

一般口演 | 第40回医療情報学連合大会（第21回日本医療情報学会学術大会） | 一般口演

一般口演5

画像情報・生体信号処理

2020年11月19日(木) 14:00 ~ 15:23 E会場 (コンgresセンター5階・52~54会議室)

[2-E-2-03] YOLOv3を用いた子宮頸部細胞診画像クラスタリング手法の提案

*南部 優太¹、真里谷 奨^{2,3}、新開 翔太²、浅沼 広子^{3,4}、廣橋 良彦³、齋藤 豪²、鳥越 俊彦³、佐藤 生馬⁵、藤野 雄一⁵

(1. 公立はこだて未来大学大学院システム情報科学研究科システム情報科学専攻, 2. 札幌医科大学医学部産婦人科学講座, 3. 札幌医科大学医学部第一病理学講座, 4. 札幌医科大学医学部病理診断学, 5. 公立はこだて未来大学システム情報科学部情報アーキテクチャ学科)

*Yuta Nambu¹, Tasuku Mariya^{2,3}, Syouta Shinkai², Hiroko Asanuma^{3,4}, Yoshihiko Hirohashi³, Tsuyoshi Saito², Toshihiko Torigoe³, Ikuma Sato⁵, Yuichi Fujino⁵ (1. 公立はこだて未来大学大学院システム情報科学研究科システム情報科学専攻, 2. 札幌医科大学医学部産婦人科学講座, 3. 札幌医科大学医学部第一病理学講座, 4. 札幌医科大学医学部病理診断学, 5. 公立はこだて未来大学システム情報科学部情報アーキテクチャ学科)

キーワード : Cervical Cytology, Deep Learning, Object Detection

子宮頸がんを対象としたサイトスクリーニングにおいて、専門医や細胞検査師の負担が大きい、検者によって診断結果にばらつきが生じるという課題がある。これらの課題に対し、情報処理を用いた自動スクリーニングを実現することで専門医らの負担を軽減し、ばらつきのない診断が可能になると考えられる。そこで、本研究では自動スクリーニングの実現を目的として、YOLOv3および独自のフィルタ処理により子宮頸部細胞診画像の自動分類を実現した。まず、分類対象をASC-US, LSIL, ASC-H, HSIL, SCCの5つと定め、子宮頸部液状化検体細胞診を施行した症例から、各クラス50枚の画像データセットを作成した。次に、学習画像枚数の不足を補うため、フィルタ処理により学習画像枚数を36倍に増加させた。そして、フィルタ処理後のデータセットに対し、訓練データセットを75%、検証データセットを12.5%としてYOLOv3の学習処理を適用した。YOLOv3の検出処理時にいずれのクラスも検出しなかった場合をNILMとすることで、6クラスの分類を実現した。最後に、NILM画像50枚とフィルタ処理後のデータセット12.5%をテストデータセットとして、精度評価を行った。精度評価の結果、正解率の平均値は87.2%であった。また、スクリーニングにおいて重要とされる再現率の平均値は78.2%であった。なかでも、HSILは正答率76.1%に対し、再現率23.7%と低精度であった。これは、HSILは悪性度が高くASC-HとSCCの中間に位置することで他クラスと混同したためだと考察される。実際に混同した頻度を調べた結果、HSILは56.7%の確率で他クラスと混同していた。以上のことから、機械学習を適用するだけでは悪性度の高いクラスの分類は難しく、画像以外の特徴量を追加するか貢献度の高い特徴量を事前に定義する必要があることが示唆された。

YOLOv3 を用いた子宮頸部細胞診画像クラスタリング手法の提案

南部優太^{*1}、真里谷奨^{*2,3}、新開翔太^{*2}、浅沼広子^{*3,4}、廣橋良彦^{*3}、
齋藤豪^{*2}、鳥越俊彦^{*3}、佐藤生馬^{*5}、藤野雄一^{*5}

*1 公立はこだて未来大学大学院システム情報科学研究科システム情報科学専攻、

*2 札幌医科大学医学部産婦人科学講座、*3 札幌医科大学医学部第一病理学講座、

*4 札幌医科大学医学部病理診断学、*5 公立はこだて未来大学システム情報学部情報アーキテクチャ学科

A Proposal of Image Clustering Using YOLOv3 for Cervical Cytology

Yuta Nambu^{*1}, Tasuku Mariya^{*2,3}, Syouta Shinkai^{*2}, Hiroko Asanuma^{*3,4}, Yoshihiko Hirohashi^{*3}, Tsuyoshi Saito^{*2},
Toshihiko Torigoe^{*3}, Ikuma Sato^{*5}, Yuichi Fujino^{*5}

*1 Future University Hakodate Media Architecture Field,

*2 Sapporo Medical University School of Medicine Dept. Of Obstetrics and Gynecology,

*3 Sapporo Medical University School of Medicine Dept. Of Pathology,

*4 Sapporo Medical University School of Medicine Dept. Of Surgical Pathology,

*5 Future University Hakodate Dept. Of Media Architecture

Abstract in English comes here.

Cytoscreening for cervical cancer requires a heavy burden on specialists and cytologists, and results may vary among cytoscreeners and institutions. To address these issues, automatic screening using information processing will reduce the burden on specialists and enable more consistent diagnosis. Therefore, in this study, we realized automatic classification of cervical cytology images by data augmentation and YOLOv3 to realize automatic screening. We recruited pictures of cervical cytology and classified them into six classes according to the Bethesda Classification. To compensate for the lack of data set, we performed image inversion and filter processing as data augmentation. In addition, this method detects only cells other than NILM and If none were detected, it judges to be NILM. The results of the accuracy evaluation of this method showed that the mean value of the recall was 80.1%. There are some issues that high malignant cells are often confused with other classes of cells and are prone to detection errors. In future, we would like to introduce hierarchical classification and some features other than image features.

Keywords: Cervical Cytology, Deep Learning, Object Detection

1. 緒論

子宮頸がんは婦人科系の悪性腫瘍では最も多く、挙児希望の多い若年層での発症も少なくないがんである。子宮頸がんを早期に発見できた場合には、部分円錐切除などの処理により子宮温存が可能である。しかし、腫瘍浸潤が認められた場合には子宮全摘出が必要となり、妊孕性は失われてしまう。さらに、他の部位への転移が認められた場合には、子宮全摘出だけでなく放射線治療や抗がん剤治療が必要となる。これらのことから、子宮頸がん検診での早期発見が求められている。

一般に子宮頸がん検診では、擦過細胞¹⁾という検査方法のもと、2段階の判断プロセスを経る。まず1次スクリーニングとして、子宮頸部をこすり取ることで得た細胞を細胞検査技師が顕微鏡で観察し、ベセスダ分類²⁾に従って推定診断する。次に2次スクリーニングとして、細胞診専門医が顕微鏡による観察および推定診断結果を参考に最終的な診断を確定する。

子宮頸がん対象としたサイトスクリーニングにおいて、専門医や細胞検査師の負担が大きいという課題がある。サイトスクリーニングでは、がん患者の見逃しがないよう感度を最大化しつつ、正常患者に陽性を出さないよう特異度を最大化する高度な診断が求められている。加えて、子宮頸がん集団検診の機会増加に伴った受診者増加に対応するため、検診速度の高速化も求められている。これらの要求により、専門医や細胞検査師の負担が大きくなっている。

また、サイトスクリーニングにおいて明確かつ機械的に診断

可能な基準が定義されていないという課題もある。サイトスクリーニングにおいて、重要とされる特徴量は存在しているが、その特徴量から細胞を異常であると判断する定量的な閾値は曖昧な部分が多い。そのため、診断能力は検者の経験に依存することとなり、受診する病院や検者によって診断結果にばらつきが生じる。

これらの課題に対し、情報処理技術を用いた自動スクリーニングを実現することで専門医らの負担軽減、および、ばらつきの少ない診断が可能になると期待される。自動細胞診画像分類の先行研究として、単細胞診画像を分類する手法が多数提案されている。ここでの単細胞診画像は、1枚の画像に1つの細胞が存在する画像を指す。先行研究では、正常/異常の2クラス分類手法³⁻⁸⁾と悪性度を判別する多クラス分類手法³⁻⁵⁾が存在し、いずれも高精度な分類を実現している。しかし、これらの手法は、単細胞診画像という比較的ノイズの少ない画像を対象としており、単細胞特徴を良好に取得できることが前提となっている。そのため、サイトスクリーニングの現場で用いられる複数細胞が映るような画像にそのまま適用することはできない。

この課題を踏まえ、複数細胞診画像を対象とした分類手法が提案されている。複数細胞診画像に対しても同様に、正常/異常の2クラス分類手法と悪性度を判別する多クラス分類手法が存在している。2クラス分類手法の多くは、セグメンテーションやディープラーニングを用いることで、複数細胞診画像を単細胞診画像へ分離している^{7,9-11)}。そして、分離された単細胞診画像に対して、既存の単細胞特徴を用いた分類を行

う。単細胞分離処理の精度が万全ではないため、単細胞診画像分類と比較すると精度は劣るが 95%以上の精度が報告されている。対して、複数細胞診画像に対する多クラス分類手法の精度は十分でない。複数細胞診画像から有所見細胞を検出する手法として、一般物体検出手法の応用が提案されている^{12,13}。これらの手法は、一般物体検出手法を使うことで、単細胞への分離や、アーチファクト除去、セグメンテーションなどの前処理を省略することに成功している。また、これらの手法は、複数細胞診画像を対象として有所見細胞の検出、悪性度の分類を可能とするため、サイトスクリーニングに求められる要件をより満たしている。しかし、これらの手法は平均再現率が 70%に満たず、陽性の見逃しつまり偽陰性が多くなることが予想される。つまり、一般物体検出手法を応用することは有用であると考えられるが、精度が低いためにスクリーニング手法としては不十分である。

2. 目的

そこで、本研究では自動スクリーニングの実現を目的として、YOLOv3¹⁴およびデータ拡張による複数細胞診画像を対象としたより高精度な悪性度分類手法を提案する。

3. 方法

本手法では、分類対象を 6 クラスと定め、子宮頸部液状化検体細胞診を施行した症例から画像データセットを作成する。次に、学習画像枚数の不足を補うため、反転・フィルタ処理によりデータセットを拡張する。そして、拡張後のデータセットに対し YOLOv3 の学習処理を適用する。以下に手法の詳細を述べる。

3.1 データセットの作成

分類対象をベセスダ分類に従い NILM, ASC-US, LSIL, ASC-H, HSIL, SCC の 6 つと定め、子宮頸部液状化検体細胞診 (Cellprep®) を施行した症例より無作為に症例を抽出し、対物 40 倍で撮影する。その後、NILM を除いた有所見細胞 5 クラスのアノテーションを行う。アノテーション済み画像の例を図 1 に示す。アノテーションデータは、画像上における矩形の x 座標, y 座標, 高さ, 幅の 4 つの浮動小数点数および、正解クラスを識別する整数で構成され、テキストファイルとして保存する。




図 1 アノテーション済み画像の例

3.2 データセットの拡張

前述のデータセットの構築は多くの時間と手間を要し、大量の画像データセットを作成することは容易ではない。そこで、学習画像枚数の不足を補うため、反転・フィルタ処理によりデータセットの拡張を行う。反転・フィルタ処理は、先行研究¹⁵

にて有用であると示されたもの(表 1)を使用する。まず、RAW 画像に対し表 1 に示した 3 つの反転処理を加えることで画像枚数を 3 倍とし、RAW 画像を含め RAW 画像 1 枚当たり 4 枚に拡張する。その後、拡張された 4 枚の画像に対し表 1 に示した 8 つのフィルタ処理を加えることで、RAW 画像を含めて 9 倍、合計 36 倍に拡張する。

表 1 データ拡張処理の詳細

処理名	パラメータ
水平反転	
垂直反転	
水平垂直反転	
ヒストグラム平坦化	
コントラスト強調	Min=50, Max=205
コントラスト低減	Min=50, Max=205
ガンマ補正	$\gamma=0.75$
ガンマ補正	$\gamma=1.5$
移動平均フィルタ	5x5 kernel
ガウシアンノイズ	Mean=0, $\sigma=15$
ソルトペッパーノイズ	sp_rate=0.5

3.3 トレーニング

ニューラルネットワークフレームワークの Darknet を用いて YOLOv3 の学習処理を行う。一般に検出速度と検出精度はトレードオフの関係にあるが、YOLOv3 は他の物体検出手法に比べ検出精度と検出速度のバランスが良い¹⁴。そのため、高い検出精度を維持しながら、専門医の検鏡に合わせたリアルタイムスクリーニング支援を視野に含めた高速処理が期待できる。

また、YOLOv3 は対象画像全体をグリッド分割したのち、それぞれのグリッドに対してバウンディングボックスを生成し信頼度スコアを推測する。つまり、検出したいオブジェクトが存在していない領域に対しても、信頼度スコアが 0 になるように学習しているといえる。つまり、有所見細胞のみを学習させたモデルの検出結果が None である場合、その結果を有所見細胞が存在していないと解釈し、排他的に NILM であると結論付けることができる。排他的に NILM を検出することで、データセットに NILM を含める必要がなくなるため、数が多くアノテーションに時間のかかる NILM のアノテーションが省略可能となる。以上を踏まえ、NILM を除いた拡張後のデータセット(5 クラス)に対し、その一部を訓練データセットとして抽出し、Darknet を用いて学習処理を行う。

3.4 信頼度スコア閾値の決定

前述のとおり YOLOv3 は、検出したオブジェクトに対し信頼度スコアを算出する。この信頼度スコアが小さい場合は、正しくないオブジェクトを検出している可能性が高い。よって、信頼度スコアがある閾値未満である場合は、検出結果から省く必要がある。ただし、この閾値が大きすぎる場合、信頼度スコアは低い検出結果としては正しいケースが省かれてしまい、偽陰性が増える。

そこで、適切な閾値を定めるため、検証データセットを用いてグリッドサーチを行う。検証データセットは、拡張後のデータセット(5 クラス)の一部とする。閾値を 0.1, 0.2, ..., 0.8, 0.9 と 0.1 間隔で変更したときの再現率を調べ、最も高い再現率を記録した閾値を、最適な閾値とする。ここで、評価指標を再現率と定めた理由は、スクリーニングにおいては偽陽性を減らすことよりも偽陰性を減らすことのほうが重要であるためである。

3.5 評価実験

札幌医科大学附属病院にて撮影された画像を対象に本提案手法の精度評価を行った。精度評価指標は、適合率、再現率、F 値とした。データ拡張の効果を調べるため、データ拡張を行ったデータセットと行っていないデータセットの両方に対して同様の精度評価を行った。以下に詳細を述べる。

札幌医科大学附属病院にて撮影され、倫理委員会の承認を得た計 576 枚、6クラスの子宮頸部細胞の病理画像を実験に用いた。6クラスの内訳は、NILM, ASC-US, LSIL, ASC-H, HSIL, SCC である。これらの画像は、NILM クラスの画像であれば NILM しか含まれておらず、ASC-US クラスの画像であれば、ASC-US と NILM しか含んでいない。よって、1枚の画像に対して ASC-US と SCC が混在するといった、NILM 以外のクラス同士が混在しているケースは存在しない。次に、臨床細胞専門医 2 名（産婦人科 1 名、病理医 1 名）および細胞検査士 1 名により、NILM を除いた 5 クラスの画像に対しアノテーションを行った。

本実験では、拡張なしデータセットと拡張ありデータセットを対象に学習処理を行ったのち、テストデータセットに対して検出処理を適用することで精度評価を行った。

まず、アノテーションによって得られた画像データセットを学習データセット・テストデータセットへ分割した。これは、学習処理・信頼度スコア閾値の決定・精度評価のためである。学習データセットが不均衡である場合は検出精度に偏りがでる恐れがあるため、学習データセットの枚数は枚数の少ない ASC-US に合わせて 50 枚で統一し、残った画像をテストデータセットとした。比較実験のため、学習データセットを複製し、複製されたものにのみ反転処理・フィルタ処理を加えデータ拡張を行った。以上の手順より、拡張なし学習データセット、拡張ありデータセット、テストデータセットを得た。それぞれのデータセットの内訳を表 2 に示す。

次に、拡張なし学習データセットと拡張あり学習データセットを対象にそれぞれ Darknet を用いて学習処理を適用した。学習パラメータは表 3 に示した。この際、それぞれのデータセットの 80% を訓練データセットとして学習しており、残りの 20% を検証データセットとした。訓練データセットを対象とした 10000Batch の学習過程において、検証データセットへ適用したとき損失関数の出力が最小であったものを最適モデルとした。その後、最適モデルを用いて検証データセットへの検出処理を行い、再現率が最小値をとる最適な閾値を決定した。最後に、得られた最適モデルと閾値を用いてテストデータセットへの検出処理を行い、適合率・再現率・F 値を算出した。これらの検出処理において、1枚の画像に対し複数の異なるクラスが検出された場合、信頼度スコアが最も高いものを検出結果として採用した。適合率・再現率・F 値の計算式は式(1)から式(3)に示す。

$$\text{適合率} = (\text{真陽性数}) / (\text{真陽性数} + \text{偽陽性数}) \cdots (1)$$

$$\text{再現率} = (\text{真陽性数}) / (\text{真陽性数} + \text{偽陰性数}) \cdots (2)$$

$$\text{F 値} = (2 \times \text{適合率} \times \text{再現率}) / (\text{適合率} + \text{再現率}) \cdots (3)$$

表 2 データセットの内訳(枚)

	拡張なし	拡張あり	テスト
NILM	0	0	50
ASC-US	50	1800	9
LSIL	50	1800	15
ASC-H	50	1800	55
HISL	50	1800	93
SCC	50	1800	104

表 3 学習パラメータ

パラメータ名	設定値
Batch	64
Subdivisions	32
Width	416
Height	416
Channels	3
Momentum	0.9
Decay	0.0005
Learning_rate	0.001
Burn_in	1000
Max_batches	10000
Policy	Steps
Steps	8000, 9000
Scales	0.1, 0.1

4. 結果

信頼度スコア閾値と平均再現率の関係を図 2 に示す。図 2 より、最適な閾値は、拡張あり学習データセット・拡張なし学習データセットともに 0.1 であった。拡張なし学習データセット、拡張あり学習データセットを学習したモデルの閾値 0.1 における適合率・再現率・F 値をそれぞれ表 4、表 5 に示す。




図 2 信頼度スコア閾値と平均再現率の関係

表 4 拡張なし学習データセットにおける精度評価結果

悪性度	適合率[%]	再現率[%]	F 値[%]
NILM	60.3	88.0	71.5
ASC-US	27.3	33.3	30.0
LSIL	47.1	53.3	50.0
ASC-H	53.4	56.4	54.9
HSIL	52.0	14.0	22.0
SCC	67.6	92.3	78.0
平均	51.3	56.2	53.6

表 5 拡張あり学習データセットにおける精度評価結果

悪性度	適合率[%]	再現率[%]	F 値[%]
NILM	68.2	90.0	77.6
ASC-US	36.0	100.0	52.9
LSIL	51.7	100.0	68.2
ASC-H	66.1	74.5	70.1
HSIL	75.6	33.3	46.3
SCC	83.5	82.7	83.1
平均	63.5	80.1	70.9




図3 HSILをASC-Hと混同した検出失敗例




図4 HSILをSCCと混同した検出失敗例

5. 考察

本考察では、データ拡張による効果と学習済みモデルの精度を分析し、検出失敗傾向と対策について考察する。また、類似する先行研究と精度を比較し、その違いと要因について考察する。

5.1 データ拡張の効果

まず、データ拡張の効果について考察する。いずれの精度評価指標においてもデータセットの拡張を行った場合のほうが平均的に高精度であった。平均値において、適合率は12.2%、再現率は23.9%、F値は17.2%向上した。よって、データ拡張は分類精度の向上に貢献したと考えられる。ただし、データ拡張によりSCCのみ再現率が低下している。これは、適合率と再現率にはトレードオフの関係が成り立つため、適合率が向上すると引き換えに再現率が低下したためだと考えられる。SCCの再現率は低下後であっても82.7%であるため、他クラスと比較したとき低い値ではない。また、SCCのF値は向上しているため、総じてSCCの精度も向上しているといえる。よって、本実験ではデータ拡張による検出精度への明確なデメリットは見受けられなかった。

5.2 学習済みモデル精度

次に、より精度の高かった拡張あり学習データセット学習モデルの精度に関して考察する。このモデルは、平均的に適合率に比べ再現率の高いモデルとなっている。これは、適合率ではなく再現率を優先して信頼度スコアの閾値を決定したことによる。スクリーニングにおいては感度が重視されるため、スクリーニングに適当な精度を持つモデルの構築ができた。

課題として、低悪性度群(NILM, ASC-US, LSIL)に関しては、適合率が低いことが挙げられる。再現率が高いため見逃しは少ないが、適合率が低いと過剰に低悪性度群を検出

表6 提案手法の評価結果

悪性度	適合率[%]	再現率[%]	F値[%]
正常群	68.2	90.0	77.6
内科的経過観察群	44.4	100.0	61.5
要外科的処置群	99.5	81.3	89.5
平均	70.7	90.4	79.4

表7 先行研究の評価結果

悪性度	適合率[%]	再現率[%]	F値[%]
正常群	52.6±9.1	44.3±9.4	47.9±9.0
内科的経過観察群	68.3±8.2	83.4±9.7	75.0±8.6
要外科的処置群	83.3±4.9	81.6±4.2	82.3±2.9
平均	66.1±3.1	62.8±6.3	64.3±4.6

していることがわかる。適合率を損なう検出ミスは48例あったが、そのうち91%は高悪性度群(ASC-H, HSIL, SCC)を誤って低悪性度群として検出したケースであった。このような、高悪性度群を低悪性度群であると判断するミスは、悪性度を過小評価しているため改善が必要である。改善方法として、少なくとも正常群・低悪性度群・高悪性度群を混同しないよう、これら3つの群に分類したのち、悪性度を詳細分類する階層的な分類手法が有用であると考えられる。

5.3 HSILの再現率

もう1つの課題として、HSILの再現率が低いことが挙げられる。HSILの再現率を損なう検出ミスは56例あった。そのうち41%は前述した低悪性度群との混同であったが、30%はASC-Hとの混同(図3)であり、29%はSCCとの混同(図4)であった。このことから、HSILはASC-HとSCCの中間に位置するため、近傍のクラスと混同しやすいと考えられる。この問題を言い換えると、低悪性度群と高悪性度群の混同を解消できたとしても、高悪性度群の内部で混同が発生することを示唆している。よって、高い精度を目指すならば、画像の畳み込み処理だけでなく患者の年齢など画像以外の特微量や、核の大きさ・クロマチン凝集・N/C比など、すでに有用であることが判明している画像特徴を数値化することが精度向上に貢献すると考察される。

5.4 先行研究との比較

最後に、複数細胞診画像に対してFaster R-CNNを用いて分類を試みた先行研究[14]と精度の比較を行う。この先行研究では、NILMを正常群、ASC-US・LSILを内科的経過観察群、ASC-H・HSIL・SCCを要外科的処置群としてまとめ、3クラス分類を行っている。本研究では5クラスの学習データをYOLOv3のトレーニングに用いたため、厳密には先行研究の実験環境とは一致しない。しかし、精度評価の際にASC-USとLSILの混同を分類ミスとせず内科的経過観察群としてまとめ、同様にASC-H・HSIL・SCCの混同を分類ミスとせず要外科的処置群とすることで、疑似的に精度比較を行うことが可能である。よって、この条件で精度評価結果を解釈しなおしたものが表6である。先行研究の結果も同様に表7に示した。

先行研究と比較した結果、適合率・再現率・F値ともに本提案手法が優位であった。本研究では再現率を重視したため、再現率において特に優位であった。優位であった理由として、データ拡張の有無と物体検出手法の違いが挙げられる。この

2つの違いがそれぞれの精度の差に影響しているかは不明である。しかし、前述の評価実験の結果から、データ拡張は精度の底上げに貢献した可能性が高く、手法の違いは正常群の検出、つまり排他的に NILM を検出したことが貢献した可能性が高い。ただし、本研究ではホールドアウト検証の後、テストデータセットに対する精度評価をしているのに対し、先行研究では 5 分割交差検証の結果を精度評価の結果としている。そのため、精度評価手法の観点からも一概に比較できないことに注意が必要である。

6. 結論

本研究では、子宮頸部細胞の病理画像から有所見細胞を検出し、その悪性度を自動で分類する手法を提案した。その結果、悪性度が低い細胞に関しては精度が良好であるものの、悪性度が高い細胞に関しては混同が多く検出ミスが目立つ結果となった。今後の展望として、階層的分類の導入や画像特徴以外の特徴量の検討が挙げられる。具体的には、先行研究¹³⁾に述べられていたように、正常群・内科的経過観察群・要外科的処置群などと分け、群ごとに N/C 比などの特徴量を用いて詳細分類することが必要であると考えられる。

参考文献

- 1) 国立がん研究センター. 子宮頸がん基礎知識. がん情報サービス. 2019.
[http://ganjoho.jp/public/cancer/cervix_uteri/index.html (cited 2020-Aug-22)].
- 2) Solomon D, Davey D, Kurman R, et al. The 2001 Bethesda System: Terminology for reporting results of cervical cytology. J Am Med Assoc 2002;287(16):2114-2119.
- 3) Gautam S, K. HK, Jith N, Sao AK, Bhavsar A, Natarajan A. Considerations for a PAP Smear Image Analysis System with CNN Features. 2018. [<http://arxiv.org/abs/1806.09025> (cited 2020-Aug-22)].
- 4) Chankong T, Theera-Umporn N, Auephanwiriyakul S. Automatic cervical cell segmentation and classification in PAP smears. Comput Methods Programs Biomed 2014;113(2):539-556.
- 5) Bora K, Chowdhury M, Mahanta LB, Kundu MK, Das AK. Pap smear image classification using convolutional neural network. ACM Int Conf Proceeding Ser 2016.
- 6) William W, Ware A, Basaza-Ejiri AH, Obungoloch J. A pap-smear analysis tool (PAT) for detection of cervical cancer from pap-smear images. Biomed Eng Online 2019;18(1):1-22.
- 7) Zhou K, Gu Z, Li A, Cheng J, Gao S. "DeepCerv: Deep Neural Network for Segmentation Free Robust Cervical Cell Classification," in Computational Pathology and Ophthalmic Medical Image Analysis 2018;11039:86-94.
- 8) Sun G, Li S, Cao Y, Lang F. Cervical cancer diagnosis based on random forest. Int J Performability Eng 2017;13(4):446-457.
- 9) Zhang J, Liu Y. Cervical Cancer Detection Using SVM Based Feature Screening. In: International Conference on Medical Image Computing and Computer-Assisted Intervention 2004; 3217:873-880.
- 10) Plissiti ME, Nikou C, Charchanti A. Automated detection of cell nuclei in Pap smear images using morphological reconstruction and clustering. IEEE Trans Inf Technol Biomed. 2011;15(2):233-241.
- 11) Zhao M, Wu A, Song J, Sun X, Dong N. Automatic screening of cervical cells using block image processing. Biomed Eng Online. 2016;15(1).
- 12) M. Xu, "Cervical cytology intelligent diagnosis based on object detection technology," in 1st Conference on Medical Imaging with Deep Learning 2018, no. Midl 2018, pp. 1-9
- 13) 津森太亮, 木戸尚治, 平野靖, 森正樹, 稲井邦博, 今村好章. Faster R-CNN を用いた子宮頸部細胞診における悪性細胞の検出. Med IMAGING Technol 2019;37(3):155-163.
- 14) Redmon J, Farhadi A. YOLOv3: An Incremental Improvement. 2018. [<https://arxiv.org/abs/1804.02767> (cited 2020-Aug-22)].
- 15) 南部優太, 佐藤生馬, 永井智大, et al. 覚醒下脳腫瘍摘出術における手術工程同定に向けた深層学習による術具検出手法の提案. 日本コンピュータ外科学会誌. 2018;20(4):251.