



HAL
open science

Compensation de la latence Glass-to-Glass via extrapolation du flux vidéo : faisabilité et cas d'usage

Hind Kanj, Anthony Trioux, Marco Cagnazzo, François-Xavier Coudoux,
Patrick Corlay, Michel Kieffer

► To cite this version:

Hind Kanj, Anthony Trioux, Marco Cagnazzo, François-Xavier Coudoux, Patrick Corlay, et al.. Compensation de la latence Glass-to-Glass via extrapolation du flux vidéo : faisabilité et cas d'usage. GRETSI 2023 - XXIXème Colloque Francophone de Traitement du Signal et des Images, Aug 2023, Grenoble, France. pp.133-136. hal-04371281

HAL Id: hal-04371281

<https://centralesupelec.hal.science/hal-04371281>

Submitted on 3 Jan 2024

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

Compensation de la latence Glass-to-Glass via extrapolation du flux vidéo : faisabilité et cas d'usage

Hind KANJ¹ Anthony TRIOUX¹ Marco CAGNAZZO² Francois-Xavier COUDOUX¹ Patrick CORLAY¹ Michel KIEFFER³

¹UMR 8520 - IEMN, DOAE, Univ. Polytechnique Hauts-de-France, CNRS, Univ. Lille, YNCREA, Centrale Lille, France

²LTCI, Télécom ParisTech, Institut Polytechnique de Paris, F-91123 Palaiseau Cedex, & DEI, University of Padova, Italy

³Univ. Paris-Saclay, CNRS, CentraleSupélec, L2S, F-91192 Gif-sur-Yvette

Résumé – Les applications telles que la télé-conduite et la téléprésence reposant sur des services vidéo doivent garantir une interaction en temps réel avec une qualité d'expérience satisfaisante. La réduction du délai G2G (Glass-to-Glass), c'est à dire le délai entre l'acquisition et l'affichage d'une image sur un terminal distant, est essentielle pour ces applications. L'extrapolation d'images vidéo basée sur l'apprentissage profond a récemment été considérée pour réduire le délai G2G. Dans cet article, nous examinons l'efficacité de cette technique pour réduire la latence globale dans un système de transmission vidéo point à point. L'objectif est de déterminer le domaine de fonctionnement, les avantages et les inconvénients de cette approche. Pour cela, nous comparons le compromis latence-qualité pour deux méthodes de compensation de latence : la réduction du débit de codage et l'extrapolation. Les résultats montrent que les méthodes d'extrapolation peuvent fournir une réduction significative du délai G2G avec une perte de qualité acceptable, surtout pour les applications avec des contenus vidéo à faible information temporelle.

Abstract – Applications such as teleoperated driving and telepresence rely on video services to ensure real-time interaction with a satisfying quality of experience. Reducing the Glass-to-Glass (G2G) delay, *i.e.*, the time delay between acquiring a video frame and displaying on a remote terminal is critical for these applications. Deep learning-based video frame extrapolation has been recently considered to reduce G2G delay. In this paper, we examine the efficiency of this extrapolation technique in reducing the global latency in a point-to-point video transmission system. The goal is to define this approach's operating region and determine its pros and cons. To this end, we compare the latency-quality trade-off for two latency compensation methods: typical encoding rate reduction and extrapolation. Our experiments show that extrapolation methods can provide a significant reduction of G2G delay with an acceptable loss in quality, particularly for applications inducing video content with low temporal complexity.

1 Introduction

Ces dernières années, les services vidéo ont été intégrés dans des applications émergentes et interactives telles que la téléprésence [1] ou la téléconduite à distance [2]. Pour garantir une qualité d'expérience satisfaisante (QoE) dans des contextes de téléprésence, ou un comportement sûr d'un système commandé à distance, il faut que les contenus visuels soient fournis à l'opérateur humain (ou à la machine) avec une bonne qualité et une latence réduite.

La latence dans ces applications est déterminée par le délai Glass-to-glass (G2G), c'est à dire le délai entre l'acquisition et l'affichage d'une image[3] comme illustré à la Figure. 1. Le délai G2G acceptable pour la visioconférence ou les jeux en ligne doit être inférieur à 100 ms pour être en dessous du seuil de perception humaine [4], et pour les applications interagissant avec des machines, le délai est encore plus faible (10-30 ms) [5]. Néanmoins, le délai G2G minimum réalisable (actuellement entre 50 et 400 ms [6]) est limité par les délais d'acquisition, de codage, de transmission, de décodage et de mise en mémoire tampon.

Diverses études ont essayé de réduire chaque source de latence. Pour réduire le délai d'acquisition, on utilise traditionnellement des caméras analogiques, car elles offrent une faible latence à cause de l'absence de mise en mémoire tampon et de traitement des données [7]. Dans le codage vidéo, la configuration Low Delay P (LDP) permet de réduire la latence du codage [8] car elle évite le délai de réorganisation des images. Une autre approche courante consiste à réduire le débit d'en-

codage [9] pour diminuer la quantité de données transmises par image, et par conséquent, la latence.

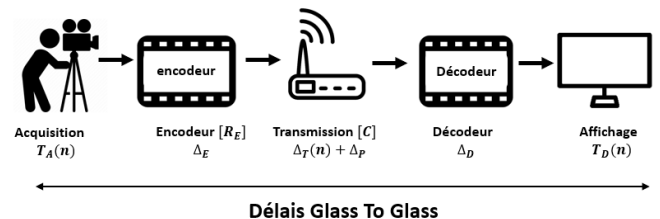


FIGURE 1 : Latence G2G dans un schéma de transmission vidéo point à point

Récemment, l'extrapolation des images vidéo a été considérée comme une approche alternative pour réduire le délai G2G et obtenir une latence faible à nulle [10]. L'extrapolation vidéo exploite les techniques d'apprentissage profond en extrayant des caractéristiques des images déjà acquises pour prédire les images futures. Si l'horizon d'extrapolation est suffisamment lointain pour compenser les différentes latences (acquisition, encodage, transmission, etc.), l'image extrapolée qui est transmise à la place de l'image en cours d'acquisition pourra être affichée au niveau du récepteur au même instant qu'elle sera acquise à l'émetteur, ce qui entraîne une réduction drastique de la latence G2G. Cependant, la méthode proposée par [10] n'a pas pris en compte l'impact des délais de codage et de transmission, ni le délai de l'extrapolation.

Généralement, une compensation de latence entraîne une dégradation de la qualité vidéo. Par exemple, réduire le débit d'encodage entraîne des artefacts de codage très visibles, alors

que les images extrapolées diffèrent des images originales. Dans cet article, nous étudions ce compromis qualité-latence pour des scénarios tels que la téléconduite et la visioconférence. Nous cherchons à étudier la zone d'opération où l'extrapolation d'image est efficace et à identifier ses avantages et ses inconvénients par rapport à la réduction du débit d'encodage. Le reste de l'article est organisé comme suit : La Section 1.1 décrit le modèle utilisé pour évaluer la latence de G2G du schéma de transmission vidéo. La configuration de la simulation est détaillée et les résultats sont présentés et discutés dans la Section 2. Enfin, la Section 5 conclut ce travail et donne des perspectives.

1.1 Méthodologie

1.2 Modèle d'estimation du délai G2G

La Figure. 1 décrit le schéma de diffusion vidéo considéré. La vidéo est codée à un débit R_E et transmise via une liaison de capacité C , supposée constante et non affectée par R_E . L'analyse pourrait être facilement étendue à un canal dont la capacité varie dans le temps.

Les images vidéo sont acquises avec une période Δ_F . On suppose que l'acquisition de la n -ième image commence au temps $T_A(n) = n \times \Delta_F$. Le délai d'acquisition et de codage d'une image est supposé constant et égal à Δ_E . La taille de l'image encodée est $S(n)$. Une fois encodée, l'image est prête à être mise en paquets et protégée par codage canal. Étant donné qu'une image codée ne peut être transmise avant que les images précédentes ne soient complètement codées et transmises, l'image n commence à être transmise à l'instant :

$$T_T(n) = \max[T_A(n) + \Delta_E, T_T(n-1) + \Delta_T(n-1)], \quad (1)$$

où $\Delta_T(n-1) = S(n-1)/C$ est le délai de transmission de la $n-1$ -ième image codée. Pendant la transmission, la n -ième image se propage dans le canal jusqu'au récepteur durant $\Delta_P(n)$ (ce délai dépend de la distance et de la congestion du réseau). Quand l'image n atteint le récepteur, elle est décodée pendant Δ_D , puis affichée au temps $T_D(n)$, par conséquent :

$$T_D(n) = T_T(n) + S(n)/C + \Delta_P + \Delta_D. \quad (2)$$

Le délai G2G est alors la différence entre le moment où une image est affichée au récepteur et le moment où elle a commencé à être acquise à l'émetteur.

$$\Delta_G(n) = T_D(n) - T_A(n). \quad (3)$$

Dans cette étude, afin de respecter les contraintes de faible latence, nous avons utilisé la configuration d'encodage vidéo LDP. La latence doit être évaluée en faisant la moyenne 1) des images I et P, puis 2) des images I uniquement représentant la latence maximale du fait qu'elles comportent plus de bits que les images P. Cela permet de simuler l'effet d'un buffer tampon qui stocke les images vidéo et les lit avec une cadence constante permettant un affichage régulier sans pause.

1.3 Méthode de référence : Réduction du débit de codage

En réduisant le débit d'encodage vidéo, la quantité de données par image encodée à transmettre diminue, et le temps nécessaire à l'envoi d'une image est réduit. Si le débit d'encodage pour l'image n est réduit de R_E à $R'_E = \alpha R_E$, $\alpha \in]0, 1]$, la latence de transmission résultante sera telle que

$$R'_E \Delta_F / C < R_E \Delta_F / C. \quad (4)$$

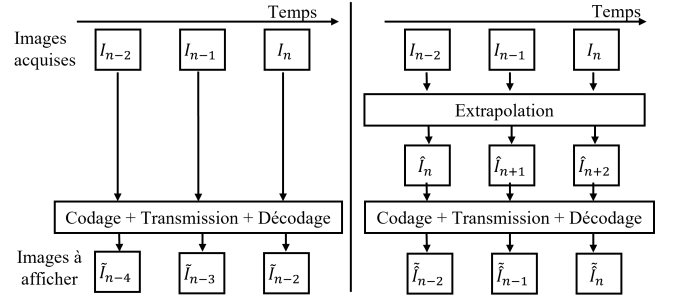


FIGURE 2 : Illustration de la transmission vidéo sans extrapolation et avec extrapolation. \hat{I} et \tilde{I} indiquent respectivement l'image extrapolée et décodée.

Supposons qu'une vidéo codée à $R_E = 10$ Mb/s est transmise sur un canal de capacité moyenne $C = 10$ Mb/s à 25 fps, le délai de transmission d'une image est de 40 ms. En considérant un facteur de réduction du débit d'encodage vidéo $\alpha = 1/10$, la taille moyenne de l'image est également divisée par 10 et le délai de transmission devient 4 ms.

1.4 Méthode analysée : Extrapolation

L'extrapolation d'image est considérée comme un outil alternatif pour compenser la latence. Elle est applicable à l'encodeur ou au décodeur. Dans cet article, seule l'extrapolation à l'encodeur est considérée, les deux techniques offrant des performances similaires [10].

Pour compenser le délai G2G, un extrapolateur est inclus dans la chaîne de transmission avant l'encodage, *i.e.*, au temps $n \times \Delta_F$ pour la n -ième image. Ce dernier prend k images précédentes (I_{n-k}, \dots, I_{n-1}) comme images de contexte pour produire une estimation de l'image I_{n+h} , où h représente l'horizon temporel d'extrapolation. Par exemple, supposons que le délai G2G soit de $2 \times \Delta_F$, c'est-à-dire lorsque I_n est acquis au moment $T_A(n) = n \times \Delta_F$, l'image affichée au récepteur est I_{n-2} , si l'extrapolation n'est pas introduite (Figure. 2). En utilisant un extrapolateur avec un horizon temporel $h = 2$, à $t = (n-2) \times \Delta_F$, I_n est prédite et envoyée au récepteur. Ainsi, l'image affichée au récepteur à $t = n \times \Delta_F$ sera l'image prédite de I_n . Quand l'extrapolateur n'est capable de prédire qu'une seule image à l'avance, l'extrapolation d'horizon h nécessite h itérations d'extrapolation, donc le délai d'extrapolation est $h \times \Delta_X$, avec Δ_X est le délai d'extrapolation. Alors, la version extrapolée de l'image I_n est prête à être transmise à :

$$T_T(n) = \max[T_A(n-h) + h\Delta_X + \Delta_E, T_T(n-1) + \Delta_T(n-1)]. \quad (5)$$

2 Configuration de la simulation

Nous proposons de comparer l'efficacité de ces méthodes en évaluant le compromis qualité-latence dans plusieurs scénarios. Nous considérons différentes séquences vidéo : *Stefan*, *Tennis*, et *Touch down pass* à 30 fps, *Soccer*, *Four people*, *Johnny* à 60 fps de la collection Xiph [11] et *Bike 1*, *Bike 2*, *Road*, *Person* à 10 fps de la base de données Kitti [12]. On prend les 90 premières images de chaque séquence, redimensionnées à 640×448 pixels.

Le codec VTM 18.0 est utilisé pour encoder les images originales et extrapolées avec la configuration LDP¹ et trois débits d'encodage typiques : $R_E = \{1, 5 \text{ Mb/s}, 800 \text{ kb/s}, 400 \text{ kb/s}\}$ [13]. La taille du groupe d'images (GOP) ou le

¹encoder_lowdelay_P_vtm.cfg

nombre d'images entre les I-frames successives est fixé à 32 images. Nous considérons des valeurs typiques de délai d'acquisition et d'encodage $\Delta_E = 23$ ms et de délai de décodage $\Delta_D = 5$ ms [2, 3].

Pour éviter l'accumulation de la latence due à l'augmentation du temps de transmission, la capacité du canal est prise supérieure à R_E , $C = \{3 \text{ Mb/s}, 6 \text{ Mb/s}, 10 \text{ Mb/s}, 20 \text{ Mb/s}\}$. Le délai de propagation est pris $\Delta_P = 3$ ms qui est une valeur typique dans les réseaux d'accès 5G.

Parmi les techniques d'extrapolation [14], nous considérons le réseau SDC-Net [15], offrant les meilleures performances [10]. Différentes hypothèses pour le délai d'extrapolation (qui dépend de la plateforme matérielle) sont considérées : $\Delta_X \in \{0, 1/4, 1/2, 3/4\} \times \Delta_F$ pour déterminer quand la méthode d'extrapolation est efficace et viable.

Deux métriques objectives de la qualité vidéo sont prises en compte [16] : le rapport signal à bruit (PSNR), et l'index de similarité structurelle (SSIM).

3 Résultats des simulations

Bien que les images extrapolées soient déformées, la structure et la position de l'objet dans la scène sont en grande partie préservées [10]. Par conséquent, le SSIM est une métrique plus appropriée pour évaluer les artefacts d'extrapolation car il ne repose pas sur des comparaisons pixel à pixel comme le PSNR.

La Figure. 3 montre la variation de PSNR et de SSIM en fonction de la latence moyenne et maximale pour deux cas extrêmes (une complexité temporelle faible et moyenne). Des résultats supplémentaires peuvent être trouvés sur le lien suivant : ². Indépendamment de la qualité de départ de la vidéo, celle-ci diminue lorsqu'on utilise l'extrapolation pour atteindre environ 27.13 dB pour la séquence *Soccer* et 36.30 dB pour *Four people* par rapport au cas sans réduction de latence ($\alpha = 1$). Nous remarquons pour la séquence *Soccer* (Figure. 3a- 3b) que malgré la baisse de qualité dans l'extrapolation, le gain dans la compensation de latence est plus élevé que celui obtenu avec la réduction du débit de codage, en particulier lorsque le délai d'extrapolation hypothétique est faible. Par exemple, pour $R_E = 800$ kb/s et $C = 6$ Mb/s, les deux méthodes entraînent une baisse du PSNR d'environ 8 dB (Visuellement Figure. 4). D'autre part, 50.03 ms et 53.49 ms de latence moyenne et maximale, respectivement, sont gagnés (si l'extrapolateur n'introduit aucun retard, $\Delta_X = 0$) en utilisant l'extrapolation avec $h = 3$, alors que seulement 2.06 ms de latence moyenne et 23.23 ms de latence maximale sont obtenus avec la méthode de réduction du débit d'encodage lorsque $\alpha = 1/8$. Néanmoins, pour un grand R_E et un canal à largeur de bande limitée, si l'extrapolation introduit un retard, l'approche de réduction du débit d'encodage devient plus efficace.

Concernant la séquence *Four people*, pour toutes les valeurs de R_E , l'approche d'extrapolation fournit un gain accru en termes de latence. Pour un canal de faible capacité, même si on compense une latence similaire, la qualité obtenue avec la méthode d'extrapolation est meilleure. Par exemple, en considérant $C = 6$ Mb/s, malgré que $\Delta_X = 3/4 \times \Delta_F$, pour obtenir une latence maximale de 37.31 ms avec un horizon d'extrapolation $h = 5$, un PSNR de 36.30 dB et un SSIM de 0.97 sont obtenus. Par contre, l'utilisation de la réduction du débit de codage avec $\alpha = 1/8$ conduit à un PSNR de 33, 36 dB, un SSIM

de 0, 91 et une latence maximale de 35, 65 ms (Figure. 3c- 3d). Cela montre que la compensation de latence par extrapolation est une méthode viable pour les applications où un contenu vidéo à faible complexité temporelle est transmis.

4 Discussion

La réduction du débit d'encodage est une technique simple, bien connue et maîtrisée en termes de qualité et d'artefacts générés, offrant une plus grande flexibilité/granularité par rapport à l'extrapolation. En effet, la réduction de la latence par extrapolation dépend de l'horizon temporel h , alors que la réduction du débit d'encodage est contrôlée par le facteur de réduction α . Le choix d'un α approprié permet de réduire la latence de manière plus fine. Néanmoins, cette méthode ne permet de réduire la latence que de quelques ms, au prix d'une baisse significative de la qualité. De plus, un délai G2G nul (ou négatif) n'est pas réalisable avec cette approche car cela nécessiterait de ne pas transmettre de données. D'autre part, l'extrapolation permet de compenser une latence plus importante à condition que le délai d'extrapolation reste faible, e.g., en utilisant un processus non-itératif qui pourrait prédire directement l'image désirée. Cela induirait probablement une perte de qualité supplémentaire qui sera étudiée dans un travail futur. En ce qui concerne la perte de qualité, l'extrapolation semble mieux convenir aux contenus à faible complexité temporelle. Un défi concernant la méthode d'extrapolation est le changement soudain de scène (cut), puisque l'image prédite est basée sur les images contextuelles précédentes, l'utilisation d'extrapolation pendant ces cuts conduirait à des informations inexactes. On peut proposer un mécanisme de commutation entre la réduction du débit de codage et l'extrapolation pour éviter un tel problème. Enfin, dans le cas de la multidiffusion, le délai G2G subit par différents récepteurs peut être variable. Lors de l'extrapolation à l'encodeur, l'horizon temporel est décidé au niveau de l'encodeur et, donc, h ne peut être choisi que pour optimiser une certaine mesure de performance globale parmi tous les utilisateurs, e.g, compenser un délai moyen ou le délai de l'utilisateur le plus impacté.

5 Conclusion et perspectives

Deux méthodes de compensation de la latence vidéo sont comparées : la réduction du débit d'encodage et l'extrapolation des images. Cette étude illustre l'efficacité de l'extrapolation en considérant le compromis qualité-latence et détermine sa région d'opération. Les résultats montrent que l'extrapolation est plus performante que la réduction du débit en terme de compensation de latence et peut atteindre une latence G2G nulle ou négative, notamment lors de la transmission de contenus à faible complexité temporelle. Néanmoins, la réduction du délai d'extrapolation est une étape nécessaire lorsque des canaux de faible capacité sont considérés. Actuellement, l'extrapolation est une technique prometteuse, mais elle est encore dans sa phase initiale concernant la qualité et le délai d'extrapolation. Cet article fournit un bon aperçu basé sur des paramètres statiques (capacité du canal, débit d'encodage, etc.) et sert de base indispensable à des travaux plus complexes visant à proposer des mécanismes adaptatifs tenant compte la variabilité de ces paramètres.

Acknowledgments : Ce travail a été financé par le fond national ANR AAPG2020 dans le cadre du projet ZL-LVC (ANR-20-CE25-0014).

²https://drive.google.com/drive/folders/1-Es1_-jpCpRgsYZtIdTw1M3t3imFDuvo?usp=sharing

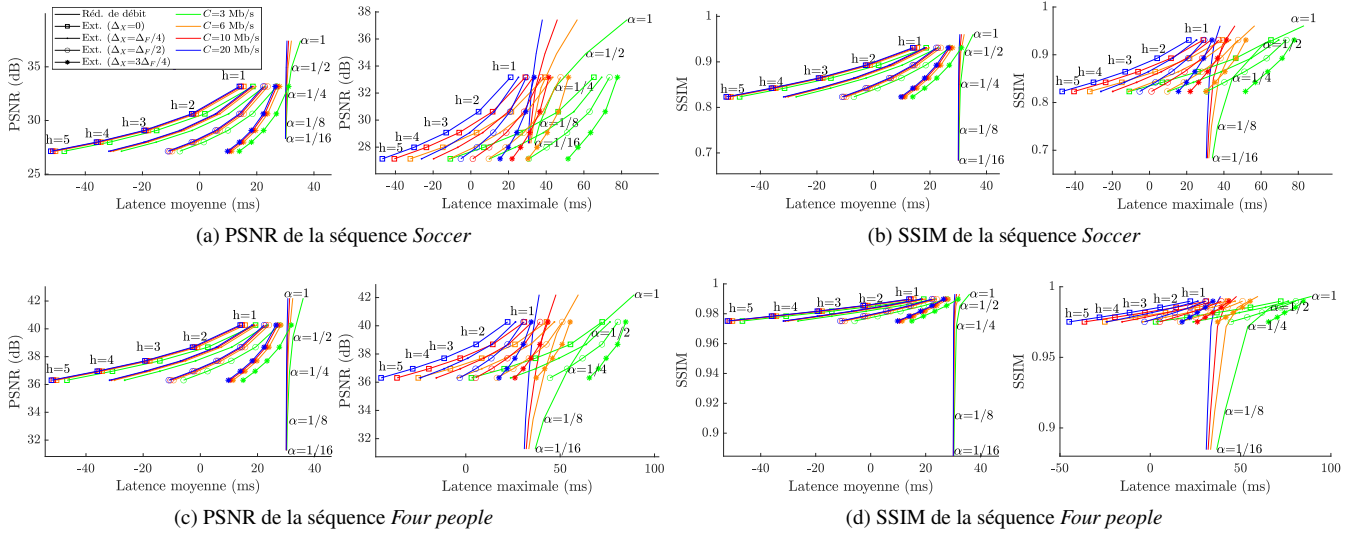


FIGURE 3 : Evolution de la qualité en fonction du retard G2G moyen (à gauche) et maximum (à droite) pour $R_E = 800$ kB/s. Premier ligne : pour la séquence *Soccer* : a) PSNR, b) SSIM. Deuxième ligne : pour la séquence *Four people* : c) PSNR, d) SSIM.



FIGURE 4 : Comparaison visuelle de *Soccer* ($R_E = 800$ kb/s, $C = 6$ Mb/s) : (a) Image originale, (b) Réduction de débit ($\alpha = 1/8$, PSNR = 29.74 dB et SSIM = 0.74) et (c) Extrapolation ($h=3$, $\Delta_X = 0 \times \Delta_F$, PSNR = 29.07 dB et SSIM = 0.86).

Références

- [1] Mihir Mody, Pramod Swami, and Pavan Shastry. Ultra-low latency video codec for video conferencing. In *2014 IEEE CONECCT*, 2014.
- [2] Oussama El Marai and Tarik Taleb. Smooth and low latency video streaming for autonomous cars during handover. *IEEE Netw.*, 34(6), 11, 2020.
- [3] Christoph Bachhuber, Eckehard Steinbach, and al. On the minimization of glass-to-glass and glass-to-algorithm delay in video communication. *IEEE Trans. Multimed.*, 20(1), 1, 2018.
- [4] Lothar Pantel and Lars C. Wolf. On the impact of delay on real-time multiplayer games. In *Proceedings of the 12th International Workshop on Network and Operating Systems Support for Digital Audio and Video*, New York, NY, USA, 2002. Association for Computing Machinery.
- [5] Sergiy Melnyk, Abraham Tesfay, and al. Reliable low latency wireless communication enabling industrial mobile control and safety applications. 4, 2018.
- [6] Shree Krishna Sharma, Isaac Woungang, and al. Toward tactile internet in beyond 5G Era : Recent advances, current issues, and future directions. *IEEE Access*, 8, 3, 2020.
- [7] Sven Ubik and Jiří Pospíšilík. Video camera latency analysis and measurement. *IEEE Trans. Circuits Syst. Video Technol.*, 31(1), 1, 2021.
- [8] Soulef Bouaafia, Randa Khemiri, and al. Complexity analysis of new future video coding (fvc) standard technology. *Int. J. Digit. Multimed. Broadcast.*, 2021, 8, 2021.
- [9] Ahmed Badr, Ashish Khisti, and al. Perfecting protection for interactive multimedia : A survey of forward error correction for low-delay interactive applications. *IEEE Signal Process. Mag.*, 34(2), 3, 2017.
- [10] Melan Vijayaratnam, Marco Cagnazzo, and al. Towards zero-latency video transmission through frame extrapolation. In *2022 IEEE ICIP*, 10, 2022.
- [11] Xiph.org media, URL <https://media.xiph.org/video/derf/>.
- [12] Andreas Geiger, Philip Lenz, and al. Vision meets robotics : The kitti dataset. *Int. J. Robot. Res.*, 32(11), 2013.
- [13] Conditions for visual comparison of VCB, IVC and WVC codecs, iso/iec jtc1/sc29/wg11 mpeg2013/n13943, 2013.
- [14] Qingming Huang, Zhongxiao Li, and al. Video frame prediction with dual-stream deep network emphasizing motions and content details. *Appl. Soft Comput.*, 125, 6, 2022.
- [15] Fitsum A. Reda, Guilin Liu, and al. SDC-Net : Video prediction using spatially-displaced convolution. In *Computer Vision – ECCV 2018*, Cham, 2018. Springer International Publishing.
- [16] David R. Bull and Fan Zhang. *Intelligent image and video compression : communicating pictures*. Academic Press, London, second edition. edition, 2021.