

診療ワークフローにおける AI 活用戦略

小原 真 株式会社フィリップス・ジャパン MR クリニカルサイエンス

はじめに

AI は、現在の科学技術分野において最も注目されている技術の 1 つとなっている。コンピュータ処理能力の向上、大量データの蓄積が容易になってきたこと、新しく開発された AI モデルの多くがオープンソースによって共有可能になったことが普及の主因とされている。この潮流は医療分野においても例外ではなく、AI 技術を効果的かつ効率的に導入していくことが、今後の発展に重要と考えられている。

Philips では、患者を中心とした診療ワークフロー(図 1)を視野に入れたソリューション開発を進めており、AI はこのフロー内のプロセスを横断的にサポートし、アプリケーションとアプリケーションをシームレスに統合していくための重要なツールとして捉えている。

AI を臨床で効果的に展開していくためには、診療ワークフローの各プロセスに、施設のニーズに適合するコンテンツを導入していく必要がある。それを効率的に行うには、コンテンツそのものの開発だけではなく、AI の研究開発を促進し、開発されたコンテンツをスムーズに臨床に導入していくためのプラットフォームの整備が重要となる。Philips では、その視点でデザインされた AI 開発プラットフォーム IntelliSpace Discovery(ISD)を提供している。

本稿では、Philips の AI 戦略の中心となる ISD プラットフォームと、実際に ISD 環境で開発された、腫瘍セグメンテーションモデルを紹介する。

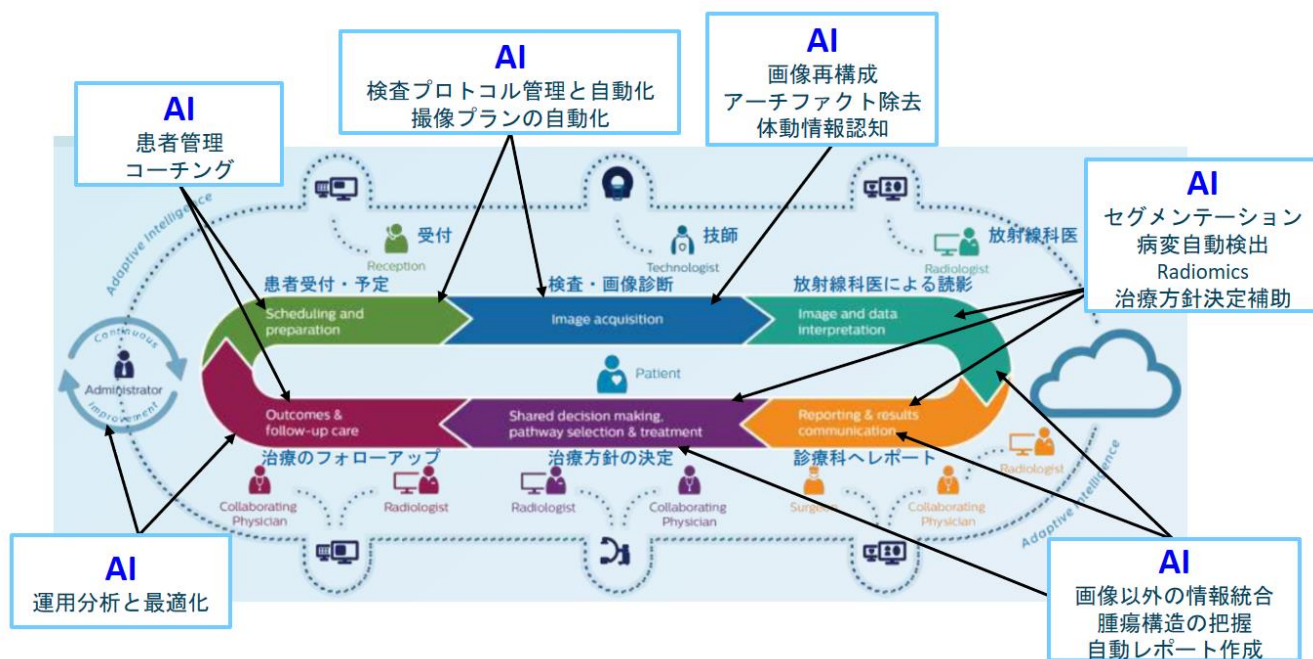


図1: 患者を中心とした診療ワークフローと AI 活用のイメージ

患者受付、検査・画像診断、読影、レポート、治療、フォローアップという患者を中心とした診療ワークフロー。AI をフロー横断的に各プロセスで活用することにより、診療ワークフローあるいは放射線医学のクオリティ向上につなげる戦略を示している。

AI 開発プラットフォーム

AI への関心の高まりから、研究開発への取り組みをスタートする施設が増加している。しかしながら AI モデル開発には、大量データのマネージメント、目的プロジェクトに応じた前処理や教師データの作成、Machine Learning(ML) または Deep Learning(DL)の実施、開発されたモデルのテストといった複数の要素をセットにした環境構築が必要となる。通常はそれぞれの要素が別プラットフォームにて実施管理されることが多く、結果的に作業が煩雑となり AI 研究を実行するための難易度を高める結果となっている。ISD のコンセプトは、そのように独立した要素を統合させる一体型の環境を構築し、プロジェクトに応じてカスタマイズしていくことである。

図 2 でその実施フローを示している。ユーザーのフロントエンドとなるワークステーションにおいて、高レベルなデータ処理だけでなく、データベースや ML サーバーへのダイレクトアクセス、ML あるいは DL の実行、モデルアーキテクチャーの最適化、開発モデルの検証やテストなど AI に必要なすべての処理を一元化して実施することが可能となる。開発されたモデルは、同じプラットフォームを準備することで容易に実装できることから、スムーズにマルチセンタートライアルを実施することが可能となる。今後は、マルチセンターによって有用性が検証された AI モデルを、病院内環境に適合させ、院内の診療ワークフローの中に組み込んで運用していけるようなプラットフォームも開発していく予定である。

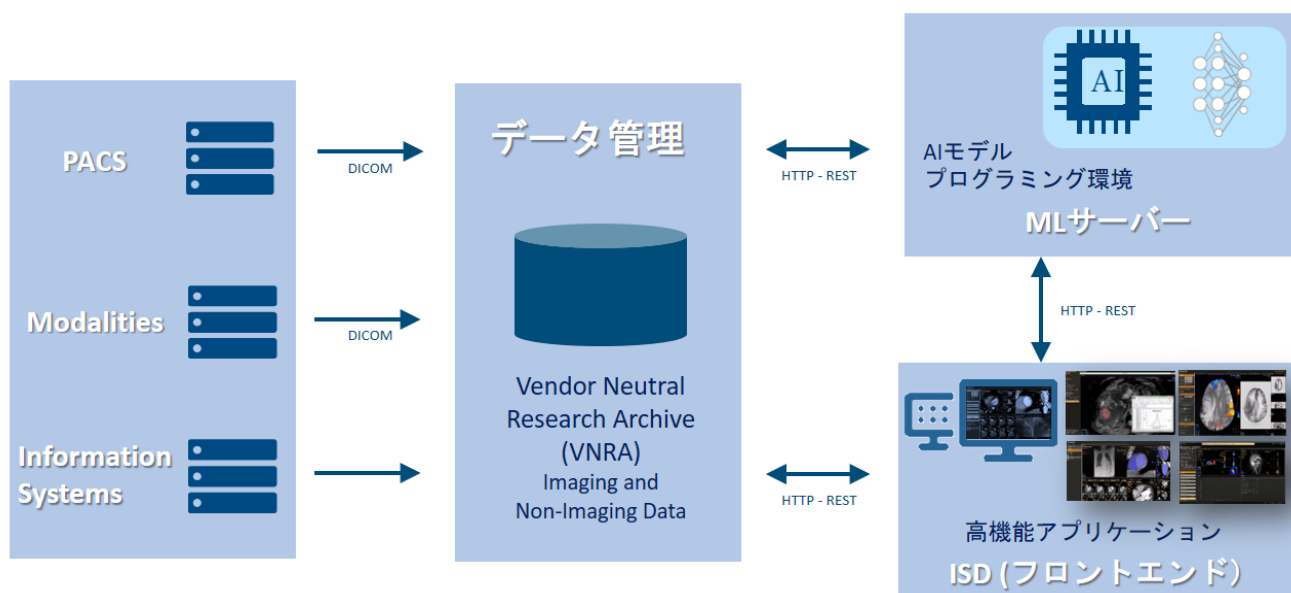


図 2: ISD を用いた AI 開発プラットフォームのコンセプト

ISD から、ML サーバーあるいはデータ管理サーバーとコミュニケーションを取り、ユーザーはフロントエンドからの一元管理で、データへのアクセスや取り込み、データ処理、ML の実施をコントロールすることができる。データのやり取りを行う際に必要な保管場所の共有、フォーマットの適合など、プロジェクトに応じたプラットフォームのカスタマイズを行う。

実際のアプリケーションの例

実際に IntelliSpace Discovery (ISD)を用いた例として、脳腫瘍(グリオブラストーマ: GBM)の自動セグメンテーションを目的とした DL モデル開発の研究を紹介する。¹⁾ GBM は、頻度の高い脳腫瘍であり、治療方針決定やフォローアップにおいては、腫瘍全体だけではなく造影濃染領域や壊死領域の正確な把握が重要となる。しかしながら、セグ

メンテーションをマニュアルで行うのは煩雑かつ主観的であり、フォローアップ期間に異なる医師が診断や画像処理をする場合は、正確な腫瘍の経時的変化(治療効果)の把握を妨げる可能性もある。

この開発では、220 人分の T1w、T2w、Flair、造影後 T1w(CE-T1w)画像を教師データに用いた。図 3 にこのプロジェクト用にカスタマイズされた ISD プラットフォームのデータ処理パイプラインを示している。教師データ用の前処理、AI モデル開発・評価といった全てのプロセスを一つのプラットフォーム上で実行することができる。

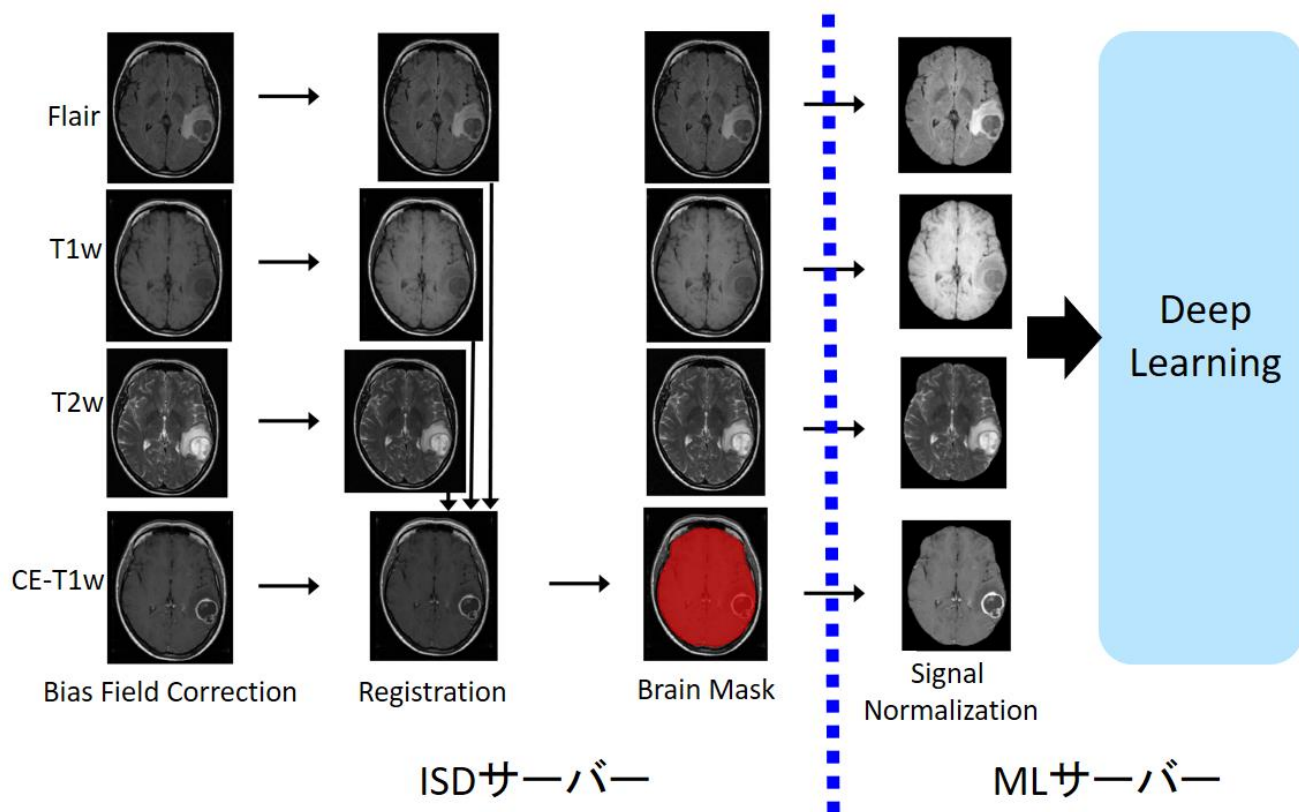


図 3 : ISD プラットフォームを用いたデータ処理パイプライン

教師データの T1w、T2w、Flair、CE-T1w に対する前処理から DL までのパイプラインを示している。ISD で信号の均一化補正 (Bias Field Correction)、CE-T1w をリファレンスとした各コントラスト画像の位置や形状補正(Registration)、脳実質のマスキング (Brain Mask) を施したデータを、ML サーバーの AI モデルアーキテクチャで取り込み、信号の正規化 (Signal Normalization) を行った後に DL を実施している。この DL によって開発されたモデルもフロントエンドの ISD 側から実行し、検証やテストを行うことが可能となる。

DL モデルアーキテクチャーには、脳病変セグメンテーション用に開発された DeepMedic²⁾を用いた。DL で開発されるモデルは、教師データに依存するため、目的に応じた教師データセットを用意する必要がある。例えば、学習用データすべてを同じ装置で取得した場合、その装置と同じ機種で得られたデータに対しては高精度な結果が得られるが、異なる機種で取得されたデータを解析すると精度が低下する可能性がある。この研究では、多施設で応用できる汎用性の高いモデル開発を目的としたため、15 施設の異なる磁場強度が混在した 8 種類の MR 装置および幅を持たせた撮影条件(プロトコル)で撮像された 64 例のデータで DL モデルの開発を行った。

図 4 では、開発モデルを用いて解析された 2 症例におけるセグメンテーション結果を示している。腫瘍全体の領域、造影剤によって増強された領域、壊死組織の領域をコンポーネント別にセグメンテーションしている。造影濃染領

域に比べた壊死領域の比率の違い(症例(a)は(b)に比べて壊死組織の割合が高い)を視覚的、客観的、定量的に把握することが可能となる。DLモデルによるセグメンテーションの評価は、医師によるセグメンテーションを参照に DICE スコアを用いて行われている。これは、医師が実施したセグメンテーションとの類似性を示す指標である。DICE スコアは、腫瘍全体のセグメンテーションにおいて 0.86 ± 0.09 、増強組織において 0.78 ± 0.15 、壊死組織において 0.62 ± 0.30 であった。マルチセンタートライアルで、DLモデルが高精度で GBM のセグメンテーションが可能であることを示している。

図 5 には GBM セグメンテーションモデルでセグメンテーションされた腫瘍体積の経時的変化を示している。治療後フォローアップにおける効果判定の際に、検査装置、検査方法に変化があった場合でも、客観的、定量的な評価を提供できるツールとして期待できる。

AI によってセグメンテーションが自動化され、上述した腫瘍の組織コンポーネント領域が定量的に評価できると、治療に伴う腫瘍の経時的変化を客観的に行うことが可能となったり、施設横断的に共通な評価手法を確立できる可能性がある。




図 4: GBM セグメンテーションモデルのテスト結果

DeepMedic を GBM 用に学習させたセグメンテーションモデルを、実際の症例に用いた結果を示している。腫瘍全体(白)、造影された組織(水色)、壊死組織(紫)のそれぞれをコンポーネント別にセグメンテーションしている。

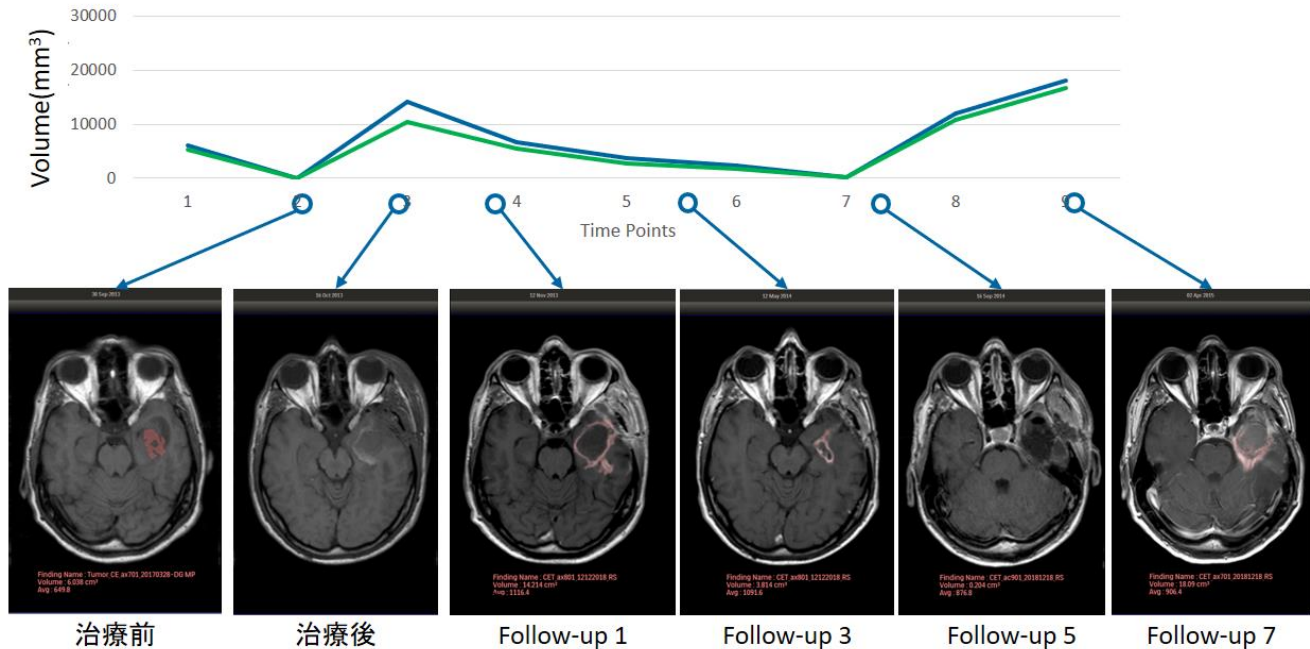


図5: GBM セグメンテーションによる腫瘍体積の経時的変化

治療前、治療後、その後の各フォローアップにおける腫瘍体積の経時的変化を、AI モデルを用いて自動計測している。

まとめ

AI 開発用の ISD プラットフォームと、それを用いて開発した GBM セグメンテーションモデルを紹介した。プロジェクトに適合するようにカスタマイズされた環境を設置することで、高性能ワークステーションによるデータ処理から、オフライン処理やフォーマット変換を介すことなく、直接 ML に移行することができる。今後の AI 開発を加速し、診療ワークフロー内の各プロセスのクオリティ向上や連携の強化を促進し、最終的に患者が受ける医療レベルが向上するように、Philips が提供する AI 環境を充実させていきたい。

参考文献

1. Perkuhn M et al. Clinical Evaluation of a Multiparametric Deep Learning Model for Glioblastoma Segmentation Using Heterogeneous Magnetic Resonance Imaging Data From Clinical Routine. Invest Radiol. 2018;647-654.
2. Kamnitsas K et al. Efficient multi-scale 3D CNN with fully connected CRF for accurate brain lesion segmentation. Med Image Anal. 2017;36:61–78.