

ディープラーニングの製造への応用

先端技術総合研究所 大竹 守¹・日下 裕幸²・柏木 正浩^{3,4}
生産システム革新センター 黒澤 公紀⁵

Application of Deep Learning to Manufacturing

M. Otake, H. Kusaka, M. Kashiwagi, and K. Kurosawa

AI技術のひとつであるディープラーニングは近年急速な進歩を遂げ、様々な産業分野への応用が期待されている。当社では、ディープラーニングによる画像認識技術を半導体レーザーウエハの外観検査に応用し、独自のネットワーク構造を構成し学習データの選定を行うことで99%を超える判定精度を達成した。既にこの外観検査システムは半導体レーザーの製造工程に導入、安定的に運用されている。また、本技術は圧着端子の外観検査についても応用を進め判定精度99%以上を実現している。

Recently, Deep Learning which is one of the AI technologies has advanced rapidly and is expected to be applied to various industries.

We applied image recognition technology based on Deep Learning to the visual inspection of semiconductor laser wafers. By constructing our original network structure and preparing high quality dataset for learning, our visual inspection system achieved over 99% pass/fail judgement accuracy. This system has already been introduced into our semiconductor laser manufacturing process and has been stably operated.

This technology was also applied to visual inspection of crimp-type terminals and achieved over 99% judgement accuracy.

1. ま え が き

近年、Artificial Intelligence（以下AIと記す）技術の発展が多く産業で技術革新につながっている。特に有望なのが人間の脳神経ネットワークを模倣したディープラーニングである。2012年にはA. Krizhevskyらが発表したディープラーニングを用いたモデルAlexnet¹⁾が画像認識のエラー率を大幅に低減した。そして2015年にはMicrosoft社がResNet²⁾というモデルを発表し、人間のエラー率5%を下回る画像認識の精度を実証した。これはディープラーニングによりコンピュータが画像をデータとして活用できるようになったことを意味する。

さらに最近では研究が進み複数の物体を検知するようなモデルも提案されている^{3),4),5)}。提案されているモデルの一つであるSingle Shot Multibox Detector³⁾では1枚の画像から複数の対象を検出する処理を1秒当たりおよそ60回行うことが出来る。

また、与えられた環境において最大限の成果が得られ

るような解法を学習する強化学習という分野においてはディープラーニングを取り入れることで、囲碁のプロ棋士の棋譜を学習してプロ棋士に勝利したAlpha Go⁶⁾、囲碁の基本ルールだけを与え自己との対戦のみでそのAlpha Goに勝率9割の強さにまで成長したAlpha Go Zero⁷⁾などが登場した。これらの技術は様々な制御や自動化への応用が期待されている。

このように最新のAI技術（ディープラーニングなど）は特定のタスクに限定すれば人間を超える成果を出し得るということがわかり、ソフトウェア産業だけでなく様々な業界への応用が進められている。例えば教育業界では、AI技術を用いることで個人個人の勉強の習熟度に合わせ、教え方や問題を変える適応学習（アダプティブ・ラーニング）というサービスが打ち出され注目を集めている。また金融業界では為替や株式の値動きを予測するためにAI技術が使われ始めている。さらに製造業でも同様にAI技術による生産性の向上が期待されている。例えば部品の外観検査や、最適な加工条件の導出などへのAI技術の利用が考えられている。また、工場においても種々のセンサからのデータをAI技術で解析することにより故障や異常の前兆を検知し、未然に防ぐなどのシステムも考えられている。

当社でも外観検査にAI技術（ディープラーニング）の

1 解析技術研究部

2 解析技術研究部（工学博士）

3 解析技術研究部 グループ長（工学博士）

4 レーザフォトンクス研究部 部長（工学博士）

5 生産システム革新センター 副センター長

導入を進めており、これまでディープラーニングによる画像認識技術を用いた半導体レーザーエハ外観検査装置^{8),9)}を報告してきた。本稿では当社におけるディープラーニングの製造応用を紹介する。

2. ディープラーニングと判別理由の可視化

1956年のダートマス会議において人工知能 (Artificial Intelligence) という言葉が使われて以降数多くの技術が提案されている。近年最もよく使われているディープラーニングは1980年代に提案されたニューラルネットワーク

というモデルを基礎としている。ニューラルネットワークは人間の神経細胞であるニューロンをモデル化した人工ニューロンを基本単位としている。ニューロンと人工ニューロンを図1に示す。ニューロンは複数の樹状突起から入力される電気信号がある一定のしきい値を超えると、軸索から電気信号を出力する。この複数ある樹状突起のどの入力信号を重視するかは優先度が割り振られている。人工ニューロンにおいて入力を x_1, x_2, \dots, x_n 、優先度を重み w_1, w_2, \dots, w_n 、定常状態におけるバイアス電位を b とすると、総入力 u は各入力信号の重み w を用い、しきい値と比較する為にバイアスの状態も合わせて




図1 ニューロンと人工ニューロン
Fig. 1. neuron and artificial neuron.

$$u = w_1x_1 + w_2x_2 + \dots + w_nx_n + b$$

と表せる。軸索からの出力 y はこの総入力 u に応じて変化するので関数 f を用いて

$$y = f(u)$$

と表せる。 f は活性化関数と言われ、様々な関数 (ステップ関数, シグモイド関数, ランプ関数) が提案され使用されている (図2, 3, 4)。

この人工ニューロンをネットワーク状に組み合わせたものがニューラルネットワークである。(図5) さらにこのニューラルネットワークを多層に深く (Deep) したものがディープラーニングである。中でも全てのニューロンが結合しているものは全結合型と呼ばれている。

ディープラーニングは人間が行うような情報に基づく判別や予測が出来る。入力された情報から正しい出力 (判別や予測) を得るには、人工ニューロンの重みやバイアスを最適化する必要がある。一般的に最適化する過程を学習と呼ぶ。学習には非常に大量の既知の入出力のデータ、学習データが必要であり、またその学習に際しても非常に大きな計算量が必要となることから、提案された当初は本来の性能を発揮することは難しかった。しか




図2 ステップ関数
Fig. 2. step function.




図3 シグモイド関数
Fig. 3. sigmoid function.




図4 ランプ関数
Fig. 4. ramp function.




図5 ニューラルネットワーク
Fig. 5. neural network.

し近年では計算機のプロセッサ性能が向上し、インターネットによるデータ収集が容易になったことから、高精度に膨大な数の重みやバイアスの最適化が可能となり、ディープラーニングは人間を超えるような性能を実現し始めている。

ディープラーニングの応用として最も成功しているのが画像認識である。最近の画像は撮像デバイスが高解像度のためデータ量が非常に大きくなっており、全結合型のディープラーニングのモデルではパラメータ数が非常に多くなり、学習に長時間必要となる。そのため全結合型の手前にフィルタを畳み込むことで有力な情報だけを抽出する畳み込みニューラルネットワーク（Convolutional Neural Network, 以下CNNと記す）と呼ばれるモデルが良く用いられている。CNNでは学習の際にフィルタのパラメータも同時に最適化されることから、人間がフィルタを定義する必要はない。画像のサイズや対象に合わせて畳み込み層の層数や構造を最適化することで様々な画像において認識の精度が95%を超えるような結果が出ている。このCNNを製造業では外観検査工程などに応用することで、高精度な外観検査工程の自動化が実現できると期待されている。

製造業の製造工程においてディープラーニングを活用するために重要となるのが判別の理由を可視化することである。一般的な外観検査では定められた基準をもとに人間が外観の判別を行っている。CNNを用いた外観検査システムにおいても同様の基準に則って判別が行われる必要がある。そのためディープラーニングを用いたシステムが判別した際の理由についても妥当であるか開発時に確認が必要となる。CNNの判別理由を理解しようという研究は以前から行われている^{10),11)}。主には畳み込み層で抽出された特徴のうち、どの特徴を重視して判別しているかを可視化している。この判別に用いた特徴を強調した画像はヒートマップと呼ばれる。図6は圧着端子の加締め部に異常がある際の画像をCNNで判別した際に出したヒートマップの一例である。人と同じ上手く加締められていない部分の特徴から判断していることがわか



図6 ヒートマップによる判別根拠の可視化
Fig. 6. Visualization of judgement basis of AI by heat map.

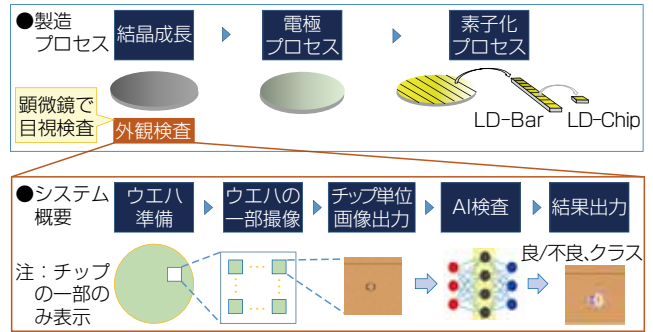


図7 半導体レーザウエハ外観検査システム概要
Fig. 7. Outline of visual inspection system of semiconductor laser.

る。このようにヒートマップを用いることで、CNNの判別が基準に則って判別しているのか確認が出来る。弊社では製造工程に導入する全てのCNNにおいて判別の可視化を導入している。

3. ディープラーニングの製造応用例

当社でのディープラーニング応用事例を紹介する。

3.1 半導体レーザウエハ外観検査システム

本項では、グループ会社であるオプトエナジー社にて製造しているファイバーレーザ用高出力半導体レーザ製造工程への導入事例を紹介する（図7）。

半導体レーザの製造工程においては最初の結晶成長工程後に行われている外観検査が全体の歩留まりを左右する非常に重要な工程である。そのため単なる良否の判別でなく、良品4種類、不良品3種類の計7種類の判別を実施している。高出力の半導体レーザでは僅かな異常や欠陥が大きく影響するため、知識と経験に基づいた高度な判断が要求され、従来のパターンマッチングによる自動化が出来ずに目視で外観検査を行っていた。今回、ディープラーニングを用いることでこの高度な判断の自動化を行った。

半導体レーザウエハ外観検査システムを構築するにあたり、入力画像サイズは微細な異常も検出できるように10⁶ pixelオーダの高解像度なものとした。モデルについては様々な畳み込み層を持つ独自の構造とした。学習デ

ータについては判別すべき種別の下でさらに細かい種別分けを行い、それぞれの種別での学習データの分布を管理している。各種別の画像はオプトエナジー社の協力により収集したうえで、画像反転などの一般的なデータ増強を行い十分な学習データ数を確保した。ディープラーニングにおいてこのような学習を行う際、一般的な計算機では計算時間が長くなることから、行列演算を得意とする高性能なGraphics Processing Unit（画像処理装置のこと、GPU）を搭載したNVIDIA社製DGX-1を用いた。学習により完成したディープラーニングを用いた半導体レーザーハ外観検査システムは精度検証において99%を超える良否判別精度を実現した。現在このシステムは製造工程に導入、運用されている。直近の複数ロットにわたる良否判別精度を箱ひげ図にしたものを示す。（図8）箱が全て98%の上に位置し、複数ロットにわた




図8 製造工程にて運用している半導体レーザーハ外観検査システムにおける良否判定精度の推移
Fig. 8. changes in judgment accuracy of visual inspection system of semiconductor laser operated in manufacturing process.

り高い良否判別精度を維持できていることがわかる。その平均は99%を超えており、従来の外観検査を行っている人間の判定精度を上回る状態で運用されている。

3.2 圧着端子外観検査.

本項ではディープラーニングの別の外観検査への導入例として、電気配線の接続に用いる圧着端子の外観検査システムを紹介する。現在は自動機による電気配線端末への端子圧着処理後、圧力検査システムを用いて良否の自動判定が行われているが、圧力検査では判別しきれない不良があることから目視判定もあわせて行っている（図9）。また市販の画像検査装置システムを新たに導入検討しているが、閾値設定が複雑なため判定精度の維持が難しく異常が発見できないケースが存在している。

今回、ディープラーニングによる自動化の実現可能性を検証するため、ある1種類の圧着端子（圧着端子A）を対象としてディープラーニングによる画像判別を実施した。検証には一般的な画像認識モデルを使用した。半導体レーザーハ外観検査システムと同様に、学習データには各種別内での細分類、整理、画像反転などによるデータ増強処理を行い、十分な数の画像を用意した。学習にはNVIDIA社製のDGX-1を使用した。

判別精度の検証ではテスト用画像5200枚の判別を行い、99.96%と非常に高い精度で種別判別が行えていることを実証した（表1）。

別の種類の圧着端子（圧着端子B）についても検証した結果、判別精度100%を実現した。（表2）現在は製造工程への本格導入にむけて自動判別システムの開発を進めている。




図9 現行の圧着端子圧着工程
Fig. 9. current crimping process.

表2 圧着端子B-判定結果
Table 2. judgement result of crimp-type terminal B.

		AI判定正解率 100%					再現率
		クラス 1	クラス 2	クラス 3	クラス 4	クラス 5	
正解	クラス 1	68	0	0	0	0	100.00%
	クラス 2	0	48	0	0	0	100.00%
	クラス 3	0	0	48	0	0	100.00%
	クラス 4	0	0	0	48	0	100.00%
	クラス 5	0	0	0	0	48	100.00%
適合率		100.00%	100.00%	100.00%	100.00%	100.00%	

表1 圧着端子A-判定結果
Table 1. judgement result of crimp-type terminal A.

		AI判定正解率 99.96%								再現率
		クラス 1	クラス 2	クラス 3	クラス 4	クラス 5	クラス 6	クラス 7	クラス 8	
正解	クラス 1	2399	0	0	0	0	0	1	0	99.96%
	クラス 2	0	400	0	0	0	0	0	0	100.00%
	クラス 3	0	0	400	0	0	0	0	0	100.00%
	クラス 4	0	0	0	400	0	0	0	0	100.00%
	クラス 5	0	0	0	0	400	0	0	0	100.00%
	クラス 6	0	0	0	0	1	399	0	0	99.75%
	クラス 7	0	0	0	0	0	0	400	0	100.00%
	クラス 8	0	0	0	0	0	0	0	400	100.00%
適合率		100.00%	100.00%	100.00%	100.00%	99.75%	100.00 %	99.75%	0.00%	

4. む す び

本報告では、当社のディープラーニングを用いた画像認識技術の適用例を紹介した。高出力半導体レーザーの製造工程においてディープラーニングを用いた半導体レーザーウエハ外観検査システムを導入済みである。長期にわたり良否判定精度は99%を超え、従来検査を行っている人間の判定精度を上回る状態で既に運用されている。本技術は圧着処理後の圧着端子外観検査にも応用し、2種類の圧着端子に対する検証ではクラス判別精度それぞれ99.96%、100%と非常に高い精度で判定が行えた。今後もディープラーニングの要素技術を積極的に取り入れ、ものづくりに適用していく予定である。

参 考 文 献

- 1) A. Krizhevsky, I. Sutskever, G. E. Hinton, "ImageNet classification with deep convolutional neural networks" In NIPS, pp. 1106-1114, 2012.
- 2) Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. Deep residual learning for image recognition. CoRR, abs/1512.03385, 2015.
- 3) W. Liu, D. Anguelov, D. Erhan, C. Szegedy, S. E. Reed, C. Fu, and A. C. Berg. SSD: single shot multibox detector. In ECCV, pages 21-37, 2016.
- 4) J. Redmon, S. K. Divvala, R. B. Girshick, and A. Farhadi. You only look once: Unified, real-time object detection. In CVPR, pages 779-788, 2016.
- 5) S. Ren, K. He, R. B. Girshick, and J. Sun. Faster R-CNN: towards real-time object detection with region proposal net-works. TPAMI, 39 (6) : 1137-1149, 2017.
- 6) David Silver, Aja Huang, Chris J. Maddison, Arthur Guez, Laurent Sifre, George van denDriessche, Julian Schrittwieser, Ioannis Antonoglou, Veda Panneershelvam, Marc Lanctot, Sander Dieleman, Dominik Grewe, John Nham, Nal Kalchbrenner, Ilya Sutskever, Tim-othy Lillicrap, Madeleine Leach, Koray Kavukcuoglu, Thore Graepel, and Demis Has-sabis. Mastering the game of Go with deep neural networks and tree search. Nature, 529 (7587) : 484-489, January 2016.
- 7) David Silver, Julian Schrittwieser, Karen Simonyan, Ioannis Antonoglou, Aja Huang, Arthur Guez, Thomas Hubert, Lucas Baker, Matthew Lai, Adrian Bolton, Yutian Chen, Timothy Lillicrap, Fan Hui, Laurent Sifre, George van den Driessche, Thore Graepel, and Demis Hassabis, Mastering the game of go without human knowledge. Nature, 550:354-359, 2017.
- 8) 黒澤 公紀 "フジクラにおけるAI(深層学習)の取組と高出力半導体レーザーウエハ概観検査への適用" GTC-Japan, 2017.
- 9) H. Kusaka, "Practical Application of Deep Learning in Smart Factory : Visual Inspection System of Semiconductor Laser" GTC-San Jose, 2018.
- 10) B. Zhou, A. Khosla, L. A., A. Oliva, and A. Torralba. Learning Deep Features for Discriminative Localization. CVPR, 2016.
- 11) R. R. Selvaraju, M. Cogswell, A. Das, R. Vedantam, D. Parikh, and D. Batra, Grad-cam: Visual explanations from deep networks via gradient-based localization. In arXiv: 1610.02391v3, 2017.