

デジタルオプティクスからみたイメージングのこれから

堀 崎 遼 一

デジタルオプティクスは、光学と情報科学を融合させ、光学技術、光学デバイス、計算機処理を包括して光学システムをデザインする研究領域である。特に近年の情報科学の進展はすさまじく、その恩恵を受けた光学技術が当該領域でさまざま提案されている。また、デジタルオプティクスの中でもイメージングに限定された領域はコンピュータシミュレーションとよばれ、画像認識を土壌に発展してきた深層学習の利用も活発化している。本稿では、筆者の視点からデジタルオプティクスの現状を俯瞰し、その将来ビジョンを記す。

1. 情報光学とデジタルオプティクス

光学と情報科学の学際領域として、情報光学が知られている。情報光学では 1980 年代に光コンピューティングに関する研究が盛んに行われた¹⁾。半導体集積技術が発展するにつれ、情報光学において電子技術を利用したハイブリッド型光電融合システムの開拓、そして、それらの非コンピューティングへの応用が進んだ。デジタルホログラフィーやフーリエプロファイロメトリーは、この流れの中で生まれたイメージング技術の傑出した例といえる^{2,3)}。時代が進み 1990 年代から 2000 年代にかけ、計算機のパワー向上に伴い、情報光学分野の中でもさらに計算機処理に重みを置く先鋭化された領域がデジタルオプティクスである。デジタルオプティクスの黎明期に提案された波面符号化や複眼カメラにおいて、デジタルオプティクス前と比べ、計算機処理を踏まえ光学系を非従来の観点からデザインしていることは、光学設計における重要なターニングポイントである^{4,5)}。

2. デジタルオプティクスの現在とこれから

2000 年代から現在に至るまで、GPU に代表されるように、計算機のパワーは指数関数的に伸び続けている。これに歩調を合わせ情報科学は長足の進歩を遂げ、その影響は

あらゆる分野に及ぶようになった。光学もその例外ではない。特にデジタルオプティクスは、上述のように情報科学に寄り添ってきた歴史的背景もあり、光学の他分野と比べ、より積極的にこの流れを追い風にして技術革新を進めてきた。デジタルオプティクスに強く影響を及ぼした情報科学技術として、コンプレッシブセンシングと機械学習が挙げられる。

2.1 コンプレッシブセンシング

サンプリング定理からも示唆されるように、計測システム一般において、大きなデータを計測しようとするとき多数回の計測、あるいは多数の計測素子が必要になる。コンプレッシブセンシングは、ランダム性を含む計測プロセスと対象のスパース性を仮定した再構成アルゴリズムにより、サンプリング定理で決定されるよりもはるかに小さな計測回数や計測素子数で大きなデータを計測することを可能にした⁶⁾。三次元空間、波長、偏光などから構成される三次元以上の情報を用いてイメージセンサーを用いて計測する場合は、各次元に沿った走査が必要になる。コンプレッシブセンシングにより、シングルショット多次元情報取得におけるこの本質的なトレードオフが回避できるようになった⁷⁾。

コンプレッシブセンシングでは、上述のようにランダム性を含む計測プロセスが一般に要求される。そのため、空間光変調器などを積極的に利用した一画素イメージングは、デジタルオプティクスの黎明期にみられる計算機処理が光学設計に寄与するアプローチの極端な例ともいえる⁸⁾。一方で、ランダム性を含む計測プロセスを、散乱などの自然由来の光学現象で実装する試みも進んでいる⁹⁾。どちらのアプローチも示唆に富むが、現在は奇をてらっている側面もあり、光学素子が充実している可視光領域において、従来のイメージングシステムに対し大きなアドバンテージを示せてはいない。前者は光学系が大型化・複雑化する傾向にあり、後者はキャリブレーション精度が最終性能を著しく制限する。

一方で、ランダム性を伴わない回折や伝搬などの光学現象を利用したコンプレッシブセンシングが、デジタルホログラフィー、X 線 CT、MRI へ応用されている^{10,11)}。こ

東京大学大学院情報理工学系研究科
E-mail: horisaki@g.ecc.u-tokyo.ac.jp

れらは従来型ハードウェアを維持したまま、再構成アルゴリズムを修正するだけで再構成品質が向上する。そのため、コンプレッシブセンシングの今後の実用化は当該技術が入口となる可能性が高い。また、コンプレッシブセンシングを利用したイメージング技術の原理実証は、光学素子が充実している可視光領域で行われることが多い。今後は、非可視光領域でのデモンストレーションによって、その波長領域における従来法に対するアドバンテージを示す試みとその先にある実用化が進んでいくと予想される。

2.2 機械学習

光学計測や光制御において、順問題の記述とそれを踏まえた逆問題の解法の導出は長く人力で行われてきた。しかし、深層学習を含めた機械学習の発展により、これらをビッグデータの学習により自動化する試みが進められている。特に深層学習で用いられる畳み込みニューラルネットワークは、画像認識を目的に開発されてきた歴史的背景や多くの光学現象が畳み込みで記述できることから、イメージング技術との整合性が高い¹²⁾。そのため、深層学習を含む機械学習の導入は、デジタルオプティクスにおいて活発に進んだ¹³⁾。

例えば、散乱体を通したイメージングやフォーカシングに機械学習が適用され、光学系の簡略化が達成されている^{14,15)}。このアプローチでは、散乱体の出力から入力を求める逆関数を学習に基づく非線形関数でフィッティングしている。また、通常の計算機合成ホログラム (CGH) で前提となっている反復演算による生成アルゴリズムを畳み込みニューラルネットワークに置き換えた、高速な CGH の計算法が実現している¹⁶⁾。さらに一画素イメージングや被写界深度拡張の高機能化のために、光学系と再構成アルゴリズムをエンドツーエンドで協調設計するアプローチに関しても活発に研究が進められている^{17,18)}。機械学習により画像生成を短絡した超高速「イメージング」フローサイトメトリーもデモンストレーションされている¹⁹⁾。

深層学習の大きな課題として、学習データの準備コストや説明可能性が挙げられる。現在は深層学習の導入による性能向上のインパクトの大きさから、これらの課題解決に目をつぶる傾向にあるが、実用化において避けては通れない。前者に関しては敵対的生成ネットワークを用いた画像合成により、そのコスト緩和が期待できる²⁰⁾。後者に関しては、出力画像の信頼度マップを得られるベイズ畳み込みニューラルネットワークなどのアプローチが考えられる²¹⁾。これら情報科学分野で生み出されていく技術が、今後も引き続き光学を革新する種となることが予想される。

2.3 これから

ここまで述べてきたように、デジタルオプティクスの進歩は情報科学に促されてきた。この流れは今後も継続していくと思われる。一方で、例えば微細化加工技術の発展は著しく、メタサーフェスやメタレンズなどの新たな光学機能を発現する素子の研究が活発に行われている²²⁾。また SPAD (single photon avalanche diode) センサーやイベント方式センサーなどの新たなセンサー開発も進められている^{23,24)}。これらの光学デバイスを取り込むことによる、デジタルオプティクス、ひいては光学のさらなる革新を期待せざるを得ない。

文 献

- 1) 武田光夫：光学, **50** (2021) 34-38.
- 2) J. Goodman and R. Lawrence: Appl. Phys. Lett., **11** (1967) 77-79.
- 3) M. Takeda, H. Ina and S. Kobayashi: J. Opt. Soc. Am., **72** (1982) 156-160.
- 4) E. Dowski and W. Cathey: Appl. Opt., **34** (1995) 1859-1866.
- 5) J. Tanida, T. Kumagai, K. Yamada, S. Miyatake, K. Ishida, *et al.*: Appl. Opt., **40** (2001) 1806-1813.
- 6) R. Baraniuk: IEEE Signal Process. Mag., **24** (2007) 118-121.
- 7) A. Wagadarikar, R. John, R. Willett and D. Brady: Appl. Opt., **47** (2008) B44-B51.
- 8) M. Duarte, M. Davenport, D. Takhar, J. Laska, T. Sun, *et al.*: IEEE Signal Process. Mag., **25** (2008) 83-91.
- 9) S. Sahoo, D. Tang and C. Dang: Optica, **4** (2017) 1209-1213.
- 10) D. Brady, K. Choi, D. Marks, R. Horisaki and S. Lim: Opt. Express, **17** (2009) 13040-13049.
- 11) C. Graff and E. Sidky: Appl. Opt., **54** (2015) C23-C44.
- 12) Y. LeCun, Y. Bengio and G. Hinton: Nature, **521** (2015) 436-444.
- 13) G. Barbastathis, A. Ozcan and G. Situ: Optica, **6** (2019) 921-943.
- 14) R. Horisaki, R. Takagi and J. Tanida: Opt. Express, **24** (2016) 13738-13743.
- 15) R. Horisaki, R. Takagi and J. Tanida: Appl. Opt., **56** (2017) 4358-4362.
- 16) R. Horisaki, R. Takagi and J. Tanida: Appl. Opt., **57** (2018) 3859-3863.
- 17) C. Higham, R. Murray-Smith, M. Padgett and M. Edgar: Sci. Rep., **8** (2018) 2369.
- 18) V. Sitzmann, S. Diamond, Y. Peng, X. Dun, S. Boyd, *et al.*: ACM Trans. Graph., **37** (2018) 114.
- 19) S. Ota, R. Horisaki, Y. Kawamura, M. Ugawa, I. Sato, *et al.*: Science, **360** (2018) 1246-1251.
- 20) I. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, *et al.*: arXiv:1406.2661 (2014).
- 21) A. Kendall and Y. Gal: "What uncertainties do we need in Bayesian deep learning for computer vision?" *Proc. of the Conference on Neural Information Processing Systems (NIPS)* (Long Beach, 2017) pp. 5580-5590.
- 22) W. Chen, A. Zhu and F. Capasso: Nat. Rev. Mater., **5** (2020) 604-620.
- 23) C. Bruschini, H. Homulle, I. Antolovic, S. Burri and E. Charbon: Light: Sci. Appl., **8** (2019) 87.
- 24) G. Gallego, T. Delbruck, G. Orchard, C. Bartolozzi, B. Taba, *et al.*: IEEE Trans. Pattern Anal. Mach. Intell., **44** (2022) 154-180.