

高効率で省電力な IoT・ビッグデータ処理基盤

研究代表者 甲藤 二郎
(基幹理工学部 情報通信学科 教授)

1. 研究課題

各種センサ、スマートフォン、自動車、列車、移動ロボット等、IoT (Internet of Things) デバイスは多岐に渡り、またそのセンシングデータも、加速度、温度等の小容量データから高精細映像等の大容量データまで、あるいは、SNS (Social Networking Service) 等の遅延要求の緩いものから自動運転、Industry 4.0 等の遅延要求の厳しいものまで、これまた多岐に渡っている。また、災害時や大きなイベント時にはバースト的に大量のデータが発生するが、どのような環境下でも安全かつ高信頼なセンシングを確保すると共に、適切な情報を抽出できるデータ処理技術の確立が求められている。さらには、東日本大震災時の反省に基づき、電力供給が限られた中でも長時間動作可能な省電力化技術の確立が求められると共に、COVID-19 対策に貢献する情報通信処理技術の開発が期待されている。

2022 年度の研究成果としては、第一に、480fps (frames per second) 以上の高フレームレート映像の超解像技術に関する検討を行った。従来技術では、高フレームレート映像の超解像は画質が向上しない問題を指摘し、その上で、複数 fps の超解像結果の合成を行う方式の提案と有効性実証を行った。第二に、リモート接続時の、心拍数推定による個人認証を困難にする映像伝送方式の提案を行った。近年、映像信号からの心拍数推定技術が進歩しており、映像信号の微小な時間変動を検知し、個人認証に拡張する検討が進められている。そこで、映像信号の時間変動を抑圧する方式を提案し、画質劣化を小さく抑えた上で心拍数推定を困難にすることを可能にした。第三に、映像信号の未来フレームを予測する Video Prediction 技術の検討を行い、独自の方式を提案し、有効性検証を行った。

2. 主な研究成果

2.1 高フレームレート映像の超解像処理

2.1.1 はじめに

近年、スマートフォンなどの日常的に使われるようなデバイスによる高フレームレート映像の撮影が可能になり、高フレームレート映像が一般的になっている。このため、高フレーム映像の高解像度化や高効率な圧縮符号化技術が必要とされている。そこで本節では、超解像技術の高フレームレート動画への適用について検討する。

2.1.2 関連研究

Video Super-Resolution (VSR) において、近年多くの深層学習をベースとした手法が提案されている。これらの多くは optical flow を利用して特徴抽出を行う。特に、BasicVSR (C. Kelvin et al., CVPR 2021) は、VSR に必要なコンポーネントを 4 つの basic function (propagation,

alignment, aggregation, upsampling) に分類し、VSR においてシンプルかつ強力なベースラインを実現した。そして、BasicVSR++ (C. Kelvin et al., CVPRW 2021) では、BasicVSR を拡張し、同様のパラメータ数を維持しながらも性能を向上させた。

また、この数年、国際学会において高フレームレート映像を用いた画像処理の報告例が増え始め、著名な例では、240fps 映像データセットを用いた NVIDIA の Super SloMo (CVPR 2018) が挙げられる。さらに、ICCV 2021 では、韓国 KAIST から、ハイスピードカメラで撮影した 960fps データセット X4K1000fps が提案された。ただし、対象とする画像処理タスクは、ほとんどが高フレームレート映像データセットを ground truth として使用するフレーム補間であり、超解像、雑音除去 (denoising)、ボケ除去 (deblurring)、映像圧縮等の検討はほとんど報告されていない。

2.1.3 高フレームレート映像の超解像処理の課題

まず、960fps の動画からフレームを間引くことで、オリジナルの 960fps データセットとは別に、480fps、240fps、120fps、60fps のデータセットを生成した。これら 5 種類のデータに対して、超解像ネットワークとして BasicVSR++ を使用して超解像モデルを学習し、それぞれのデータにおいて比較を行う。

図 1 に、60fps から 960fps のデータセットで学習した超解像モデルによるそれぞれのデータセットの超解像結果の比較結果を示す。青い棒グラフが 960fps で学習したモデルを示し、オレンジが 480fps、灰色が 240fps、黄色が 120fps、水色が 60fps を示す。また、一番左のまとまりが 960fps データによる評価結果を示し、二番目が 480fps、三番目が 120fps、一番右が 60fps のデータセットで学習した場合の超解像結果を示す。この結果から、ある程度のフレームレート (240fps 等) まではフレームレートが高くなるほど超解像の精度も高くなるが、一定以上のフレームレートにおいては逆にフレームレートが高くなるほど超解像の精度が低くなるという、高フレームレート映像の特性が確認できる。






図 1: 各種 fps データセットで学習した超解像モデルによる特性評価

この現象を考察するために、図 2 は映像超解像の基本原則を示している。該当フレームの点線で示した円は半画素 (0.5 画素) 位置の画素を示し、この画素の値を正確に推定することが超解像の目的となる。映像超解像の場合、動き推定によって、参照フレーム内に半画素ずれた画素が存在すれば、理想的な超解像が実現できる。しかし、図 2(a) は動き量が非常に小さい場合であり、この場合は良好な超解像を実現できないことが予想される。フレームレート

が高いほど、オプティカルフローの値は小さくなるため、240fps 以上の高フレームレート映像では、図 2(a) のケースが多発することが予想される。一方、図 2(b) は、動き量がほぼ半画素の参照画素が見つかった場合であり、この場合は良好な超解像の実現が予想される。



(a) 動き量が小さ過ぎる場合



(b) 動き量が適切な場合

図 2: 映像超解像の原理

2.1.4 提案方式と実験結果

図 2 の予想に基づき、超高フレームレート映像における optical flow の大きさと超解像精度の関係を調査した結果、低解像度映像の optical flow の大きさが約 0.25 から 0.35 以下となっているピクセルが大多数を占める場合に超解像精度が低くなることが分かった。この調査結果を基に、optical flow の大きさによって入力動画のフレームレートを変更し、超解像の精度を高めるフレームワークを提案する。図 3 に提案するフレームワークを示す。Optical flow の大きさについては 0.5 程度を閾値とする。もし optical flow の大きさが閾値より小さければ、フレームを間引きフレームレートを低くすることで optical flow の大きさが閾値以上となるよう調整し、その後超解像ネットワークに入力する。




図 3: 提案フレームワーク

提案フレームワークにおいて、optical flow の推定には RAFT (Z. Teed et al., ECCV2020) を、VSR ネットワークには BasicVSR++を利用した。また、テストデータセットとしては、前述の X4K1000FPS を使用した。ベースラインとしては、960fps データセットにより学習した超解像モデルを採用する。その後、複数 fps の結果を平均する fps ensemble、および提案フレームワークに適用した結果を用い、比較を行った。本実験の結果を図 4 および図 5 に示す。なお、実験に用いたシーケンスのうち、optical flow の大きさが 0.5 以下だったものは TEST06、TEST07、TEST08、TEST09、TEST10 の 5 つであった。これらの結果より、fps ensemble および提案フレームワークにより超解像の精度が向上していることが確認できた。




図 4: 提案手法による超解像結果 (PSNR 比較)




図 5: 提案手法による超解像結果 (実画像)

2.1.5 おわりに

本節では、超解像における高フレームレート映像の特性を調査し、その特性を考慮した超解像フレームワークを提案した。今後の展望としては、ピクセル単位の optical flow を利用することでフレーム内の動きが大きい部分は隣接フレームから、その他の部分はより遠くのフレームを使うなどの超解像手法や、超高フレームレート映像の超解像ネットワーク学習における利用法、超高フレームレート映像における符号化歪み低減などについても検討していきたい。

2.2 セキュアな映像伝送方式

2.2.1 はじめに

近年、認証システムとして生体認証が様々なサービスで活用されており、身近な存在となっている。そのような生体認証として、接触型の心拍数推定によるユーザ認証システムが存在する。また、心拍数の取得は非接触でも可能であり、特に、フォトプレチスモグラフィ (rPPG: remote photoplethysmography) という技術を用いてカメラで撮影した顔映像から心拍数を取

得することができる。そこで本節では、rPPG を用いたリモート接続時の心拍ベースのユーザ認証システムへの攻撃を危惧し、対策としてカメラによって取得される映像の外見上の変化を抑えつつ、その映像から心拍数の取得を妨げる変換システムを設計し、セキュアで低遅延な映像信号のリアルタイム伝送を目指すした。

2.2.2 関連研究

(a) pyVHR (G. Boccignone et al., IEEE Access, 2020)

rPPG ベースの心拍数推定をサポートするオープンフレームワークとして pyVHR が存在する (図 6 参照)。rPPG では、RGB カメラを使用して人間の皮膚表面の脈拍による微小な色の変化を検出することで、人間の心臓活動を非接触でモニタリングすることを可能にしている。pyVHR では ICA、PCA、GREEN、CHROM、POS、SSR、LGI、PBV、OMIT といった複数の rPPG メソッドが採用されている。




図 6: pyVHR の概要

(b) rPPG を用いたセキュリティ攻撃 (R. M. Seepers et al., IEEE Journal of Biomedical and Health Informatics, 2018)

連続する心拍の時間間隔 (IPI: interpulse interval) から個人及び時間に固有の識別子を導出することができる。IPI は 2 つの連続する心拍の時間差として定義される。各 IPI にはある程度のランダム性が含まれており、このランダム性により、図 7 のように IPI から一意の生体認証識別子を導出することが可能になる。本文献は、この心拍ベースのセキュリティ (HBBS) において、rPPG を使用して、接触デバイスから心拍を取得するのと同様の精度で生体認証識別子を生成し、攻撃者がセキュリティ侵害できる可能性を示している。





図 7: IPI を使用した生体認証識別子の生成


2.2.3 提案方式と評価実験

rPPG によるリモート接続時の心拍数取得によるセキュリティ攻撃を防ぐために、映像信号の時間変動を除去する処理を行い、処理前後の心拍数の推定精度を評価する実験を行った。本実験では、LGI-PPGI データベース (<https://github.com/partofthestars/LGI-PPGI-DB>) に含まれる映像の中から、被験者 harun と cpi の resting、talk の 2 種類の映像を利用した。resting は室内で撮影された静的な映像である。

時間変動除去処理について、概要を図 8 に示す。図 8(a) は、映像送信側の時間変動除去処理の構成を示し、図 8(b) は、その中の補正処理部の詳細を示す。ここで ROI (Region of Interest) は映像フレーム内の顔領域を示し、GOP (Group of Pictures) は複数の映像フレームの塊を示す。また、 μ_{GOP} は GOP の平均値、 $I(n)$ は第 n フレームの映像信号、 $\mu(n)$ は第 n フレームの平均値を示し、 $I(n) - \mu(n) + \mu_{GOP}$ を補正映像として出力する。このような前処理を施すことで、各映像フレームの平均値は等しく μ_{GOP} となり、画質を大きく劣化させることなく、映像フレームの微小な時間変動を利用する心拍推定が困難になる。なお、以降の実験では、rPPG 信号において RGB の中でも G チャンネルが最も影響を与えていることから、G チャンネルの値に着目して処理を行う。



(a) 時間変動除去処理の構成



(b) 補正処理の詳細

図 8: 時間変動除去処理の構成

この処理を適用した各映像に対して、pyVHRを用いて、ROIを顔領域から座標で額、両頬、鼻の領域を矩形選択する方法で指定して、rPPGメソッドを適用して心拍数推定を行い、推定値と真値でRMSE値を算出した。さらに、元映像に対する処理後の映像の品質を示すPSNR値とSSIM値の算出も行った。そのPSNR値とSSIM値を表1に示し、RMSE値を被験者ごとに表2、表3に示す。

表 1: 元映像に対する処理後映像の映像品質

被験者	セッション	PSNR	SSIM
harun	resting	43.32	0.9937
	talk	40.01	0.9948
cpi	resting	43.13	0.9969
	talk	34.91	0.9805

表 2: 処理映像の心拍数推定誤差 (harun)

	元映像		時間変動除去後	
	resting	talk	resting	talk
ICA	5.73	20.66	57.28	39.89
PCA	6.48	26.72	50.31	41.56
Green	40.45	36.31	44.24	45.02
Chrom	20.10	21.61	46.96	44.96
POS	4.72	40.24	52.04	48.51
SSR	4.58	37.99	51.22	—
LGI	4.49	31.09	45.57	46.91
PBV	33.06	36.00	53.11	46.81
OMIT	4.49	30.84	45.55	47.26

表 3: 処理映像の心拍数推定誤差 (cpi)

	元映像		時間変動除去後	
	resting	talk	resting	talk
ICA	3.64	28.71	29.54	27.39
PCA	3.94	25.28	28.36	26.44
Green	3.42	31.49	65.68	31.35
Chrom	3.32	28.11	56.55	35.61
POS	3.80	41.96	36.61	35.39
SSR	3.50	29.04	38.33	—
LGI	3.36	29.29	31.03	34.59
PBV	15.73	31.19	61.60	35.36
OMIT	3.36	29.75	31.03	34.33

以上の結果より、resting のような室内で撮影された映像に関しては、時間変動除去処理がより心拍数の取得を妨げながら、映像の変化の少ない処理が可能であることが確認できる。ただし、照明環境や被験者の動きによっては、正確な心拍数の取得が困難になる場合もある。

2.2.5 おわりに

本節では、心拍ベースのセキュリティへの攻撃を防ぐために、映像の見た目の変化を抑制しつつ心拍数の取得を妨げる処理として RGB の G チャネルの時間変動を除去する処理を実行し、その評価を行った。その結果、静的状態の映像に対して心拍数の取得を妨げながら、映像の変化の少ない処理が可能であることが確認できた。今後は、被験者の動きや照明環境といった撮影環境に堅牢な心拍数推定と心拍ベースのセキュリティ攻撃への防御を検討していく。

2.3 SRVP と SLAMP を用いた映像予測

2.3.1 はじめに

近年、映像信号の未来フレームを予測する外挿モデルが数多く提案されている。フレーム外挿モデルは Autoregressive Model 型と State-Space Model 型の 2 種類があり、具体的な映像予測ニューラルネットワークとして、以下の手法の調査と方式改善を試みた。

- ✓ PredNet (Deep Predictive Coding Networks, ICLR 2017)
- ✓ CrevNet (Conditionally Reversible Video Prediction, NIPS 2019)
- ✓ LVT (Latent Video Transformer, VISIGRAPP 2021)
- ✓ CCVS (Context-aware Controllable Video Synthesis, NIPS 2021)
- ✓ SVG (Stochastic Video Generation, PMLR 2018)
- ✓ SRVP (Stochastic Latent Appearance and Motion Prediction, ICML 2020)
- ✓ SLAMP (Stochastic Latent Residual Video Prediction, ICCV 2021)
- ✓ OVP-VFI (Optimizing Video Prediction via Video Frame Interpolation, CVPR 2022)
- ✓ DMVFN (Dynamic Multi-Scale Voxel Flow Network, CVPR 2023)

本節では特に SRVP と SLAMP を用いた映像予測の改善方式に関する報告を行う。

2.3.2 関連研究

SVG は潜在変数を用いて確率的にフレームを予測し、生成する初期の外挿モデルである。潜在変数は、フレームを予測する際に入力する最初の数フレームから、物体が次にどのように動くかなどの確率的な情報を保持する変数である。モデルに過去のフレームと潜在変数を入力し、LSTM に通した後、デコーダーによって出力されるものが予測フレームとなる。また、SRVP は SVG と同様に潜在変数を用いて確率的に映像のフレームを予測するモデルである (図 9)。SRVP の特徴は、予測をする際に、潜在変数に加えて物体の形状や背景などの情報を保持するコンテンツ変数と呼ばれる変数を用いる点である。SRVP は SVG よりも高精度な予測フレームを生成することができる。また、SLAMP は SVG の改良版の外挿モデルである (図 10)。SVG が生成するフレームに加えて、2 枚のフレームと潜在変数を入力としてオプティカルフローを抽出し、ワーピングによって SVG とは別のフレームを生成する。後者の生成フレームはオプティカルフローを用いているため、よりフレーム内の物体や背景の動きに特化した予測を行う。生成された 2 枚のフレームを組み合わせることで最終的に 1 枚の外挿フレームを決定する。




図 9: SRVP の構成図




図 10: SLAMP の構造と予測結果例

2.3.3 SRVP と SLAMP を用いた評価実験

SRVP と SLAMP を用いた評価実験を行った。まず、pretrained model の評価を行った。図 11 に、実験で用いたデータセットうち Stochastic Moving MNIST (SMMNIST)、KITTI、Cityscapes の外挿結果を示す。SMMNIST は 2 つの手書き数字が異なる速度で直線的に移動し、端でランダムにバウンドするデータセットであるが、フレーム数を表す t が大きくなる。つまりより未来になるほど両モデルの数字の軌道が ground truth と比べてずれていくことが分かる。また、SLAMP に関しては数字の輪郭が少し崩れていくことが分かる。SLAMP は SRVP のように時不変の変数を用いていないので、物体の形状が崩れやすくなっていると考えられる。KITTI と Cityscapes は自動車の前方カメラによって撮影されたもので、pretrained model が用意されていたのは SLAMP のみであった。 t が大きくなると生成されたフレームは全体的にボケが生じてくるが、自動車からの景色特有の周りの背景が手前に向かってくるような動きは予測できているという印象を受ける。






図 11: 外挿フレームの可視化(上 : SMMNIST、中 : KITTI、下 : Cityscapes)

次に、実験環境を構築して SRVP と SLAMP の学習を行った。ここで用いたデータセットは、人間が単一の動きをする動画群の KTH と、ロボットアームが机上の物体を押しやり掴んだりする動画群の BAIR である。学習後のモデルの定量的な評価結果を表 4 に示す。SRVP と SLAMP の各値は、評価指標によって互いを上回ったり下回ったりしており、2 つのモデルの予測精度に大きな差はないと言える。また、KTH よりも BAIR の方が全体的に劣る値となっているが、BAIR は KTH と比べるとフレーム内の物体が不規則な動きをするデータセットであり、予測が困難であるためこのような結果となったと考えられる。以上より、外挿モデルはデータセットによって異なる予測精度を示すことが分かった。

表 4: 各外挿モデルの定量的評価の結果

	PSNR($\uparrow$)		SSIM($\uparrow$)		LPIPS($\downarrow$)	
	KTH	BAIR	KTH	BAIR	KTH	BAIR
SRVP	28.13	17.73	0.8323	0.7835	0.1135	0.08323
SLAMP	29.04	17.46	0.8475	0.7655	0.1355	0.09149

2.3.4 SLAMP の改善方式と評価実験

SLAMP では図 12 の赤枠部分でオプティカルフローを用いたワーピングが行われるが、ここでは図 13 のように物体の動く方向とは逆向きのベクトルである $t \rightarrow t-1$ 方向のオプティカルフローによる backward warping が行われる (図中に示すように、2 次元の動きベクトルを HSV 空間の色で表現している)。この部分を $t-1 \rightarrow t$ のフローを用いた forward warping に変更することを提案する。これによって元の SLAMP と同等以上の性能を発揮することを期待する。forward warping は同じピクセルにマッピングされて白くなったり、マッピングされないピクセルが黒くなったりする問題がある。この問題に対応するために、summation splatting と average splatting を実装する (Softmax Splatting, CVPR 2020)。前者はワーピングする際にマッピングされたものの総和を計算することで、オクルージョンが発生する可能性を下げることができる。後者は同じピクセルにマッピングされたものに対して平均をとることで、ピクセルが重なる部分の輝度値を下げる可以降低。

この 2 つの手法を SLAMP に移植したモデルを別々に用意し、それぞれのモデルを評価する。KTH を用いて学習し、定量的評価を行った結果を表 5 に示す。summation splatting を実装した SLAMP+sum が LPIPS において最も優れた数値を達成し、SRVP のすべての指標を上回る結果を得た。また、図 14 に示すように確かに順方向のオプティカルフローを生成できていることが確認できた。一方、average splatting を実装した SLAMP+ave は全体的にほかのモデルより劣る結果となった。ここで、提案手法の SLAMP+sum と SLAMP の定性的比較を図 15 に示す。SLAMP に関しては t が大きくなるとフレーム内の人間の形が徐々にくずれてくるが、

SLAMP+sum は形を保っており、ground truth に近い予測ができていることが分かる。以上の結果から、SLAMP に forward warping を実装した提案手法は、SLAMP と比べて動く物体の形状を崩しにくいフレームを生成する特徴があると考えられる。




図 12: SLAMP の構成図のワーピング部分




図 13: SLAMP が生成するオプティカルフロー

表 5: 各モデルの定量的評価結果 (KTH)

モデル名	PSNR($\uparrow$)	SSIM($\uparrow$)	LPIPS($\downarrow$)
SRVP	28.13	0.8323	0.1135
SLAMP	29.04	0.8475	0.1355
SLAMP+sum	28.38	0.8358	0.1105
SLAMP+ave	27.34	0.8339	0.1529




図 14: SLAMP+sum が生成するオプティカルフロー




図 15: SLAMP+sum と SLAMP による KTH の外挿フレームの比較

2.3.4 おわりに

本節では、2 つの外挿モデル SRVP と SLAMP を用いた評価実験を行い、それぞれのモデルの特徴について考察を行った。また、SLAMP に forward warping を適用した提案手法についても同様に評価実験を行い、定量的評価、定性的評価を通して既存の外挿モデルよりも優れた結果を達成しうることを示した。今後は backward と forward を併用する方式の検討を進める。

3. 共同研究者

佐藤 拓朗 (早稲田大学・特任教授)
 亀山 渉 (早稲田大学・教授)
 金井 謙治 (早稲田大学・次席研究員)
 孫 鶴鳴 (早稲田大学・次席研究員)
 山崎 恭 (北九州市立大学・准教授)
 市野 将嗣 (電気通信大学・助教)

4. 研究業績

4.1 学術論文

【論文誌】

- [1] Heming Sun, Lu Yu, and Jiro Katto: “Q-LIC: Quantizing Learned Image Compression with Channel Splitting,” IEEE Transactions on Circuits and Systems for Video Technology, Early Access, Dec.2022.
- [2] Bo Wei, Hang Song, Jiro Katto, and Takamaro Kikkawa: “RSSI-CSI Measurement and Variation Mitigation with Commodity WiFi Device,” IEEE Internet of Things Journal, Nov.2022.

【査読付き国際学会】

- [1] Kasidis Arunruangsirilert, Bo Wei, Hang Song, and Jiro Katto: "Pensieve 5G: Implementation of RL-based ABR Algorithm for UHD 4K/8K Content Delivery on Commercial 5G SA/NR-DC Network," IEEE WCNC 2023, Mar.2023.
- [2] Kasidis Arunruangsirilert, Pasapong Wongprasert, and Jiro Katto: "Performance Evaluations of C-Band 5G NR FR1 (Sub-6 GHz) Uplink MIMO on Urban Train," IEEE WCNC 2023, Mar.2023.
- [3] Joi Shimizu, Shion Komatsu, Satsuki Kobayashi, Heming Sun and Jiro Katto: “iPhone 240fps Video Dataset for Various Model Training Tasks,” IEEE ICCE 2023, Jan.2023.
- [4] Misa Nimura, Kenji Kanai and Jiro Katto: “Accuracy evaluations of real-time LiDAR-based indoor localization system,” IEEE ICCE 2023, Jan.2023.
- [5] Heming Sun, Lu Yu and Jiro Katto: “Improving Latent Quantization of Learned Image Compression with Gradient Scaling,” IEEE VCIP 2022, Dec.2022.
- [6] Jinming Liu, Heming Sun and Jiro Katto: “Semantic Segmentation in Learned Compressed Domain,” PCS 2022, Dec.2022.
- [7] Yutaka KATSUYAMA, Toshio SATO, Kazuhiko TAMESUE, Takuro SATO, Yuichi NAKAMURA, and Jiro KATTO: “A Study of Prediction of Operation Information by LSTM Using ElectroMyoGraphy Signals and Operation Information,” ICETC 2022, Nov.2022.
- [8] Heming Sun, Yiqing Yang, Fangzheng Lin, Lu Yu, Jiro Katto, and Masahiro Fujita: “F-LIC: FPGA-based learned image compression with a fine-grained pipeline,” IEEE ASSCC 2022, Nov.2022.
- [9] Ao Luo, Heming Sun, Jinming Liu, and Jiro Katto: “Learned Image Compression with Filter-Pruned Hyperprior Module” IEEE ICIP 2022, Oct.2022.
- [10] Fangzheng Lin, Heming Sun, and Jiro Katto: “Streaming-Capable High-Performance Architecture of Learned Image Compression Codecs,” IEEE ICIP 2022, Oct.2022.
- [11] Kenji Kanai, Toshitaka Tsuda, Hidenori Nakazato, Jiro Katto: “Information-Centric Service Mesh for Autonomous In-network Computing,” ACM ICN 2022, Sep.2022.
- [12] Jinming Liu, Heming Sun, and Jiro Katto: “Improving Multiple Machine Vision Tasks in the Compressed Domain,” ICPR 2022, Aug.2022.

- [13] Daiki Maruyama, Bo Wei, Hang Song, and Jiro Katto: “Pilot Allocation Optimization using Digital Annealer for Multi-cell Massive MIMO,” IEEE WCNC 2022, Apr.2022.

【特許】

- [1] 特願 2023-49862: 心拍情報隠蔽映像伝送方式および装置
[2] 特願 2023-49863: 映像超解像方式および装置

4.2 総説・著書

なし

4.3 招待講演

- [1] Jiro Katto: “Recent Advances in Learned Image/Video Compression,” SISA 2022, Sep.2022

4.4 受賞・表彰

- [1] 甲藤二郎: 電気通信普及財団賞（テレコムシステム技術賞）

4.5 学会および社会的活動

- [1] 総務省 放送システム委員会委員

5. 研究活動の課題と展望

今後の研究課題として、以下の研究開発を進める。(1) 超解像以外の高フレームレート映像向け画像処理技術の開発、(2) 被験者の動きや照明環境等の撮影環境の変化にもロバストな心拍数推定技術とセキュアな時間変動除去技術の開発、(3) 未来予測性能と高速化性能を両立する映像予測技術の開発。その上で、テストベッド等を活用した実装評価実験も進める。