



2020
SUMMER **VOL.4**

“情報循環”

IoTや5Gなどの最新技術によって、都市に点在するあらゆるモノがネットワークで繋がると、都市全体はあたかも生態系のシステムのようになり、それはまるで、自然界における物質循環を見ているようです。都市では日々、いわゆるビッグデータといったさまざまな情報が発生しています。自然界に例えるならば、森の中に積もった落ち葉や、山肌を流れる雨水のようなものです。それらが微生物に分解され植物の最適な養分となるように、収集された情報もAIによって分析され有益な情報となり、電気やガスといった各都市サービスに最適な形で還元されています。こうしたいわゆるスマートシティの実現によって、これまで不可能だったアプローチによるサービスが可能となり、社会や産業、人の暮らしまでもが大きく変化しようとしています。モノとモノとが繋がり、その間を情報が循環していく世界。自然界での生態系と同様、健全なエコシステムとして機能させていくことが、これからのエンジニアには求められています。

ものづくりを支える技術情報誌

エンジニアリング ENGINEERING REPORT

研究と試行を重ねて成功を掴む!
最新技術・手法による組込みシステムへのアプローチ

Engineering Report Vol. 4発行にあたって ————— 01

特集1 AIは使いどころが肝心!
マシンビジョンにおけるAI活用 ————— 02

特集2 従来のシステムをマイクロサービスに再構築せよ!
組込み分野におけるクラウドネイティブの取り組み ——— 06

特集3 ソフトウェア品質はコントロールできる?
ODC分析手法の導入 ————— 08

Engineering NEWS

自動決済・店舗マーケティングソリューション
次世代型ショーケース ————— 10

Canon

キヤノン IT ソリューションズ株式会社

Engineering Report Vol. 4 発行にあたって

昨冬につづきEngineering Report Vol.4をお届けすることになりました。

巻頭言の執筆にあたり、私が注目している“スマートシティ”についてお話ししたいと思います。

現在、世界中の都市で急速に“スマートシティ化”が進められており、数多くの実績が上がっています。しかし、一言で“スマートシティ”といっても、具体的にイメージするのが難しいと思う方もいらっしゃるのではないでしょうか。世界で取り組まれているスマートシティの事例としては、都市部における交通渋滞の緩和、ごみ収集車や都市バスのルート最適化、公共無線LANスポットの設置などが挙げられます。どの事例も都市が抱えていた課題を、IoTやビッグデータといった最新技術を駆使して解決しています。つまり、スマートシティとは都市におけるあらゆるITソリューションの集大成であると言えます。

わが国においては「次世代エネルギー・社会システム協議会」が設置され、横浜市、京都府、北九州市、豊田市において実験が行われているものの、まだまだ本格的な実用化には至っていないのが現状です^[1]。それは日本の都市インフラが既に質の高いサービスを提供できていることから、他国に比べるとスマートシティ化に際して求められる要求が高く、結果として導入ハードルが高くなっていることが要因の一つと考えられています。しかしながら、そうした日本の各都市も高度経済成長期に集中整備された都市インフラの一斉老朽化、少子高齢化による労働力不足が懸念されており、将来的にはスマートシティ化が必須と言われています。

スマートシティの実現に向けては、IoT、ロボット、AI、ビッグデータ、画像認識技術、セキュリティといった様々な技術が必要になります。車や家電、産業機器、様々な日用品など、モノとモノとがネットワーク上で繋がり情報交換するIoTは、調査・確認などに費やす時間を短縮し、個々の端末に必要な情報を素早く共有することができます。また、IoTによって収集された膨大なビッグデータを使ってAIを学習させ、人から人へ伝えられていた職人技を再現し、それまで不可能だった高度な分析や予測を可能にします。更に、画像認識技術の発達とロボットの自律化によって省人化を超えて人間よりもサービスが高度化し、人間の業務負荷が軽減されることも考えられます。

当社はスマートシティに必要な要素技術を多く保有しており、お客様の課題を解決する高い技術力と、様々な分野の開発現場で積み重ねた確かな実績があります。今回はその中でも、画像処理、クラウド、品質検証に関して技術やソフトウェアの品質向上に向けた私たちの活動を紹介したいと思います。

私たちキャノンITSは、共想共創カンパニーとしてスマートシティの実現の為に、私たちの持っている技術を提供して行きたいと考えています。

参考文献

[1] スマートシティの事例(シスコ)

https://www.soumu.go.jp/main_content/000447791.pdf
総務省ホームページ 2016

キャノンITソリューションズ株式会社
執行役員
エンベデッドシステム事業部長

谷口 肇



【表紙の写真】

富士山は神奈川県以西であれば様々なところで顔を見られますが、桜と富士山の膝から上のペアとなると意外に場所が限られます。静岡県が富士五湖のほうまで足を延ばすしかないようです。なるべく近郊でと、ネットを彷徨い続けやっと見つけ出したこの場所は東名のインターから15分ぐらいの隠れたスポット。ただ、春先の霞がかかり残念な絵になってしまいました。菜の花と河津桜が咲く空気の澄んだ2月下旬あたりがベストのようです。

撮影地 神奈川県足柄上郡大井町篠塚 令和2年4月撮影

AIは使いどころが肝心! マシンビジョンにおけるAI活用

キヤノンITソリューションズ株式会社
エンベデッドシステム事業部
技術推進課

橋本 隆之



1. はじめに

製造業が取り組むFA(Factory Automation)では、ルールベースの画像処理を用いたマシンビジョンが現在も利用されています。マシンビジョンは、文字通りマシン(ロボットを含む)のビジョン(視覚処理)を担う技術であり、対象物を鮮明に捉えるための撮像技術や、撮像された画像からマシンに必要な情報を抽出する画像処理技術が中心となります。撮像技術は、可視光のカメラだけではなく、近赤外光のカメラやハイパースペクトルのカ

メラなど人間の視覚を超える技術が登場しています。画像処理技術は、ディープラーニング技術の登場により、従来のルールベースの画像処理では実現できなかった視覚処理において、AI活用が急速に進んでいます。

ここでは、当社が取り組むマシンビジョンにおけるAI(ディープラーニング技術)活用について、これまでの経験に基づく知見を紹介します。

2. 画像処理とAIの優位性

マシンビジョンにおける視覚処理を、ルールベースの画像処理からAIに全て置き換えることは、技術面やコスト面からあまり現実的ではなく目的に応じて使い分ける必要があります。マシンビジョンに要求される視覚処理(目的)別に、画像処理とAIの優位性を下表で比較します。それぞれの項目に対して、◎から×まで優位性の有無を4段階で表現しました。

視覚処理(目的)	画像処理	AI
計測	位置姿勢計測	×
	距離計測	×
	カウント	◎
	領域抽出	◎
読み取り	バーコード認識	×
	QRコード認識	×
	文字認識	◎
欠陥検査	スクラッチ検査	◎
	色ムラ検査	◎
	印字不良検査	◎
分類	機種・品種分類	◎
	欠陥分類	◎

表1. マシンビジョンにおける画像処理とAIの優位性

位置姿勢計測や距離計測は、AIによる精度の高い計測が難しく、従来の画像処理技術を活用することになります。カウントや領域抽出においては、対象物の形状や色に個体差があったり、対象物が重なったりするケースでは画像処理技術での対応が難しく、AIに優位性があります。バーコードとQRコードの読み取りは、ピクセルの明暗情報を正確に読み取る必要があり、従来の画像処理技術を活用することになります。文字認識では、OCRの画像処理を用いることが一般的ですが、文字が変形する場合や一部が汚れている場合に対応が難しく、AIに優位性があります。欠陥検査(スクラッチ、色ムラ、印字不良)は、欠陥の見え方に個体差があるケースが多く、それらのバリエーションをAIで学習させることで認識が可能になります。分類(機種・品種分類、欠陥分類)も欠陥検査と同様で、対象物の見え方に個体差があるケースでは、AIに優位性があります。

以上のように、対象物の個体差があるケースにおいては、画像処理よりもAIのほうが柔軟に対応することができます。

3. AIの活用

マシンビジョンにAIを活用する場合、視覚処理や対象物に合った最適なネットワークを設計する必要があります。ディープラーニングの技術は現在も全世界で研究されており、新しい研究成果を設計に取り入れることが成功のカギになります。

ここでは、前述のAIに優位性がある視覚処理に対して活用できる、代表的なAIネットワークを紹介します。実際に活用する場合は、代表的なAIネットワークのままでは認識性能の向上が困難なケースが多く、対象物の撮像方法や学習の状況に応じてネットワークを改良していく必要があります。

■カウント

複数の対象物を同時に撮像し、対象物の数をカウントする処理になります。従来のルールベースの画像処理では、形状マッチングや正規化相関マッチングによる探索によって対象物を検出します。しかしながら、対象物が互いに重なっている場合や、形状が若干異なる場合においては対応が困難になります。




図1. AI活用による製造部品(ボルト)のカウント

AIでは対象物のバリエーションを学習させることで検出が可能になります。このような物体検出用の代表的なネットワークに、SSD(Single Shot Multi Detector)^[1]やYOLO(You Only Look Once)^[2]があります。SSDはアルゴリズム上、YOLOと比較して小さい物体を検出しづらい傾向があります。

AIは使いどころが肝心! マシンビジョンにおけるAI活用

■領域抽出

複数の対象物を同時に撮影し、対象物の領域を抽出する処理になります。

従来のルールベースの画像処理では、画像を二値化し、各領域のクロージング、穴埋め、ラベリングによって領域を抽出します。しかしながら、対象物が互いに重なっている場合や、表面の凹凸によって輝度差が大きくなる場合に対応が困難になります。

AIでは対象物のバリエーションを学習させることで検出が可能になります。代表的なネットワークにMask R-CNN^[3]があります。



図2. AI活用による製造部品(ボルト、ナット)の領域抽出

■欠陥検査

欠陥検査の代表的な例として、スクラッチ検査、色ムラ検査、印字不良検査があります。

これらの検査は、対象物の微小かつ不定形な欠陥を抽出する処理となり、従来のルールベースの画像処理では、欠陥特有の特徴量を抽出するアルゴリズムを個別に実装する必要があります。そのため、画像処理技術者の能力によって認識性能が大きく左右されます。

AIでは対象物の欠陥のバリエーションを学習させることで、欠陥特有の特徴量を抽出することが可能になります。代表的なネットワークとしてAlexNet^[4]やSegNet^[5]があります。SegNetは領域分割のネットワークとなり、画素単位で画像を分割することで欠陥領域を画素単位で抽出することができます。

また欠陥検査では、そもそも不良があまり発生せず、欠陥のバリエーションを学習させることが困難なケースがあります。そのようなケースでは、個体差のある良品のみを大量に学習し、良品

の個体差よりも差異が大きいものを不良として判定するネットワークを活用することができます。代表的なネットワークとしてVAE (Variational AutoEncoder)^[6]やAnoGAN (Anomaly Detection with Generative Adversarial Network)^[7]があります。




図3. AI活用による部品表面のスクラッチ欠陥検査

■分類

画像内の対象物を検出した後、機種や品種、欠陥を分類する処理になります。

従来のルールベースの画像処理では、SIFT (Scale-Invariant Feature Transform)、AKAZE (Accelerated-KAZE)、ORB (Oriented-BRIEF)などのアルゴリズムによって対象物の特徴点や特徴量を抽出し、あらかじめ登録されたテンプレートモデルとの類似度をもとに分類します。しかしながら、対象物が経年劣化で汚れている場合や、表面のテクスチャが複雑な場合は対応が困難になります。

AIでは対象物の欠陥のバリエーションを学習させることで、上記の問題に対応することが可能になります。代表的なネットワークとしてVGGNet^[8]やResNet^[9]があります。




図4. AI活用による製造部品(ナット)のサイズ分類

4. AI活用の課題

当社がお客様にAI活用を提案する中で議論される課題を紹介します。

■教師データの収集に労力がかかる

AI活用を検討する際、教師データの収集に労力がかかることが課題になります。

AI活用のメリットは、対象物の個体差を正確に認識する人間と同レベルの認識性能を実現することであり、人間が学習に要した情報量と同程度の情報量をAIに学習させることは避けることができません。教師データの良し悪しがAIの学習効率にも影響するため、教師データのバリエーションや判定基準を明確にした上で、教師データを効率よく収集することによって、労力を最小限に抑えることができます。




図5. ヒートマップによる製造部品(ナット)の特徴点可視化

■認識性能が向上しない

教師データを十分収集しても認識性能が向上しないケースがあります。その要因として撮像設計、前処理設計、AIネットワーク設計が十分でないことが考えられます。

撮像設計は、対象物からAIが認識しやすい画像情報を取得するための最も重要なファクタになります。カメラやレンズの分解能、露光時間、絞り、被写界深度や照明の種類、形状、サイズ、照射角度などを複合的に考慮し、最適な撮像方法を設計する必要があります。

前処理設計は、後段のAIが認識しやすいように、画像から不要な情報を除去したり、正規化したりすることで学習効率を向上させるための重要なファクタになります。ただし、画像処理によってアーチファクト*が発生しないように注意する必要があります。

AIネットワーク設計は、対象物や視覚処理に応じて最適な学習をさせるための重要なファクタになります。AIネットワークに入力する学習データの仕様や拡張方法(Data Augmentation)、学習パラメータをあらかじめ設計し、学習を計画的に進めながら、学習結果の傾向を分析していくことが認識性能向上の近道になります。

■AIの信憑性を説明できない

AIの内部処理はブラックボックスであるため、AIが正しく認識していることを証明できないという課題があります。この課題を解決する方法として、ネットワークの内部処理をヒートマップ(信頼度マップ)で可視化する手法が登場しています。

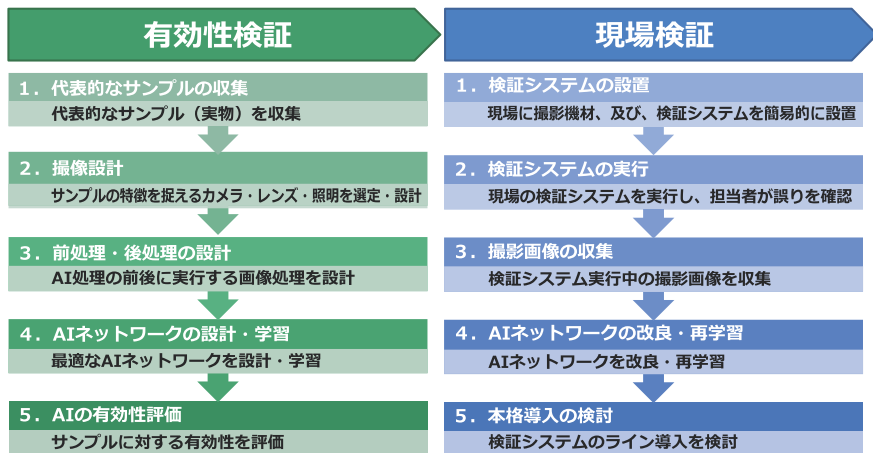
ヒートマップを生成する代表的な手法として、CAM(Class Activation Mapping)^[10]があります。

*現実の被写体でない人工的に生成された特徴

5. AI活用の実現性検証

AI活用の検討段階として実現性検証(PoC)を実施するケースが大半になります。

当社では、実現性検証を2段階に分けて実施することを推奨しており、前段階では代表的なサンプルを用いて「有効性検証」を実施し、後段階では工場のライン上にて「現場検証」を実施します。



6. AI活用の今後

■半教師学習

従来の教師あり学習では、教師データの収集とラベリングに膨大な労力がかかります。そこで、少ないデータで学習させる手法として半教師学習が注目されています。半教師学習の学習方法は教師あり学習と変わりませんが、学習の中でラベルがない画像に対しては、その特徴から仮のラベルを与えて学習をさせます。ただし、これだけでは従来の教師あり学習よりも精度が落ちてしまうため、ラベルをつけた画像の特徴と、仮のラベルをつけた画像の特徴を比較し、その差も学習させて精度を向上させていく技術が研究されています。この技術によって、いずれは大量の教師データ収集とラベリング作業が緩和されることが期待されています。

■エッジコンピュータ

近年では、小型で処理能力が高いGPUチップやAI推論専用チップが登場しており、カメラと一体化したエッジコンピュータが急速に普及していくと予想します。

現在、キヤノンでは、カメラと一体化したAIエッジコンピュータ「AI Edge Vision System」を開発しています。カメラユニットにはキヤノンの5Mグローバルシャッターのセンサーを搭載し、エンジンユニットにはNVIDIA社のJetsonを搭載します。カメラユニットで撮像された画像データをエンジンユニットのGPUメモリに高速転送し、画質補正（BayerからRGB変換、ホワイトバランス補正、ガンマ補正など）、画像処理、AI推論までの一連の処理をGPUで高速実行が可能になります。画像処理は90種類以上のAPIを提供しており、用途に合わせて利用することが可能です。

筐体自体が小型化されることで、既存の生産ラインやロボット本体への設置が容易となり、様々な用途での利用が期待されます。



キヤノンが開発中のAI Edge Vision System

参考文献

- [1] W.Liu, D.Anguelov, D.Erhan, C.Szegedy, S.Reed, C.Fu, A.C. Berg. "SSD: Single Shot MultiBox Detector", European Conference on Computer Vision (ECCV), 2016.
- [2] J.Redmon, S.Divvala, R.Girshick, A.Farhadi. "You Only Look Once: Unified, Real-Time Object Detection", Computer Vision and Pattern Recognition (CVPR), 2016.
- [3] K.He, G.Gkioxari, P.Dollar, R.Girshick. "Mask R-CNN", International Conference on Computer Vision (ICCV), 2017.
- [4] A.Krizhevsky, I.Sutskever, G.E.Hinton. "ImageNet Classification with Deep Convolutional Neural Networks", Neural Information Processing Systems (NIPS), 2012.
- [5] V.Badrinarayanan, A.Kendall, R.Cipolla, S.Member, "SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation", Pattern Analysis and Machine Intelligence (PAMI), 2017.
- [6] D.P.Kingma, M.Welling. "Auto-encoding variational bayes", arXiv:1312.6114, 2013.
- [7] T.Schegl, P.Seebock, S.M. Waldstein, U.Schmidt-Erfurth, G.Langs. "Unsupervised Anomaly Detection with Generative Adversarial Networks to Guide Marker Discovery", Information Processing in Medical Imaging (IPMI), 2017.
- [8] K.Simonyan, A.Zisserman. "Very Deep Convolutional Networks for Large-scale Image Recognition", arXiv:1409.1556, 2014.
- [9] K.He, X.Zhang, S.Ren, J.Sun. "Deep Residual Learning for Image Recognition", Computer Vision and Pattern Recognition (CVPR), 2015.
- [10] B.Zhou, A.Khosla, A.Lapedriza, A.Oliva, A.Torralba. "Learning Deep Features for Discriminative Localization", Computer Vision and Pattern Recognition (CVPR), 2016.

従来のシステムをマイクロサービスに再構築せよ！ 組込み分野におけるクラウドネイティブの取り組み

キャンノンITソリューションズ株式会社
エンベデッドシステム事業部
技術推進課 石井 信吾



1. はじめに

近年、デジタルトランスフォーメーション(以下、DX)への機運の高まりから、パブリッククラウドを活用することでDXの実現に取り組む企業が増えています。これまで、パブリッククラウドへの移行が進んでいた領域は情報系システムが中心でしたが、近年は基幹系システムや、IoTに代表される組込み機器との連携先として、パブリッククラウドが選択されるケースが増えています。

しかし、既存のオンプレミス基盤を単純にパブリッククラウドへ移行するだけでは、実際の運用コストはそれほど変わらず、

本来DXで成すべき「攻めのIT」へ効果的に繋げることはできません。真の意味でのDXを実現するためのクラウドシステムは、迅速な開発が求められるだけでなく、さまざまなビジネス環境の変化に対応可能である必要があります。

ここでは、パブリッククラウドの能力を最大限活用し、組織の競争力を高めるためのキーワードである“クラウドネイティブ”について、私達の知見や事例を紹介します。

2. クラウドネイティブとは

世の中にデジタルビジネスが溢れ、「顧客すら正解がわからない」と言われる昨今では、投入する製品やサービスが市場に受け入れられるかは不透明です。

しかし、長期間要件の変わらない大規模システムの開発のような、いわゆるウォーターホール型の開発技術や手法では、市場の反応に対する変更や修正に対してフレキシブルな対応ができません。したがって、アジャイルな開発手法や継続的なサービスのデリバリー、基盤の構成や外部サービスの利用をダイナミック

に行える、クラウドベースの技術・手法が必要になります。

こうした開発・運用の考え方に与えられている呼称が、「クラウドネイティブ」です。つまり、単純に仮想マシンをクラウド上に用意して従来型のシステムを構築するのではなく、コンテナやマイクロサービスなどといった、クラウドならではの要素技術を組み合わせてシステムを構築するというアプローチこそが、クラウドネイティブの考え方となります。

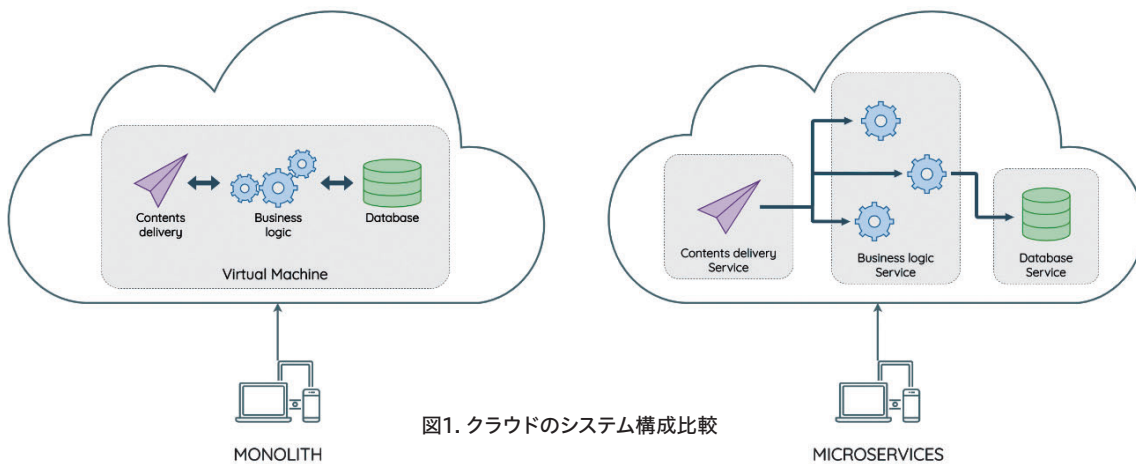


図1. クラウドのシステム構成比較

また、クラウドネイティブを語るうえでは、「サーバーレス」というキーワードを外すことはできません。サーバーレスはその言葉の通り、「サーバーを持たない」という考えが基底にあります。現在サーバーレスには、BaaS(Backend as a Service)とFaaS(Function as a Service)の2つの側面があります。

BaaSは、アプリケーションに必要なさまざまなバックエンドの機能が、REST APIやクライアントライブラリを通じて提供されるAPIベースのサービスです。FaaSは任意のアプリケーションコードをイベントドリブン方式で実行できるコンピューティングサービスで、コンピューティングサービスの中でも最上位に抽象度が高いという特性があります。

これらを組み合わせて構成するのがサーバーレスアーキテクチャと呼ばれます。サーバーを持たないことでサーバーの管理

を不要とし、高次のレイヤーのみに集中するシステム開発を実現するという概念で、これはクラウドの特性をフル活用したクラウドネイティブな考え方です。

クラウドネイティブは既にIT市場のメインストリームを走り始めています。IDC Japanは、2021年までにPaaSを用いて開発される世界のアプリケーションの約80%が、マイクロサービスとクラウドファンクションズ(注:FaaS)を利用すると予想しています。また日本国内においては、2021年までに国内のエンタープライズアプリケーションが、ハイパーアジャイルアーキテクチャ(注:クラウドネイティブとほぼ同義)への移行を本格化し、新規アプリケーションの約50%が、マイクロサービスおよびクラウドファンクションズに対応した、クラウドプラットフォーム(PaaS)で開発されると予測しています。

3. 当社の取り組み

当社は、オフィスデバイスを接続するクラウドサービスをAWSに移行し、リリースの迅速化や運用の省略化を目指しました。ここでは、その際の課題と工夫したポイントについて紹介します。

従来システムのDBはRDBMSで構築されていましたが、サーバーレス構成とするにあたりAmazon DynamoDBに移行しました。RDBMSは正規化したテーブル構造にすることが設計の基本となり、必要に応じて複数のテーブルをJOINしてデータを取り出していました。対してDynamoDBでは関連する情報は1つにまとめることが設計の基本となります。つまり、サーバーレス構成とするには、情報の単位について検討した上で、テーブルの再設計を行う必要があります。そこで、まずはWebAPIの見直しを行いました。従来のAPIでは複数の機能を一括処理していましたが、操作対象のリソースを明確にし、リソースごとの機能にAPIを分割しました。その後、DynamoDBのテーブルの単位もリソースとマッピングして設計し直しました。

4. 今後の取り組み

当社では、AI(=ディープラーニング)を活用した画像認識技術による欠陥検査や商品在庫管理システムなどの開発に取り組んでいますが、現在はエッジで動作するスタンドアローンのシステムです。昨今、クラウドサービス各社がディープラーニングのサービスを提供していますが、ネットワーク速度やコスト面から、画像認識をクラウド上で実施することは現状では難しいと考えています。しかし、クラウドと連携することで以下の課題解決を目指しています。

エッジでAIを動作させるシステムを運用するにあたっては、学習モデルを常に更新するための仕組みが必要となります。商品在庫管理システムでは、画像認識により消費者が手に取った商品の識別を行います。新商品追加時には、その商品を学習し直したモデルをアップロードし、複数のエッジシステムに配置しておく必要があります。

また、設置環境の照明条件などの違いにより、画像の認識精度が異なってきます。実際の運用状況に合わせたチューニング作業が必要となりますが、現地での作業が困難なケースもあります。そのためリモートでの結果データの取得、学習モデルの再学習、再配布をクラウドと連携して実施するシステムの開発に取り組んでいます。

従来システムのビジネスロジック部分はAWS Lambdaに移行しました。Lambdaへの移行にあたり、はじめに実装言語の検討が必要となります。まずは、従来システムと同じJava言語の実装をそのまま移植することを検証しました。概ね動作はしたのですが、初回アクセス時の関連ライブラリ読み込み処理に時間がかかる課題がありました。そのためスクリプト言語のPythonを採用しました。また、従来のモノリシックなシステムを機能分割して、それぞれ独立したサービスにする必要があります。その際の単位は前述のDynamoDBの再設計と同様に、リソース単位でサービスを分割する構成としました。

このように、DynamoDB・Lambdaへの移行に伴い根本的な設計変更を行いました。モノリシックなシステムをマイクロサービスアーキテクチャへ、自然に設計変更することができました。これらの設計変更によってメンテナンス性が向上し、リリース周期の大幅な改善にもつながりました。また、システム全体がダウンするような致命的な障害発生も抑えられています。

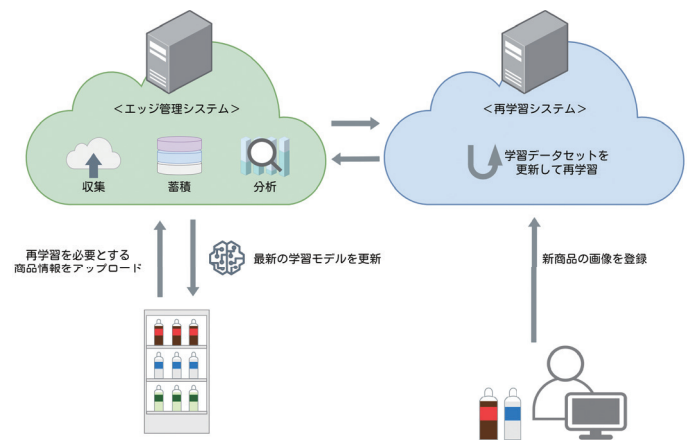


図2. 画像認識システムとクラウドの連携

また、商品在庫管理システムは、消費者が手に取った商品をトレースする事ができるため、手には取ったが購入には至らなかったなどの消費行動を取得することもできます。それらのいわゆるビッグデータをクラウド上に蓄積することで、消費行動の分析につなげることができます。

このように、データ分析システムの構築をクラウドネイティブな設計とすることにより、クラウドサービスが提供する分析機能を、より効果的に活用していくことを我々は目指しています。

ソフトウェア品質はコントロールできる？ ODC分析手法の導入

キヤノンITソリューションズ株式会社
エンベデッドシステム事業部
エンベデッドシステム第二開発本部エンベデッドシステム21
開発部エンベデッド213品質検証課 岡本 陽一



1. はじめに

ソフトウェア産業では品質面で多くの課題を抱えています。安全性や品質レベルへの要求が高まる一方で、価格競争の激化によるコスト抑制が強く求められています。テスト終盤に至っても出荷レベルの品質に達せず、リリース延期や市場への不具合流出に繋がるケースも少なくありません。コストを抑え品質を担保することが、ソフトウェア開発における共通の課題となっているのが現状です。

2. ODC分析とは

ODC分析(Orthogonal Defect Classification)は、設計段階から検証フェーズに至るソフトウェア開発のほぼ全体で、レビュー指摘と不具合を分類しシグナチャー(時系列変化)を抽出する事でタイムリーにソフトウェア開発者に改善点をフィードバックしソフトウェア品質および開発プロセスを改善していく方法論です。1992年、IBMワトソン研究所のRam Chillarege氏によって発表されたODC分析は、その後長年にわたりIBM社内プロジェクト品質の改善手法として活用され、昨今ソフトウェア業界においてもなお、注目されている品質分析手法となっています。

またODC分析を実施することで、品質状況を把握し「何が起きているのか?」「どこに問題があるのか?」を効率よく把握する

それらの課題解決の施策として、ソフトウェア品質を可視化しコントロールすることが品質を高め、コスト削減に繋がる大きな一手と言えます。ソフトウェア品質を可視化するための分析手法としては、信頼度成長モデルが主流ですが、「数」を扱うため一面しかとらえることができません。多角的に品質を可視化できるODC分析は、プロセス改善においても開発効率においても改善効果が期待でき、お勧めできる手法の一つです。

ことが可能となります。開発サイクル内に「分析」⇒「課題」⇒「施策」のループを作ることが可能なため、開発サイクル内での品質向上が期待できます。さらに品質管理手法として標準的な信頼度成長モデルで一般的な傾向をとらえ、意味的なデータを俯瞰するためのODC分析を併用することによって、より高い相乗効果を得ることができます。

ODC分析の場合、分析対象は「レビュー指摘」と「不具合」になります。ODC分析では不具合を4つの属性、すなわち「トリガー」、「インパクト」、「タイプ」と「ソース・エイジ」で表しますが、今回は、タイプ属性「製品品質の成熟度」、トリガー属性「テスト品質の成熟度」について解説します。

3. ODC分析の活用方法と事例

■ODC分析の活用方法

テストフェーズにおける「不具合」に対して不具合属性を付与していきます。

あるべき姿(期待するシグナチャー)の時系列変化や、現状との比較により、開発プロセスのどこに問題があったのかを判断します。

例1)タイプ属性「製品品質の成熟度」

某製品の結合テストでの適用事例です。




図1. 結合テスト(シグナチャー)




図2. 結合テスト




図3. 再開後の結合テスト

①期待する結果(シグナチャー)と比較し、品質の問題を発見

結合テストにおけるタイプ属性の望ましい割合と比較したところ、対象製品は結合テストフェーズとしては「機能」の割合が大きすぎ危険な状態であることが分かりました(図1, 図2)。その後、その不具合部分の原因調査と開発プロセスの改善を提案し、基本設計の見直しと単体テストの追加を実施しました。

②結合テストをパス

品質改善後に結合評価を再開し、「機能」は適切な割合に落ち着き製品の成熟が確認できたため、無事製品リリースに繋げることができました(図3)。

どちらの事例も開発フェーズ中に改善を行う事で、早期解決することができました。また、開発プロセスの改善に加え、不具合流出における手戻りコスト削減にも繋がりました。

例2)トリガー属性「テスト品質の成熟度」

某製品の結合テスト～システムテストフェーズでの適用事例です。




図4. プレ結合テスト

図5. 結合テスト

図6. システムテスト

①プレ結合テストで想定外の不具合が多く発生

結合前のプレテストを実施した結果です(図4)。テストは基本機能から詳細組合せ、深いテストという順で計画することが基本ですが、この例では探索的テストを最初に実施したことで複合不具合の割合が多くなりました。この結果はあるべき姿・期待するシグナチャーと異なるため一旦テストを中断して、テスト戦略を見直しました。

②テスト戦略見直し後、結合テストで期待通りの不具合が発生

結合テストを実施した結果です(図5)。基本機能から多くの不具合が発生しており、想定通りにテストが進められていることがわかります。引き続き基本機能を徹底的にテストした後、後半は設定値のバリエーションや操作順序依存のテストを徐々に増やしました。

③その後、システムテストをパス

その後のシステムテストでは基本機能の他、設定値バリエーションや操作順序依存、相互作用など深いテストによる不具合が検出されていることがわかります(図6)。こうして、トリガー属性のシグナチャー(時系列変化)の観点から品質に問題無しと判断できたことで、無事製品リリースに至りました。

4. さいごに

冒頭で述べた通り、ODC分析は、効率的に運用でき、効果的な改善施策に結び付けられる品質分析手法であり、以後の開発プロセス改善効果も期待できる、優れた分析手法と言えます。ソフトウェア業界が注目し、ODC分析の普及に向け業界全体が後押ししている今だからこそ、是非多くの企業に導入して欲しいと考えます。ODC分析の導入には、要員の不具合属性付与スキル育成などいくつかの課題はあり、全てがクリアできる“魔法の杖”ではありません。しかしながら、活用していくことで、ソフトウェア品質

をこれまで以上にコントロールできるようになります。導入に向けお困りの時はいつでもご支援いたします。この有益な分析手法をぜひ実感していただきたいと思っております。

日本科学技術連盟(日科技連)*が「ODC分析研究会」を発足し、ODC分析の普及に向けた取り組みを進めています。解説書や教育資料の提供なども予定されていますので、是非参考にしてみてください。

参考文献

[1]山崎 隆:ODC分析による欠陥除去と品質の成熟度可視化
～医療機器の安全性・高品質性を担保するために～、独立行政法人情報処理推進機構(IPA)、2014、
<https://www.ipa.go.jp/files/000040829.pdf>

[2]ODC分析 技術文書WG 杉崎 真弘氏(SUGIシステムズエンジニアリング)、2019、
https://www.juse.or.jp/sqip/odc_workshop/2/file/2p_hokoku_2.pdf

・アドバイザー

ODC分析研究会 運営委員:キヤノン株式会社 瀬能 芳幸氏

*日本科学技術連盟(日科技連)ODC分析研究会

https://www.juse.or.jp/sqip/odc_workshop/index.html

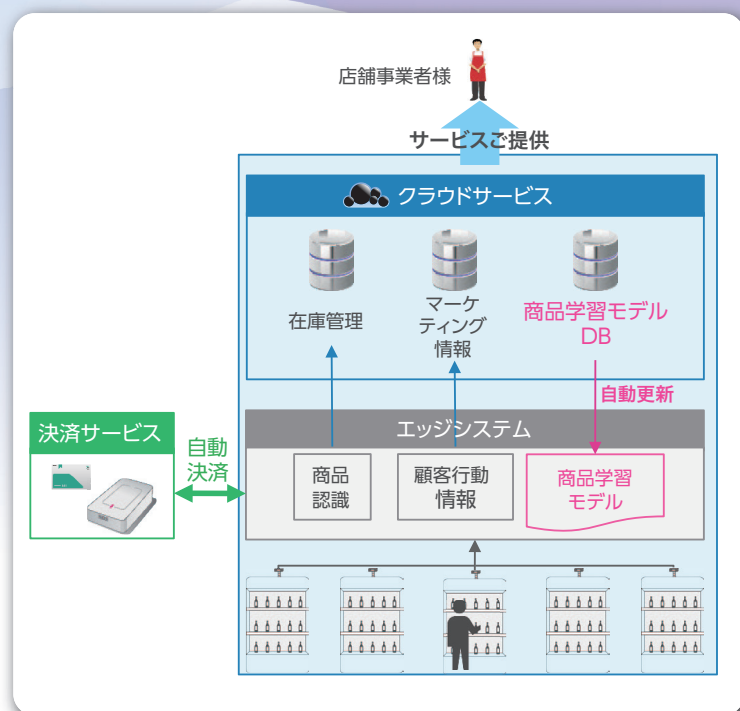
自動決済・店舗マーケティングソリューション 次世代型ショーケース

自動決済や店舗マーケティングのための次世代型ショーケース



- サンデン・リテールシステム株式会社と共同開発中の次世代型ショーケースです。
- ショーケースからの商品の取り出しを画像処理により自動で認識することで、店舗内の在庫管理や自動決済、店舗マーケティングなどのさまざまな用途に活用できます。

ショーケースで実現するマイクロマーケット向け無人販売



- オフィスコンビニのような従業員の配置が難しいマイクロマーケットにおいて、商品の無人販売を実現します。
- 電子決済や社員の給与天引きシステムなど、さまざまな決済手段と連携可能です。
- 商品を認識するための学習モデルは、クラウドを介して自動的に更新されます。店舗側での商品登録作業は不要です。
- 在庫管理やマーケティング情報のご提供といったクラウドサービスを店舗事業者様にご提供いただけます。

共同開発



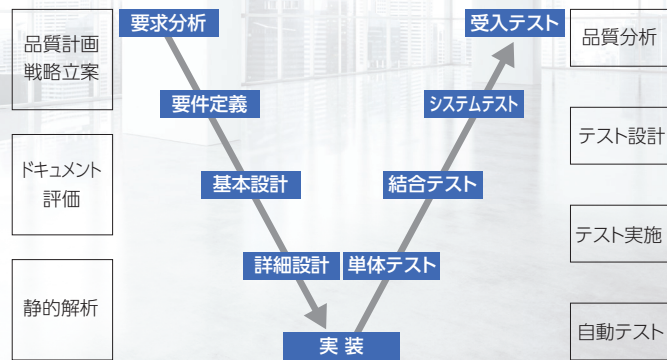
サンデン・リテールシステム株式会社

品質 検証 サービス

幅広いサービスと確かな実績で
品質向上を支援します

▼サービス一覧

品質コンサルティング プロジェクト改善



▼テスト種別

- 第三者検証
- 開発内テスト
- 受入テスト
- 市場問題
対応テスト
- ユーザビリティ
- 回帰テスト
- 負荷・耐久
- セキュリティ
- 互換
- シナリオマニュアル
- 探索的テスト

▼実績例

キヤノン製品 組み込みソフトウェア



その他



New!

オンライン無料品質改善診断 はじめました!

簡単な質問に回答するだけで、ソフトウェアの品質状況を無料で簡易診断し、品質改善に向けた施策を提示します。 <https://www.canon-its.co.jp/solution/qv/>



キヤノンITS 品質検証

検索

Canon キヤノン ITソリューションズ株式会社

- 発行日：2020年6月30日発行
- 編集・発行：キヤノンITソリューションズ株式会社
エンジニアリング事業統括推進本部
〒140-8526 東京都品川区東品川2-4-11 野村不動産天王洲ビル
電話：03-6701-3368

■ 発行責任者：池田 幸一

■ 印刷：キヤノンプロダクションプリンティングシステムズ株式会社

※本誌で紹介している製品・サービスの名称は一般に各社の商標または登録商標です。本誌記事の無断転載・複写を禁じます。

キヤノンITソリューションズの提供する エンジニアリングソリューション

ものづくり企業としての生き立ちを活かし、長年の研究開発で培った先端技術を活かして、お客様のニーズにワンストップに対応できる最適なソリューションを提供しています。業務に役立つ多様な商品群やITスキルを駆使した付加価値サービスとともに、お客様のビジネスと社会の発展に貢献できるエンジニアリング事業の拡大を推進していきます。

ENGINEERING

技術と品質でものづくりを支える、
エンジニアリングソリューションプロバイダーです。