


心機能の定量化による心疾患総合診断・治療支援システムの構築



大規模循環器系データセットの構築

医療画像データ:

- 造影心臓CT画像: **約17,000症例**
- 造影冠動脈データ+アノテーション: 247症例

電子カルテ:

- 標準化データ: **67,789症例**
- 非構造化データ: **14,712症例**

ドメイン適応

- **ドメインギャップ**: 病院A (ソースドメイン) で取得したデータを用いて学習したモデルを, 病院B (ターゲットドメイン) のデータにそのまま適用しても, 病院間の計測機器の性能差などにより, 望む性能が得られない。
- **高アノテーションコスト**: 医療データへのアノテーションは, 専門的知識を持つ医師が行う必要があり大量に得ることが難しい。
- **教師無しドメイン適応**: 多くのラベル付きデータがあるドメインから, ラベル付きデータがほとんどない別のドメインに知識を転送することで, ドメインギャップを解消しつつ訓練データが限られている問題に取り組む。

判別的な特徴に着目した教師無しドメイン適応

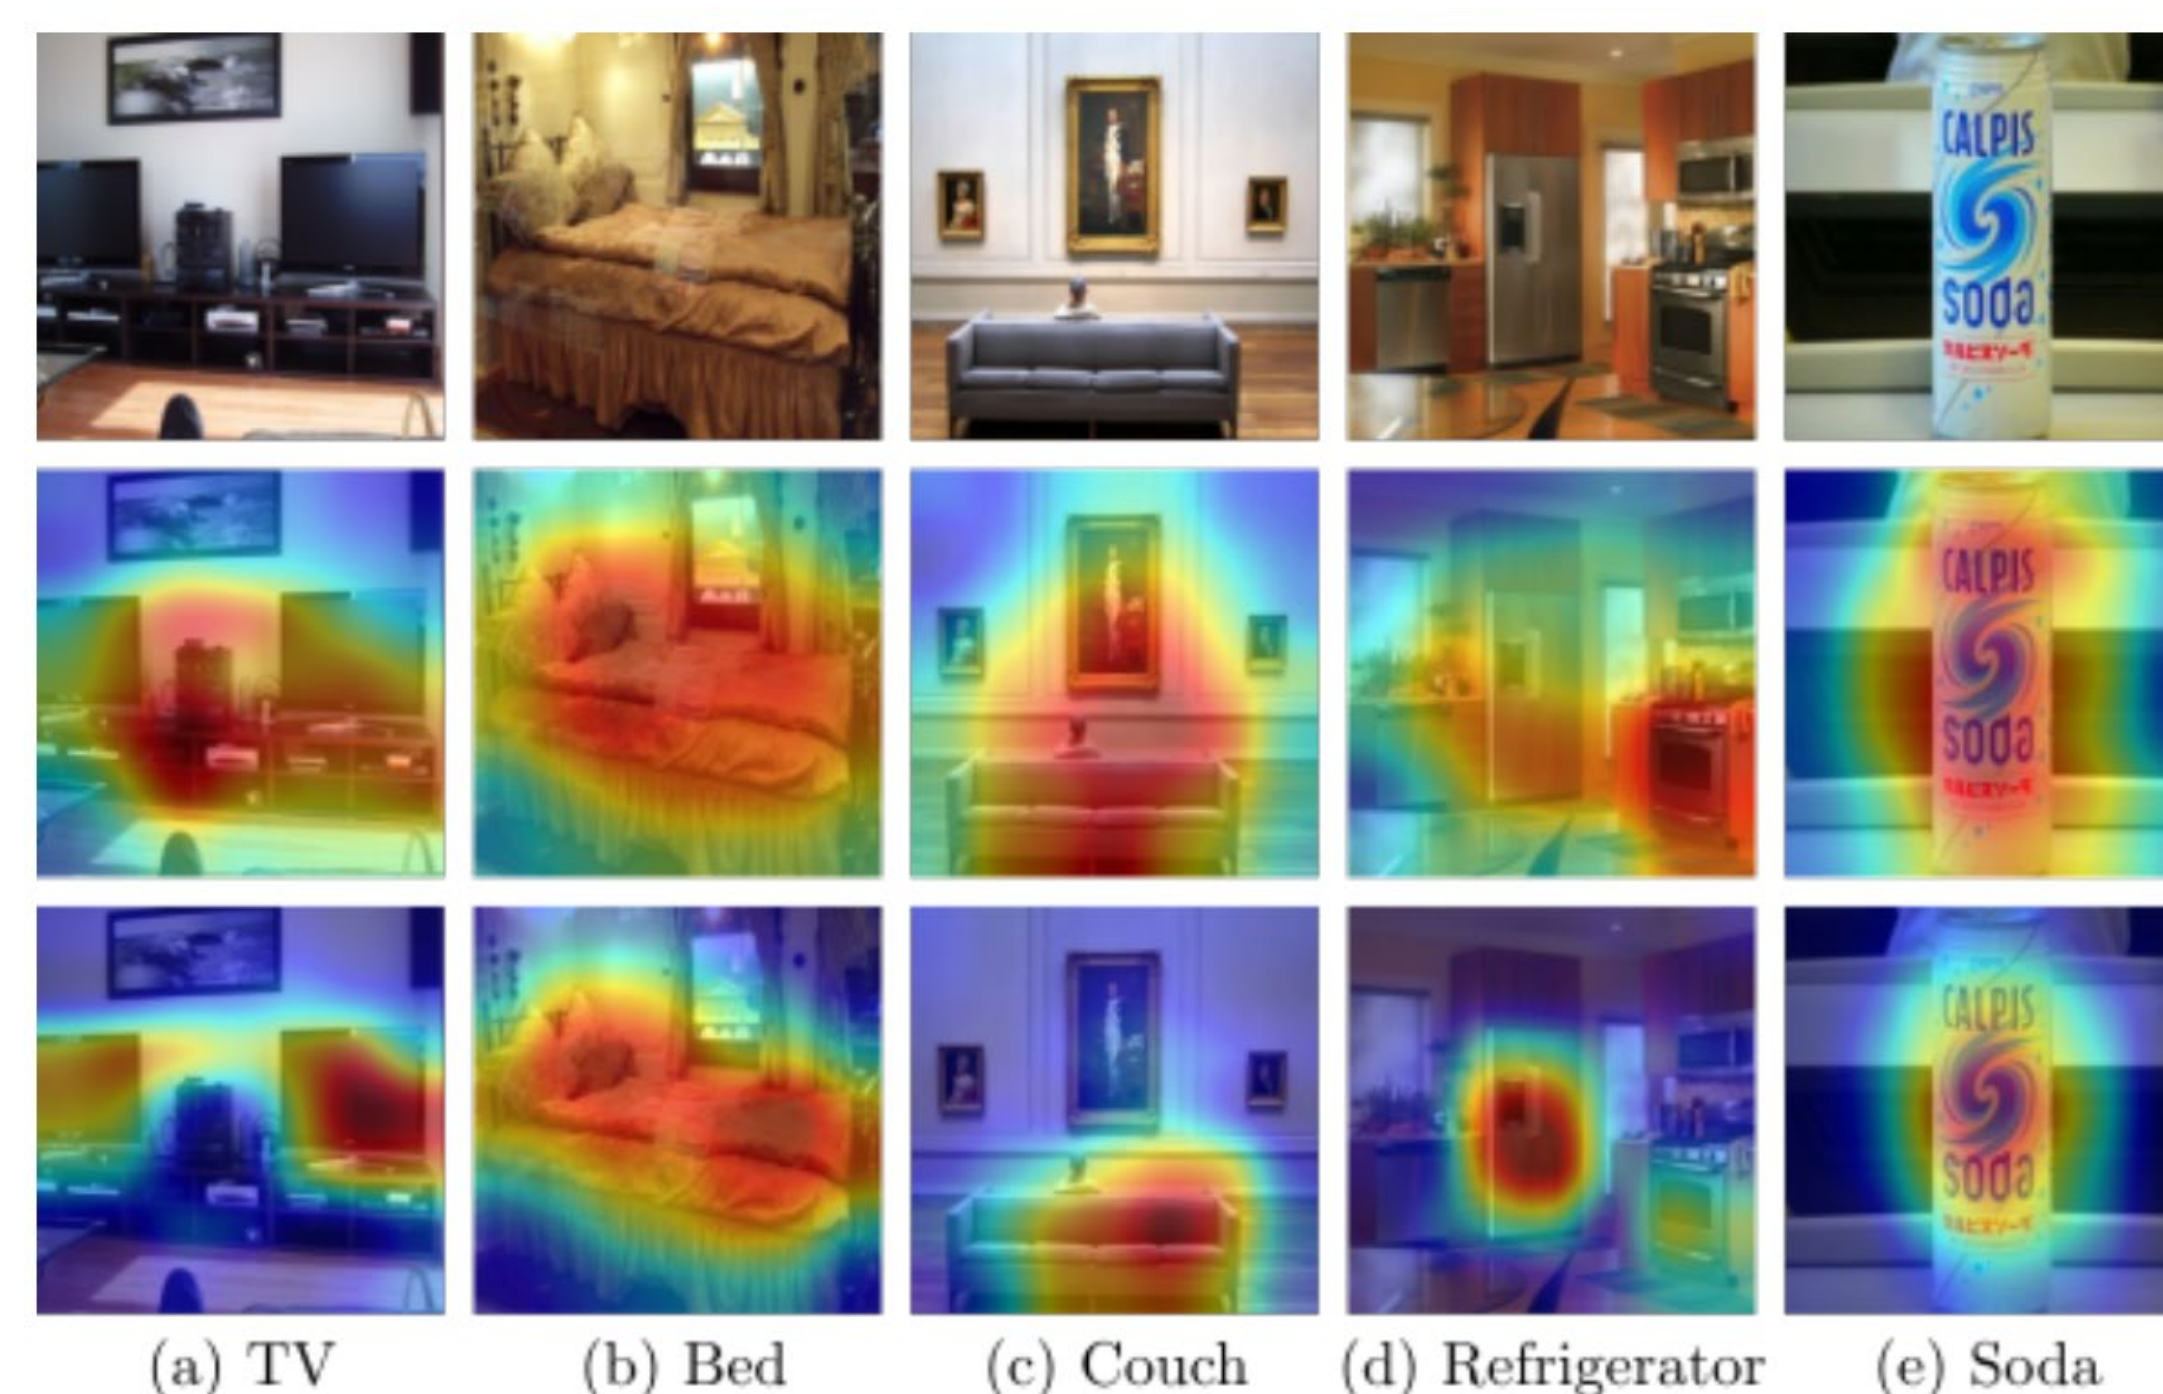
- ソースとターゲットのドメイン分類器が, クラス分類に重要な特徴に焦点を当てることで, ドメイン適応の性能を向上

右図: 敵対的ネットワークで整列された特徴のヒートマップ。ベースライン手法の場合, ドメイン分類のネットワークは背景を含む画像の大部分に焦点を当てる。一方, 提案手法において, ドメイン分類ネットワークは主に前景のオブジェクトに焦点を当てることができ, 認識対象に焦点を当てたドメイン適応が実現可能。

オリジナル

ベースライン

提案手法



T. Westfechtel, H. Yeh, Q. Meng, Y. Mukuta, T. Harada. Backprop Induced Feature Weighting for Adversarial Domain Adaptation with Iterative Label Distribution Alignment. WACV2023.

結合誤差を最小化する教師無しドメイン適応

- 様々な研究が知識を転送する先のターゲット誤差の上限を提唱しているが, ほとんどの研究では, その難解さのために結合誤差は無視されている。
- この問題に対処するために, 結合誤差の上限に関する新しい目的関数を提案

$$\epsilon_T(h) \leq \epsilon_S(h) + \max_{f_1, f_2 \in H} |\epsilon_S(f_1, f_2) - \epsilon_T(f_1, f_2)| + \lambda$$

知識転移先の誤差
これを最小化したいが, 直接評価できないので右辺の上限を最小化する。

知識転移元の誤差
転移元にはラベル付きデータがあるので計算可能。

クラス情報を考慮しないソースとターゲットの分布の乖離度合い
多くの研究はこれを最小化させることでソースからターゲットへの転移を実現している。

結合誤差
多くの研究はこの計算が困難であるので無視されてきたが, 本研究ではこの結合誤差を考慮することができるようになった。

D. Zhang, T. Harada. Unsupervised Domain Adaptation via Minimized Joint Error. Transactions on Machine Learning Research (TMLR), 2023.