

# トランスコスモス財団調査研究助成事業 2023 報告書

2024/6/19

公立ほこだて未来大学

特命教授 藤野 雄一

## 1 はじめに

本報告書は、トランスコスモス財団調査研究助成事業による助成にて実施した「子宮頸がん自動スクリーニングの実現に向けた選好学習に基づく扁平上皮細胞診断手法の提案」に関する2023年度研究に関するものである。

## 2 構成

本研究報告は以下の構成にて記述する。

- 1) 背景と目的
- 2) 手法
- 3) 実験, 結果, 考察
- 4) 結論
- 5) 未来大における ICT 医療への取り組み状況
- 6) 別紙
- 7) 参考文献

## 3 背景と目的

### 3.1 子宮頸がん治療

子宮頸がんは、世界的に女性の間で4番目に罹患率の高いがんで、若年層の女性にも高い罹患率であり、効果的な治療介入と予後のためには早期発見が不可欠である<sup>1)</sup>。悪性と診断された場合、最悪、子宮摘出術を選択することとなり、若年層世代の女性にとっては今後の妊娠が望めなく、精神的なダメージが大きい。子宮全摘出を防ぐためには、早期に発見・治療することが重要である。そこで婦人科では、スクリーニングとして子宮頸がん検診を実施している。子宮頸がん検診は、子宮頸部の悪性病変を早期に発見するために必須な検査である。子宮頸がん検診では一般に、擦過細胞診と呼ばれる検査方法をとる。これは、子宮頸部をこすり取ることで得た細胞を顕微鏡で観察し有初見細胞を抽出した後、ベセスダシステムに従って診断する方法である。この細胞診には悪性細胞の見逃しがないよう感度を最大化しつつ、正常細胞を誤検出しないよう特異度を最大化することが求められる。そのため、専門医や細胞検査師にかかる負担は大きい。また、ベセスダシステムは、診断根拠となる定量的な閾値を定義する規程ではない。そのため、重要とされる特徴量はあるものの、細胞を異型であると判断する基準は曖昧である。このことは、診断能力は検者の経験に依存することとなり、一部の研究では診断一致率が低いことを意味している。すなわち、このような手作業によるスクリーニングは各細胞診専門医の技量に依存することとなり、観察者によって診断精度にばらつきが生じ、持続的な更新と専門知識の共有が必要である。した

がって、自動化された子宮頸がん検診の技術的進歩は、検診時に子宮頸がんを見逃すリスクを軽減するために極めて重要になっている。これらの課題を軽減する方法として、情報処理技術を用いた自動スクリーニング技術が求められている。

現在まで、複数の研究者が正確で効率的な自動がん検出法の開発に取り組んできた。これらの課題に対する潜在的な解決策として、ディープラーニング手法が導入されてきた<sup>2)</sup>。しかし、これらの研究の多くは、独自の制約やアーキテクチャ設計を組み込むことで、深層学習モデルの性能を向上させることを主な目的としており、こうした取り組みでは、分類モデルの意思決定基盤を解明する必要性が見落とされがちである。

一方、ディープラーニング・アルゴリズムのブラックボックス的特性は、臨床的な解釈可能性と透明性の欠如によって特徴付けられ、より広範な臨床的統合を抑制してきた<sup>3)</sup>。明確な説明がなければ、AI が生成した分類を信頼することは困難となり、その結果、臨床への応用のためにはその解釈の内容を説明できることが重要性である<sup>4)</sup>。

### 3.2 本研究の目的

近年、アテンションメカニズムと呼ばれる手法が画像の特徴を表現するのに有効であることが実証され、その結果、関連する研究においてより高い成果が得られている<sup>5)</sup>。我々が取り組む細胞診画像にはしばしば無関係な背景オブジェクトが含まれるため、アテンションメカニズムに基づくアプローチにより、核、細胞質、細胞の積み重なりなど、適切な領域にモデルを集中させることができる、と考えている。さらに、アテンションメカニズムは、モデル出力に深く影響するチャンネルの可視化と理解を容易にする。しかし、細胞診は細胞の微細な違いに基づいてカテゴリーを識別する非常に繊細な画像診断法であるため、評価されたモデルチャンネルのみを予測結果の基礎として解釈することは難しい。

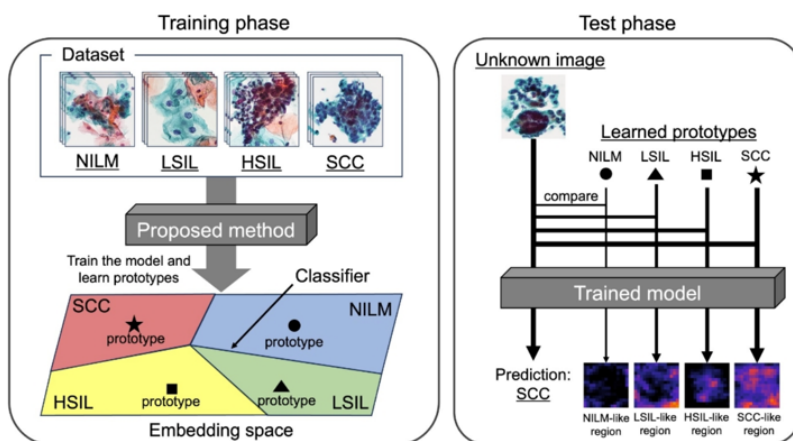


図1.手法の概要訓練フェーズでは、提案手法はコントラスト埋め込みを用いてモデルを訓練し、クラスプロトタイプを学習する。テストフェーズでは、提案モデルはクラスラベルを予測し、アテンション機構を用いて各プロトタイプに類似した領域を可視化する。

我々は、未知の細胞診画像を分類し、各クラスに関連する画像領域を強調表示するために、アテンションメカニズムを用いた新しいクラス認識可視化手法を提案する。図1に手法の概要を示す。プロトタイプ学習パラダイムを活用することで、提案手法はモデルの学習と各クラスの典型的な特徴（プロトタイプ）の学習を同時に行う。学習されたモデルはテスト段階での予測生成に使用される。同時に、注意モジュールは各クラスのプロトタイプを画像と対比し、モデルがクラスに類似しているとみなす領域をヒートマップとして表現する。ここで表示されるクラスを意識したヒートマップは、人間の認知過程と密接に関わり、分類作業において視覚的に首尾一貫した説明を提供することができる、と考えている。一方、プロトタイプを確認するためには、画像から適切な特徴を抽出することが不可欠である。そこで、効率的な特徴表現に不可欠な対比学習のための損失関数を学習プロトコルに組み込んだ。選考学習は、同じクラス内の画像の特徴を群化する一方で、異なるクラスの特徴を遠ざけることで、より洗練された画像埋め込みモデルを実現する。本研究の示す重要な点は以下の通りである。

- 対比的埋め込みとプロトタイプ学習ストラテジーを融合させた新しい学習法を紹介
- プロトタイプ比較による細胞分類タスクのための新しいクラス認識視覚的説明手法の提案
- 子宮頸部細胞診データセットの定量分析による、提案アプローチの有効性の検証

これらの検証により、本研究では、子宮頸がんを対象とした自動スクリーニングのための自動分類手法を明確化することで、専門医らの負担軽減とともに定量的な診断の支援を目指す。

## 4 手法

### 4.1 モデル

提案モデルは3つのニューラルネットワークモジュールから構成される。エンコーダ  $E$ 、相互ベクトル生成器  $G$ 、投影ヘッド  $H$ 。提案モデルは、クラスの代表的な埋め込みであるプロトタイプを同時に学習し、入力画像に対応するラベルを予測する。まず、エンコーダ  $E: X \rightarrow RD$  は入力画像の埋め込み  $h_i = E(x_i)$  を計算する。各プロトタイプは、そのクラスに属する埋め込み量の平均ベクトルである。

$$c^k = \frac{1}{|D_k|} \sum_{(x_i, y_i) \in D_k} E(x_i) \quad (1)$$

$D_k$  は、クラス  $k$  でラベル付けされたインスタンスの集合を表す。これらのプロトタイプは、以下のモデルのデータフローには登場しないが、後述の可視化フェーズで使用される。

続いて、注目ベクトルを生成するモデルとして、API-Net<sup>6)</sup> の注目一対相互作用 (API) 構造を導入した。API 構造は2つの入力画像の埋め込みを比較し、注目チャンネルを定義する注目ベクトルを生成する。具体的には、2つのインスタンス  $h_i, h_p$  ( $i, p \in \{1, \dots, N\}, i \neq p$ ) を埋め込み画像からサンプリングした。相互ベクトルは相互ベクトル生成器  $G: R^{2D} \rightarrow RD$  を用いて計算した。図2にモデルの概要を示す。なお、本モデルの詳細は筆者らが発表した文献<sup>7)</sup>を参照されたい。

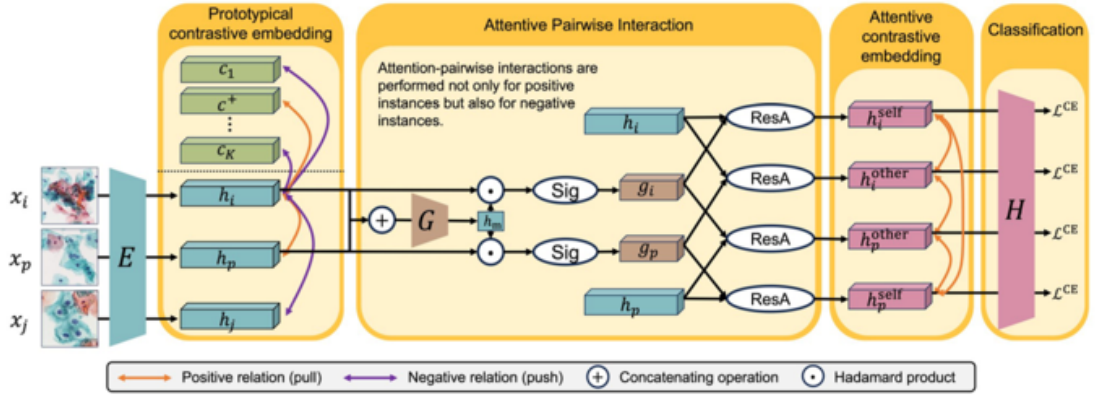


図 2. 入力画像  $x_i$ 、正インスタンス  $x_p$ 、負インスタンス  $x_j$ 。図中の「Sig」はシグモイド関数、「ResA」は残差注意を意味する。

## 4.2 トレーニング

エンコーダ  $E$ 、相互ベクトル生成器  $G$ 、および投影ヘッド  $H$  のパラメータは、わかりやすくするために、単数のパラメータに統合され、 $\theta$  と表記される。

### 1) プロトタイプエンベッディング:

エンコーダ  $H_\theta$  は、同じクラス内のインスタンスに対しては類似した埋め込みを生成し、異なるクラス間のインスタンスに対しては乖離した埋め込みを生成する。さらに、 $D_k$  に整列された埋め込みインスタンスは、 $c_k$  との類似性を示すと同時に、異なるクラスのプロトタイプとの非類似性を示すはずである。このことから、我々は適切な損失関数として教師付き対比損失[19]を採用する。この損失を最小化することで、同じクラスに属するインスタンス（ポジティブインスタンスとみなされる）は互いに密集し、異なるクラスからのインスタンス（ネガティブインスタンスとラベル付けされる）は互いに反発するように、モデルが改良されることが保証される。プロトタイプ計算とモデル学習を両立させるため、学習データセットをランダムに2つの等しい要素、 $D_{\text{spt}}$  と  $D_{\text{qry}}$  に分割し、 $D_{\text{spt}}$  を用いてプロトタイプを計算した。 $D_{\text{qry}}$  に埋め込まれた入力画像を用いて、以下の損失関数を最小化した。

$$\mathcal{L}^{\text{PC}}(E_\theta | D^{\text{qry}}) = \sum_{(\mathbf{x}_i, y_i) \in D^{\text{qry}}} \left( \frac{-1}{|P(i)|} \sum_{p \in P(i)} \log \frac{\exp(E_\theta(\mathbf{x}_i)^\top \cdot E_\theta(\mathbf{x}_p)/\tau)}{\sum_{a \in A(i)} \exp(E_\theta(\mathbf{x}_i)^\top \cdot E_\theta(\mathbf{x}_a)/\tau)} - \log \frac{\exp(E_\theta(\mathbf{x}_i)^\top \cdot \mathbf{c}^+/\tau)}{\sum_{c_k \in C} \exp(E_\theta(\mathbf{x}_i)^\top \cdot c_k/\tau)} \right).$$

ここで、 $A(i) \equiv \{1, \dots, |D_{\text{qry}}|\}$  である。 $\forall i$  であり、 $P(i) \equiv \{p \in A(i) : y_p = y_i\}$  は、 $i$  とは異なる  $D_{\text{qry}}$  のすべての正インスタンスのインデックスの集合である。プロトタイプ  $C$  は、 $D_{\text{spt}}$  から式(1)によって計算される。(1) によって  $D_{\text{spt}}$  からプロトタイプ  $C$  が計算され、 $c$  は  $x_i$  と同じクラスの正のプロトタイプである。さらに、 $\tau > 0$  は、負のインスタンス変動に対するペナルティの強さを決定する温度パラメータを示す。

### 2) アテンションエンベッディング:

与えられた入力特徴  $\mathbf{x}_i$  に対して, API-Net のイントラクラス戦略とインナークラス戦略に従って, 2 つのペア  $(\mathbf{x}_i, \mathbf{x}_j)$  と  $(\mathbf{x}_i, \mathbf{x}_j')$  を得る. クラス内戦略では,  $\mathbf{x}_i$  と同じクラスに対応し, ユークリッド距離で  $\mathbf{x}_i$  の埋め込みに最も近い埋め込みを持つ入力特徴として  $\mathbf{x}_j$  が選択される. 内側クラス戦略では,  $\mathbf{x}_i$  とは異なるクラスに対応し, その埋め込みがユークリッド距離において  $\mathbf{x}_i$  の埋め込みに最も近い入力特徴として,  $\mathbf{x}_j'$  が選択される. 各ペアに対して気配りペアワイズ相互作用を行うことで,  $\mathcal{D}^{qry}$  の各インスタンスに対して 8 つの気配り特徴ベクトル  $(\mathbf{x}$  と  $(\mathbf{x}_{interi}, \mathbf{x}_{self}, \mathbf{x}_{interi}, \mathbf{x}_{other}, \mathbf{x}_{self}, \mathbf{x}_{other})'$ ) が得られる.  $\mathcal{D}^{qry}$  の全インスタンスに対する気配り特徴ベクトルの  $8|\mathcal{D}^{qry}|$  ペアの集合とする. 強調しても, 同じクラスに対応する場合は収束するはずである. 逆に, 異なるクラスに関連するインスタンス同士は反発し合うはずである. そのため, 教師付き対比的損失 (supervised contrastive loss) を用いてモデル E と G を用いる.

$$\mathcal{L}^{PC}(E_\theta | \mathcal{D}^{qry}) = \sum_{(\mathbf{x}_i, y_i) \in \mathcal{D}^{qry}} \left( \frac{-1}{|P(i)|} \sum_{p \in P(i)} \log \frac{\exp(E_\theta(\mathbf{x}_i)^\top \cdot E_\theta(\mathbf{x}_p)/\tau)}{\sum_{a \in A(i)} \exp(E_\theta(\mathbf{x}_i)^\top \cdot E_\theta(\mathbf{x}_a)/\tau)} - \log \frac{\exp(E_\theta(\mathbf{x}_i)^\top \cdot \mathbf{c}^+/\tau)}{\sum_{\mathbf{c}_k \in \mathcal{C}} \exp(E_\theta(\mathbf{x}_i)^\top \cdot \mathbf{c}_k/\tau)} \right)$$

ここで,  $I \equiv \{1, \dots, 8|\mathcal{D}^{qry}|\}$ ,  $A'(\ell) \equiv \{1, \dots, 8|\mathcal{D}^{qry}|\}$  である.  $\forall \ell$  であり,  $P'(\ell) \equiv \{p \in A'(\ell) : y \sim p = y \sim \ell\}$  は,  $\ell$  とは異なる H 内のすべての正インスタンスのインデックスの集合である. 以上の説明の詳細は上述同様, 筆者らの文献<sup>7)</sup>を参照されたい.

## 5 実験

### 5.1 データセット

提案手法の性能を評価するために, 3 つの異なる子宮頸部細胞診データセットを用いた. 我々が検討している環境でのカスタムデータセットは, 主に複数の子宮頸部細胞診細胞からなるクラスター領域を抽出したものである. Herlev データセット<sup>8)</sup> は, 各画像内の単一細胞をユニークに捉えたもの, Mendeley LBC<sup>9)</sup> データセットは, より広い視野を提供し, 複数の細胞クラスターを示すものを採用した.

カスタムデータセットは, LBC 検体 (Cellprep®, Roche diagnostics) として利用するために撮影された 703 の細胞診画像からなる. Bethesda 分類に従い, これらの画像は 4 つの子宮頸部細胞診クラス (NILM : 174 枚, LSIL : 172 枚, HSIL : 180 枚, SCC : 177 枚) に分類された. これらの検体は, 2015 年から 2018 年の間に共同研究機関である札幌医科大学で実施された LBC 検査症例から無作為に選択された. 2 名の細胞診専門医と 1 名の細胞診専門医が参加した専門家協議により, 各ベセスダ分類のアノテーション結果が得られた.

Herlev の乳頭塗抹データセットは, 7 つの異なるクラスに不均等に分散した 917 枚の細胞画像から構成されている. Mendeley Liquid-Based Cytology データセットは, 子宮頸部細胞診の包括的なスライド画像 963 枚からなり, やはり 4 つのクラスに不均等に分散している. これらのデータセットの概要並びにハイパーパラメータを表 1 に示す.

**Table 1.** Statistics of three datasets, in terms of number of classes  $K$ , number of instances  $N$ , and image size (width, height). Hyperparameters for each dataset used in the experiment, number of epochs,  $\alpha$ ,  $\beta$ , and  $\tau$ , are described. In our dataset and the Herlev dataset, we listed the average size of the images.

Dataset	$K$	$N$	Image size (w, h)	Epochs	$\alpha$	$\beta$	$\tau$
Our	4	703	(300, 297)	150	1.00	0.01	0.1
Herlev	7	917	(155, 139)	100	10.00	1.00	1.0
Mendelay	4	963	(2,048, 1,536)	50	10.00	1.00	1.0

## 5.2 インプリメント

API-Net と同様に、エンコーダ  $E$  は ImageNet 上で事前に学習された ResNet101 として実装され、最後の層は削除された。相互ベクトル生成器  $G$  には 2 つの完全連結層が組み込まれ、投影ヘッド  $H$  は 1 つの完全連結層で構成された。ResNet101 の中間層の出力から、埋め込み空間の次元  $D$  を 2,048 に設定した。データ補強のため、入力画像は 512px にリサイズされ、続いて 480px にランダムにトリミングされた。さらに、学習データを提供する際に、画像はランダムに水平および垂直方向に反転された。正規化は、訓練データセットから決定された RGB 値の平均と標準偏差を利用して実行され、訓練データとテストデータの両方に適用された。最適化には SGD [20] を使用し、学習率 0.01、運動量 0.9、減衰量  $5e-4$  で全データセットに適用した。

## 5.3 実験目的

子宮頸部細胞診画像データセットを用いて、以下の 3 点を実験目的とした。

- 1) 我々の提案する手法が API-Net と ResNet101 の性能指標を上回っているかどうか
- 2) 細胞専門医のために我々の方法を用いて作成された可視化の情報性と関連性を決定
- 3) ハイパーパラメーターの変更に応じて、提案技術の挙動と適応性を評価

性能指標を並置するために 5 重の交差検証を行い、4 つの評価基準を採用、すなわち精度、再現性、精度、F1 スコアである。可視化結果を評価するため、学習したプロトタイプを用いてテスト画像のヒートマップを作成し、臨床的妥当性と有効性の定性的検証を容易にした。ハイパーパラメーターの動向を評価するため、3 つの損失関数のうち 1 つを省略した場合の結果を比較した。さらに、損失関数の重み  $\alpha$  と  $\beta$  を変化させたときの挙動を調べた。最後に、教師付きコントラスト損失に統合される温度パラメータ  $\tau$  を調整した場合の性能ダイナミクスを分析した。

## 6 結果

### 6.1 分類性能

表 2 は 3 つのデータセットにおける ResNet101, API-Net, 提案手法の評価結果である。これらの結果は、提案手法が全てのデータセットにおいて最も良い性能を示すことを示している。このことは、分類性能を向上させるために、プロトタイプ学習と教師付き対比損失を組み込むことの有効性を示している。さらに、これらの Recall 値と precision 値のわずかな差は、モデルが特定のクラスへの明確な偏りを示さなかったことを示している。細胞診スクリーニングでは、低悪


性度クラスの出力に偏りがあると見逃されるがんの数が増加し、高悪性度クラスの出力に偏りがあるとシステムがスクリーニングの役割を果たせなくなる。したがって、この性能は細胞診スクリーニングに適していると考えられる。Herlev データセットの性能は、すべてのモデルで他のデータセットより低かった。これは、Herlev データセットには分類すべきクラスが多いためと考えられる。

## 6.2 可視化性能

図 3 は、モデルが NILM と HSIL を正しく予測し、SCC の HSIL を正しく予測しなかった例を示している。NILM クラスでは、可視化されたアテンション領域ヒートマップにおいて、モデルは意図的に核構造から注意をそらしているように見えている。対照的に、より非典型的な HSIL/SCC クラスでは、特にクロマチン凝集や構造異常を示す領域では、アテンションが主に核に集中している。このことは、正解例は正しいクラスを選択する根拠を可視化することができ、一方、誤答例はどの領域が誤答につながったかによって、人間が割り当てたラベルが場合によっては間違っている可能性を示している。提案するモデルのアテンション領域は、細胞学者や細胞検査士が通常精査する領域と一致しており、モデルの推論プロセスが理解しやすくなっていることを示している。

**Table 2.** Performance (in %) comparisons in terms of the average top-1 accuracy, recall, precision, and F1-score on the datasets. The best results are shown in boldface. The bottom three displays the results when only certain loss terms are used.

Method	Our				Herlev				Mendeley			
	Acc	Rec	Pre	F1	Acc	Rec	Pre	F1	Acc	Rec	Pre	F1
ResNet101 [22]	91.6	91.6	92.2	91.7	73.6	76.2	76.5	76.4	99.4	98.9	98.3	98.6
API-Net [18]	91.2	91.2	91.6	91.3	71.8	73.7	75.4	74.6	98.9	97.0	97.5	97.2
Proposed	<b>94.6</b>	<b>94.6</b>	<b>94.8</b>	<b>94.7</b>	<b>74.6</b>	<b>77.7</b>	<b>77.9</b>	<b>77.8</b>	<b>99.9</b>	<b>99.8</b>	<b>99.7</b>	<b>99.8</b>
Proposed( $\mathcal{L}^{CE} + \mathcal{L}^{PC}$ )	93.6	93.6	93.9	93.7	72.3	75.3	75.6	75.4	99.6	99.4	98.8	99.0
Proposed( $\mathcal{L}^{CE} + \mathcal{L}^{AC}$ )	92.2	92.2	92.6	92.3	73.7	76.7	76.9	76.8	99.6	99.4	98.9	99.1
Proposed( $\mathcal{L}^{CE}$ )	93.3	93.3	93.6	93.4	73.1	76.4	77.0	76.7	99.4	99.2	98.3	98.7



**Fig. 3.** Examples where the model made correct predictions for NILM and HSIL and incorrect predictions for SCC: the leftmost image denotes the raw input image, and the other four images represent the heatmaps of the NILM, LSIL, HSIL, and SCC obtained by the proposed model from left to right.

## 7 考察

表 2 は、我々のデータセットの性能を、教師ありの対照埋め込み損失の有無で比較したものであるが、この結果は、すべての損失関数を導入した場合に、最良の性能が得られることを示している。しかし、(LCE + LAC)と(LCE)を比較すると、LAC を加えた場合の性能の方が低いことも示している。このことは、LAC は単独よりも、LPC と組み合わせて採用した方が良いことを示唆している。この性能低下は、ハイパーパラメータをより詳細にチューニングすることで解消できる可能性がある。

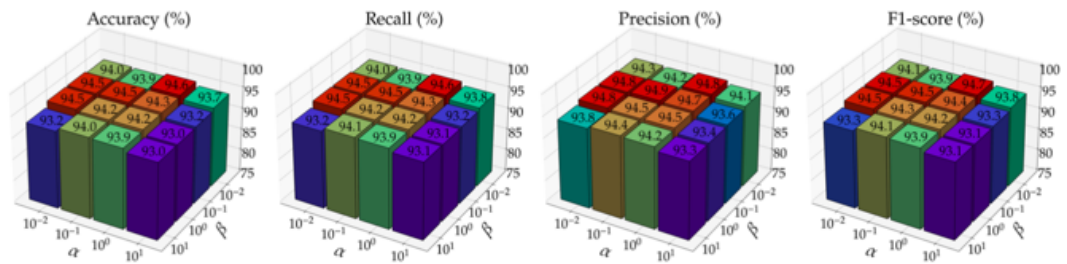


Fig. 4. Results of metrics (in %) concerning various hyperparameters  $\alpha$  and  $\beta$




Fig. 5. Results of metrics (in %) concerning various temperature parameters  $\tau$ . The horizontal axis is  $\tau$ , the vertical axis is the average value for five-fold cross-validation, and the standard deviation across folds is shown in the fill.

さらに、各データセットに関連して考察する。図 4 は、 $\{10^{-2}, 10^{-1}, 10^0, 10^1\}$  の範囲でハイパーパラメータ  $\alpha$  と  $\beta$  を指数関数的に変化させた結果であり、これらの結果は、データセットに対する最適値は  $\alpha = 1$  と  $\beta = 0.01$  であることを示している。計算資源に制約がある場合は、 $\alpha$  と  $\beta$  の両方を含む二次元グリッド探索の代わりに、同一の  $\alpha$  値を採用した一次元グリッド探索で十分かもしれない。 $\alpha$  と  $\beta$  の両方が過大な値であると、分類性能に直接関係する LCE の最小化を妨げる可能性があり、潜在的に劣悪な分類結果をもたらす可能性がある。

図 5 は、データセットの温度パラメータを変化させたときの性能の軌跡を示している。これらの結果から、温度パラメータ  $\tau=0.1$  が提案手法にとって理想的な選択であることがわかった。これらの結果から、温度パラメータを極端に小さくすると性能に悪影響があることがわかった。

## 7 結論

本研究では、分類モデルの学習、プロトタイプの学習、アテンションメカニズムによる未知画像との比較を並行して行うことで、各クラスの有意領域を明らかにする手法を提案、検証した。本手



法は、従来の手法を凌駕する性能とわかりやすい可視化結果を提供する。この試みは、細胞診における視覚的証拠の透明性と精度の両方を向上させるための重要な一歩である。さらに、我々の手法は、その構造基盤としてどのような CNN モデルにも適応可能であることから、優れた表現能力を持つモデルを利用することで、分類性能をさらに向上させ、より解明的な可視化をもたらすことができる。今後の研究では、最適に捕捉されたインスタンスのニュアンスをカプセル化する埋め込み表現の学習を掘り下げ、学習段階におけるペアワイズデータの効果的なサンプリング戦略を明確化することが重要である。

さらに、我々は、本研究の発展型として子宮体がんの病理診断における診断支援法も提案しているので参考にされたい<sup>10)</sup>。

## 8 未来大における ICT 医療への取り組み状況

本報告では子宮頸がん細胞診において、選好学習に基づく扁平上皮細胞診断手法を提案し、その結果を考察した。我々は本研究のような、AI を用いた自動診断支援に加え、ネットワーク医療における脳腫瘍摘出手術における遠隔診断支援法、認知症前段階である MCI を早期にスクリーニングする手法などを検討している。本報告はこれらの研究の一部であり、今後、健常者支援など、少子高齢化真っ只中の我が国の健康を ICT で支援することなども検討していきたい<sup>11)</sup>。

一方、我々は、医療 ICT を 3 年時の段階で学ぶデジタルヘルスプロジェクト学習も運営しており、その成果も期待している。2023 年度は別紙 1 に示すようなテーマで取り組んでおり、毎年、医療関係者に高く評価されている<sup>12)</sup>。

我々の医療 ICT への取り組み成果を共有するため、毎年、未来大学メディカル ICT 研究会を開催しているが、2023 年度には、第 13 回研究会（2024.3）を開催し、本研究を含む我々の研究成果、また共同研究相手他の最新研究成果などを共有してきた。そのプログラムを別紙 2 に示す。

最後に貴財団からの長年に渡る支援に対し、心からの感謝の意を表す。

## 8 別紙

1. 別紙 1 2023 年度未来大メディカル ICT 研究会 プログラム 2024.3
2. 未来大学プロジェクト学習 デジタルヘルス 2023

## 参考文献

- <sup>1)</sup> Sung, H., Ferlay, J., Siegel, R.L., Laversanne, M., Soerjomataram, I., Jemal, A., Bray, F. ,” Global cancer statistics 2020: Globocan estimates of incidence and mortality worldwide for 36 cancers in 185 countries”, CA: A Cancer Journal for Clinicians (2021)
- <sup>2)</sup> Yu, S., Feng, X., Wang, B., Dun, H., Zhang, S., Zhang, R., Huang, X. , “Automatic classification of cervical cells using deep learning method”, IEEE Access 9, 32,559- 32,568 (2021)
- <sup>3)</sup> Lu, M.Y, Williamson, D.F.K., Chen, T.Y., Chen, R.J., Barbieri, M., Mahmood, F., “Data-efficient and weakly supervised computational pathology on whole-slide images”, Nature Biomedical Engineering 5(6), 555-570 (2021)
- <sup>4)</sup> Alias, N. A., Mustafa, W. A., Jamlos, M. A., Alquran, H., Hanafi, H. F., Ismail, S., Rahman, K.S.A., “Pap smear images classification using machine learning”, A literature matrix. Diagnostics 12(12) (2022)
- <sup>5)</sup> Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A.N., Kaiser,L.u., Polosukhin, I. “Attention is all you need.In”, Advances in Neural Information Processing Systems, vol. 30 (2017)
- <sup>6)</sup> Zhuang, P., Wang, Y., Qiao, Y., ”Learning attentive pairwise interaction for finegrained classification”, Proceedings of the AAAI Conference on Artificial Intelligence 34(07), 13,130–13,137 (2020) “
- <sup>7)</sup> Yuta Nambu, Tasuku Mariya, Syota Shinkai, Mina Umemoto, Tsuyoshi Saito, Toshihiko Torigoe, Hiroshi Inamura and Yuichi Fujino, "Visual Explanation of Classification Model Using Prototypical Contrastive Embedding in Cervical Cytology", ICICT2024, London, Springer, Feb., 2024
- <sup>8)</sup> Jantzen, J., Norup, J., Dounias, G., Bjerregaard, B., “ Pap-smear benchmark data for pattern classification.In”, Proc.NiSIS 2005, pp.,
- <sup>9)</sup> Hussain, E., Mahanta, L.B., Borah, H., Das, C.R.: Liquid based-cytology pap smeardataset for automated multi-class diagnosis of pre-cancerous and cervical cancer lesions. Data in Brief 30, 105,589 (2020)
- <sup>10)</sup> Mina U., Tasuku M., Yuta N., Mai N., Toshihiro H., Shintaro S., Takayuki K., Yuka T., Shota S., Motoki M., Masahiro I., Yoshihiko H., Tadashi H., Toshihiko T., Yuichi F., Tsuyoshi S., ” Prediction of Mismatch Repair Status in Endometrial Cancer from Histological Slide Images Using Various Deep Learning-Based Algorithms”, Cancers (Basel). 2024 May 9;16(10):1810. doi: 10.3390/cancers16101810.
- <sup>11)</sup> 藤野雄一, 佐藤生馬, “未来大学におけるメディカルIT研究の状況“, 電子情報通信学会, 環境電磁工学研究会(EMCJ), 2024.6
- <sup>12)</sup> 公立ほこだて未来大学ホームページ, <https://www.fun.ac.jp/pbl-theme#1-1>


# デジタルヘルス2023

## Digital Health 2023

加藤 太 郎 Soutaro Katou  
 里村 駿 秀 Hayahide Satomura  
 井坂 圭 太 Keita Isaka  
 富樫 暁 登 Haruto Togashi  
 稗田 一 瑛 Issa Hieda  
 湊 雅 弥 Masaya Minato  
 奥田 拓 真 Takuma Okuda  
 石原 幸 弥 Yukiya Ishihara  
 細谷 陸 人 Rikuto Hosoya  
 井口 玲 人 Akito Iguchi  
 安田 凌 Ryo Yasuta  
 梅原 麻 由 佳 Mayuka Umebara  
 小北 駿 Shun Kokita

### 概要

Outline



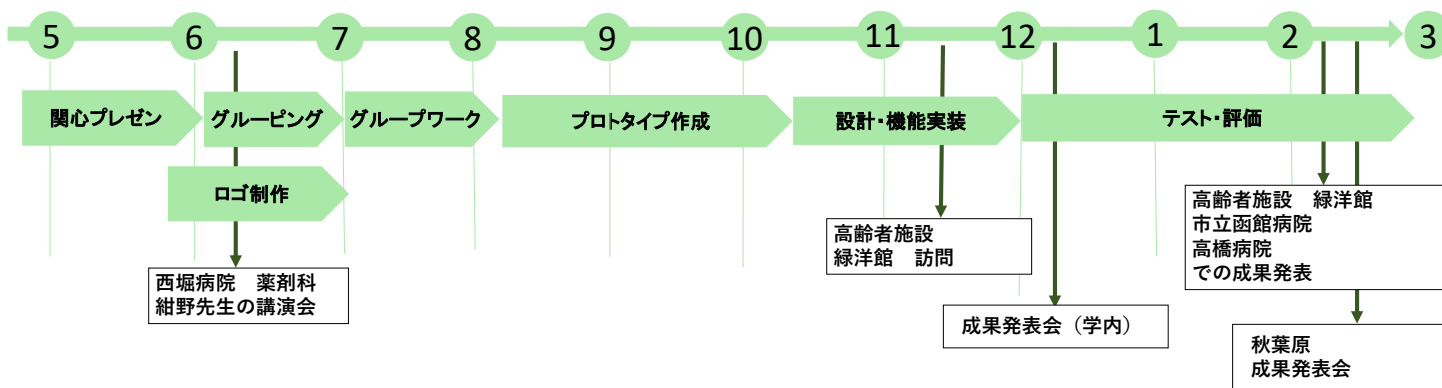
### グループ活動

Group Activity Contents

<p><b>A</b> デジタルツインを用いた肥満に対する健康支援「ヘルスマイル」</p> <p>近年先進国型の癌が増加しており、その原因は肥満が多くの割合を占めている。これを解決するために私たちはヘルスマイルというアプリを提案する。このアプリはユーザーの健康状態を、ゆるキャラをモチーフにしたAIとの会話、ウェアラブルデバイスやタニタのデバイスを使用して取得、可視化し、データを共有するものである。私たちはこれらによるユーザーの生活習慣の改善を促すことを目的としている。</p>	<p>An app for recording, diagnosing, and sharing daily health conditions "Healthmile"</p> <p>In recent years, the number of cancers in developed countries has been increasing, and obesity is the cause of a large proportion of these cancers. To solve this problem, we propose an app called "Healthmile". This app visualizes the user's health status through conversations with an AI based on a Mascot character, wearable devices, and Tanita devices, and shares the data with others. The purpose of the application is to encourage users to improve their lifestyle habits.</p>
<p><b>B</b> 看護師記録記述システム「NIAS+」</p> <p>日本の医療労働組合連合によれば、看護師たちは自身の仕事に負担を感じており、特に看護記録の作成においてその課題が際立っています。私たちは、看護師の負担を軽減するために、入力作業の効率化などの機能を提案します。</p>	<p>Nursing Record Description System "NIAS+"</p> <p>According to the Japanese Federation of Health Care Workers Unions, nurses feel burdened by their own work, and this challenge is particularly pronounced in the creation of nursing records. We are proposing features such as streamlining the input process to ease the burden on nurses.</p>
<p><b>C</b> 「夫婦」と「記録」を繋ぐ経過・健康記録支援アプリ「ピアと。」</p> <p>近年、妊娠件数の減少が続いています。この中で注目されているのは、妊婦が抱える問題、具体的には「健康管理」「夫婦関係」「当事者としての認識の不足」などです。私たちは、「キャラクター」を用いて、健康記録の入力や運動促進、夫婦間の情報共有、そして妊娠中や育児に関する知識の獲得を円滑に行えるようにするアプリを提案します。</p>	<p>Connecting "couples" and "Records" - the progress and health record support app "Piato"</p> <p>In recent years, the number of pregnancies has continued to decline. In this context, attention has been focused on the problems faced by pregnant women, specifically "health management", "marital relations", and "lack of awareness as a party". We propose an application that uses "characters" to facilitate the input of health records, the promotion of exercise, the sharing of information between couples, and the acquisition of knowledge about pregnancy and childcare.</p>
<p><b>D</b> バリデーション療法を用いた会話型ロボット「ヴァリー」</p> <p>独居認知症が増加しており、その独居によるストレスや不安が問題視されています。そのため、私たちは認知症の症状緩和やストレス、不安の軽減、そして毎日の薬の補助を可能にするため、Chat-GPTを利用した会話型ロボットの提案をします。</p>	<p>Conversation Robot Utilizing Validation Therapy "Vali"</p> <p>The number of people with dementia living alone is increasing, and the stress and anxiety caused by this solitude is becoming an issue. Therefore, we are proposing a conversational robot using Chat-GPT to alleviate symptoms of dementia, reduce stress and anxiety, and provide assistance with daily medications.</p>

### 活動経過

Activity Process



# 第13回 公立はこだて未来大学メディカル ICT 研究会

2024年3月吉日

公立はこだて未来大学 教授 石樽 康雄  
公立はこだて未来大学 准教授 佐藤 生馬

拝啓

新春の候、皆様におかれましてはますますご健勝のこととお慶び申し上げます。

昨年度のメディカル ICT 研究会は2023年3月に開催させていただきましたが、多くのみなさまにお集まりいただき、大変ありがとうございました。今回、公立はこだて未来大学では体制の変更もあり、あらためてみなさまへのご挨拶と本研究会の継続的な発展を目指して下記日程にて開催させて頂きたく、ご連絡を申し上げます。

年度末のお忙しい中、皆様におかれましてはスケジュール調整が大変困難かと存じますが、ご都合がよろしければ、ぜひ函館にてお会いできればと存じます。新型コロナウイルス、インフルエンザ等の感染症に関しましては大学内では十分衛生、換気に注意し、また現地参加が難しい方々にはオンラインにての参加をお願いし開催予定ですので、皆様のご参加をお待ちしております。

敬具

## 記

- ・日時 2024年3月11日(月) 13:00-17:50  
3月12日(火) 9:30-11:50
- ・場所 公立はこだて未来大学 講義室 R791 / 一部オンラインセッションのみ zoom で配信

## プログラム

〇1日目 3月11日 13:00-17:05

1. オープニング 13:00-13:05

公立はこだて未来大学 石樽 康雄

2. 一般セッション I 13:05-14:05

1) 13:05-13:25 “公立はこだて未来大学における医療・健康 ICT 研究について”

公立はこだて未来大学 石樽 康雄

2) 13:25-14:05 “覚醒下脳腫瘍摘出術における ICT 技術を用いた手術支援”

公立はこだて未来大学 佐藤 生馬

3. 基調講演 I 14:15-15:45

- 3) 14:15-15:00 “術中情報の可視化と臨床への応用 ～覚醒下手術と IEMAS および Hyper SCOT の歩み～”  
東京女子医科大学 田村 学, 正宗 賢
- 4) 15:00-15:45 “リアルワールドデータの活用による Precision-medicine の実現”  
NTT ライフサイエンス 是川 幸士

4. 一般セッション II 15:55-16:55

- 5) 15:55-16:15 “介護現場でのロボット介護の現状”  
社会医療法人至仁会 介護老人保健施設 遊 施設長 伊関 洋
- 6) 16:15-16:35 “眠りスキャン導入後の介護現場の現状”  
社会医療法人至仁会 介護老人保健施設 遊 介護福祉士 田代 敏行
- 7) 16:35-16:55 “生活習慣病予防のための保健指導面談における動機付け対話プロセスの分析”  
NTT 社会情報研究所 Well-being 研究プロジェクト 佐藤 妙

5. 基調講演 II 17:05-17:50

- 8) 17:05-17:50 “NTT における Well-being 研究のご紹介～人文・社会科学を含む異分野との ICT 連携を通じて～”  
NTT 社会情報研究所 Well-being 研究プロジェクト 宮本 勝

○2 日目 3月12日 9:30-12:10

6. 基調講演 III 9:30-10:15

- 9) 9:30-10:15 “米国における医療情報の活用動向について” (オンライン)  
札幌医科大学 辰巳 治之

7. 一般セッション III 10:25-11:45

- 10) 10:25-10:45 “産婦人科診療支援の現状とニーズ～札幌医科大学産婦人科学講座の取り組み～”  
札幌医科大学産婦人科 梅本 美菜
- 11) 10:45-11:05 “比較の概念を導入した深層学習による効率的で説明可能な子宮頸部細胞診断支援システムの研究”  
公立ほこだて未来大学 D3 南部 優太
- 12) 11:05-11:25 “新しい当事者参画医療社会モデル構築に向けて”  
東京女子医科大学 北原 秀治
- 13) 11:25-11:45 “機会出し看護師ロボットシステムの今と昔”  
東京女子医科大学 吉光 喜太郎, 正宗 賢

8. クロージング 11:45-11:50

公立ほこだて未来大学 石樽 康雄

9. その他

- 本研究会の一部の内容は未公開研究テーマを含んでいます。よって、本研究会の模様を録画、写真撮影を行うことはご遠慮いただくようお願いいたします。なお、講演者の許可が得られた一部の講演資料に関しては、ご希望の方には配布を予定しています。