



ロボット皮膚のためのゲル痛覚センサ～ドメイン適応技術に基づく傷検出 AI システムの開発

Development of Gel Tactile Sensors for Robot Skin - Wound Detection AI System Based on Domain Adaptation Techniques

周智威¹⁾, 加藤史洋*¹⁾, 竹田隼²⁾, 岩田浩康²⁾
ZHOU ZHIWEI, Kato Fumihito, Takeda Hayato and Iwata Hiroyasu

*Corresponding author

1) 早稲田大学

概要: 本研究ではロボットハンドの痛覚センサの構築をめざして, ゲル皮膚の割れや傷を検出するためのドメイン適応技術に基づく DANN 手法を提案する. ゲル皮膚の傷は, 切創, 擦過傷, および無傷の三種類に分類される. NN の訓練のために収集した 1440 枚の画像を用いて訓練パラメータを最適化し, 未学習の背景テクスチャにおける識別精度が 71%から 82.5%に向上した.

キーワード: 深層学習, ゲルセンサ, ロボット皮膚

1. はじめに

近年, ロボット技術の進歩に伴い, ヒューマノイドロボットの普及が進み, 医療分野における応用がますます現実のものとなってきている. 例えば, 患者の皮膚疾患を視診および触診することを目的とした AI 搭載ロボット AIREC[1]が提案されている. 診察中に患者の皮膚に損傷を与えないよう, ロボットには柔らかい皮膚素材を使用する必要がある. ロボット技術の医療応用が進展する中で, ロボットの皮膚素材の選定は重要な課題となっている.

1.1 ロボット皮膚や自己修復機能

ゲルはその柔軟性と透明性から, ヒューマノイドロボットや触覚センサーなどの分野で広く利用されている. 例えば, TELESAR V[2][3], TELESAR VI[4], TWENDY-ONE[5]といったロボットの手部には, それぞれ異なるゲル材料が用いられている. しかし, ゲルは長期間の使用により, 切創損傷や摩擦損傷といったさまざまな損傷を受ける. これらの損傷は, ロボットハンドの外観や機能に悪影響を及ぼす可能性がある.

このような損傷問題に対処するため, 自己修復機能を持つゲル材料の応用を探っている. 例えば, 熱刺激によって修復可能な自己修復の提案[6]がなされている. 一方, 材料供給を伴う自己修復ゲル材料も提案されている. 内部に組み込まれた中空ガラス繊維を通じて修復物質を放出し, 修復する手法の提案[7]がなされている.

損傷の状況に応じて, 異なる修復戦略が必要である. 表面的な摩擦損傷は熱刺激によって修復可能であるが, 深い切創損傷には修復ゲルを供給する必要がある. 損傷の修復戦略を決定するためには, 損傷の種類を識別することが不可欠である. 本研究では, 痛覚センサーに基づくシステムを提案し, 損傷の種類を識別してそれぞれ前述の処理を行うことを目指す.

1.2 ロボット皮膚傷種の認識

深層学習手法の急速な発展, 特に畳み込みニューラルネットワーク (CNN) が画像分類タスクで顕著な成功を収めたことにより, CNN モデルを用いた損傷分類が注目されている. 損傷検出と分類に関しては, 多くの関連研究[8][9]が既に存在している. しかし, ロボットの皮膚用ゲルの損傷検出モデルについての研究は少なく, 公開されているロボット皮膚データセットは存在しない. 本研究は深層学習技術を用いたロボット皮膚の傷のデータを収集した上で皮膚の傷種の分類および痛覚センサを提案する.

2. 方法

異なる背景での皮膚画像の分類精度を向上させることは重要である. 医療への適用を検討しているためである. 医療現場では, ゲル越しの画像での視診が必要とされる場面があるが, 疾患によっては背景画像が変わることが想定される. 背景画像が事前にわからない場合でも, 皮膚画像から傷の状況を正確に把握できる必要がある.

この課題を解決するため、DANN (Domain Adversarial Neural Network) [10]を用いることで、多様な背景での疾患の皮膚画像でもゲルの傷の認識が可能なAI痛覚センサを開発する。提案手法による痛覚センサを構築することで、皮膚画像の背景が想定とは異なる場合でも、傷の状況を確実に把握することができる。処理の手順は次のとおりである。1) HAM10000[11]データセットを背景として使用し、ゲル画像を収集するためのデータ収集プラットフォームを構築する。2) これらのゲル画像をソースドメインとターゲットドメインに分割する。3) CNNモデルとDANNネットワークをベースとした分類モデルをそれぞれ構築する。4) 両者のモデルを比較し、ターゲットドメインデータでのパフォーマンスを評価することで、異なる皮膚テクスチャ下での痛覚センサの汎用性を示す。

2.1 データ収集

実際のロボット AIREC の損傷状況を観察した結果、主に切創と擦過傷に集中していることが観察された(図1)。



図 1: AIREC ハンドの損傷

AIREC が診療中で頻繁に見られる 2 種類の損傷を再現するために、本研究では、自己修復ゲルと類似した特性を持つ透明のゲル(エクシール社製)を使用し、実際の AIREC 皮膚上で観察される損傷を模倣してデータ収集を行った。データ収集の手順は以下の通りである。まず、ゲル原液 6g と硬化剤 6g を 1:1 の比率で混合し、3 分間攪拌する。次に、十分に混合された液体を長さ 75mm、幅 25mm、高さ 10mm の型に注ぎ、24 時間静置する。24 時間後、硬化したシリコーンを取り出し、25mm×25mm の 3 つの部分に裁断する。メスを使用してゲルの中心に長さ 8mm、幅最大 1mm の切り傷を作成し、これを「切創」と定義する。次に、グリープテープを使用してゲルの中心部分を磨耗させ、「擦過傷」とする。最後に、切創や磨耗を施さない完全なゲルを保存し、これを「無傷」とする。

実際の使用環境における変動要素(例えば、患者の異なる肌色、毛髪、皮膚の模様など)をシミュレートするために、公開データセット HAM10000[11]から異なる皮膚背景画像(図2)を使用した。図2における(a), (b), (c)背景で収集された画像データを「ソースドメイン」と定義し、(d), (e), (f)背景で収集された画像データを「ターゲットドメイン」と定義した。

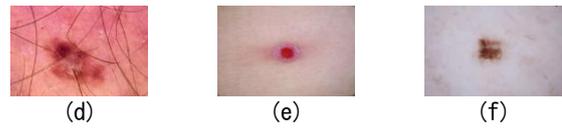
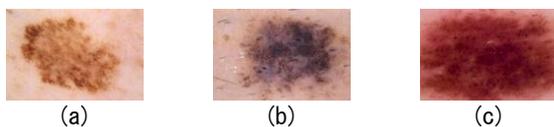


図 2: 異なる皮膚背景

AIモデルのロバスト性を向上させるために、カメラからの垂直距離をそれぞれ 40mm, 60mm, 80mm, 100mm に設定し、ゲルの画像データを収集した。また、各ゲル画像サンプリングにおいて、ゲルの損傷部分の表裏両面の画像を収集することで、データの多様性を確保しロバスト性を強化した。本研究では、合計 1440 枚の画像を収集した。サンプルデータは図4に示されている。

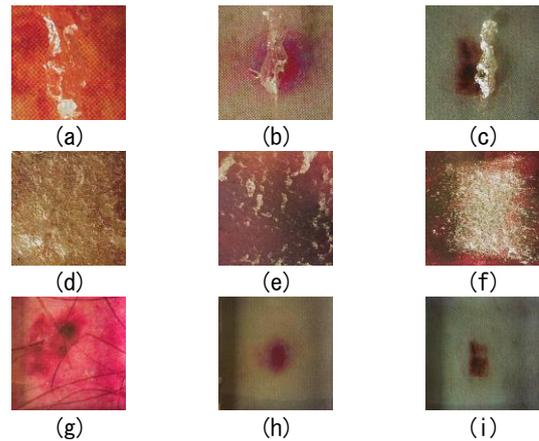


図 3: サンプルデータ

2.2 CNN と DANN の構築とトレーニング

畳み込みニューラルネットワーク (Convolutional Neural Networks, CNN) は、画像分類、物体検出、画像セグメンテーションなどのコンピュータビジョンタスクに広く利用される深層学習モデルである。従来の CNN は、ソースドメイン(トレーニングデータ)とターゲットドメイン(テストデータ)の分布が類似している場合に性能が良いが、分布が異なる場合には性能が著しく低下することが知られている。

ドメイン適応技術ネットワーク (Domain Adversarial Neural Network, DANN) は、モデルのターゲットドメインにおける汎用性を向上させることを目的とした手法である。DANN は、敵対的なトレーニングを導入することで、ソースドメインとターゲットドメインの特徴分布を整列させ、ドメイン間の差異を減少させる。具体的には、DANN は共有特徴抽出器、傷分類器、ドメイン分類器から構成されている。ドメイン分類器は、敵対的損失関数を介して、特徴抽出器がソースドメインとターゲットドメイン上で類似した特徴表現を生成するように強制し、モデルのターゲットドメイン上の性能を向上させる。

本研究は、CNNモデル(図5a)とDANNモデル(図5b)を構築し、それぞれのモデルでソースドメインとターゲットドメインのデータを抽出してトレーニングした。

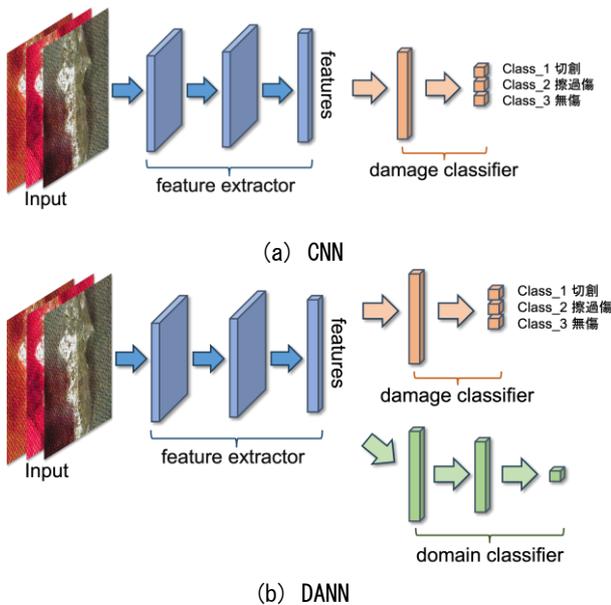


図 4: CNN と DANN のアーキテクチャ

トレーニングの前処理には、ランダムな画像クロップが選択されており、画像入力はランダムに 28x28 のサイズにクロップされる。これにより、トレーニングデータの多様性と堅牢性が向上する。入力されたテンソルの標準偏差を 0.5、平均を 0.5 に正規化し、ピクセル値を[-1,1]の範囲にスケールした。これにより、モデルの収束速度が向上する。Optimizer は確率的勾配降下法 (Stochastic Gradient Descent, SGD) が選択され、ハイパーパラメータの momentum は 0.9 に設定されている。初期学習率は 0.0001 に設定されており、学習回数が 100 になった時は学習率を元の 1/10 に変更する段階学習のトレーニング戦略が採用されている。これは、モデルの収束を加速し、波動を防ぐためである。

2.3 結果分析

CNN と DANN に対して t-SNE 分析を行った。普通の CNN モデルはソースドメインのデータに対して上手く分類を行うことができるが、ターゲットドメインのデータは特徴をうまく分類することができない (図 5)。

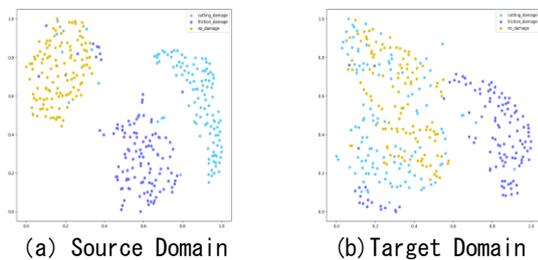


図 5: CNN を用いた t-SNE 結果

一方、DANN モデルはターゲットドメインでの特徴の分類において、普通の CNN モデルよりも優れた効果を示している (図 6)。

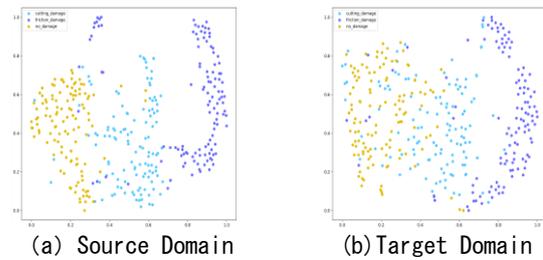


図 5: DANN を用いた t-SNE 結果

また、精度を計算することで、普通の CNN モデルはターゲットドメインでの分類精度が 71.2% であるのに対し、DANN モデルは 82.5% となり、11.3% 向上した。この結果から、DANN モデルを導入した痛覚センサーは異なる背景でも優れた分類効果を発揮することが示された。

3. まとめ

本研究ではロボットハンドの痛覚センサを自己修復ゲルで構築することを目指し、事前検討として自己修復性能がないウレタンゲルを用いて傷の検出と識別手法の構築を目指した。本研究では新規にロボット皮膚損傷データセットを収集した。そして、このデータセットを使用して、CNN モデルと DANN モデルの損傷検出効果を比較した。その結果、DANN モデルが異なる皮膚テクスチャでの損傷検出において CNN モデルよりも優れていることが示された。この DANN モデルを触覚センサーに搭載することで、異なる皮膚テクスチャにおける損傷検出が可能になることが示唆された。

謝辞

本研究は、JST【ムーンショット型研究開発事業 Grant 番号【JPMJMS2031】、日本学術振興会 科研費 Grant 番号【JP22K18220】の支援を受けたものである。

参考文献

- [1] AIREC. (n.d.). *About AIREC*. <https://airec-waseda.jp/about/>
- [2] K. Sato, K. Kamiyama, N. Kawakami, and S. Tachi, "Finger-shaped gelforce: Sensor for measuring surface traction fields for robotic hand," *IEEE Transactions on Haptics*, vol. 3, no. 1, pp. 37–47, 2010.
- [3] C. L. Fernando, M. Furukawa, T. Kurogi, S. Kamuro, K. sato, K. Minamizawa, and S. Tachi, "Design of telesar v for transferring bodily consciousness in telexistence," in *2012 IEEE/RSJ International Conference on Intelligent Robots and Systems*, 2012, pp. 5112–5118.
- [4] S. Tachi, Y. Inoue, and F. Kato, "Telesar vi: Telexistence surrogate anthropomorphic robot vi," *International Journal of Humanoid Robotics*, vol. 17, no. 05, p. 2050019, 2020. [Online]. Available:

- <https://doi.org/10.1142/S021984362050019X>
- [5] T. Sugaiwa, H. Iwata, and S. Sugano, “Shock absorbing skin design for human-symbiotic robot at the worst case collision,” in *Humanoids 2008 - 8th IEEE-RAS International Conference on Humanoid Robots*, 2008, pp. 481–486.
- [6] Kowalewska, A.; Majewska-Smolarek, K. Synergistic Self-Healing Enhancement in Multifunctional Silicone Elastomers and Their Application in Smart Materials. *Polymers* 2024, 16, 487. <https://doi.org/10.3390/polym16040487>
- [7] Trask RS, Williams GJ, Bond IP. Bioinspired self-healing of advanced composite structures using hollow glass fibres. *J R Soc Interface*. 2007 Apr 22;4(13):363-71. doi: 10.1098/rsif.2006.0194. PMID: 17251131; PMCID: PMC2359865
- [8] Ambaye, G., Boldsai Khan, E. & Krishnan, K. Robot arm damage detection using vibration data and deep learning. *Neural Comput & Applic* 36, 1727–1739 (2024). <https://doi.org/10.1007/s00521-023-09150-3>
- [9] Malekjafarian, A.; Golpayegani, F.; Moloney, C.; Clarke, S. A Machine Learning Approach to Bridge-Damage Detection Using Responses Measured on a Passing Vehicle. *Sensors* 2019, 19, 4035. <https://doi.org/10.3390/s19184035>
- [10] Ganin Y, Ustinova E, Ajakan H, et al. Domain-adversarial training of neural networks[J]. *Journal of machine learning research*, 2016, 17(59): 1-35.
- [11] Tschandl, P., Rosendahl, C. & Kittler, H. The HAM10000 dataset, a large collection of multi-source dermatoscopic images of common pigmented skin lesions. *Sci Data* 5, 180161 (2018).