

既存の食品加工・検査ラインに組み込み可能な AI 異常検知システムの実装

— 研究開発・実装・販売・実利用を通じたデータ活用サイクルの構築 —

善甫 啓一^{a,b} 石田 尚^c

^a 筑波大学 システム情報系 知覚拡張システム研究室 ^b Xtrans tech 株式会社 ^c 株式会社イシダテック

要 約

本稿では、大学、装置メーカー（BtoB ビジネス事業者）、顧客（BtoC ビジネス事業者）の3社が連携することで、AIを組み込んだ食品製造ライン用検査装置の開発から実装を事業として推進した事例を紹介する。既存の製造ラインには、目視での検査や、X線画像や可視光画像による検査装置が導入されているが、人手を要することや、定量的・定型的な検査が困難である対象製品が存在することが課題であった。そこで、現状のアセットを可能な限り活用しつつ深層学習型のAIを組み込んだ検査装置を開発した。開発の過程では、製品の検査データを元に疎結合することで、TRL（Technology Rediness Level: 技術成熟度レベル）を一元的・段階的に進捗させ事業を成熟させるような従来の手続きではなく、それぞれの立場で分担し事業を推進した。

1. データ活用サイクル

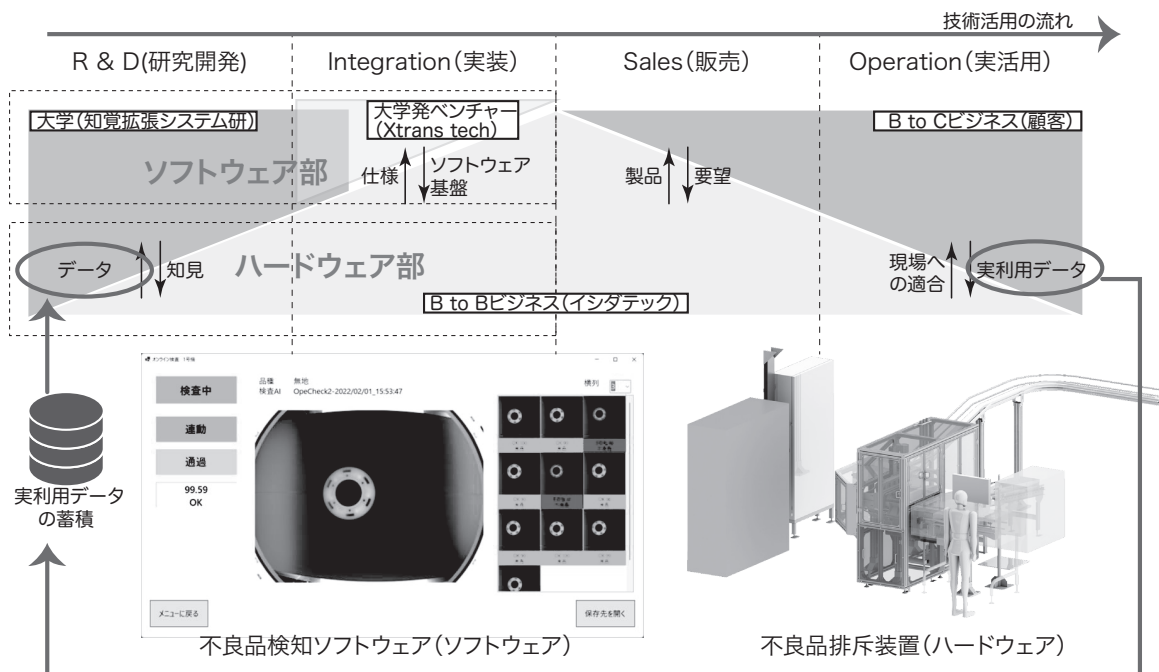


図1 本取り組みにおいて紹介する異常検知システムのソフト、既存のラインに組み込み可能な不良品排斥装置および顧客現場における実活用を通じたデータ活用サイクル

a ぜんぼ けいいち
●住所 [〒305-8573] 茨城県つくば市天王台 1-1-1
●E-mail zempo@iit.tsukuba.ac.jp

c いしだ ひさし
●住所 [〒425-0004] 静岡県焼津市坂本 335
●E-mail info@ishida-tec.co.jp

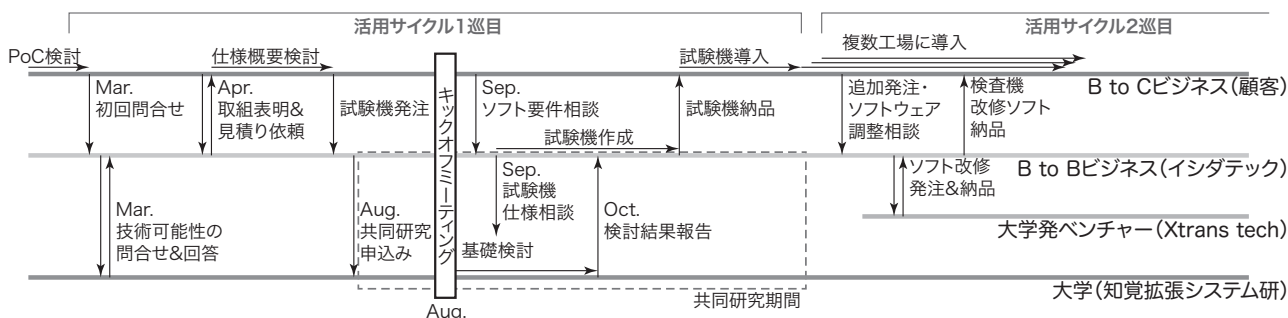


図2 本取り組みにおけるデータ活用サイクルの1巡目から2巡目序盤までのタイムライン

2. 背景・動機

食品製造事業者は、あらゆる組織レベル・拠点で公的・私的な基準を設け、安全な食品製造のための品質管理を運用している。その中でも、検品工程は不良品の出荷を防ぐため、製品の水準を検査する工程であり、品質管理の要である。現在、多くの食品工場における製造ラインでは、製品水準を担保する規格を設けて、検査することで、不良品の検出に取り組んでいる。例えば、パッキン片や気泡など異物の混入を検出するためのX線撮像や、汚れ・傷・梱包漏れなどの外観検査をするための可視光撮像を行うラインロボットが導入されている食品工場は多くある。

しかし、これらのラインロボット単体では検出が不可能な不良があり、多くの食品工場ではラインロボットによる検査に加えて従業員の目視による判断工程が必要とされている。これにより単純作業に伴う過剰なコストが問題視されていた。本取り組みの背景には、検品工程の品質向上および省力化を達成したい製造現場の課題があった。

著者・石田の所属する(株)イシダテックは、加工や搬送などの工程を強みとしたラインロボットを取り扱っており、食品工場を有するメーカーを主な顧客として装置の開発・設計段階から受注生産している。顧客企業からの要望を元に、著者・善甫の所属する筑波大学・知覚拡張システム研究室と共同で装置開発を行った。図1にそれぞれの役割分担及び相互関係を示す。顧客からの要望及び試験データを起点として、研究開発(I. R&D)、組み込み(II. Integration)、販売(III. Sales)、現場稼働(IV. Operation)を通して、識別機開発の源泉となるデータを収集・活用する(以降、この流れを、データ活用サイクルと称する)。

筆者らは、このデータ活用サイクルを通して、既存の食品加工・検査ラインに組み込み可能な異常検知システムを実装した。このシステムには、不良品が検出された際に食品加工ラインから排斥する機能とともに、不良品の判断を行うAI識別機能も内蔵されている。

図2にデータ活用サイクルの1巡目から2巡目序盤までの時系列を示す。本取り組みは、現場の要望および試験データを元に顧客自らが基礎検証を行った深層学習型AIをPoC(Proof of Concept)として、主としてイシダテックが機械装置開発を行い、主として筑波大学がソフトウェア基盤部分を担当した。

3. 技術的な問題点

3.1 検査装置における問題点

これまでの画像を用いた異常検知装置は、パターンマッチング方式が主流であり、その実は、予め良品とみなされる形状や色調などを、光学計測や磁気学計測といった計測系を用いて測定可能なデータに変換し、計測・撮像されたデータから、事前に設定した特定の指標やその組み合わせに対してしきい値処理を行い、異常検出を行っている。

実例としてイシダテックでは、これまでに重量、温湿度、可聴音や超音波の発生、伝達度合いや反射、光の透過量、液体の導電率、物体表面の硬さや柔らかさ等の計測系をインラインで計測し、これを定量的に評価して良品のみ製造ラインに残るようにするといったラインロボット・食品製造ラインを実装・構築してきた。

図3は、スケソウダラのすり身を、実用されている装置において世界で最も優れた精度で10kg分充填し、フィルム包装する「充填包装機」である。食品のようにある程度非定形であっても、上述の通り定量的に計測可能であれば、しきい値に幅をもたせることでその差を吸収しつつ、取り扱いが可能である。この充填包装機にも重量データ、圧力データのフィードバック制御が使用されている。顧客・現場の要望を汲み取り、現場への適合・データ収集を繰り返すことで、高品質な充填精度を達成し、世界各地に導入されている。

ところが、良品と不良品を従来の定量的な数次元のデータからは判定ができないもの、例えば同じ色味、サイズであるが一方は良品であり、もう一方は不良品であ




図3 すり身充填包装期の3Dモデルと出来上がり製品の例¹

るといった製品は一般的に前述の方法での良否の判定が困難である。

さらに、産業的に制御可能な品質に対するしきい値の調整は、工場運営レベルでは非常に難しいものも存在する。例えばグレースケールの画像上の影のように境界の明確化やパターン化が難しいものである。このような対象物は、装置的な異常検知が難しく、人の目視に頼らざるを得なかった。

自動車部品や産業用精密部品などの検知用に深層学習型のAIは市中にあるが、食品のような非定型物を学習および判定するのにそぐわないことに加え、インダテック単体では技術開発が困難であった。

3.2 AI実装上の問題点

良品であるか不良品であるかを識別するAIを構築するためには、それぞれの模範となる例（教師データ）が数多く必要となる。しかし、食品製造事業では品質維持・管理のため安全寄りの運用をしていることにより、良品の画像は数多く発生するが、得られる不良品のデータが極端に少ない点が問題である。

また、不良品の分類基準も装置が一義的に扱うほどには明確に定義されていないことが多く、良品・不良品のように2値化した分類がそぐわない問題であることが多い。図4に、良品に対して発生しうる不良品を模して作成した検査画像の例を示す。図4（上段）は、X線の透過度が異なる物体が製品内に存在している様子がX線画像内に写っており、2値化した分類が適切であるが、図4（下段）は、セロハン包装の捻じり度合いに起因した不良品であり、2値化した分類が困難である。

この様に起こりうるすべての不良品の分類を想定し、それぞれの分類に対応する不良品の教師データを事前に準備することは、食品工場の生産ラインに導入する上で、現実的ではない。




図4 発生しうる不良品を模した検査画像

（上段）油脂もしくは乳製品のX線画像の例
（下段）セロハン包装された製品の可視光画像の例

4. 後付け可能なAI異常検知システム

4.1 グレーゾーン出力を許容したAI識別機

前述のように、完全な2値分類が困難な問題の識別を行い、片方の教師データが極端に少なくとも分類を行う必要がある。そこで、良品とも不良品とも高い確度をもって推定できない画像に対して、「グレー判定」を出力する識別機を用いる。このグレー判定と識別された画像に対しては、従来どおり従業員による判断およびデータアノテーションを行うことで、上記の問題を解決する。識別用AIには、X線検査画像から不良品に固有の特徴を高い精度で検出し、その特徴の有無で良品と不良品を分類する能力が求められる。このような画像の分類問題に対しては畳み込みニューラルネットワーク（Convolutional Neural Network, CNN）が研究され、非常に大きな成果を上げている。

モデルの設計と学習にかかるコストの観点から、CNNを用いて問題を解決する際には、典型的な画像分類問題に対して高い精度を有する学習済みのCNNモデルのファインチューニングを行い、対象の分類問題に適応させることが広く行われている。ファインチューニングは学習済みモデルの出力側にある全結合層のみを再学習するものであり、画像から特徴を抽出する畳み込み層をそのままにしつつ、抽出された特徴から入力画像を分類する全結合層のみを新たなデータセットで学習させることで、少ないデータセットや学習時間での精度の高い分類を目的としている。従って、新たな分類問題を考え

¹ 日本かまぼこ協会ウェブサイトより引用
<https://www.nikkama.jp/>（アクセス日：2022/4/22）

際には、まず学習済みモデルのファインチューニングによる検討が、経済的に合理性がある。

図5にCNNを搭載した識別用ソフトウェアの外観を示す。X線画像、可視光画像など画像の種類を問わず学習し、良品、不良品、もしくはグレー判定を出力する。製造ライン上に組み込まれている従来型のX線画像検査機や可視光画像検査機の画像保存先を、NAS(Network Attached Storage)にすることで、本ソフトウェアによる監視・判断・PLC判断の出力が可能となる。




図5 識別用ソフトウェア v1 インターフェイス

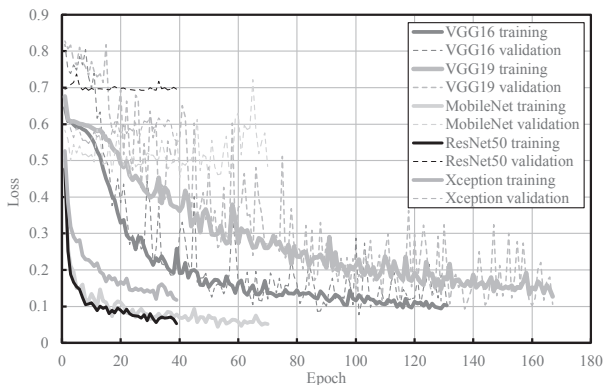


図6 各モデルでの loss 対エポック数。同色の線は同じモデルについての loss 値を表し、太線が教師データに対して、細線が検証データについて表す

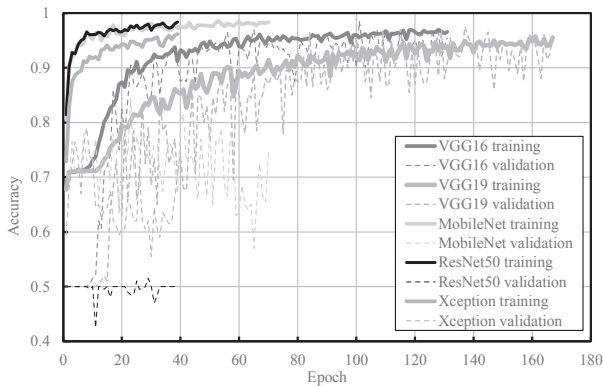


図7 各モデルでの accuracy 対エポック数。同色の線は同じモデルについての accuracy 値を表し、太線が教師データに対して、細線が検証データについて表す

4.2 AI部分の性能評価

4.2.1 モデルの選定

CNNに関して、いくつかの ImageNet¹⁾ データセットで学習済みのモデルをファインチューニングし、顧客メーカーが製造・販売を行う製品の食品画像のX線検査画像の不良品分類問題に適したモデルや、学習に必要なとなるハイパーパラメータの検討を行う。

ImageNetの画像データセットに対する事前学習済みの VGG16²⁾、VGG19²⁾、ResNet50³⁾、MobileNet⁴⁾、Xception⁵⁾ モデルを取り上げ、これらをファインチューニングし、推論の精度の差を確認した。学習は入力バッチサイズを16、最適化アルゴリズムを確率的勾配降下法とし、学習率を 1×10^{-4} として、validation loss の値の収束を学習の終了条件とした。Loss 対エポック数のグラフを図6、accuracy 対エポック数のグラフを図7に示す。VGG16とVGG19以外のモデルはlossとaccuracy共にtrainingとvalidationでの乖離が大きいの。これはモデルが学習データに過剰にフィットして汎化性能が低下する、過学習の状態にあると考えられる。過学




図8 各バッチサイズでの loss 対エポック数。同色の線は同じバッチサイズについての loss 値を表し、太線が教師データに対して、細線が検証データについて表す




図9 各バッチサイズでの accuracy 対エポック数。同色の線は同じバッチサイズについての accuracy 値を表しており、太線が教師データに対して、細線が検証データについて表す

表 1 バッチサイズ毎の 1 エポックの学習にかかる時間

バッチサイズ	16	32	64	128
学習時間 [s/epoch]	15	14	14	14

習はデータセットが小さいか、あるいは問題の複雑さに対して複雑すぎるモデルを用いると発生すると言われていた。したがって、データセットを大きくした場合には過学習の傾向が抑えられる可能性がある。

本検証においては VGG16 が validation accuracy の最大値 0.985 を達成した。また、モデルのレイヤー数が大きくなるにつれて validation accuracy が下がる傾向が見られた。よって、今回のデータセットに対しては簡単なモデルのほうが適している事がわかる。VGG16 よりもレイヤー数の少ないモデルにおける挙動についても検討が必要であるが、実用上、十分な精度であることが確認できる。

4. 2. 2 パッチサイズの検討

モデルの学習において、教師データセットをいくつかのサブセット（バッチ）に分け、それを入力として学習させる方法が一般的に用いられている。サブセットに含まれる入力画像の数をバッチサイズと呼ぶ。学習の過程でモデルのパラメーターはサブセットごとに更新されるため、小さいバッチサイズを選択すると、パラメーターの更新においてそこに含まれる各入力画像の影響を大きく受ける一方で、パラメーターの更新にかかる計算コストが大きくなるとされている。ここでは、モデルの比較において最も良い成績であった VGG16 について、バッチサイズを 16、32、64、128 とした場合の学習の進捗を確認した。なお、最適化アルゴリズムを確率的勾配降下法とし、学習率を 1×10^{-4} とした。Loss 対エポック数のグラフを図 8、accuracy 対エポック数のグラフを図 9 に示し、各バッチサイズでの 1 エポックの学習にかかる時間を表 1 に示す。

その結果、バッチサイズが小さいほど学習の進捗が早いことが確認できた。また、学習にかかる時間はバッチサイズに対して変化は微小であった。これは今回の学習がファインチューニングであり、モデル全体のパラメータを学習するよりも計算コストが少なく、パラメータ更新自体にかかる計算時間よりもその他のオーバーヘッドが支配的であった可能性がある。

学習にかかる計算時間を短くする方法としては、学習の初期においては大きな学習率を選び、学習が進むにつれて学習率を小さくする手法が一般的であったが、それに対




図 10 排斥装置のシステム




図 11 AI 検査デモ装置

してバッチサイズを学習が進むにつれて大きくする手法が提案されている⁶⁾。バッチサイズを大きくすることは学習率を小さくすると同様の効果があり、したがって学習率を変化させるよりもバッチサイズを大きくする方が計算時間の短縮に効果があるとされている。今後、ファインチューニングでなくモデル全体のパラメーターの学習を行う場合には、学習時間の短縮も考えられる。

4. 3 AI を組み込んだ排斥装置

図 10 に有彩色カメラ、X線検査カメラなどの何らかの計測系インプットから、最終的に排斥装置が動作する装置動力系までの流れを示す。計測系により認識されたデータは、NASに代表される記憶媒体に記録される。この媒体は、多くの場合、通常製造現場にある既存検査機と接続されている。データを既存検査系と同時に、AIソフトウェアが搭載されたPCに振り分け、AIによる検査を行う。

検査結果は、PLCに代表されるライン制御系に定義された信号として伝達され、規定のロジックのもと、例えば既存検査系がOK判定でAIがNGであれば排斥といった具合に、装置の動力系と操作者用のタッチパネルなどの表示系に連携する。図 11 にデモ装置、図 12 に現在稼働している排斥機や表示機の 3D モデルを示す。

なお、PC および PLC は保護されたネットワークでリモート接続可能であり、これにより効果的なデータ活用と企業間連携が可能となった点も特筆する。




図12 カートン入り製品向け検査・排斥装置

4.4 AIを組み込んだ排斥装置の評価

イシダテックのラインロボットは、導入する生産拠点の製品とラインの特性、またその運用状況に合わせた装置の設計・製作を行い顧客の製造ライン内に組み込まれている。現在、X線検査画像の再検査用に装置#1と#2、またセロハン包装された製品の可視光画像検査装置として装置#3を導入・稼働しており、次のような実績がある。

- ・ AI部分は80msに1画像の処理が可能
- ・ 1日40万個以上の製品を検査
- ・ 装置稼働開始月(経過時間)
装置#1: 2020年3月(2年2ヶ月)
装置#2: 2021年11月(6ヶ月)
装置#3: 2021年10月(7ヶ月)

これらのAIを組み込んだ排斥装置は、以下の特徴を有する。

多品種対応の可能性

品種に応じてAIを切り替える必要があるため、多品種に対応している。装置#1と#2は、自動的にライン上の製品に応じた学習済みのAIの切り替えが可能である。

構成の柔軟性

不良品が検出されたら、停止措置のみを行う製造ラインにおいては、既存ラインの工事は不要であり、監視上PCの設置及びPLC信号用ネットワークのみへの接続だけで実装が可能である。また、既存ラインに新たな計測系・排斥装置を組み込んだ実装も可能である。

情報の集約性

生産数と良品判定数、不良判定数表示を操作盤上に一覧表示することで、現場管理者が複数の装置を確認して回ることなく、状況の把握が可能である。これにより、微調整が生産装置の不調に対して、現場作業員が素早い気づきを得ることができる。

5. データ活用サイクルの必要性

以上、筆者らが構築したデータ活用サイクルの実例を紹介した。学術界の立場として、データ活用サイクルの構築により、現地・現物のデータが得られることや、技術に対応する真のニーズが理解できる点が利点として挙げられる。BtoBビジネス事業者としては、装置を納入するだけの伝統的なものづくり産業ではなく、データを通じた顧客と価値共創を行うサービス事業への発展可能性が利点である。これにより、サービス要件が確定する前段階から顧客のニーズに対して、柔軟な対応が可能となる。

図13にTRL (Technology Readiness Level; 技術成熟度レベル)、魔の川、死の谷を示す。TRLは、1974年にNASAにより提唱された概念であり、特定の技術の成熟度の評価を行うことが可能な定量尺度であり、基礎研究から応用研究・開発を経て、実証や事業化へ技術が成熟してゆく流れを表している。また、魔の川や死の谷は技術経営分野で用いられる概念であり、それぞれ、基礎研究から製品化を目指す開発段階へ進める際の関

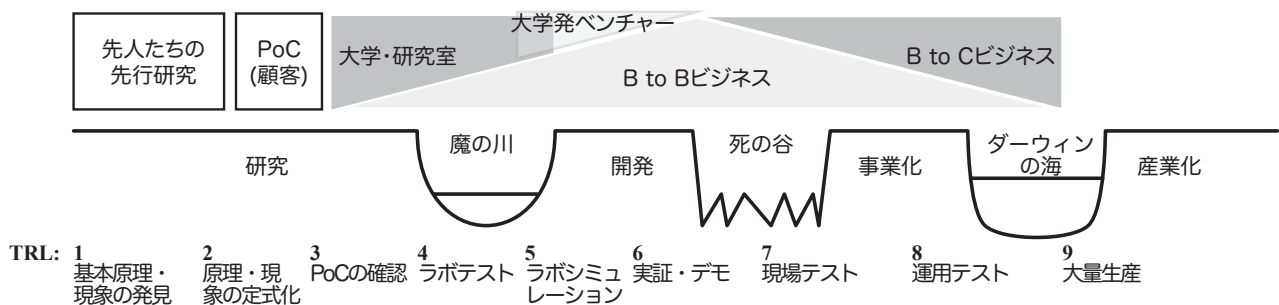


図13 TRLそれぞれの段階、魔の川、死の谷および、本取り組みの役割分担

門、開発段階から事業化段階へ進めるかどうかの関門である。それぞれの段階で求められる主体的な実行者の能力やモチベーション、必要コストや探索すべきニーズが異なるため、技術成熟手続きにおいては頻繁につまずきが起こる。

本取り組みは、大学、装置メーカー（BtoB ビジネス事業者）、顧客（BtoC ビジネス事業者）の3社がデータを元に疎結合した事例である。死の谷や魔の川に対して、TRLを一元的・段階的進捗させ事業を成熟させるような従来の手続きではなく、それぞれの立場で分担し事業を推進した。このようなオープンイノベーションを意識したデータ連携がAIを活用したビジネスにも今後求められるであろう。

謝辞

今回の取り組みについて、高い課題意識を持ち、協力的にデータの連携・取り組みの推進を図ってくださった株式会社明治小西 信行氏（技術研究所次世代ものづくり研究部装置開発グループ）に深い謝意を示す。

参考文献

- 1) Jia Deng et al., "ImageNet: A large-scale hierarchical image database," 2009 IEEE Conference on Computer Vision and Pattern Recognition, Miami, FL, 2009, pp. 248-255.
- 2) Karen Simonyan and Andrew Zisserman, "Very deep convolutional networks for large-scale image recognition," arXiv:1409.1556 [cs.CV], 2014.
- 3) Kaiming He, Xiangyu Zhang, Shaoqing Ren and Jian Sun, "Deep Residual Learning for Image Recognition," arXiv:1512.03385 [cs.CV], 2015.
- 4) Andrew G. Howard et al., "MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications," arXiv:1704.04861 [cs.CV], 2017.
- 5) François Chollet, "Xception: Deep Learning with Depthwise Separable Convolutions," arXiv:1610.02357 [cs.CV], 2016.
- 6) Samuel L. Smith, Pieter-Jan Kindermans, Chris Ying and Quoc V. Le, "Don't Decay the Learning Rate, Increase the Batch Size," arXiv:1711.00489 [cs.LG], 2018.

