii, že paradoxne od určitého momentu bude narastať chybovosť predikcie na validačnej sade dát. Neurónová sieť je pretrénovaná, príliš sa prispôsobila svojím vzorom a stráca schopnosť generalizácie. Na obrázku 9.3 vidieť príklad, ako jeden z testovacích modelov počas overovania voči validačnej sade prestáva byť vierohodný, pretože pri narastajúcej stratovosti nemôže dochádzať k zlepšeniu subjektívneho vnímania kvality obrazu.

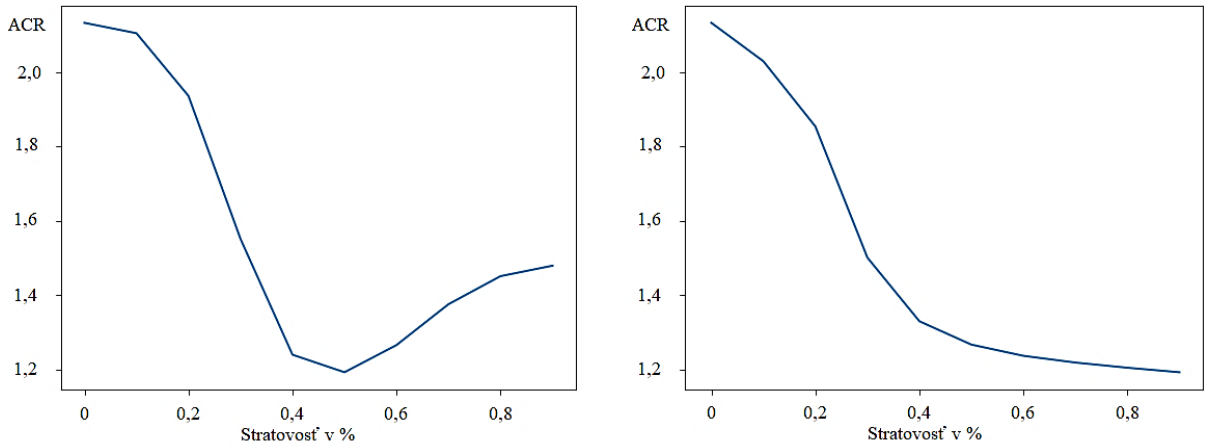

Obr. 9.2: Graf predikcií neurónovej siete v stave pretrénovania (vľavo) a po jeho eliminovaní pomocou Dropout techniky (vpravo).

Pretrénovaniu sa dá vyhnúť niekoľkými spôsobmi. Prvý krok je včasné odhalenie pretrénovania v bode, keď začne narastať chybovosť predikcie za použitia validačnej sady. Ak je trénovanie v tomto bode zastavené a dosiahnutá presnosť predikcie je uspokojivá je po probléme. Pomôcť môže aj redukovanie veľkosti siete, ktorá sa následne nebude tak ponášať na svoje trénovacie vzory [frn6].

Špeciálna technika, ktorú podporuje knižnica Keras je tzv. Dropout. Táto technika popísaná autormi v práci [49], náhodne vyberie neuróny, ktoré budú ignorované počas trénovania. Prínos spočíva v prerušení väzieb a tým pádom pri spätnej úprave váh metódou Backpropagation nebudú tieto neuróny brané do úvahy. Rolu týchto neurónov preberú zvyšné neuróny v sieti a dochádza tak v rámci siete k predikcii menej závislej na trénovacej množine. Počas testovania tejto metódy bola nastavená hodnota pravdepodobnosti zahodenia náhodne vybraného neurónu na 0,05 a 0,08 čo odzrkadľuje pravdepodobnosť zahodenia na 5% a 8%.

```
def baseline_model(self, neurons):
        model = Sequential()
        # import pdb; pdb.set_trace()
        if self.normalize:
            model.add(BatchNormalization(input_shape=(6,)))
            model.add(Dense(neurons[0], activation=self.activation))
        else:
             model.add(Dense(neurons[0],input_shape=(6,),
             activation=self.activation))

        if len(neurons) > 1:
            for i, n in enumerate(neurons[1:]):
                if i >= 5:
                model.add(Dropout(0.08))
                model.add(Dense(n, activation=self.activation))
        model.add(Dense(1))
```

Pri každom opätovnom prenastavovaní váh sú deaktivované iné neuróny a sieť tak dokáže lepšie zovšeobecňovať. Výsledok použitia Dropout techniky znázorňuje pravý graf na obrázku 9.2.

9.5 Spôsob použitia navrhnutého modelu pri predikcii

Z výsledkov uvedených v predchádzajúcich podkapitolách vyplýva, že najefektívnejšia topológia z pohľadu presnosti predikcie a výpočtového času je 98-79-59-40-20. Dosahuje výraznú časovú úsporu voči komplikovanejším topológiám a to za cenu minimálneho zhoršenia odhadu predikcie. Aktivačná funkcia hyperbolický tangens (tanh) z pohľadu presnosti predikcie dosahuje najlepšie výsledky s minimálnou časovou stratou celkovej výpočtovej doby na druhú aktivačnú funkciu v poradí s názvom ReLu.

Tieto výsledky sú zakomponované do súboru *test_model.py,* ktorý na základe týchto vstupných dát a načítaných váh neurónov vykonáva predikciu subjektívneho hodnotenia kvality videa v škále MOS na základe vstupných parametrov. Schéma popisujúca spôsob výpočtu je zobrazená na obrázku 9.3. V prvom kroku sa načíta zvolená topológia a aktivačná funkcia, v druhom kroku váhy neurónov, ktorých hodnoty sú pre každú topológiu vygenerované v súbore *correlations_pearson_rmse.*

```
path = os.path.dirname(__file__)
name = '2017-07-19 10_40_58.235351'  // načítanie topológie zo súboru
str_config = "[{'config': {'input_dtype': 'float32', 'epsilon': 0.001,
      'name': 'batchnormalization_85', 'mode': 0, 'batch_input_shape':
      (None, 6), 'trainable': True,....// konfigurácia neurónov
```

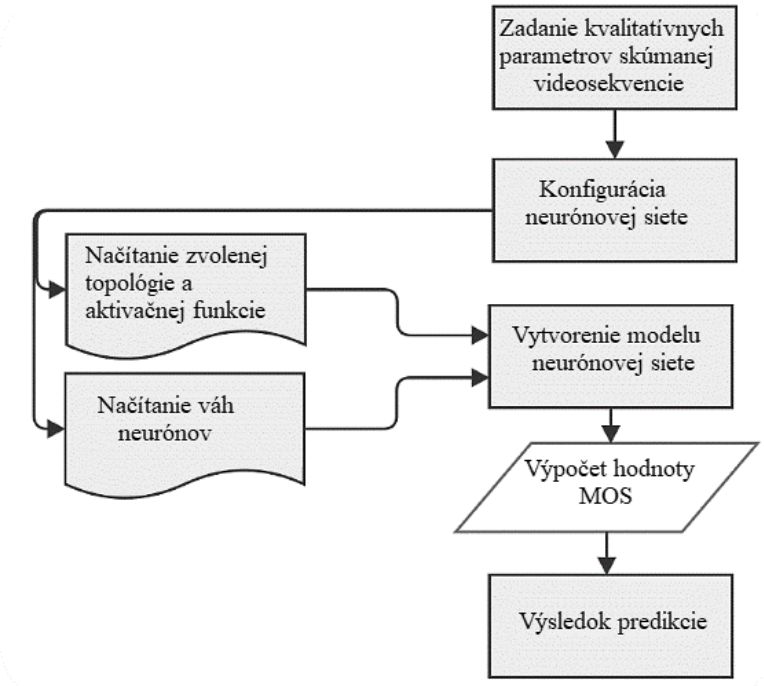

Obr. 9.3: Schéma priebehu výpočtu predikovanej hodnoty MOS navrhnutým modelom.

Otestovanie iného nastavenia sa vykoná jednoducho zmenou názvu h5f súboru a k nemu súvisiace nastavenia zo spomenutého súboru. Medzi vstupné parametre, ktoré je potrebné pre vykonanie predikcie zadať, patria: kodek, rozlíšenie, bitový tok, scéna, stratovosť a SSIM hodnota.

Pre parametre kodek, rozlíšenie a scéna je možne voľbu zadať číslom alebo slovom v tomto formáte:

```
params_map = {
'codec': {'h264': 0, 'h265': 1},
'resolution': {'hd': 0, 'fhd': 1, 'uhd': 2},
'scene': {'campfire': 0, 'construction': 1, 'runners': 2, 'wood': 3,
'night': 0, 'static':1, 'sport': 2, 'dynamic': 3},
}
```

Obmedzenia pre rozsah hodnôt, ktoré je neurónová sieť schopná spracovať a predikovať výsledok:

```
assert ssim    > 0     assert ssim    <= 1
assert loss    > 0     assert loss    <= 1
assert bitrate > 0     assert bitrate <= 15
```

Pred zadaním príkazu je potrebné sa nachádzať v adresári so spúšťacím súborom (ktorý si načíta uložené váhy neurónov). Ako príklad predikcie zo zadanými parametrami slúži nasledujúca ukážka voľby vstupných parametrov:

```
python3 test_model.py --test --codec h265 --bitrate 5 --ssim 0.86665 --
resolution UHD --loss 0.3 --scene dynamic
Using TensorFlow backend.
...
2.38354 // referenčná spriemerovaná hodnota z dotazníkov: 2.367


python3 test_model.py --test --codec h264 --bitrate 5 --ssim 0.97512 --
resolution HD --loss 0.2 --scene sport
Using TensorFlow backend.
...
3.26261  // referenčná spriemerovaná hodnota z dotazníkov: 3.217
```

9.6 Štatistické vyhodnotenie úspešnosti predikcie navrhnutého modelu

Keďže pri topológii neurónovej siete 98-79-59-40-20 a použití aktivačnej funkcie tanh nedochádzalo pri nezávislých pokusoch k pretrénovaniu a sledované štatistické parametre dosahovali požadovanú úroveň, bol tento model určený ako najvhodnejší pre ďalšie využitie. Porovnanie s referenčnými vzorkami bolo preto vykonané s touto topológiou.

Štatistické vyhodnotenie podobnosti medzi referenčnými dátami získanými dotazníkovým šetrením metódou ACR (testovacia sada) a výsledkami predikovanými

navrhnutým modelom je možné spracovať viacerými spôsobmi. Pre všetky tu uvedené štatistické metódy platí, že boli vykonané s intervalom spoľahlivosti 95 %.

Navrhnutý model neurónovej siete pracuje s dvomi typmi videokodekov. Štatistické zisťovanie teda prebiehalo pre dve testovacie sady (samostatne pre H.264 a H.265), aby sa eliminovalo prípadné skreslenie vzniknuté využitím spoločnej testovacej sady. Takto koncipované testy poukážu na to, či nedochádza k výrazne lepšej aproximácií výsledkov pre jeden z použitých kodekov.

Ako prvý krok k posúdeniu podobnosti medzi referenčnými hodnotami a predikčnými výsledkami modelu slúži výpočet konfidenčných intervalov smerodajných odchýliek, mediánov alebo priemerov.

Tab. 9.3: Výsledky štatistických veličín referenčných a modelových vzoriek.

Kodek	Množina	$\sigma_{min\,[-]}$	$\sigma_{max[-]}$	medián [-]	priemer [-]
H.264	Referenčná	0,748	0,980	2,509	2,467
	modelová (NS)	0,722	0,945	2,567	2,497
H.265	Referenčná	0,556	0,728	1,742	1,822
	modelová (NS)	0,541	0,708	1,722	1,812

Tabuľka 9.3 jasne dokazuje blízkosť mediánov, priemerov aj intervalov smerodajných odchýlok oboch množín a z faktického hľadiska je možné uvažovať o tom, že pochádzajú z výberu z rovnakej populácie.

Namerané, respektíve vypočítané agregované štatistiky vzhľadom k tomu, že sa prakticky nemenia naprieč jednotlivými opakovaniami experimentu, nespĺňajú predpoklad, že pochádzajú z normálneho rozdelenia. Pre formálne overenie tohto faktu bol použitý Shapiro-Wilk test normality, ktorý tento predpoklad potvrdil. Pre zamietnutie hypotézy o normálnom rozložení dát, stačí ak p-value je nižšia ako kritická hodnota 0,05 (napríklad pre dvojicu množín kodeku H.264 bola p-value referenčnej množiny 0,019 a modelovej množiny 0,016). Voľba štatistickej metódy preto padla na neparametrický test zhodnosti mediánov tzv. Mann-Whitney-Wilcoxonov test. V prípade, že ak výsledná p-value bude vyššia ako kritická hodnota 0,05 tak je možné uvažovať o uvedených výberoch v tom zmysle, že pochádzajú z rovnakej populácie.

Tab. 9.4: Výsledky Mann-Whitney-Wilcoxonovho testu o zhodnosti mediánov.

Kodek	Množina	Súčet poradí	W	p-value
H.264	Referenčná	107,139	5979	0,7497
	modelová (NS)	109,861		
H.265	Referenčná	108,736	5806,5	0,9566
	modelová (NS)	108,264		

Výsledky z tabuľky 9.4 poukazujú na silnú podobnosť medzi referenčnou a modelovou sadou. Test potvrdil, že medzi sadami nie je štatisticky významný rozdiel. Ďalšou možnosťou porovnania presnosti miery predikcie (tentoraz vizuálna) je porovnanie krivky hustoty rozdelenia (density trace). Tá poskytuje neparametrický odhad funkcie hustoty pravdepodobnosti populácie podľa zadaných dát. Obrázok 9.4 znázorňuje ako verne modelová

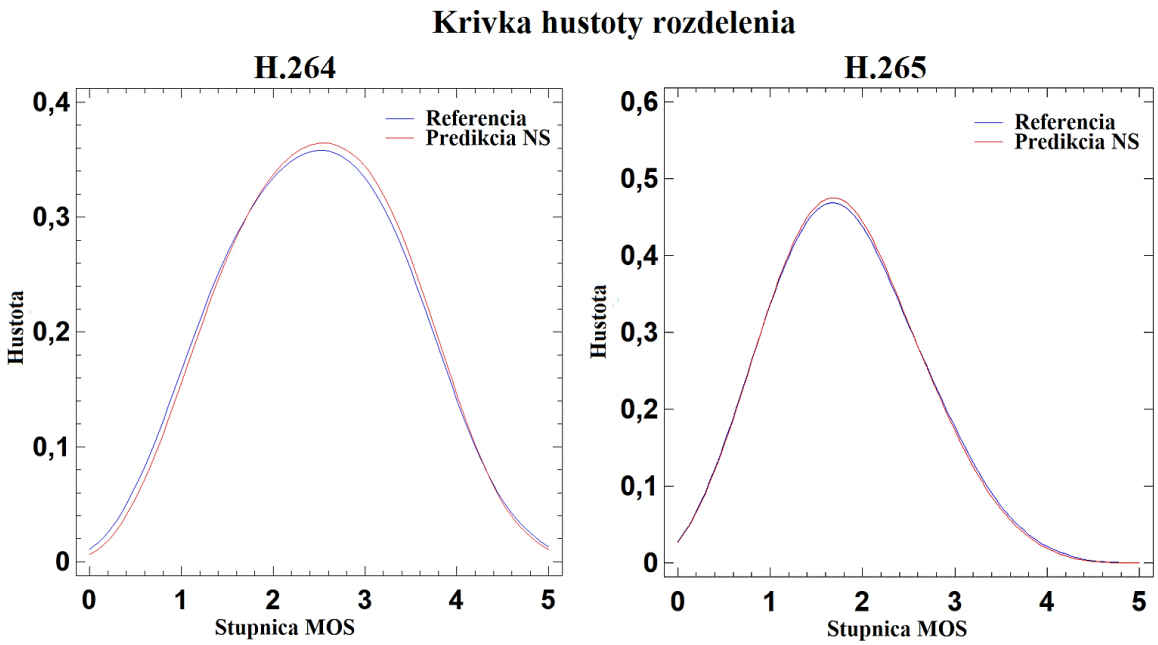

Obr. 9.4: Graf hustoty rozdelenia pre referenčnú a modelovú sadu.

sada kopíruje tú referenčnú pre oba typy kodekov, čo opätovne potvrdzuje schopnosť navrhnutého modelu poskytovať relevantné výsledky. Z obrázku je možné vyčítať odchýlky voči normálnemu rozdeleniu hlavne v miernej nesymetrickosti ľavej a pravej strany kriviek grafov.

Posledným krokom k overeniu podobnosti medzi referenčnou a modelovou sadou bolo vytvorenie korelačného diagramu. Pomocou tohto diagramu je možné jednoducho zistiť vzťah medzi oboma premennými. Korelačné diagramy pre oba kodeky sú znázornené na obrázku 9.5.

Aj na základe korelačných diagramov je možné prehlásiť vysokú mieru vierohodnosti modelu. Porovnaním korelačných koeficientov a chybovosti vyjadrenú pomocou RMSE pre jednotlivé testovacie sady využívané pre overenie fungovania neurónovej siete poukázali na schopnosť modelu približne s rovnakou presnosťou predikovať výsledky pre oba kodeky, čím je tento model v súčasnosti ojedinelý, hlavne z pohľadu predikcie pre kodek H.265.

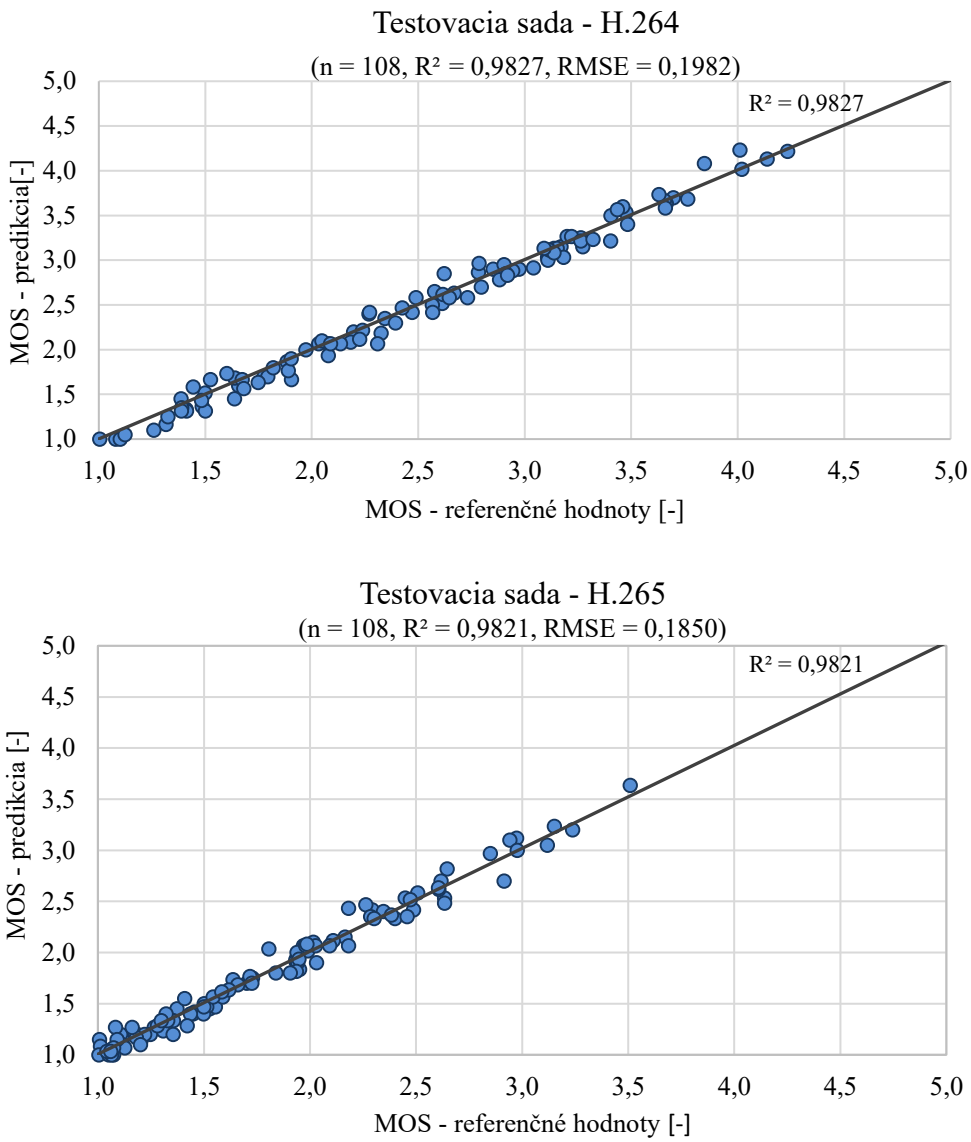

Obr. 9.5: Korelačný diagram pre kodek H.264 (hore) a H.265 (dole).

9.7 Zhrnutie a porovnanie s už publikovanými predikčnými modelmi

Štatistické vyhodnotenie navrhnutého modelu neurónovej siete je potrebné doplniť porovnaním s dostupnými riešeniami z ktorých najdôležitejšie výsledky boli popísané v kapitole 5. Navrhovaný model vychádza zo štatistík stratovosti v sieti, ktorú je možné monitorovať a vyhodnocovať počas prenosu sieťovou infraštruktúrou. Tento model vykonáva mapovanie týchto štatistík doplnených o informácie reprezentujúce kvalitatívne parametre prenášanej videosekvencie na subjektívnu kvalitu videa vyjadrenou stupnicou MOS. Ako bolo ukázané v predchádzajúcich podkapitolách, navrhnutý model je schopný dosahovať porovnateľných výsledkov s dostupnými riešeniami. Zložitosť celého spracovania vstupných dát je redukovaná na obecné štatistické vyhodnotenie, na ktoré je možné použiť vstupné dáta vygenerované ľubovoľným modelom alebo skutočnou prevádzkou.

Štatisticky sú všetky predložené závery podložené dostatočným množstvom pozorovaní a následnou exploračnou analýzou alebo neparametrickými štatistickými testami. Z tohto dôvodu je možné považovať prezentovaný model za vhodný pre približné odhadovanie kvality videa špeciálne pre potreby analýzy vplyvu zhoršených podmienok sieťových parametrov na poskytovanú kvalitu pre koncového zákazníka v reálnom čase.

Pre úplné zhodnotenie dosiahnutých výsledkov úspešnosti predikcie je nevyhnutné porovnať výkonnosť modelu s dostupnými modelovými algoritmami. Medzi sledované parametre je potrebné začleniť nielen tie, ktoré popisujú presnosť predikcie ale aj metodiku tvorby modelu.

Tabuľka 9.5 má za cieľ porovnať doteraz uverejnené algoritmy s navrhnutým modelom. Z pohľadu komplexnosti vstupných údajov, žiadny uvedený model neobsahuje takú škálovateľnosť v podobe zadávania až 6 kvalitatívnych parametrov súčasne. Rozsah vzoriek pre tvorbu modelov voči tu popísanej vytvorenej databáze ani zďaleka nedosahoval podobné veľkostné parametre. Pri porovnaní štatistických ukazovateľov aproximácie požadovaných výsledkov uvedených algoritmov sa len jeden významnejšie približoval k nameraným hodnotám predkladaného modelu a aj to pre dnes už zastaraný kodek, rozlíšenie a hlavne veľmi malý rozsah testovacej sady. Pretože sa ale jedná o priekopnícky počin vo využití strojového učenia pre odhadovanie kvality videa, je tu uvedený aj napriek svojej morálnej zastaranosti. Z pohľadu možnosti predikcie pre kodeky H.264 a H.265 súčasne, je predkladaný model ojedinelý a plne konkurencieschopný so zavedenými algoritmami pre predikciu kvality videa.

Tab. 9.5: Porovnanie navrhnutého modelu s publikovanými algoritmami.

Publikácia	Počet video sekvencií	Trénovacia/ Testovacia sada	Rozlíšenie	Kodek	BR	FR	PLR	Typ strojového učenia	r [-]	RMSE [-]
[25]	ND	80/14	CIF (352x288)	MPEG-2	X	X	X	RNN	0,9812	0,07
[26]	4	275/110	HD	H.264	X	-	X	BPNN	0,9446	0,257
[27]	3	289/ND	HD	H.264	X	-	X	regresia	0,9265	ND
[28]	3 dostupné databázy	ND	HD	H.264	-	-	-	Elastic Net	0,9	0,58
[29]	5	3600/ND	HD, FullHD	H.264	X	-	X	regresia	0,77	0,63
								RNN	0,85	0,51
								DBN	0,83	0,54
[30]	4 a 3 pre testovaciu sadu	60/45	HD, FullHD	H.264	-	-	-	ABFR (regresia)	0,9244	0,53
[50]	4	ND	HD	H.264	-	-	-	RNN	ND	0,37
[51]	16	480/ND	HD, FullHD	H.265	-	X	X	Regresia	0,9339	ND
[52]	3	5400/ND	FullHD	H.265	-	-	X	Regresia	0,92	0,23
MODEL	**4**	**19440/216**	**HD, FullHD, UHD**	**H.264 H.265**	**X**	**-**	**X**	**BPNN**	**0,9827 0,9821**	**0,1982 0,1850**

Vysvetlivky: BR – bitový tok, FR – obnovovacia frekvencia, PLR – stratovosť, ND – nedefinované

10 Prínosy dizertačnej práce

V rámci výskumu ktorého závery popisuje predkladaná dizertačná práca bolo dosiahnutých niekoľko výsledkov, ktoré je možné považovať za prínosné pre oblasť predikcie kvality obrazovej služby. Medzi prínosy tejto práce patrí:

- Analýzou publikovaných vedeckých prác a vlastným výskumom boli identifikované parametre (príznaky) videosekvencií, ktoré sú nevyhnutné pre výpočet predikcie zabezpečujú širokú variabilitu možných scenárov vyskytujúcich sa v bežnej praxi.

- Bola vytvorená databáza poškodených videosekvencií reflektujúc degradáciu kvality spôsobenú stratovosťou počas prenosu. Tieto videosekvencie boli ohodnotené subjektívne, značným počtom pozorovateľov a objektívnou metrikou SSIM. Poskytuje možnosť výberu kodekov, kvalitatívnych charakteristík a scén. Pri zachovaní metodiky tvorby je možné databázu neustále rozširovať a používať pre rozličné testovacie a výskumné scenáre hlavne smerom k postupnému prechodu na kódovací algoritmus H.265.

- Bol navrhnutý nový spôsob hodnotenia kvality videa v podobe modelu neurónovej siete, umožňujúci odhadnúť subjektívne vnímanie kvality z pohľadu koncového užívateľa pomocou vstupných príznakov videosekvencie a výsledku objektívnej hodnotiacej metriky. Toto prepojenie nahrádza potrebu vykonávania separátneho testovania subjektívnou a objektívnou formou. Výsledky predikcie sa približujú referenčným výsledkom získanými pomocou spomenutej databázy ohodnotených videosekvencií.

- Popisovaný model spolu s definovanými charakteristikami bol navrhnutý tak, aby sa dal nasadiť v rôznorodých prostrediach podľa aktuálnej potreby. V súčasnosti žiadny model nedokáže predikovať výsledky kvality obrazovej služby využitým toľkých vstupných parametrov a zároveň je schopný predikcie pre oba kodeky H.264 aj H.265. V najbližších rokoch sa očakáva vznik legislatívneho rámca pre hodnotenie IPTV aby užívatelia mali možnosť ochrany u regulačnej autority, preto bude nevyhnutné poskytnúť monitorovacie nástroje na systematické hodnotenie kvality ponúkanej služby pre regulačnú autoritu ako aj pre poskytovateľa daných služieb.

Záver

Predkladaná dizertačná práca prináša spôsob ako prepojiť výsledky objektívneho testovania kvality obrazovej služby s tými subjektívnymi. Návrh riešenia spočíva vo vytvorení modelu neurónovej siete umožňujúci odhadovať kvalitu videa pre kodeky využívané (nielen) pre digitálne kódovanie televízneho vysielania. Pretože model zahŕňa aj kodek H.265, ktorý postupne nahradí dnes využívaný kodek H.264, zachytáva tento model aj trend blízkej budúcnosti.

Dôvodom výskumu v tejto oblasti je narastajúci prenos digitálnej formy televízneho vysielania pomocou paketovej IP siete, čo vedie k zvýšenému záujmu o monitorovacie a testovacie nástroje. Tie by mali byť schopné určovať a analyzovať maximálne priepustné zaťaženie využívanej prenosovej infraštruktúry, alebo priebežne monitorovať jej aktuálny stav, tak aby prevádzkovateľ tejto infraštruktúry bol včas o vzniknutom probléme informovaný a mohol pružne reagovať na danú situáciu.

Vzhľadom k množstvu prenášaných dát je náročné sledovať a vyhodnocovať kvalitu prenášaného obsahu, hoci práve to je to najdôležitejšie, podľa čoho koncoví užívatelia hodnotia úroveň ponúkanej služby operátora. Hoci vznik objektívnych metrík umožňuje porovnať pokles kvality pomocou matematických algoritmov porovnaním s referenčnou vzorkou, problematické je interpretovať tento pokles do podoby subjektívneho vnímania zákazníkmi.

Táto situácia predstavuje príležitosť pre strojové učenie ako prvok umelej inteligencie umožniť prepojenie medzi subjektívnymi a objektívnymi výsledkami testov a podľa úrovne natrénovania odhadovať subjektívnu kvalitu videa.

Pri skúmaní výsledkov súvisiacich publikovaných prác bolo potrebné jasne určiť a vymedziť oblasť výskumu, ktorou možno danú problematiku posunúť ďalej a ktorej je venovaný zvyšok tejto práce.

V rámci prínosu práce je podrobne popísaná metodika práce, spôsoby a nástroje akými bol zadefinovaný cieľ dosiahnutý. Definované sú sledované parametre, ktoré sú z pohľadu autora významné pre kvalifikovaný odhad subjektívneho vnímania kvality videa, pričom v takej miere neboli použité pre žiadny autorovi známy spôsob predikcie kvality videa. Ďalšie kapitoly popisujú spôsob vytvorenia modelu vo forme neurónovej siete schopný z určených vstupov predikovať výslednú kvalitu videa reprezentujúcu subjektívne vnímanie pozorovateľa a štatistické vyhodnotenie vierohodnosti tejto predikcie. Posledným krokom je porovnanie dosiahnutých výsledkov s výsledkami ostatných modelov súvisiacich od publikovaných prác výskumníkov.

Pri pohľade na zadefinované ciele dizertačnej práce v kapitole 6, je možné konštatovať, že boli všetky naplnené. Zadefinovanie sledovaných parametrov, tvorba databázy subjektívnych a objektívnych ohodnotení bola popísaná v kapitole 7. Analýza vplyvu stratovosti v sieti, ktorá reprezentuje výkonnosť prenosovej cesty sa nachádza v kapitole 8, pričom autor využíva už nadobudnuté poznatky získané počas doktorského štúdia. S využitím získaných informácií a podkladov bol vytvorený predikčný nástroj na báze neurónovej siete. S ohľadom na potreby trénovania a testovania neurónovej siete boli využité dáta vychádzajúce

z vytvorenej databázy videosekvencii. Spolu s overením presnosti miery predikcie a porovnaním s konkurenčnými výpočtovými modelmi sa problematike dôsledne venuje kapitola 9.

Táto práca prináša model umožňujúci odhad subjektívnej kvality obrazovej služby v závislosti na parametroch stratovosti a typu testovaného videa (rozlíšenie, bitový tok, scéna) nielen pre aktuálne široko používaný kodek H.264 ale aj pre jeho nástupcu kodek H.265. Týmto významne rozširuje možnosti predikcie doteraz uverejnených modelov. Výsledky prezentovaného modelu sú porovnateľné s uverejnenými alternatívami, pričom štatistické ukazovatele vykazujú vyššiu mieru presnosti predikcie. Nasadenie tohto nástroja pre priebežné vyhodnocovanie poskytovanej kvality operátormi je nenáročné a celý výpočtový proces trvá niekoľko sekúnd.

Ďalší vývoj sa bude uberať na praktickú využiteľnosť predikčného nástroja v reálnom prostredí a rozširovanie databázy ohodnotených videosekvencií tak, aby postupne mohlo dochádzať k spresňovaniu odhadu subjektívneho vnímania a zapracovanie rozširujúcich vstupných parametrov modelu pre lepšie prispôsobenie sa konkrétnej situácii.

Referencie

[1] C. Keimel, J. Habigt, K. Diepold. Hybrid no-reference video quality metric based on multiway PLSR. *Proceedings of the 20th European Signal Processing Conference,* 2012.

[2] M. Bukowsky, I. Sedano, K. Brunnstron, M. Leszczuk, N. Staelens. Hybrid video quality prediction: reviewing video quality measurement for widening application scope. *Multimedia Tools and Applications*, 2015, vol. 74, no. 2, pp. 323-343.

[3] M. Uhrina, J. Hlubik, M. Vaculik. Correlation between objective and subjective methods used for video quality evaluation. *Advances in Electrical and Electronic Engineering*, 2013, vol.11, no. 2, pp. 136-145.

[4] The Moving Picture Experts Group. *MPEG Standards*. Dostupné na: http://mpeg.chiariglione.org/standards.

[5] V. Lo. *A Beginners Guide for MPEG-2 Standard*. University of Hong Kong. Dostupné na: http://www.iem.thm.de/telekom-labor/zinke/mk/mpeg2beg/beginnzi.htm.

[6] Odporučenie ITU-T H.264. *H.264:Advanced video coding for generic audiovisual services*. Dostupné na: http://www.itu.int/rec/T-REC-H.264-201602-S, 2016.

[7] Y. Lu Yang. *Real-time End-to-End H.265/HEVC Solution for Intel® Architecture-based Platforms*. Dostupné na: https://software.intel.com/en-us/android/articles/real-time-end-to-end-h265hevc-solution-for-intel-architecture-based-platforms#3.3.

[8] Odporučenie ITU-T P.910. *Subjective video quality assessment methods for multimedia applications.* Dostupné na: https://www.itu.int/rec/T-REC-P.910-200804-I/en, 2008.

[9] Odporučenie ITU-T BT.500-13. *Methodology for the subjective assessment of the quality of television pictures.* Dostupné na: https://www.itu.int/rec/R-REC-BT.500-13-201201-I/en, 2012.

[10] S. Winkler, P. Mohandas. The Evolution of Video Quality Measurement: From PSNR to Hybrid Metrics. *IEEE Transactions on Broadcasting,* 2008, vol.54, no. 3, pp. 660-668.

[11] Z. Wang, A.C. Bovik, H.R. Sheikh, E.P. Simoncelli. Image quality assessment: from error visibility to structural similarity. *IEEE Transactions on Image Processing,* 2004, vol.13, no. 4.

[12] H.R. Sheikh, A.C. Bovik. Image information and visual quality. *IEEE Transactions on Image Processing,* 2006, vol.15, no. 2, pp. 430-444.

[13] T. Kratochvíl. *Digitální televizní a rozhlasové systémy.* Ústav radioelektroniky FEKT VUT v Brně. Dostupné na: http://www.radio.feec.vutbr.cz/kosy/soubory/update01/04/01_kratot_pwp.pdf.

[14] České Rádiokomunikace. *Spustili jsme testovací vysílání DVB-T2 s kodekem HEVC.* Tlačová správa. Dostupné na: https://radiokomunikace.cz/spustili-jsme-testovaci-vysilani-dvb-t2-s-kodekem-hevc.

[15] C. Santos, E.P. Ribeiro, C.M. Pedroso. The application of neural networks to improve the quality of experience of video transmission over IP networks. *Engineering Applications of Artificial Intelligence,* 2014, vol. 27, pp. 137-147.

[16] C.H. Tsai, Y.T. Chih, W.H. Wong, C.Y. Lee. A Hardware-Efficient Sigmoid Function With Adjustable Precision for a Neural Network System. *IEEE Transactions on Circuits and Systems II: Express Briefs,* 2015, vol. 62, no.11, pp.1073-1077.

[17] Odporučenie ITU-T P.800. *Methods for subjective determination of transmission quality.* Dostupné na: http://www.itu.int/rec/T-REC-P.800/en, 1996.

[18] E. Dumic, M. Mustra, S. Grgic, G. Gvozden. Image quality of 4:2:2 and 4:2:0 chroma subsampling formats. *Proceedings of International Symposium ELMAR*, 2009, pp. 19-24.

[19] Ch. Poynton. *Digital video and HDTV: algorithms and interfaces.* Morgan Kaufmann Publishers, 2003, ISBN 15-586-0792-7.

[20] P. Hanhart, P. Korshunov, T. Ebrahimi. Benchmarking of quality metrics on ultra-high definition video sequences. *Proceedings of 18th International Conference on Digital Signal Processing*, 2013, pp. 1-8.

[21] S. Winkler. Analysis of Public Image and Video Databases for Quality Assessment. *IEEE Journal of Selected Tfopics in Signal Processing,* 2012, vol. 6, no. 6, pp. 616-625.

[22] SJTU Media Lab: *Databáza testovacích sekvencií*. Dostupné na: http://medialab.sjtu.edu.cn/web4k/index.html.

[23] M. Klima, K. Fliegel, D. Kekrt, P. Dostal, R. Podgorny. Image Quality and QoE in Multimedia Systems. *Proceedings of 19th International Conference Radioelektronika,* 2009, pp. 3-10.

[24] P. Fröhlich, S. Egger, R. Schatz, M. Muhlegger. QoE in 10 seconds: Are short video clip lengths sufficient for Quality of Experience assessment? *Proceedings of Quality of Multimedia Experience (QoMEX)*, 2012, pp. 242-247.

[25] S. Mohamed, G, Rubino. A Study of Real-Time Packet Video Quality Using Random Neural Networks. *IEEE Transactions on Circuits and Systems for Video Technology.* December 2002, vol. 12, no 12.

[26] D. Valderrama, N. Gómez. Nonintrusive Method Based on Neural Networks for Video Quality of Experience Assessment. *Advances in Multimedia*, Volume 2016.

[27] D. Botia, N. Gaviria, J.Menedez, D. Jimenez. An approach to correlation of QoE metrics applied to VoD service on IPTV using a Diffserv Network. *4th IEEE Latin-American Conference on Communications (IEEE LATINCOM),* November 2012.

[28] Søgaard, J., Forchhammer, S., Korhonen, J. Video quality assessment and machine learning: Performance and interpretability. *7th International Workshop on Quality of Multimedia Experience,(QoMEX)*." May 2015.

[29] Mocanu, D. C., Pokhrel, J., Pablo Garella, J., Seppänen, J., Liotou, E., Narwaria, M. No-reference video quality measurement: added value of machine learning. *Journal of Electronic Imaging*, vol. 24, no. 6, 2015.

[30] M. Narwaria W. Lin. Machine Learning Based Modeling of Spatial and Temporal Factors for Video Quality Assessment. *Proc. 18th IEEE International Conference on Image Processing (ICIP)*, pp. 2513-2516, 2011.

[31] Song, Li, Tang, Xun, Zhang, Wei, Yang, Xiaokang, Xia, Pingjian. The SJTU 4K video sequence dataset. *5th International Workshop on Quality of Multimedia Experience (QoMEX),* 2013.

[32] Clumsy 0.2. *An open-source utility for simulating broken networks on Windows.* Dostupné na: http://jagt.github.io/clumsy/.

[33] Grois, D., Nguyen, T., Marpe, D. Coding efficiency comparison of AV1/VP9, H.265/MPEG-HEVC, and H.264/MPEG-AVC encoders. *Picture Coding Symposium (PCS),* 2016.

[34] FFmpeg. *A complete, cross-platform solution to record, convert and stream audio and video.* Dostupné na: https://www.ffmpeg.org/.

[35] MSU Video Quality Measurement Tool. *Program for objective video quality assessment.* Dostupné na: http://www.compression.ru/video/quality_measure/video_measurement_tool.html.

[36] T. Zinner, O. Abboud, O. Hohlfeld, T. Hossfeld, and P. Tran-Gia. Towards QoE Management for Scalable Video Streaming. *Proc. 21st ITC Specialist Seminar on Multimedia Applications - Traffic, Performance and QoE*, Miyazaki, Japan, March 2010.

[37] A.O. Adeyemi-Ejeye, M. Alreshoodi, L. Al-Jobouri, M. Fleury, J. Woods. Packet loss visibility across SD, HD, 3D, and UHD video streams. *Journal of Visual Communication and Image Representation*, Volume 45, Pages 95-106, 2017.

[38] S. Argyropoulos, A. Raake, M. N. Garcia and P. List, "No-reference bit stream model for video quality assessment of h.264/AVC video based on packet loss visibility. *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP).* Prague, pp. 1169-1172, 2011.

[39] Schukzrinne, H., S. Casner, R. Frederick, V. Jacobson. RFC 3550. *RTP: A Transport Protocol for Real-Time Applications*. 2003. Dostupné z: https://www.ietf.org/rfc/rfc3550.txt.

[40] Simsons, Wes. *Video Over IP: IPTV, Internet Video, H.264, P2P, Web TV, and Streaming: A Complete Guide to Understanding the Technology.* 2. vyd. New York: Focal Press, 2008, 504 s. ISBN 02-408-1084-8.

[41] S. K. Im and A. J. Pearmain. Error resilient video coding with priority data classification using H.264 flexible macroblock ordering. *IET Image Processing*, vol. 1, no. 2, pp. 197-204, June 2007.

[42] A. Sood, N. K. Chilamkurti and B. Soh. Study and Analysis of an Error Resilient Technique in H.264 Video Using Flexible Macroblock Grouping. *International Conference on Wireless Communications, Networking and Mobile Computing*, Wuhan, pp. 1-4, 2006.

[43] Rozhlas a televízia Slovenska. *Rio po prvýkrát v UltraHD rozlíšení.* Tlačová správa. Dostupné na: https://www.rtvs.sk/televizia/clanky/113080/rio-po-prvykrat-v-ultrahd-rozliseni.

[44] H. Bai, W. Lin, M. Zhang, A. Wang and Y. Zhao. Multiple Description Video Coding Based on Human Visual System Characteristics. *IEEE Transactions on Circuits and Systems for Video Technology*, vol. 24, no. 8, pp. 1390-1394, 2014.

[45] D. Li and M. Cai. A Video Quality-Estimation Model for Streaming Media Services Based on Human Visual System. *International Conference on Computational Intelligence and Software Engineering*, Wuhan, pp. 1-4, 2009.

[46] J. Rozhon, M. Voznak, F. Rezac, J. Slachta. Utilizing the Neural Networks for Speech Quality Estimation Based on the Network Characteristics. *In SPRINGER : Lecture Notes in Electrical Engineering*, Vol. 371, pp. 99-109, 2016.

[47] Keras. *The Python Deep Learning library.* Dostupné na: https://keras.io/

[48] G. Hackeling. *Mastering Machine Learning with scikit-learn.* Packt Publishing 2014, ISBN 978-1-78398-836-5. Dostupné na: http://pdf.th7.cn/down/files/1603/Mastering%20Machine%20Learning%20with%20scikit-learn.pdf

[49] Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., Salakhutdinov, R. Dropout: A simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*, 15, pp. 1929-1958, 2014.

[50] G. K. D. Singh, Y. Hadjadj-Aoul, and G. Rubino. Quality of experience estimation for adaptive Http/Tcp video streaming using H.264/AVC. *In Proceedings of the 9th Anual IEEE Consumer Communications and Networking Conf. Multimedia and Entertaiment Networking and Services (CCNC '12),* pp. 127–131, 2012.

[51] Z. Cheng, L. Ding, W. Huang, F. Yang and L. Qian,. A unified QoE prediction framework for HEVC encoded video streaming over wireless networks. *IEEE International Symposium on Broadband Multimedia Systems and Broadcasting (BMSB*), Cagliari, pp. 1-6, 2017.

[52] L. Anegekuh, L. Sun, E. Jammeh, I. H. Mkwawa and E. Ifeachor. Content-Based Video Quality Prediction for HEVC Encoded Videos Streamed Over Packet Networks. In *IEEE Transactions on Multimedia*, vol. 17, no. 8, pp. 1323-1334, 2015.

Citované príspevky autora

[frn1] Frnda, J.; Voznak, M.; Rozhon, J.; et al. Prediction Model of QoS for Triple Play Services. *Proceedings of 21st Telecommunications Forum (TELFOR)*, Pages: 733-736, 2013.

[frn2] Frnda, J., Voznak, M., Sevcik, L. Prediction Model of Triple play services for QoS Assessment in IP Based Networks. *Journal of networks*, Vol. 10 Issue: 4 Pages: 232-239, 2015.

[frn3] Frnda, J., Voznak, M., Sevcik, L. Impact of packet loss and delay variation on the quality of real-time video streaming. *Telecommunication Systems*, Vol. 62 Issue: 2, Pages**:** 265-275, 2016.

[frn4] Frnda, J., Sevcik, L., Uhrina, M., Voznak, M. Network degradation effects on different codec types and characteristics of video streaming. *Advances in Electrical and Electronic Engineering*, 12 (4), pp. 377-383, 2014.

[frn5] Frnda, J., Voznak, M., Hlozak, M., et al. Application Tool for Prediction and Implementation of QoS in IP Based Network. *In SPRINGER: Advances in Intelligent Systems and Computing.* Vol: 370, Pages: 143-153, 2015.

[frn6] J. Frnda, J. Rozhon, M. Voznak, J. C-W. Lin, T-Y. Wu. A new tool for quality of multimedia estimation based on network behaviour, *In ELSEVIER Perspectives in Science*, Volume 7, Pages 87-94, 2016.

[uhr1] Uhrina, M., Frnda, J., Sevcik, L., Vaculik, M. Impact of H.264/AVC and H.265/HEVC compression standards on the video quality for 4K resolution. *Advances in Electrical and Electronic Engineering,* 12 (4), pp. 368-376, 2014.

[uhr2] D. Uhrin, P. Partila, J. Frnda, L. Sevcik, M. Voznak, J. C-W. Lin. Design of Emotion Recognition System. *Proceedings of the 2nd Czech-China Scientific Conference 2016*, pp. 53-63, Feb. 2017.

[uhr3] Uhrina, M., Sevcik, L., Frnda, J., Vaculik, M. Impact of H.265 and VP9 Compression Standards on the Video Quality for 4K Resolution. *22nd Telecommunications Forum Telfor*, pp. 905-908, 2014.

[sev1] Sevcik, L., Tomala, K., Frnda, J., Voznak, M. QoS of triple play services in LTE networks. *In SPRINGER: Advances in Intelligent Systems and Computing, AISC,* Volume 298, pp. 25-33, 2014.

Publikačná a projektová činnosť autora

Účasť v projektoch

- Špecifický výskum SGS FEI VŠB TOU projekt SP2013/94 s názvom: *Výskum vplyvu okolitého prostredia na vlastnosti rádiového kanálu a vývoj nových prístupov k hodnoteniu kvality služieb (QoS) multimédií v sieťach 4G.*
- Špecifický výskum SGS FEI VŠB TOU projekt SP2014/72 s názvom: *Výskum atmosférických vplyvov na prenosy v rádiovom kanáli.*
- Špecifický výskum SGS FEI VŠB TOU projekt SP2015/82 s názvom: *Vyťažovanie informácií z komunikačných sietí, a ich modelovanie a simulácia.*
- The European Union's EuropeAid/131928/C/SER/Multi Programme for EaP countries. *5th Workshop – Quality of Service and Customer protection*, ENPI / 2012 / 307-572 Kyiv, Ukraine 2014.
- Projekt na podporu aktivít VŠB-TUO s Čínou za podpory Moravskosliezského kraja s názvom: *Výskum v oblasti riadenia prístupu k službám v konvergovaných sieťach NGN pomocou prediktívnych metód a efektívne vyhľadávanie v databázových štruktúrach.* Absolvované dve mesačné výskumné stáže na Shenzhen Graduate School of Harbin Institute of Technology v rokoch 2015 a 2016.
- HUAWEI – zmluvný výskum (2014-2015): *Predikcia kvality Triple-play služieb v rôznych podmienkach konfigurácie sieťových prvkov Huawei.*

Publikačná činnosť

(excerpované z príslušných databáz k 21.11.2017)

- Web of Knowledge

  – 14 záznamov: 10x konferencia, 4x časopis
- Elsevier Scopus

  – 19 záznamov: 13x konferencia, 6x časopis
- Počet citácií bez autocitácií autora

  – Scopus (47, h-index 4), Web of Knowledge (17, h-index 3)
- Citácie na Google Scholar (99, h-index 6)

Získané ocenenia:

- Ocenenie dekana FEI prof. Ing. Pavel Brandštettera, CSc. v roku 2017 za dosiahnuté výsledky počas doktorského štúdia udelené na workshope WOFEX 2017.
- Best Paper Award za článok Sevcik, L., Voznak, M., Frnda, J. *QoE Prediction Model for Multimedia Services in IP Network Applying Queuing Policy* publikovaný na 17th International Symposium on Performance Evaluation of Computer and Telecommunication Systems (SPECTS), 2014.

Výsledky publikované v časopisoch

- Frnda, J., Voznak, M., Sevcik, L. Prediction Model of Triple play services for QoS Assessment in IP Based Networks. *Journal of networks*, Vol. 10 Issue: 4 Pages: 232-239, 2015. (**ESCI list, WoS/ISI,** SJR 0.259/Q3)
- Frnda, J., Voznak, M., Sevcik, L.:Impact of packet loss and delay variation on the quality of real-time video streaming. *Telecommunication Systems*, Vol. 62 Issue: 2 Pages**:** 265-275, 2016. (**SCIE list, WoS/ISI - IF 1.542/Q3**, SJR 0.566/Q2)
- Lin, J.C.-W., Yang, L., Fournier-Viger, P., Frnda, J., Sevcik, L., Voznak, M. An evolutionary algorithm to mine high-utility itemsets. (2015) *Advances in Electrical and Electronic Engineering,* 13 (4), pp. 392-398. (SJR 0.249/Q3)
- Frnda, J., Sevcik, L., Uhrina, M., Voznak, M. Network degradation effects on different codec types and characteristics of video streaming. (2014) *Advances in Electrical and Electronic Engineering*, 12 (4), pp. 377-383. (SJR 0.249/Q3)
- Uhrina, M., Frnda, J., Sevcik, L., Vaculik, M. Impact of H.264/AVC and H.265/HEVC compression standards on the video quality for 4K resolution. (2014) *Advances in Electrical and Electronic Engineering*, 12 (4), pp. 368-376. (SJR 0.249/Q3)
- Fajkus, M., Nedoma, J., Bednarek, L., Frnda, J., Vasinek, V. Analysis of the applicability of singlemode optical fibers for measurement of deformation with distributed systems BOTDR, (2016) *Advances in Electrical and Electronic Engineering*, 14 (Special Issue), pp. 453-459. (**ESCI list, WoS/ISI**, SJR 0.247/Q3)
- Nedoma, J., Fajkus, M., Bednarek, L., Frnda, J., Zavadil, J., Vasinek, V. Encapsulation of FBG sensor into the PDMS and its effect on spectral and temperature characteristics, (2016) *Advances in Electrical and Electronic Engineering*, 14 (Special Issue), pp. 460-466. (**ESCI list, WoS/ISI**, SJR 0.247/Q3)
- J. Frnda, J. Rozhon, M. Voznak, J.C.-W. Lin, T.-Y. Wu: A New Tool for Quality of Multimedia Estimation Based on Network Behaviour, In ELSEVIER: *Perspectives in Science*,, Vol. 7, March 2016, pp. 87-94.

- J.C.-W. Lin, W. Gan, P. Fournier-Viger, L Yang, Q. Liu, J. Frnda, L. Sevcik, M. Voznak. High Utility-Itemset Mining and Privacy-Preserving Utility Mining, In ELSEVIER: *Perspectives in Science*, Vol. 7, March 2016, pp. 74-80.
- T.-Y. Wu, J.C.-W. Lin, C.-M. Chen, Y.-M. Tseng, J. Frnda, L. Sevcik, M. Voznak,. A brief review of revocable ID-based public key cryptosystem, In ELSEVIER: *Perspectives in Science*, Vol. 7, March 2016, pp. 81-86.

Výsledky publikované na konferenciách

- Frnda, J., Voznak, M., Hlozak, M., et al. Application Tool for Prediction and Implementation of QoS in IP Based Network. In SPRINGER: *Advances in Intelligent Systems and Computing*, Vol: 370, Pages: 143-153, 2015. (**WoS/ISI,** SJR 0.149/Q4)
- Sevcik, L., Uhrin, D., Frnda, J., et al. Encryption for confidentiality of the network and influence of this to the quality of streaming video through network. *Conference on Mobile Multimedia/Image Processing, Security, and Applications, Proceedings of SPIE*, Volume: 9497, Article Number: 94970A, 2015. (**WoS/ISI,** SJR 0.203)
- Voznak, M., Prokes, M., Sevcik, L., Frnda, J.;et al. Vulnerabilities in GSM technology and feasibility of selected attacks. *Conference on Sensors, and Command, Control, Communications, and Intelligence, Proceedings of SPIE*, Volume: 9456, Article Number: 94560T, 2015. (**WoS/ISI**, SJR 0.203)
- Sevcik, L., Voznak, M., Frnda, J. QoE Prediction Model for Multimedia Services in IP Network Applying Queuing Policy. *Proceedings of 17th International Symposium on Performance Evaluation of Computer and Telecommunication Systems (SPECTS) part of SummerSim Multiconference* Location: Monterey, Pages: 593-598, 2014. **(WoS/ISI)**
- Frnda, J., Voznak, M., Rozhon, J.; et al. Prediction Model of QoS for Triple Play Services. *Proceedings of 21st Telecommunications Forum (TELFOR),* Pages: 733-736, 2013. **(WoS/ISI)**
- Sevcik, L., Tomala, K., Frnda, J., Voznak, M. QoS of multimedia services in 4G networks. (2015), *38th International Conference on Telecommunications and Signal Processing, TSP 2015*, art. no. 7296450. **(WoS/ISI)**
- Frnda, J., Voznak, M., Fazio, P., Rozhon, J. Network performance QoS estimation (2015), *38th International Conference on Telecommunications and Signal Processing, TSP 2015,* art. no. 729644. **(WoS/ISI)**
- Sevcik, L., Tomala, K., Frnda, J., Voznak, M. QoS of triple play services in LTE networks. (2014) In SPRINGER: *Advances in Intelligent Systems and Computing, AISC,* Volume 298, 2014, pp. 25-33. (SJR 0.135/Q4)

- Frnda, J., Voznak, M., Sevcik, L. Network performance QoS prediction. (2014) In SPRINGER: *Advances in Intelligent Systems and Computing*, Volume 297, 2014, pp. 165-174. (SJR 0.135/Q4)
- Partila, P., Tovarek, J., Frnda, J., Voznak, M., Penhaker, M., Peterek, T. Emotional impact on neurological characteristics and human speech. (2014) In SPRINGER: *Advances in Intelligent Systems and Computing, AISC*, Volume 298, 2014, pp 527-533. (SJR 0.135/Q4)
- M. Hlozak, J. Frnda, Z. Chmelikova, M. Voznak. Analysis of Cisco and Huawei Routers Cooperation for MPLS Network Design, *22nd Telecommunications Forum Telfor, TELFOR*, 2014, pp. 115-118. **(WoS/ISI)**
- Sevcik, L., Uhrin, D., Frnda, J., Uhrina, M., Chmelikova, Z., Voznak, M. The Impact of Encryption on Video Transmission in IP Network, *22nd Telecommunications Forum TELFOR*, 2014, pp. 123-126. **(WoS/ISI)**
- Uhrina, M., Sevcik, L., Frnda, J., Vaculik, M. Impact of H.265 and VP9 Compression Standards on the Video Quality for 4K Resolution, *22nd Telecommunications Forum TELFOR,* 2014, pp. 905-908. **(WoS/ISI)**
- Uhrin, D., Partila, P., Frnda, J., Sevcik, L., Voznak, M., Lin J. C-W. Design of Emotion Recognition System. In InTech: *Proceedings of the 2nd Czech-China Scientific Conference 2016*, pp. 53-63, 2017.

Príloha A Databáza ohodnotených videosekvencií

Tab. A.1: Výsledky dotazníkového šetrenia.

Názov videosekvencie	SSIM	Priemer (ACR)	Smerodajná odchýlka	Variačný koeficient
Nočná sekvencia FHD 10 Mbit/H264				
CampfireFHD10_0_1	0,971	2,867	0,3428	11,96%
CampfireFHD10_0_2	0,975	2,417	0,4972	20,57%
CampfireFHD10_0_3	0,961	2,200	0,4034	18,34%
CampfireFHD10_0_5	0,945	2,000	0,4510	22,55%
CampfireFHD10_0_75	0,92	1,700	0,4621	27,18%
CampfireFHD10_1	0,904	1,367	0,4860	35,56%
Nočná sekvencia FHD 15 Mbit/H264				
CampfireFHD15_0_1	0,985	3,117	0,3237	10,39%
CampfireFHD15_0_2	0,945	2,517	0,5039	20,02%
CampfireFHD15_0_3	0,937	2,400	0,4940	20,58%
CampfireFHD15_0_5	0,89	1,700	0,5304	31,20%
CampfireFHD15_0_75	0,884	1,600	0,5272	32,95%
CampfireFHD15_1	0,861	1,333	0,4754	35,65%
Nočná sekvencia FHD 5 Mbit/H264				
CampfireFHD5_0_1	0,985	3,117	0,3724	11,95%
CampfireFHD5_0_2	0,981	2,900	0,5431	18,73%
CampfireFHD5_0_3	0,978	2,850	0,5150	18,07%
CampfireFHD5_0_5	0,964	2,083	0,5612	26,94%
CampfireFHD5_0_75	0,959	2,067	0,4825	23,34%
CampfireFHD5_1	0,922	1,683	0,4691	27,87%
Nočná sekvencia HD 10 Mbit/H264				
CampfireHD10_0_1	0,987	4,083	0,5612	13,74%
CampfireHD10_0_2	0,97306	3,533	0,7695	21,78%
CampfireHD10_0_3	0,92717	3,033	0,3171	10,45%
CampfireHD10_0_5	0,90666	2,967	0,5513	18,58%
CampfireHD10_0_75	0,8874	2,217	0,4903	22,12%
CampfireHD10_1	0,88612	1,517	0,5672	37,40%
Nočná sekvencia HD 15 Mbit/H264				
CampfireHD15_0_1	0,94442	4,233	0,5635	13,31%
CampfireHD15_0_2	0,91292	3,600	0,5584	15,51%
CampfireHD15_0_3	0,90442	2,900	0,6561	22,63%
CampfireHD15_0_5	0,86943	2,650	0,4810	18,15%
CampfireHD15_0_75	0,81258	2,467	0,5031	20,40%
CampfireHD15_1	0,76829	2,067	0,3117	15,08%
Nočná sekvencia HD 5 Mbit/H264				
CampfireHD5_0_1	0,997	4,017	0,6241	15,54%
CampfireHD5_0_2	0,995	3,700	0,5615	15,18%
CampfireHD5_0_3	0,99124	3,500	0,5042	14,41%
CampfireHD5_0_5	0,98466	3,150	0,3601	11,43%
CampfireHD5_0_75	0,97447	3,133	0,4305	13,74%
CampfireHD5_1	0,95926	2,883	0,3237	11,23%
Nočná sekvencia UHD 10 Mbit/H264				
CampfireUHD10_0_1	0,99041	3,250	0,4367	13,44%
CampfireUHD10_0_2	0,988123	3,133	0,4305	13,74%
CampfireUHD10_0_3	0,92906	2,950	0,5017	17,01%
CampfireUHD10_0_5	0,90352	2,700	0,5304	19,65%
CampfireUHD10_0_75	0,90034	2,633	0,4860	18,45%
CampfireUHD10_1	0,88437	1,933	0,4459	23,07%
Nočná sekvencia UHD 5 Mbit/H264				
CampfireUHD5_0_1	0,99291	2,617	0,5237	20,02%
CampfireUHD5_0_2	0,99088	2,417	0,5907	24,44%
CampfireUHD5_0_3	0,9821	1,667	0,4754	28,52%
CampfireUHD5_0_5	0,96412	1,450	0,5017	34,60%
CampfireUHD5_0_75	0,96256	1,317	0,4691	35,63%
CampfireUHD5_1	0,94627	1,167	0,3758	32,21%
Nočná sekvencia UHD 15 Mbit/H264				
CampfireUHD15_0_1	0,97171	2,583	0,4972	19,25%
CampfireUHD15_0_2	0,90976	2,183	0,4691	21,49%
CampfireUHD15_0_3	0,89397	2,100	0,5431	25,86%
CampfireUHD15_0_5	0,86306	1,317	0,4691	35,63%
CampfireUHD15_0_75	0,85311	1,250	0,4739	37,91%
CampfireUHD15_1	0,8421	1,100	0,3025	27,50%
Nočná sekvencia FHD 10 Mbit/H265 (HEVC)				
CampfireXFHD10_0_1	0,96886	2,150	0,3601	16,75%
CampfireXFHD10_0_2	0,94618	2,033	0,2582	12,70%
CampfireXFHD10_0_3	0,93739	1,450	0,5017	34,60%
CampfireXFHD10_0_5	0,90655	1,167	0,3758	32,21%
CampfireXFHD10_0_75	0,8869	1,167	0,3758	32,21%
CampfireXFHD10_1	0,85977	1,200	0,4034	33,61%
Nočná sekvencia FHD 15 Mbit/H265 (HEVC)				
CampfireXFHD15_0_1	0,96753	2,117	0,3237	15,29%
CampfireXFHD15_0_2	0,96659	2,067	0,5783	27,98%
CampfireXFHD15_0_3	0,93354	1,467	0,5031	34,30%
CampfireXFHD15_0_5	0,89813	1,200	0,4034	33,61%
CampfireXFHD15_0_75	0,87339	1,200	0,4034	33,61%
CampfireXFHD15_1	0,80862	1,033	0,1810	17,52%

Nočná sekvencia FHD 5 Mbit/H265 (HEVC)				
CampfireXFHD5_0_1	0,99029	2,817	0,3902	13,85%
CampfireXFHD5_0_2	0,97517	2,333	0,4754	20,37%
CampfireXFHD5_0_3	0,9227	1,500	0,5042	33,61%
CampfireXFHD5_0_5	0,91396	1,267	0,4459	35,21%
CampfireXFHD5_0_75	0,90515	1,150	0,4044	35,17%
CampfireXFHD5_1	0,88146	1,100	0,3025	27,50%
Nočná sekvencia HD 10 Mbit/H265 (HEVC)				
CampfireXHD10_0_1	0,96452	3,233	0,4265	13,19%
CampfireXHD10_0_2	0,93799	3,117	0,4544	14,58%
CampfireXHD10_0_3	0,91834	2,700	0,4975	18,42%
CampfireXHD10_0_5	0,87363	1,933	0,4459	23,07%
CampfireXHD10_0_75	0,85253	1,733	0,5783	33,37%
CampfireXHD10_1	0,7718	1,417	0,5302	37,42%
Nočná sekvencia HD 15 Mbit/H265 (HEVC)				
CampfireXHD15_0_1	0,92134	2,533	0,5357	21,15%
CampfireXHD15_0_2	0,91934	2,417	0,5612	23,22%
CampfireXHD15_0_3	0,90156	2,067	0,6342	30,69%
CampfireXHD15_0_5	0,76035	1,450	0,5652	38,98%
CampfireXHD15_0_75	0,75393	1,267	0,4459	35,21%
CampfireXHD15_1	0,73362	1,233	0,4265	34,58%
Nočná sekvencia HD 5 Mbit/H265 (HEVC)				
CampfireXHD5_0_1	0,98671	3,050	0,2867	9,40%
CampfireXHD5_0_2	0,97795	3,100	0,6023	19,43%
CampfireXHD5_0_3	0,89427	2,433	0,6207	25,51%
CampfireXHD5_0_5	0,869	1,800	0,5142	28,57%
CampfireXHD5_0_75	0,83725	1,467	0,5031	34,30%
CampfireXHD5_1	0,80873	1,333	0,4754	35,65%
Nočná sekvencia UHD 10 Mbit/H265 (HEVC)				
CampfireXUHD10_0_1	0,98425	3,200	0,4034	12,61%
CampfireXUHD10_0_2	0,98106	3,000	0,4510	15,03%
CampfireXUHD10_0_3	0,91927	2,583	0,5302	20,52%
CampfireXUHD10_0_5	0,86211	1,833	0,4572	24,94%
CampfireXUHD10_0_75	0,85503	1,700	0,5909	34,76%
CampfireXUHD10_1	0,83583	1,400	0,4940	35,29%
Nočná sekvencia UHD 15 Mbit/H265 (HEVC)				
CampfireXUHD15_0_1	0,9792	2,967	0,3667	12,36%
CampfireXUHD15_0_2	0,9619	2,533	0,5031	19,86%
CampfireXUHD15_0_3	0,95668	2,417	0,4972	20,57%
CampfireXUHD15_0_5	0,89845	2,100	0,3992	19,01%
CampfireXUHD15_0_75	0,82904	1,400	0,4940	35,29%
CampfireXUHD15_1	0,76388	1,067	0,2515	23,58%
Nočná sekvencia UHD 5 Mbit/H265 (HEVC)				
CampfireXUHD5_0_1	0,99147	3,633	0,6097	16,78%
CampfireXUHD5_0_2	0,96611	2,700	0,4621	17,12%
CampfireXUHD5_0_3	0,96294	2,517	0,5365	21,32%
CampfireXUHD5_0_5	0,94174	2,017	0,5964	29,57%
CampfireXUHD5_0_75	0,93215	1,917	0,4972	25,94%
CampfireXUHD5_1	0,85315	1,467	0,5031	34,30%
Statická scéna FHD 10 Mbit/H264				
ConstructionFHD10_0_1	0,98987	3,400	0,5272	15,51%
ConstructionFHD10_0_2	0,98192	3,167	0,3758	11,87%
ConstructionFHD10_0_3	0,95061	2,500	0,5042	20,17%
ConstructionFHD10_0_5	0,89355	2,117	0,3724	17,59%
ConstructionFHD10_0_75	0,85208	1,767	0,4265	24,14%
ConstructionFHD10_1	0,79548	1,133	0,3428	30,25%
Statická scéna FHD 15 Mbit/H264				
ConstructionFHD15_0_1	0,96346	3,000	0,3682	12,27%
ConstructionFHD15_0_2	0,89227	2,200	0,5142	23,37%
ConstructionFHD15_0_3	0,86285	2,383	0,4903	20,57%
ConstructionFHD15_0_5	0,84357	1,483	0,5039	33,97%
ConstructionFHD15_0_75	0,78489	1,733	0,4825	27,83%
ConstructionFHD15_1	0,72026	1,117	0,3237	28,99%
Statická scéna FHD 5 Mbit/H264				
ConstructionFHD5_0_1	0,97823	3,317	0,4691	14,14%
ConstructionFHD5_0_2	0,97394	3,033	0,4860	16,02%
ConstructionFHD5_0_3	0,95164	2,817	0,5365	19,05%
ConstructionFHD5_0_5	0,91166	2,083	0,3340	16,03%
ConstructionFHD5_0_75	0,90655	1,633	0,5513	33,75%
ConstructionFHD5_1	0,89197	1,350	0,4810	35,63%
Statická scéna HD 10 Mbit/H264				
ConstructionHD10_0_1	0,9865	3,800	0,5462	14,37%
ConstructionHD10_0_2	0,97284	3,567	0,6731	18,87%
ConstructionHD10_0_3	0,96181	3,217	0,4155	12,92%
ConstructionHD10_0_5	0,93882	3,100	0,4396	14,18%
ConstructionHD10_0_75	0,90082	2,850	0,4044	14,19%
ConstructionHD10_1	0,89291	2,767	0,4265	15,42%
Statická scéna HD 15 Mbit/H264				
ConstructionHD15_0_1	0,9779	3,783	0,4544	12,01%
ConstructionHD15_0_2	0,9769	3,450	0,5017	14,54%
ConstructionHD15_0_3	0,96151	3,267	0,4459	13,65%
ConstructionHD15_0_5	0,92171	2,617	0,4903	18,74%
ConstructionHD15_0_75	0,91934	2,500	0,5042	20,17%
ConstructionHD15_1	0,88114	2,067	0,5482	26,53%
Statická scéna HD 5 Mbit/H264				
ConstructionHD5_0_1	0,9948	4,667	0,5420	11,61%

ConstructionHD5_0_2	0,98578	4,133	0,5957	14,41%
ConstructionHD5_0_3	0,97956	3,217	0,4155	12,92%
ConstructionHD5_0_5	0,97044	3,133	0,3428	10,94%
ConstructionHD5_0_75	0,96191	2,950	0,2198	7,45%
ConstructionHD5_1	0,92211	2,783	0,4155	14,93%
Statická scéna UHD 10 Mbit/H264				
ConstructionUHD10_0_1	0,99275	4,217	0,5237	12,42%
ConstructionUHD10_0_2	0,99201	4,150	0,3601	8,68%
ConstructionUHD10_0_3	0,96438	3,617	0,5237	14,48%
ConstructionUHD10_0_5	0,94261	3,150	0,4810	15,27%
ConstructionUHD10_0_75	0,92064	2,867	0,5357	18,69%
ConstructionUHD10_1	0,88676	2,650	0,4810	18,15%
Statická scéna UHD 15 Mbit/H264				
ConstructionUHD15_0_1	0,9795	3,633	0,5813	16,00%
ConstructionUHD15_0_2	0,97118	3,400	0,4940	14,53%
ConstructionUHD15_0_3	0,96392	3,300	0,4621	14,00%
ConstructionUHD15_0_5	0,9274	3,117	0,3237	10,39%
ConstructionUHD15_0_75	0,87294	2,567	0,4997	19,47%
ConstructionUHD15_1	0,85721	2,300	0,4975	21,63%
Statická scéna UHD 5 Mbit/H264				
ConstructionUHD5_0_1	0,99509	4,133	0,4305	10,41%
ConstructionUHD5_0_2	0,98883	4,117	0,5849	14,21%
ConstructionUHD5_0_3	0,98372	3,917	0,6712	17,14%
ConstructionUHD5_0_5	0,96539	3,683	0,5672	15,40%
ConstructionUHD5_0_75	0,94933	2,700	0,4621	17,12%
ConstructionUHD5_1	0,9406	2,217	0,4155	18,74%
Statická scéna FHD 10 Mbit/H265 (HEVC)				
ConstructionXFHD10_0_1	0,93862	1,900	0,3992	21,01%
ConstructionXFHD10_0_2	0,92548	1,833	0,3758	20,50%
ConstructionXFHD10_0_3	0,85211	1,500	0,5042	33,61%
ConstructionXFHD10_0_5	0,80773	1,333	0,4754	35,65%
ConstructionXFHD10_0_75	0,75088	1,133	0,3428	30,25%
ConstructionXFHD10_1	0,71025	1,067	0,2515	23,58%
Statická scéna FHD 15 Mbit/H265 (HEVC)				
ConstructionXFHD15_0_1	0,8656	1,750	0,4367	24,95%
ConstructionXFHD15_0_2	0,85076	1,583	0,4972	31,40%
ConstructionXFHD15_0_3	0,77768	1,750	0,4367	24,95%
ConstructionXFHD15_0_5	0,7435	1,200	0,4034	33,61%
ConstructionXFHD15_0_75	0,68228	1,033	0,1810	17,52%
ConstructionXFHD15_1	0,66799	1,050	0,2198	20,93%
Statická scéna FHD 5 Mbit/H265 (HEVC)				
ConstructionXFHD5_0_1	0,96945	2,400	0,4940	20,58%
ConstructionXFHD5_0_2	0,96163	2,200	0,4034	18,34%
ConstructionXFHD5_0_3	0,92416	1,567	0,5326	33,99%
ConstructionXFHD5_0_5	0,89705	1,200	0,4034	33,61%
ConstructionXFHD5_0_75	0,87718	1,250	0,4367	34,93%
ConstructionXFHD5_1	0,8266	1,200	0,4034	33,61%
Statická scéna HD 10 Mbit/H265 (HEVC)				
ConstructionXHD10_0_1	0,96109	2,367	0,5197	21,96%
ConstructionXHD10_0_2	0,91792	2,000	0,5523	27,62%
ConstructionXHD10_0_3	0,87351	1,433	0,4997	34,86%
ConstructionXHD10_0_5	0,82127	1,317	0,4691	35,63%
ConstructionXHD10_0_75	0,77005	1,083	0,2787	25,73%
ConstructionXHD10_1	0,75114	1,017	0,1291	12,70%
Statická scéna HD 15 Mbit/H265 (HEVC)				
ConstructionXHD15_0_1	0,87536	1,283	0,4544	35,41%
ConstructionXHD15_0_2	0,85693	1,200	0,4034	33,61%
ConstructionXHD15_0_3	0,80488	1,217	0,4544	37,35%
ConstructionXHD15_0_5	0,78704	1,250	0,4739	37,91%
ConstructionXHD15_0_75	0,74042	1,000	0,0000	0,00%
ConstructionXHD15_1	0,66205	1,000	0,0000	0,00%
Statická scéna HD 5 Mbit/H265 (HEVC)				
ConstructionXHD5_0_1	0,98539	2,733	0,5783	21,16%
ConstructionXHD5_0_2	0,9648	2,617	0,4903	18,74%
ConstructionXHD5_0_3	0,9494	2,400	0,5880	24,50%
ConstructionXHD5_0_5	0,90058	1,817	0,6507	35,82%
ConstructionXHD5_0_75	0,87314	1,283	0,4544	35,41%
ConstructionXHD5_1	0,80869	1,150	0,4044	35,17%
Statická scéna UHD 10 Mbit/H265 (HEVC)				
ConstructionXUHD10_0_1	0,9853	3,533	0,5357	15,16%
ConstructionXUHD10_0_2	0,98064	3,300	0,4975	15,07%
ConstructionXUHD10_0_3	0,94534	2,467	0,5357	21,72%
ConstructionXUHD10_0_5	0,88519	1,683	0,5672	33,70%
ConstructionXUHD10_0_75	0,84382	1,467	0,5665	38,62%
ConstructionXUHD10_1	0,84109	1,483	0,5039	33,97%
Statická scéna UHD 15 Mbit/H265 (HEVC)				
ConstructionXUHD15_0_1	0,93795	2,467	0,5031	20,40%
ConstructionXUHD15_0_2	0,93641	2,233	0,6207	27,79%
ConstructionXUHD15_0_3	0,91862	2,067	0,6342	30,69%
ConstructionXUHD15_0_5	0,86683	1,567	0,5635	35,97%
ConstructionXUHD15_0_75	0,77712	1,300	0,4621	35,55%
ConstructionXUHD15_1	0,72645	1,000	0,0000	0,00%
Statická scéna UHD 5 Mbit/H265 (HEVC)				
ConstructionXUHD5_0_1	0,9734	3,300	0,4975	15,07%
ConstructionXUHD5_0_2	0,96863	2,767	0,4265	15,42%
ConstructionXUHD5_0_3	0,9533	2,483	0,5039	20,29%

ConstructionXUHD5_0_5	0,92849	2,350	0,6058	25,78%
ConstructionXUHD5_0_75	0,88352	1,500	0,5368	35,79%
ConstructionXUHD5_1	0,84959	1,400	0,4940	35,29%
Športová scéna FHD 10 Mbit/H264				
RunnersFHD10_0_1	0,95379	3,083	0,2787	9,04%
RunnersFHD10_0_2	0,94281	2,900	0,3025	10,43%
RunnersFHD10_0_3	0,8728	2,433	0,4997	20,54%
RunnersFHD10_0_5	0,76276	1,800	0,5462	30,34%
RunnersFHD10_0_75	0,72527	1,167	0,3758	32,21%
RunnersFHD10_1	0,71614	1,017	0,1291	12,70%
Športová scéna FHD 15 Mbit/H264				
RunnersFHD15_0_1	0,95086	2,500	0,5042	20,17%
RunnersFHD15_0_2	0,90291	2,267	0,4459	19,67%
RunnersFHD15_0_3	0,90818	1,567	0,4997	31,90%
RunnersFHD15_0_5	0,8326	1,350	0,4810	35,63%
RunnersFHD15_0_75	0,78911	1,067	0,2515	23,58%
RunnersFHD15_1	0,63422	1,000	0,0000	0,00%
Športová scéna FHD 5 Mbit/H264				
RunnersFHD5_0_1	0,98321	2,833	0,3758	13,26%
RunnersFHD5_0_2	0,97187	2,850	0,3601	12,63%
RunnersFHD5_0_3	0,90168	2,250	0,4367	19,41%
RunnersFHD5_0_5	0,85814	1,867	0,3428	18,36%
RunnersFHD5_0_75	0,83544	1,683	0,4691	27,87%
RunnersFHD5_1	0,81544	1,283	0,4544	35,41%
Športová scéna HD 10 Mbit/H264				
RunnersHD10_0_1	0,97902	3,217	0,4903	15,24%
RunnersHD10_0_2	0,97857	3,133	0,4305	13,74%
RunnersHD10_0_3	0,93132	2,333	0,5420	23,23%
RunnersHD10_0_5	0,87826	2,000	0,4871	24,36%
RunnersHD10_0_75	0,8491	1,667	0,6289	37,73%
RunnersHD10_1	0,78579	1,017	0,1291	12,70%
Športová scéna HD 15 Mbit/H264				
RunnersHD15_0_1	0,97331	3,233	0,4265	13,19%
RunnersHD15_0_2	0,97143	3,267	0,4459	13,65%
RunnersHD15_0_3	0,89359	2,133	0,5357	25,11%
RunnersHD15_0_5	0,86457	1,950	0,3873	19,86%
RunnersHD15_0_75	0,74021	1,433	0,4997	34,86%
RunnersHD15_1	0,71766	1,017	0,1291	12,70%
Športová scéna HD 5 Mbit/H264				
RunnersHD5_0_1	0,97591	3,567	0,5635	15,80%
RunnersHD5_0_2	0,97512	3,217	0,4155	12,92%
RunnersHD5_0_3	0,93523	2,917	0,3814	13,08%
RunnersHD5_0_5	0,89957	2,333	0,6806	29,17%
RunnersHD5_0_75	0,87281	1,767	0,4646	26,30%
RunnersHD5_1	0,74698	1,267	0,4459	35,21%
Športová scéna UHD 10 Mbit/H264				
RunnersUHD10_0_1	0,9736	2,983	0,5039	16,89%
RunnersUHD10_0_2	0,9686	2,733	0,4825	17,65%
RunnersUHD10_0_3	0,94788	2,583	0,4972	19,25%
RunnersUHD10_0_5	0,85574	1,533	0,5665	36,94%
RunnersUHD10_0_75	0,81989	1,300	0,4621	35,55%
RunnersUHD10_1	0,79515	1,000	0,0000	0,00%
Športová scéna UHD 15 Mbit/H264				
RunnersUHD15_0_1	0,93144	2,250	0,5712	25,39%
RunnersUHD15_0_2	0,89557	1,950	0,4288	21,99%
RunnersUHD15_0_3	0,85137	1,567	0,4997	31,90%
RunnersUHD15_0_5	0,7918	1,133	0,3428	30,25%
RunnersUHD15_0_75	0,72856	1,033	0,1810	17,52%
RunnersUHD15_1	0,67486	1,000	0,0000	0,00%
Športová scéna UHD 5 Mbit/H264				
RunnersUHD5_0_1	0,98737	3,233	0,5326	16,47%
RunnersUHD5_0_2	0,98175	3,050	0,3407	11,17%
RunnersUHD5_0_3	0,95773	2,533	0,5357	21,15%
RunnersUHD5_0_5	0,93774	2,067	0,5783	27,98%
RunnersUHD5_0_75	0,91764	1,600	0,4940	30,88%
RunnersUHD5_1	0,86424	1,000	0,0000	0,00%
Športová scéna FHD 10 Mbit/H265(HEVC)				
RunnersXFHD10_0_1	0,90205	1,400	0,4940	35,29%
RunnersXFHD10_0_2	0,87536	1,167	0,3758	32,21%
RunnersXFHD10_0_3	0,83367	1,167	0,3758	32,21%
RunnersXFHD10_0_5	0,7678	1,133	0,3428	30,25%
RunnersXFHD10_0_75	0,66766	1,100	0,3025	27,50%
RunnersXFHD10_1	0,61861	1,050	0,2198	20,93%
Športová scéna FHD 15 Mbit/H265(HEVC)				
RunnersXFHD15_0_1	0,89552	1,633	0,4860	29,75%
RunnersXFHD15_0_2	0,8398	1,500	0,5042	33,61%
RunnersXFHD15_0_3	0,77202	1,333	0,4754	35,65%
RunnersXFHD15_0_5	0,66274	1,400	0,4940	35,29%
RunnersXFHD15_0_75	0,62791	1,017	0,1291	12,70%
RunnersXFHD15_1	0,56032	1,017	0,1291	12,70%
Športová scéna FHD 5 Mbit/H265(HEVC)				
RunnersXFHD5_0_1	0,97891	2,350	0,4810	20,47%
RunnersXFHD5_0_2	0,95646	2,150	0,3601	16,75%
RunnersXFHD5_0_3	0,89561	1,783	0,4155	23,30%
RunnersXFHD5_0_5	0,80395	1,567	0,4997	31,90%
RunnersXFHD5_0_75	0,79966	1,267	0,4459	35,21%

RunnersXFHD5_1	0,74198	1,000	0,0000	0,00%
Športová scéna HD 10 Mbit/H265(HEVC)				
RunnersXHD10_0_1	0,91164	2,033	0,4860	23,90%
RunnersXHD10_0_2	0,86772	1,767	0,5635	31,90%
RunnersXHD10_0_3	0,80478	1,400	0,5272	37,66%
RunnersXHD10_0_5	0,68842	1,100	0,3025	27,50%
RunnersXHD10_0_75	0,64554	1,150	0,3601	31,31%
RunnersXHD10_1	0,57718	1,017	0,1291	12,70%
Športová scéna HD 15 Mbit/H265(HEVC)				
RunnersXHD15_0_1	0,86652	1,817	0,5672	31,22%
RunnersXHD15_0_2	0,79659	1,617	0,5552	34,34%
RunnersXHD15_0_3	0,74373	1,317	0,5039	38,27%
RunnersXHD15_0_5	0,68376	1,183	0,3902	32,98%
RunnersXHD15_0_75	0,62924	1,050	0,2198	20,93%
RunnersXHD15_1	0,53176	1,000	0,0000	0,00%
Športová scéna HD 5 Mbit/H265(HEVC)				
RunnersXHD5_0_1	0,9554	2,400	0,5584	23,27%
RunnersXHD5_0_2	0,9482	2,067	0,4459	21,58%
RunnersXHD5_0_3	0,93956	2,033	0,5813	28,59%
RunnersXHD5_0_5	0,85364	1,767	0,4997	28,29%
RunnersXHD5_0_75	0,75063	1,333	0,4754	35,65%
RunnersXHD5_1	0,65942	1,000	0,0000	0,00%
Športová scéna UHD 10 Mbit/H265(HEVC)				
RunnersXUHD10_0_1	0,95058	2,250	0,4739	21,06%
RunnersXUHD10_0_2	0,92875	1,817	0,4691	25,82%
RunnersXUHD10_0_3	0,89609	1,700	0,4621	27,18%
RunnersXUHD10_0_5	0,841	1,733	0,4459	25,73%
RunnersXUHD10_0_75	0,71219	1,167	0,3758	32,21%
RunnersXUHD10_1	0,63462	1,000	0,0000	0,00%
Športová scéna UHD 15 Mbit/H265(HEVC)				
RunnersXUHD15_0_1	0,90255	1,867	0,5031	26,95%
RunnersXUHD15_0_2	0,85739	1,517	0,5039	33,23%
RunnersXUHD15_0_3	0,83531	1,283	0,4544	35,41%
RunnersXUHD15_0_5	0,73415	1,033	0,1810	17,52%
RunnersXUHD15_0_75	0,67681	1,033	0,1810	17,52%
RunnersXUHD15_1	0,65593	1,000	0,0000	0,00%
Športová scéna UHD 5 Mbit/H265(HEVC)				
RunnersXUHD5_0_1	0,96382	2,483	0,5365	21,60%
RunnersXUHD5_0_2	0,9417	2,117	0,4903	23,16%
RunnersXUHD5_0_3	0,93025	2,067	0,5164	24,99%
RunnersXUHD5_0_5	0,88825	1,833	0,5262	28,70%
RunnersXUHD5_0_75	0,85816	1,367	0,4860	35,56%
RunnersXUHD5_1	0,84527	1,000	0,0000	0,00%
Dynamická scéna FHD 10 Mbit/H264				
WoodFHD10_0_1	0,95553	3,667	0,7516	20,50%
WoodFHD10_0_2	0,91183	3,117	0,3237	10,39%
WoodFHD10_0_3	0,85983	2,783	0,5237	18,82%
WoodFHD10_0_5	0,76276	1,450	0,5017	34,60%
WoodFHD10_0_75	0,72527	1,300	0,4621	35,55%
WoodFHD10_1	0,71614	1,150	0,3601	31,31%
Dynamická scéna FHD 15 Mbit/H264				
WoodFHD15_0_1	0,94954	2,917	0,4618	15,83%
WoodFHD15_0_2	0,83585	2,267	0,4459	19,67%
WoodFHD15_0_3	0,77539	1,950	0,5344	27,41%
WoodFHD15_0_5	0,76105	1,667	0,4754	28,52%
WoodFHD15_0_75	0,73508	1,033	0,1810	17,52%
WoodFHD15_1	0,69923	1,033	0,1810	17,52%
Dynamická scéna FHD 5 Mbit/H264				
WoodFHD5_0_1	0,97979	2,350	0,4810	20,47%
WoodFHD5_0_2	0,94281	1,917	0,4235	22,10%
WoodFHD5_0_3	0,8928	1,567	0,4997	31,90%
WoodFHD5_0_5	0,78046	1,317	0,4691	35,63%
WoodFHD5_0_75	0,76148	1,133	0,3428	30,25%
WoodFHD5_1	0,72112	1,033	0,1810	17,52%
Dynamická scéna HD 10 Mbit/H264				
WoodHD10_0_1	0,93452	3,783	0,6132	16,21%
WoodHD10_0_2	0,89953	3,583	0,4972	13,87%
WoodHD10_0_3	0,75062	3,017	0,5039	16,71%
WoodHD10_0_5	0,67543	2,983	0,4691	15,72%
WoodHD10_0_75	0,61899	2,300	0,6457	28,07%
WoodHD10_1	0,60199	2,150	0,4444	20,67%
Dynamická scéna HD 15 Mbit/H264				
WoodHD15_0_1	0,92667	3,583	0,4972	13,87%
WoodHD15_0_2	0,88735	3,233	0,4265	13,19%
WoodHD15_0_3	0,74334	2,867	0,3891	13,57%
WoodHD15_0_5	0,71401	2,550	0,5344	20,96%
WoodHD15_0_75	0,60417	2,067	0,5164	24,99%
WoodHD15_1	0,59096	1,967	0,4860	24,71%
Dynamická scéna HD 5 Mbit/H264				
WoodHD5_0_1	0,9463	3,750	0,6001	16,00%
WoodHD5_0_2	0,9416	3,733	0,4459	11,95%
WoodHD5_0_3	0,81954	2,783	0,4155	14,93%
WoodHD5_0_5	0,73221	2,833	0,3758	13,26%
WoodHD5_0_75	0,62468	2,583	0,4972	19,25%
WoodHD5_1	0,61991	2,300	0,5304	23,06%
Dynamická scéna UHD 10 Mbit/H264				

WoodUHD10_0_1	0,92561	3,200	0,4034	12,61%
WoodUHD10_0_2	0,91861	3,233	0,5635	17,43%
WoodUHD10_0_3	0,85548	2,067	0,6856	33,17%
WoodUHD10_0_5	0,77068	1,467	0,5031	34,30%
WoodUHD10_0_75	0,71785	1,267	0,4459	35,21%
WoodUHD10_1	0,66128	1,000	0,0000	0,00%
Dynamická scéna UHD 15 Mbit/H264				
WoodUHD15_0_1	0,91146	2,417	0,4972	20,57%
WoodUHD15_0_2	0,9065	2,367	0,4860	20,53%
WoodUHD15_0_3	0,84322	1,900	0,6023	31,70%
WoodUHD15_0_5	0,7487	1,467	0,5357	36,53%
WoodUHD15_0_75	0,59582	1,233	0,4265	34,58%
WoodUHD15_1	0,5602	1,050	0,2198	20,93%
Dynamická scéna UHD 5 Mbit/H264				
WoodUHD5_0_1	0,96528	3,100	0,3025	9,76%
WoodUHD5_0_2	0,95121	2,867	0,3428	11,96%
WoodUHD5_0_3	0,92114	2,417	0,5612	23,22%
WoodUHD5_0_5	0,89833	1,917	0,5907	30,82%
WoodUHD5_0_75	0,85892	1,650	0,5469	33,15%
WoodUHD5_1	0,81596	1,583	0,4972	31,40%
Dynamická scéna FHD 10 Mbit/H265 (HEVC)				
WoodXFHD10_0_1	0,91224	1,933	0,4062	21,01%
WoodXFHD10_0_2	0,86164	1,767	0,4265	24,14%
WoodXFHD10_0_3	0,83038	1,467	0,5031	34,30%
WoodXFHD10_0_5	0,74212	1,200	0,4034	33,61%
WoodXFHD10_0_75	0,64277	1,133	0,3428	30,25%
WoodXFHD10_1	0,58414	1,083	0,2787	25,73%
Dynamická scéna FHD 15 Mbit/H265 (HEVC)				
WoodXFHD15_0_1	0,85347	1,817	0,4691	25,82%
WoodXFHD15_0_2	0,84003	1,867	0,4682	25,08%
WoodXFHD15_0_3	0,77818	1,500	0,5042	33,61%
WoodXFHD15_0_5	0,63769	1,167	0,3758	32,21%
WoodXFHD15_0_75	0,58651	1,067	0,2515	23,58%
WoodXFHD15_1	0,52423	1,000	0,0000	0,00%
Dynamická scéna FHD 5 Mbit/H265 (HEVC)				
WoodXFHD5_0_1	0,92978	2,633	0,4860	18,45%
WoodXFHD5_0_2	0,88117	2,333	0,4754	20,37%
WoodXFHD5_0_3	0,88579	1,833	0,3758	20,50%
WoodXFHD5_0_5	0,81189	1,550	0,5017	32,37%
WoodXFHD5_0_75	0,70928	1,133	0,3428	30,25%
WoodXFHD5_1	0,63819	1,067	0,2515	23,58%
Dynamická scéna HD 10 Mbit/H265 (HEVC)				
WoodXHD10_0_1	0,92668	2,083	0,4235	20,33%
WoodXHD10_0_2	0,78855	2,033	0,4860	23,90%
WoodXHD10_0_3	0,70032	1,667	0,6289	37,73%
WoodXHD10_0_5	0,62459	1,500	0,5042	33,61%
WoodXHD10_0_75	0,39493	1,050	0,2198	20,93%
WoodXHD10_1	0,33301	1,050	0,2198	20,93%
Dynamická scéna HD 15 Mbit/H265 (HEVC)				
WoodXHD15_0_1	0,90735	2,283	0,5849	25,62%
WoodXHD15_0_2	0,8055	2,067	0,5164	24,99%
WoodXHD15_0_3	0,56544	1,367	0,4860	35,56%
WoodXHD15_0_5	0,4768	1,233	0,4265	34,58%
WoodXHD15_0_75	0,37591	1,067	0,2515	23,58%
WoodXHD15_1	0,31447	1,000	0,0000	0,00%
Dynamická scéna HD 5 Mbit/H265 (HEVC)				
WoodXHD5_0_1	0,93915	2,367	0,5813	24,56%
WoodXHD5_0_2	0,92906	2,333	0,5420	23,23%
WoodXHD5_0_3	0,85686	2,250	0,5407	24,03%
WoodXHD5_0_5	0,73221	1,583	0,5302	33,48%
WoodXHD5_0_75	0,55534	1,267	0,4459	35,21%
WoodXHD5_1	0,34578	1,000	0,0000	0,00%
Dynamická scéna UHD 10 Mbit/H265 (HEVC)				
WoodXUHD10_0_1	0,89777	2,467	0,5031	20,40%
WoodXUHD10_0_2	0,89419	2,450	0,5344	21,81%
WoodXUHD10_0_3	0,84844	1,900	0,6298	33,15%
WoodXUHD10_0_5	0,75182	1,467	0,5031	34,30%
WoodXUHD10_0_75	0,62396	1,050	0,2198	20,93%
WoodXUHD10_1	0,59166	1,033	0,1810	17,52%
Dynamická scéna UHD 15 Mbit/H265 (HEVC)				
WoodXUHD15_0_1	0,83729	2,450	0,5017	20,48%
WoodXUHD15_0_2	0,76016	2,217	0,4544	20,50%
WoodXUHD15_0_3	0,71494	1,800	0,4434	24,63%
WoodXUHD15_0_5	0,47204	1,200	0,4034	33,61%
WoodXUHD15_0_75	0,42121	1,033	0,1810	17,52%
WoodXUHD15_1	0,36162	1,033	0,1810	17,52%
Dynamická scéna UHD 5 Mbit/H265 (HEVC)				
WoodXUHD5_0_1	0,91172	2,817	0,5039	17,89%
WoodXUHD5_0_2	0,90998	2,467	0,5031	20,40%
WoodXUHD5_0_3	0,86665	2,367	0,5513	23,30%
WoodXUHD5_0_5	0,72004	2,050	0,3873	18,89%
WoodXUHD5_0_75	0,65369	1,667	0,5420	32,52%
WoodXUHD5_1	0,63888	1,100	0,3025	27,50%

Príloha B Experimentálne overenie dát

B.1 Export výsledkov predikcie pre jednotlivé topológie neurónovej siete

```
-----------------------------------------------------------------------------------------------
Čas   |  RMSE  | < 10 % relatívna chyba | Korelácia | Topológia |
-----------------------------------------------------------------------------------------------
09:20 AM,0.3050322626,0.6361252885,"(0.8614753704122225)","[10, 7, 4]"
09:21 AM,0.2801110112,0.6619025518,"(0.90908667579031769)","[10, 8, 6, 4, 2]"
09:20 AM,0.2763677199,0.6561368926,"(0.92115578563377468)","[10, 8, 5, 3]"
09:21 AM,0.2737792215,0.6624477953,"(0.92370339782620039)","[10, 9, 7, 5, 4, 2]"
09:21 AM,0.282923115,0.6626450119,"(0.9378820933541411)","[10, 9, 8, 6, 5, 3, 2]"
09:24 AM,0.2601170531,0.6754350371,"(0.96547036678669673)","[21, 16, 11, 6]"
09:27 AM,0.2772912618,0.6723607892,"(0.96899698266429724)","[21, 19, 17, 15, 13, 11, 9, 7, 5,
3]"
09:22 AM,0.2778606342,0.6664443156,"(0.9695065609291923)","[10, 9, 8, 7, 5, 4, 3, 2]"
09:23 AM,0.2513253908,0.6784628785,"(0.96960862899720623)","[21, 14, 7]"
09:25 AM,0.2587328763,0.6721693727,"(0.97052897654042403)","[21, 18, 15, 12, 9, 6, 3]"
09:27 AM,0.2688593388,0.6673143849,"(0.97222764745613299)","[21, 19, 17, 14, 12, 10, 7, 5, 3]"
09:25 AM,0.2457371203,0.6833410683,"(0.97574276062656229)","[21, 18, 14, 11, 7, 4]"
09:28 AM,0.2431315584,0.6859222724,"(0.97622692789569299)","[32, 22, 11]"
09:26 AM,0.2628696082,0.6723781921,"(0.97810691417109674)","[21, 19, 16, 14, 11, 8, 6, 3]"
09:24 AM,0.2395099654,0.6898491878,"(0.97888572904221161)","[21, 17, 13, 9, 5]"
09:29 AM,0.2376593677,0.6906960563,"(0.98167507664936415)","[32, 24, 16, 8]"
09:35 AM,0.2338700471,0.6929118328,"(0.98189041951053257)","[43, 29, 15]"
09:32 AM,0.2488559771,0.6830626448,"(0.98247683540113007)","[32, 28, 24, 20, 16, 12, 8, 4]"
09:44 AM,0.2357767472,0.6911600934,"(0.98351089913799028)","[54, 36, 18]"
09:30 AM,0.2361371309,0.6907018574,"(0.98359310235459352)","[32, 26, 20, 13, 7]"
09:31 AM,0.2397244422,0.6933584697,"(0.98406332675314889)","[32, 28, 23, 19, 14, 10, 5]"
09:55 AM,0.2329984155,0.6928538281,"(0.98411936398066324)","[65, 44, 22]"
09:36 AM,0.2326349562,0.6957250573,"(0.98482713232092178)","[43, 33, 22, 11]"
09:45 AM,0.228376426,0.6978364279,"(0.98572058375905958)","[54, 41, 27, 14]"
09:40 AM,0.2406094627,0.6939860793,"(0.98660413867009722)","[43, 38, 33, 27, 22, 17, 11, 6]"
10:07 AM,0.2290207258,0.6990197239,"(0.9868680319111619)","[76, 51, 26]"
10:01 AM,0.2295542837,0.7028712294,"(0.98704035788048805)","[65, 57, 49, 41, 33, 25, 17, 9]"
09:30 AM,0.2300828397,0.6983062635,"(0.9872038323072011)","[32, 27, 22, 16, 11, 6]"
09:39 AM,0.229680536,0.7002784199,"(0.98769840379639984)","[43, 37, 31, 25, 19, 13, 7]"
09:46 AM,0.2268998922,0.6996577701,"(0.98777305551648098)","[54, 44, 33, 22, 11]"
09:37 AM,0.2253501275,0.700887471,"(0.98811185633867016)","[43, 35, 26, 18, 9]"
12:07 PM,0.2224261972,0.7057656588,"(0.98848411725001495)","[142, 95, 48]"
11:17 AM,0.2211550091,0.7071461697,"(0.98860198503968078)","[120, 80, 40]"
10:38 AM,0.2243743878,0.704077727,"(0.98870765336781286)","[98, 66, 33]"
10:21 AM,0.2271195363,0.7001798143,"(0.98888103937580218)","[87, 58, 29]"
10:39 AM,0.2196610025,0.7093561476,"(0.98892222133977503)","[98, 74, 49, 25]"
10:05 AM,0.2351228673,0.699778421,"(0.98915241016878763)","[65, 59, 52, 46, 39, 33, 26, 20, 13,
7]"
10:40 AM,0.2155100101,0.7323394417,(0.98920697782471346)","[98, 79, 59, 40, 20]"
09:38 AM,0.222985371,0.7051566122,"(0.98949622434214579)","[43, 36, 29, 22, 15, 8]"
09:59 AM,0.2301142479,0.7014443133,"(0.98956073701747937)","[65, 56, 47, 38, 28, 19, 10]"
09:50 AM,0.2339046595,0.6995243622,"(0.98961549252803915)","[54, 48, 41, 34, 27, 21, 14, 7]"
11:40 AM,0.2217183288,0.708387471,"(0.98972770350255534)","[131, 88, 44]"
09:56 AM,0.225391035,0.7031670504,"(0.98980219129244285)","[65, 49, 33, 17]"
10:17 AM,0.2315983152,0.7017285372,"(0.98984264898943441)","[76, 68, 60, 51, 43, 34, 26, 17,
9]"
10:09 AM,0.2214841147,0.708352666,"(0.99010338806867326)","[76, 61, 46, 31, 16]"
05:44 PM,0.2182982614,0.7120707653,"(0.99031437796504951)","[230, 154, 77]"
10:03 AM,0.2316262542,0.7006032493,"(0.99039283797276179)","[65, 58, 51, 44, 37, 29, 22, 15,
8]"
10:56 AM,0.2240818446,0.7048143833,"(0.99072308323921476)","[109, 73, 37]"
10:50 AM,0.2294377642,0.7035382829,"(0.99081398143882937)","[98, 88, 77, 66, 55, 44, 33, 22,
11]"
```

```
09:57 AM,0.2224893326,0.705261018,"(0.990944614995523)","[65, 52, 39, 26, 13]"
09:58 AM,0.2210119466,0.7068503448,"(0.99096482388200291)","[65, 55, 44, 33, 22, 11]"
09:48 AM,0.2289188743,0.7033120629,"(0.99096536648977274)","[54, 47, 39, 31, 24, 16, 8]"
10:59 AM,0.2171148435,0.7118503475,"(0.99115834375921841)","[109, 88, 66, 44, 22]"
11:07 AM,0.2237976506,0.7080220395,"(0.99118530842610297)","[109, 96, 82, 69, 55, 41, 28, 14]"
09:47 AM,0.2208117702,0.7091299301,"(0.99125703202076321)","[54, 45, 36, 27, 18, 9]"
01:11 PM,0.2203674933,0.7099129919,"(0.99149953955801395)","[164, 110, 55]"
12:34 PM,0.225928562,0.7074826002,"(0.99155953241009864)","[142, 128, 114, 100, 86, 71, 57, 43,
29, 15]"
02:27 PM,0.2199936456,0.7107540608,"(0.99174304905996069)","[186, 124, 62]"
10:14 AM,0.229995003,0.7038051065,"(0.99177536999488203)","[76, 67, 57, 48, 38, 29, 19, 10]"
04:59 PM,0.2362129723,0.7056554547,"(0.99177548562985651)","[142, 119, 95, 71, 48, 24]"
01:50 PM,0.215130559,0.7154060296,"(0.99181453108671624)","[175, 132, 88, 44]"
10:30 AM,0.2272557307,0.7044025508,"(0.99184885389974153)","[87, 77, 66, 55, 44, 33, 22, 11]"
10:08 AM,0.2208822245,0.707505798,"(0.991933059233157)","[76, 57, 38, 19]"
10:57 AM,0.2199458337,0.7102378181,"(0.99200108883909188)","[109, 82, 55, 28]"
10:24 AM,0.2194829278,0.7096287717,"(0.99203463416134918)","[87, 70, 53, 35, 18]"
10:35 AM,0.2296810139,0.7020243636,"(0.99209687284076642)","[87, 79, 70, 61, 53, 44, 35, 27,
18, 9]"
10:12 AM,0.2284747139,0.704257541,"(0.9921070548374783)","[76, 66, 55, 44, 33, 22, 11]"
11:14 AM,0.226576756,0.7057540599,(0.99212120085877331)","[109, 99, 88, 77, 66, 55, 44, 33, 22,
11]"
04:49 PM,0.2203363958,0.7073259856,"(0.99214551540712381)","[219, 146, 73]"
11:18 AM,0.2190228263,0.7120707657,"(0.99216409584896115)","[120, 90, 60, 30]"
05:20 PM,0.2384083397,0.7037470974,"(0.99219655108522131)","[142, 119, 95, 71, 48, 24]"
10:47 AM,0.2255197295,0.7060730851,"(0.99231948376875678)","[98, 86, 74, 62, 49, 37, 25, 13]"
10:22 AM,0.2225962144,0.7070417608,"(0.99233031945876238)","[87, 66, 44, 22]"
03:13 PM,0.2151703383,0.7195475645,"(0.99237823357010024)","[197, 148, 99, 50]"
11:20 AM,0.2157222833,0.7141009279,"(0.99237901383237914)","[120, 96, 72, 48, 24]"
12:38 PM,0.2208127579,0.7083468681,"(0.99244360955643485)","[153, 102, 51]"
11:04 AM,0.2204196185,0.7110382809,"(0.9924492521513909)","[109, 94, 78, 63, 47, 32, 16]"
04:28 PM,0.2306535322,0.7091450093,"(0.99272570105868163)","[142, 119, 95, 71, 48, 24]"
10:11 AM,0.2170498672,0.712500002,"(0.99291432218435061)","[76, 64, 51, 38, 26, 13]"
11:42 AM,0.2169250165,0.7118909518,"(0.99308725691439459)","[131, 99, 66, 33]"
10:27 AM,0.2244157345,0.7070591646,"(0.99316474422477996)","[87, 75, 63, 50, 38, 25, 13]"
12:09 PM,0.2181200175,0.7099477959,"(0.99328305701266006)","[142, 107, 71, 36]"
01:47 PM,0.2187231958,0.7104930395,"(0.99335401758769126)","[175, 117, 59]"
11:01 AM,0.2178319707,0.7127726214,"(0.9936565738512404)","[109, 91, 73, 55, 37, 19]"
12:40 PM,0.2180451481,0.7107308571,"(0.993692156187584)","[153, 115, 77, 39]"
10:45 AM,0.2241150641,0.7093619472,"(0.99382620206697014)","[98, 84, 70, 56, 42, 28, 14]"
03:56 PM,0.2176560628,0.7118155463,"(0.99392248115799531)","[208, 139, 70]"
12:12 PM,0.2154194941,0.7141357307,"(0.99405447207454767)","[142, 114, 86, 57, 29]"
10:25 AM,0.2163355514,0.7142401404,"(0.99414447214786217)","[87, 73, 58, 44, 29, 15]"
03:10 PM,0.2199065049,0.7107772615,"(0.99418666070315642)","[197, 132, 66]"
01:13 PM,0.2155832567,0.7180870055,"(0.9941983435664038)","[164, 123, 82, 41]"
01:16 PM,0.2148782147,0.7152842231,"(0.994199737561279)","[164, 132, 99, 66, 33]"
11:59 AM,0.2222995656,0.7098201854,"(0.99422815455979474)","[131, 117, 102, 88, 73, 59, 44, 30,
15]"
02:02 PM,0.2186061745,0.7117285365,"(0.99425839064686639)","[175, 150, 125, 100, 75, 50, 25]"
01:53 PM,0.2142162872,0.7215719267,"(0.99437829584093973)","[175, 140, 105, 70, 35]"
05:10 PM,0.2153857102,0.7155452444,"(0.99446614317095583)","[219, 188, 157, 126, 94, 63, 32]"
02:22 PM,0.2224505597,0.7108758683,"(0.99450322717650963)","[175, 158, 140, 123, 105, 88, 70,
53, 35, 18]"
01:29 PM,0.2208093192,0.710806264,0"(0.99450547748412355)","[164, 144, 123, 103, 82, 62, 41,
21]"
11:54 AM,0.2214728467,0.7108294676,"(0.99452582172600068)","[131, 115, 99, 82, 66, 50, 33, 17]"
11:22 AM,0.2158703568,0.7153654265,"(0.99452946389811014)","[120, 100, 80, 60, 40, 20]"
12:19 PM,0.2181460782,0.7136948956,"(0.99472288616208082)","[142, 122, 102, 82, 61, 41, 21]"
05:28 PM,0.2179289006,0.7127842218,"(0.99478472765928838)","[219, 195, 171, 146, 122, 98, 73,
49, 25]"
04:13 PM,0.2159921855,0.7152610225,"(0.99479085786287191)","[142, 119, 95, 71, 48, 24]"
12:23 PM,0.222008299,0.7097679794,0"(0.99481111853023085)","[142, 125, 107, 89, 71, 54, 36, 18]"
05:47 PM,0.2149110861,0.7154466334,"(0.99491451147326482)","[230, 173, 115, 58]"
12:43 PM,0.2151982456,0.7146287724,"(0.99493612573105006)","[153, 123, 92, 62, 31]"
```

```
04:00 PM,0.2152264628,0.7143271452,"(0.99494818326048418)","[208, 156, 104, 52]"
10:42 AM,0.2160621578,0.7136194893,"(0.99497147351639548)","[98, 82, 66, 49, 33, 17]"
11:44 AM,0.2154542287,0.7151798126,"(0.99497199682199888)","[131, 105, 79, 53, 27]"
02:08 PM,0.2187290536,0.7121867762,"(0.99505347710816761)","[175, 154, 132, 110, 88, 66, 44,
22]"
02:49 PM,0.2184700479,0.7119315531,"(0.99515387325701499)","[186, 163, 140, 117, 93, 70, 47,
24]"
11:29 AM,0.2199799934,0.7117343382,"(0.99519858828331276)","[120, 105, 90, 75, 60, 45, 30, 15]"
02:29 PM,0.2149428888,0.7142169375,"(0.9952158617789596)","[186, 140, 93, 47]"
12:55 PM,0.219898023,0.7115371246,"(0.9952884737168064)","[153, 134, 115, 96, 77, 58, 39, 20]"
04:53 PM,0.2150039043,0.7152784218,"(0.99532229828038488)","[219, 165, 110, 55]"
11:25 AM,0.2198298085,0.7105916471,"(0.99538014918830486)","[120, 103, 86, 69, 52, 35, 18]"
01:20 PM,0.2143742406,0.7164095128,"(0.99544353410983233)","[164, 137, 110, 82, 55, 28]"
03:18 PM,0.2142054679,0.7199547557,"(0.99560625008933301)","[197, 158, 119, 79, 40]"
04:04 PM,0.2134392631,0.7180858461,"(0.99561062687949398)","[208, 167, 125, 84, 42]"
03:43 PM,0.2196098481,0.7124593945,"(0.99566066019709176)","[197, 176, 154, 132, 110, 88, 66,
44, 22]"
11:50 AM,0.2181893578,0.7139907187,"(0.99566512952052089)","[131, 113, 94, 75, 57, 38, 19]"
04:44 PM,0.2178897452,0.7122911831,"(0.99567576817843384)","[208, 188, 167, 146, 125, 104, 84,
63, 42, 21]"
12:46 PM,0.2141267133,0.7159744771,"(0.99568877817159107)","[153, 128, 102, 77, 51, 26]"
01:24 PM,0.2177624751,0.7123143848,"(0.99569210099698002)","[164, 141, 118, 94, 71, 47, 24]"
03:35 PM,0.2176484589,0.7137238986,"(0.9956938703801349)","[197, 173, 148, 124, 99, 74, 50, 25]"
03:28 PM,0.2157698051,0.7151044087,"(0.99578042101788267)","[197, 169, 141, 113, 85, 57, 29]"
02:57 PM,0.2181872582,0.7128248248,"(0.99582224377446971)","[186, 166, 145, 124, 104, 83, 62,
42, 21]"
11:47 AM,0.2131561702,0.7163225035,"(0.99584760150231888)","[131, 110, 88, 66, 44, 22]"
12:15 PM,0.2135523516,0.7162587019,"(0.99589635728376391)","[142, 119, 95, 71, 48, 24]"
05:04 PM,0.21167955,0.7174361943,"(0.995966615085913)","[219, 183, 146, 110, 73, 37]"
02:33 PM,0.214583098,0.7155568431,"(0.99614332820701423)","[186, 149, 112, 75, 38]"
12:50 PM,0.2170488302,0.7131090499,"(0.99622071716795124)","[153, 132, 110, 88, 66, 44, 22]"
05:52 PM,0.2139675398,0.7172273756,"(0.9962637809896524)","[230, 184, 138, 92, 46]"
02:38 PM,0.2120316431,0.7183120657,"(0.99635058210835892)","[186, 155, 124, 93, 62, 31]"
03:51 PM,0.2178138028,0.712848026,"(0.9963985460018886)","[197, 178, 158, 138, 119, 99, 79, 60,
40, 20]"
04:59 PM,0.2129634708,0.7172157739,"(0.99649075960004074)","[219, 176, 132, 88, 44]"
04:11 PM,0.2122657444,0.7177204168,"(0.9965044588663059)","[208, 174, 139, 104, 70, 35]"
02:43 PM,0.2164724154,0.714762181,"(0.99652066419612118)","[186, 160, 133, 107, 80, 54, 27]"
03:23 PM,0.2113940942,0.7185614847,"(0.99662899331737531)","[197, 165, 132, 99, 66, 33]"
04:27 PM,0.2173259372,0.7127958233,"(0.99666658221118587)","[208, 182, 156, 130, 104, 78, 52,
26]"
04:18 PM,0.2157057518,0.7142691416,"(0.99673210710521321)","[208, 179, 149, 119, 90, 60, 30]"
01:57 PM,0.2121795619,0.7185962865,"(0.99685882974075812)","[175, 146, 117, 88, 59, 30]"
```

B.2 Užívateľské rozhranie predikčného modelu

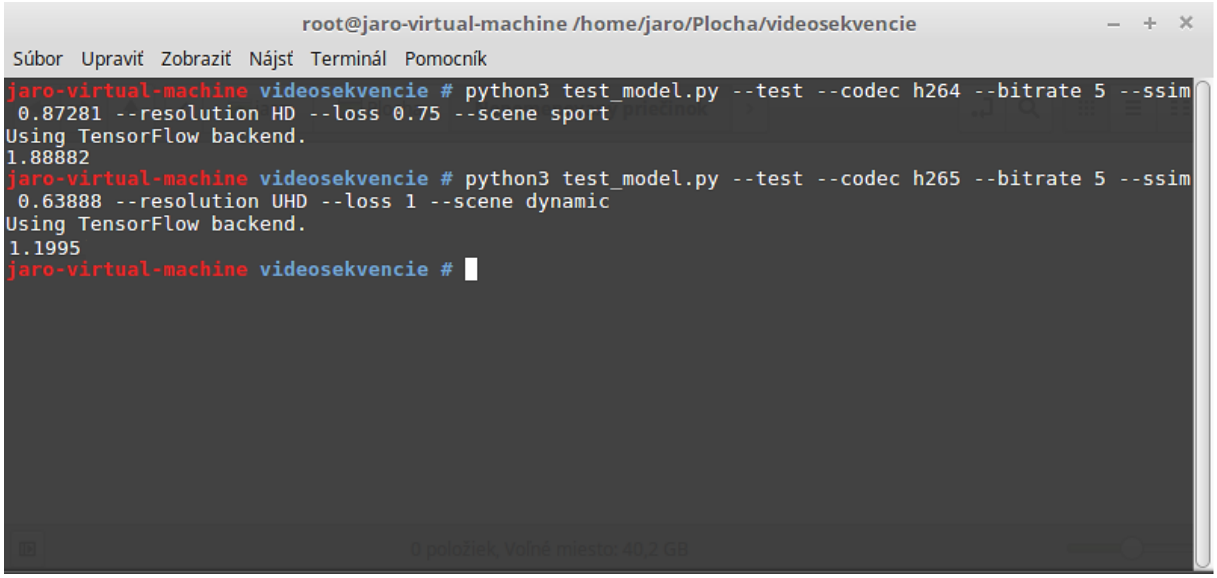

Obr. B.1: Výsledok predikcie v závislosti na zadaných vstupoch.

Príloha C Obsah priloženej SD karty

Prehľad adresárov a ich obsah:

- *Databáza videosekvencií* – obsahuje všetky použité testovacie videosekvencie
- *BPNN* – obsahuje dáta, zdrojové kódy a výsledky predikčného modelu neurónovej siete
  - *Testovanie ACR* – kompletný prepis dotazníkového šetrenia metódou ACR, štatistické vyhodnotenie
  - *correlations_pearson_rmse* – výsledky pre jednotlivé otestované topológie a ich nastavenie
  - *training_time* – trénovací čas jednotlivých topológií neurónovej siete
  - *weights_new* – konfigurácie topológií neurónovej siete
  - *working_data_clean* – pretransformované dáta z dotazníkov pre potreby tvorby a verifikácie navrhnutého modelu neurónovej siete
  - *NN.py* – trénovanie neurónovej siete
  - *verify.py* – vyhodnotenie miery presnosti predikcie
  - *test_model.py* – kalkulácia predikcie subjektívnej kvality videa pomocou navrhnutého modelu
- *Dizertačná práca* – elektronická verzia dizertačnej práce