



Figure 2. The detailed system architecture of our I2I (image to image) Adapt framework. The pathways to the loss modules denote the inputs to these modules, which are used for training. Best viewed in color.

Hoffman et al. [12] utilized fully convolutional networks with domain adversarial training to obtain domain agnostic features (i.e. shared space) for the source and target domains, while constraining the shared space to be discriminative for the source domain. Hence, by learning the mappings from source and target domains to the shared space (i.e. f_x and f_y in Figure 2), and learning the mapping from the shared space to annotations (i.e. h in Figure 2), their approach effectively enables the learned classifier to be applicable to both domains. The Deep Reconstruction Classification Network (DRCN) of Ghifary et al. [6], utilizes a similar approach but with a constraint that the embedding must be decodable, and learns a mapping from the embedding space to the target domain (i.e. g_y in Figure 2). The image-to-image translation work by Isola et al. [15] maps the source domain to the target domain by an adversarial learning of f_x and g_y and composing them $g_y \circ f_x: X \rightarrow Y$. In their framework the target and source images were assumed to be paired, in the sense that for each source image there exists a known corresponding target image. This assumption was lifted in the follow-up work of Zhu et al. [40] and Royer et al. [28], where cycle consistency was used to learn the mappings based on unpaired source and target images. While the approaches of Isola et al. [15] and Zhu et al. [40] do not address the domain adaptation problem, yet.

- date:2020-0419 ccap

高倉先生の話題提供に、関係あるのかどうか不明なのですが、マルチモーダル情報統合を考える枠組みを整理する意図で載せました。上の6つの図、それぞれ青が通常のコンベンショナルな情報入力です。動物であれば、視覚に立脚して判断できるような状況です。中央のオレンジが埋め込み空間 z で、情報統合の座と見なしうる感じです。下の黄色はアノテーションとなっていますが、通常の神経心理学的検査での正解を与える検査場面での出力です。これに対して、別のモダリティであったり、アンコンベンショナルな問い、動物についての問いであるのに、いずれの大陸由来であるとか、大きさの比較だとか、に相当する表象が右の緑から入力されると考えます。

f_x は入力 x を内部表象 z に変換し、 z から解 c が出力されると考えます。

f_y は入力 y を内部表象 z に変換します

g_x は f_x の逆、すなわち z から x を予測します

g_y は f_y の逆、すなわち z から y を予測します

英語が書かれていますので説明は不要かもしれませんが、念の為、左上は、通常のカテゴリ分類、左中は特徴弁別器と書かれています。ドメイン変換、左下は循環、右上は再構成、右中は翻訳、右下は翻訳と分類、となっています。モデルとしてはこのような枠組みを考える大枠は捉えたことになるのかしら？と思ったり。