

# Conditional GAN を用いた大規模食事画像データからの画像生成

伊藤 祥文<sup>†</sup> 丹野 良介<sup>†</sup> 柳井 啓司<sup>†</sup>

<sup>†</sup> 電気通信大学情報理工学部 〒182-8585 東京都調布市調布ケ丘 1-5-1

E-mail: †{ito-y,tanno-r}@mm.inf.uec.ac.jp, ††yanai@cs.uec.ac.jp

あらまし 現在, 深層学習技術の発展により, 深層学習を用いた様々な研究が行われている. 特に, 画像認識分野においては, 深層学習を用いることで人間の能力以上の結果を出すことができるようになってきている. そのため現在では画像の分類精度を向上させるような研究から, 画像を用いたより応用的な技術の研究が行われるようになってきている. 中でも, 2014年に自動画像生成に関する研究がなされたことが契機となり, 近年, 自動画像生成についての研究が盛んに行われるようになってきている. 本論文では, 特定カテゴリの画像生成, 特に食事画像を用いた画像生成を試みた結果について述べる. レシピデータ等を用いて画像の収集およびラベル付けを行い, それらの画像を用いて学習を行い, 画像の生成を行う. 実験では, 食事に関連する単語の中から「ラーメン」という単語を用いて Twitter で検索を行い, その内容を元に投稿された画像をラベル分けし, 画像生成を行った. 実験の結果, ある程度ラーメンらしい画像を生成することに成功した. また, 一般のレシピデータを元に, 料理に用いられている食材でラベル付けを行い画像生成を行った結果, いくつかの食材ラベルにおいて, その食材を用いたと考えられる料理の画像を生成することができた.

キーワード GAN, 食事画像, 画像生成

## Generate images from food photos by Conditional GAN

Yoshifumi ITO<sup>†</sup>, Ryosuke TANNO<sup>†</sup>, and Keiji YANAI<sup>††</sup>

<sup>†</sup> Faculty of Informatics and Engineering, The University of Electro-Communications Chofugaoka 1-5-1,  
Chofu, Tokyo, 182-8585 Japan

E-mail: †{ito-y,tanno-r}@mm.inf.uec.ac.jp, ††yanai@cs.uec.ac.jp

### 1. 背景

現在, 深層学習技術の発展により, 深層学習を用いた様々な研究が行われている. 中でも, 画像認識分野においては, 深層学習を用いて人間の能力以上の結果を出すことに成功しており, より応用的な技術の研究が進められている. 特に, 2014年に Goodfellow らによって, GAN (Generative Adversarial Network) [1] という手法を用いた自動画像生成に関する研究が発表されたことで, その手法を用いた画像生成に関する研究が多く行われている.

また近年, 我が国において食に対する関心は高まりを見せている. Cookpad などのレシピ投稿サイトへの投稿数は年々増加しており, 多くの人々が料理に対して強い関心を持っている. 特に, 余った野菜を用いた料理などのような, 特定の食材を用いた料理に関する投稿や検索は多く, その関心の高さが伺える. 同時に, レシピサイトで確認する際に重要となるものが, 完成した料理の写真である. このようなレシピサイトでは, 同じ料理の場合, 料理の写真がより綺麗なレシピのほうが閲覧数が多いと

いう傾向にある. そのため, 料理を視覚的に確認することで, その料理に興味を持って対象のレシピにアクセスするというユーザが多いことがわかる.

本研究では, 特定の料理の画像を入力とし, その料理名の料理画像の生成を行う. これにより, 作成したネットワークが正しく画像生成を行うことができることがわかる. また, 特定の食材を入力とし, その食材が用いられている料理の画像を自動で生成することに挑戦する. これにより, 食材情報からの料理選択の補助を行うことができるようになると考えられる.

### 2. 目的

本論文では, GAN の一種である Conditional GAN [2] を改良したシステムを構築することで, 特定カテゴリの画像生成を行うことを目的とする. 従来の GAN では, カテゴリを指定した画像生成を行う場合, カテゴリ固有の特徴を持った画像を生成することが困難であった. そこで, Conditional GAN を用いることでその問題を解決するとともに, そのシステムを改良することで, より食事画像の生成に適したシステムを構築する.

### 3. 関連研究

#### 3.1 Generative Adversarial Network

GAN (Generative Adversarial Network) [1] とは、深層学習を用いて画像生成を行うネットワークモデルのうち、Generator と Discriminator と呼ばれる 2 種類のネットワークを用いて画像生成を行う手法である。Generator とは、学習用データと同じような画像を生成しようとするネットワークであり、また、Discriminator とは、Generator が生成した画像が本物かどうかを識別するネットワークとなっている。GAN とは、これらのネットワークを競合させることで、式 1 のロス関数を用いてより本物に近い画像を生成するといったシステムになっている。

$$\min_G \max_D V(D, G) = E_{x \sim p_{data}(x)} \left[ \log D(x|y) \right] + E_{z \sim p_z(z)} \left[ \log(1 - D(G(z|y))) \right]. \quad (1)$$

#### 3.2 GAN を応用した自動画像生成

GAN のネットワークは応用が容易であったため、GAN の研究が発表された後、それを応用したネットワークや学習方法に関する研究が幅広く行われている。

例えば、CNN (Convolutional Neural Network) を用いて GAN を派生させたネットワークを構築することで、より本物らしい画像を生成する研究がある。LAPGAN [3] では、低解像度の画像を用いて、それよりも少し高解像度の画像を生成するということを繰り返すことで高解像度の画像の生成を行う。また、DCGAN [4] では、LAPGAN の手法をより発展させることで、一度に高解像度の画像を生成することに成功している。この研究が契機となって、その後 GAN に関する研究がさかんに行われるようになった。現在では GAN を応用した手法に関する研究が、様々な手法やアイデアを用いて行われるようになっている。

GAN の手法を応用した例として、GAN の学習方法を変えることで学習を簡単にし、安定した学習による画像生成に重点を置いた研究がある。例えば、f-GAN [5] では、学習時に GAN の目的関数を一般化することで学習の安定化を試みている。GAN の目的関数である JS Divergence を一般化した f-divergence を用いることで、通常の GAN よりも高精度なネットワークを作成している。また、LSGAN [6] では、学習時に二乗誤差を用いることで学習の安定化を図っている。GAN の Sigmoid に替えて、正解ラベルに対する二乗誤差を用いることで学習を安定させ、より本物らしい画像の生成を行っている。

また、Wasserstein GAN (WGAN) [7] では、GAN で用いられる距離手法を他の研究で用いられているものに変えることで、学習の最適化を行っている。学習時に通常の GAN で用いられる距離に変えて Wasserstein 距離を用いることで、通常の GAN よりも質の高い画像を生成することができている。この手法を発展させた手法として、WGAN-GP [8] がある。WGAN に Gradient Penalty を導入し、学習時に制約を加えることで、安定した学習を行うことができるようになっている。また、Progressive GAN [9] では、前述の LSGAN や WGAN の手法

を応用することで、高解像度かつ高画質な画像の生成に成功している。あえて小さいサイズの画像で学習を行い、徐々に高解像度の画像を用いて学習を行うことで、Generator と Discriminator 双方が徐々に成長していく。これにより、既存の GAN では生成することができなかった、 $1024 \times 1024$  のサイズの画像の生成を行っている。

このように、GAN を改良する手法は多種多様である。本研究では、Conditional GAN の手法を参考にし、生成画像のコントロールを行う。また、WGAN-GP の手法を用いて GAN を改良し、生成画像の質の向上を図る。

### 4. 手法概要

本研究の全体的な手順は、以下のようにになっている。

- (1) ラベル付き画像データの収集
- (2) GAN を用いた学習
- (3) Conditional GAN の改良
- (4) 画像の生成

まず、Twitter などの Web 上の画像データや、Cookpad データセットなどの既存のデータセットを用いて、学習時に用いる画像データを収集する。その後、Web 上から収集した画像のうち、特に食事であるとされる画像を、食事画像データセットを用いて選別する。

次に、Conditional GAN [2] を用いて学習を行う。そのために、画像の収集時に用いたテキストデータをもとに画像のラベル付けを行い、学習用のデータセットを作成する。その後、作成したデータセットを用いて Conditional GAN を用いて学習を行う。

次に、Conditional GAN を、食事画像生成に適したネットワークに改良する。あらかじめ食器と同じ形の図形を学習させた識別器を Discriminator に重みとして加え、Conditional GAN の Discriminator を 2 層にすることで、Generator がより食事画像らしい画像を出力するようにする。また、WGAN [7] を応用することにより、より質の高い画像の生成を行う。

最後に、Conditional GAN およびそれを改良した手法を用いた学習の結果を元に、画像生成を行う。生成された画像を比較し、Conditional GAN の改良による生成画像の変化を見る。

### 5. 手法詳細

#### 5.1 画像の収集

学習に用いる画像を収集する。本研究では、画像生成に GAN を用いるため、学習に用いる画像が数万枚必要になる場合があ




図 1 本研究の概要

る。そのため、学習用の画像として Web 上に大量にある画像や、データセットとして用意されている画像群を用いる。

### 5.1.1 ラーメン画像データセット

我々の研究室では、Twitter 上の食事画像付き投稿のみを収集した過去ログを保持している。そこから、図 2 のようなラーメン画像が付いている投稿を収集する。

得られた画像のうち、特に食事画像であると考えられる画像を、食事画像データセット [10] を用いて選別し、ラーメン画像の収集を行う。

### 5.1.2 Cookpad データセット

我々の研究室には、Cookpad データセットが存在している。このデータセットは Cookpad (注1)が公開しているもので、100 万件以上のレシピデータのほか、料理画像や調理手順などの情報が保存されたデータセットとなっている。

データセットは各料理ごとに図 3 の 12 のテーブルから構成されている。また、料理画像は recipes テーブル内にあるレシピ ID と同名で保存されている。本研究ではこれらの情報のうち、レシピ画像を得るためのレシピ ID の情報と、レシピの材料の情報を用いるため、recipes テーブルと ingredients テーブルの情報を用いる。

## 5.2 学 習

収集した画像を元に、GAN およびそれを派生させたネットワークを用いて学習を行う。本研究では、生成する画像をコントロールする必要があるため、学習には Conditional GAN [2] を用いる。

### 5.2.1 Conditional GAN

通常の GAN では一様分布から画像生成を行うため、生成される画像をコントロールすることができない。そこで、GAN のネットワークに、クラスラベルなどを表す condition を与えることで、条件付き確率分布を学習するモデルである Conditional GAN を用いて画像生成を行う。これにより、生成画像をコントロールすることができるようになる。

この手法は、GAN の Generator と Discriminator にカテゴリラベルを設定することにより、図 4 および図 5 のネットワークを用いて学習を行い、画像を生成するものとなっている。学習時のロス関数は、式 2 で表される。

$$\min_G \max_D V(D, G) = E_{x \sim p_{data}(x)} \left[ \log D(x|c) \right] + E_{z \sim p_z(z)} \left[ \log(1 - D(G(z|c))) \right]. \quad (2)$$



図 2 Twitter を用いて収集したラーメン画像の一部

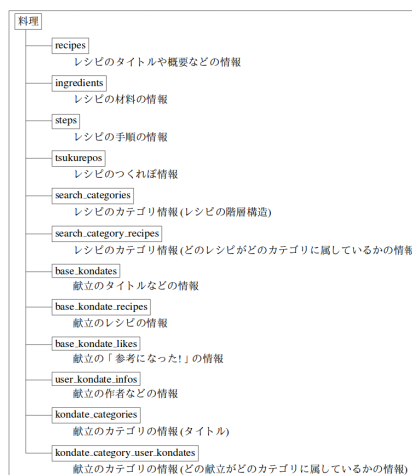


図 3 Cookpad データセットの構造

### 5.2.2 食事ラベルの作成

Conditional GAN を用いて学習を行うために、カテゴリラベルのデータを各画像ごとに設定する。これにより、生成画像を任意のクラスのものにすることが可能になる。

例えば、ラーメン画像データセットを用いる場合、カテゴリラベルとして、「ラーメン二郎」や「家系ラーメン」などのような料理名を用いることで、図 6 のような食事クラスのラベルを作成し、特定の料理の画像の生成を行う。

### 5.3 Conditional GAN の改良

通常の Conditional GAN を用いた場合では生成される画像の質が悪い可能性があるため、Conditional GAN を改良したネットワークを作成する。

食事画像を生成する場合、食事画像の輪郭が綺麗に生成することができない問題が考えられる。そのため、ラーメン画像などのような食器の形がはっきりしている画像を生成する場合、生成画像の輪郭が正しいかどうかを識別するためのネットワークを作成することで、生成画像の輪郭をはっきりさせることができる。また、様々な種類の画像を扱うため、生成画像そのものの質が悪くなる可能性がある。そのため、通常の Conditional GAN [2] を Wasserstein GAN [7] の手法を用いて最適化させることで、生成画像の質を向上させることができる。

#### 5.3.1 食器識別器

GAN で生成された画像の形が崩れることを防ぐため、食器と同じ形の図形を学習させた Discriminator を新たに用意する。具体的な方法として、図 7 のような、ラーメンどんぶりのような楕円形の食器を食器の輪郭であると仮定する。その上で図 7 のように、食器の形が正しく描けている図形を Positive 画像、そうではない画像を Negative 画像として 2 クラス分類を行う。その結果得られたネットワークを用いて、食器識別用の




図 4 Generator のネットワーク図

(注 1): <https://cookpad.com/>




図 5 Discriminator のネットワーク図

Discriminator を作成する。

用意した識別器を図 8 のように Discriminator に重みとして加えることで、生成された食事画像が食器の中にあるように見せることができる。

### 5.3.2 Wasserstein GAN

学習時に用いる GAN として Wasserstein GAN (以下 WGAN) [7] で用いられている手法を用いることで、生成画像の質を向上させることができる。

WGAN とは、Wasserstein 距離を用いて最適化を行う、GAN の学習方法の一つである。Wasserstein 距離とは輸送理論などで用いられる計算方法であり、式 3 で表される、輸送コストを最小にした時の輸送コストのことを表す距離尺度である。

$$W_p(u, v) = \left( \inf_{\gamma \in \Pi(u, v)} \int_{M \times M} d(x, y)^p d\gamma(x, y) \right)^{1/p} \quad (3)$$

WGAN では、この Wasserstein 距離を最小にするように学習を行う。通常の GAN とは異なり、WGAN の Discriminator は Generator の出力の分布と、学習時のデータ分布の Wasserstein 距離を計算しようとする。また、Generator は Discriminator が求めた Wasserstein 距離が最小になるような画像を生成し、出力画像の分布を更新する。このようにして Generator と Discriminator 双方が学習を行い、より本物らしい画像の生成を行う、というものになっている。この際、Discriminator の重みが  $[-c, c]$  の間に収まるように、Weight Clipping と呼ばれる丸め込みを行う。

しかし、WGAN では、Weight Clipping を行っているが、勾配の爆発や消失の可能性があるため学習が遅くなったり、学習に失敗したりするおそれがあるという問題点が発見された。これを改善させるための手法として、WGAN-GP [8] がある。WGAN-GP では、 $\lambda E[ (|\nabla D(\alpha x - (1 - \alpha G(z)))| - 1)^2 ]$  の形で表される Gradient Penalty という制約を WGAN の損失関数に用いることで、この問題を解決し、学習を安定させている。Gradient Penalty を導入した Discriminator および Generator のロス関数は、それぞれ式 4 および式 5 で表される。

$$L_D^{WGAN-GP} = E[D(x)] - E[D(G(z))] +$$




図 6 ラーメン画像のクラス分けのイメージ




図 7 食器識別器

$$\lambda E[ (|\nabla D(\alpha x - (1 - \alpha G(z)))| - 1)^2 ] \quad (4)$$

$$L_G^{WGAN-GP} = E[D(G(z))] \quad (5)$$

### 5.4 画像の生成

学習結果を元に GAN の Generator が画像の生成を行う。Conditional GAN では、図 8 の  $c$  の値を固定することで、任意のラベル情報を持った画像の生成を行うことができる。したがって、ある特定のラベル情報を持った  $c$  の重みのみを 1 とし、他のすべてのラベルを重み 0 として画像生成を行うことで、その特定のカテゴリの画像を生成することができる。

#### 5.4.1 評価

提案したネットワークを用いて生成した画像を、既存の GAN で生成した画像と比較することで、提案手法の評価を行う。

## 6. 実験

本研究では、以下の実験を行った。

- ラーメン画像生成

Conditional GAN を用いてラーメン画像の生成を行った。

また、食器識別器を適用してよりラーメン画像らしい画像の生成を試みた。

- レシピデータからの画像生成

Conditional GAN を用いて食事画像の生成を行った。

また、WGAN-GP を適用して、より質の高い画像の生成を試みた。

#### 6.1 ラーメン画像生成

まず、食器識別器の有用性を示すために、ラーメン画像群を用いた画像生成を行った。

本研究では、実験データとして、2011 年 5 月から 2016 年 4 月までの、5 年分の Twitter の過去ログから収集したラーメン画像付き投稿を用いた。そのうち、ベースとなる「具のないラーメン」や特に出現数が多かったカテゴリのラーメンである、表 1 にある単語および関連する単語を含む投稿を用いて収集した、15,900 枚の画像を使用した。

これらの画像を用いて、通常の DCGAN を用いた Conditional GAN を適用して特定のカテゴリのラーメン画像の生成を行った結果、図 9 のような画像が得られた。




図 8 食器識別器を導入した Conditional GAN のネットワーク図

表 1 用いたラーメンカテゴリとその枚数

カテゴリ	枚数
具のないラーメン	790 枚
ラーメン二郎	5,901 枚
家系ラーメン	2,836 枚
激辛ラーメン	3,578 枚
台湾ラーメン	1,567 枚
尾道ラーメン	1,228 枚
合計	15,900 枚

また、食器識別器を用いて改良した Conditional GAN を適用して画像生成を行った結果、図 10 のような画像が得られた。

### 6.2 レシピデータからの画像生成

次に、WGAN の導入による生成画像の変化を見るために、Cookpad データセットにある画像群を用いた画像生成を行った。

本研究では、実験データとして、Cookpad データセットのうち 50 万種類のレシピを用いた。得られたレシピで使われていた材料のうち、調味料であるものを除いた中で出現頻度が高かった、表 2 にある単語およびその関連語を用いたレシピの画像 127,690 種類を適用した。

表 2 用いた材料と画像枚数

材料	枚数
たまねぎ	29,610 枚
にんじん	22,450 枚
トマト	18,229 枚
ピーマン	8,143 枚
しいたけ	7,568 枚
ベーコン	7,978 枚
トウガラシ	5,986 枚
豆腐	9,540 枚
鶏肉	7,759 枚
豚肉	10,427 枚
合計	127,690 枚

これらの画像を用いて、通常の DCGAN を用いた Conditional GAN を適用して特定の食材を用いた料理画像の生成を行った結果、図 11 のような画像が得られた。

また、WGAN-GP をロス関数として用いた Conditional WGAN-GP を適用して画像生成を行った結果、図 12 のような画像が得られた。

## 7. 考 察

今回の実験では、ラーメン画像データセットとレシピデータ



図 9 通常の Conditional GAN を用いて生成された画像の例 (上段: ラーメン二郎 中段: 台湾ラーメン 下段: 激辛ラーメン)



図 10 食器識別器を導入した GAN を用いて生成された画像の例 (上段: ラーメン二郎 中段: 台湾ラーメン 下段: 激辛ラーメン)

セットの、2 種類のデータセットを用いて食事画像生成を試みた。

### 7.1 ラーメン画像の生成

学習データとしてラーメン画像を用いた場合、データセットの画像がラーメンのみのため、学習に用いたほぼすべての画像が共通の特徴を持っている。そのため、ラーメン固有の特徴を正しく学習することが容易であったため、本実験の結果においても比較的形の整った画像を生成することができたと推測される。一方で、画像生成に失敗した例として、輪郭がぼやけているものが見られた。これは、識別器がラーメンのどんぶりを正しく学習することができなかったためと考えられる。

そこで、Conditional GAN に食器識別器を導入して実験を行った結果、図 10 のような画像が得られた。食器識別器を導入した結果、輪郭のはっきりした画像が多く生成された。このことから、食器識別器が一定の成果を上げたと考えられる。

### 7.2 食事画像の生成

学習データとしてレシピ画像を用いた場合、データセットに多様性がありすぎるため、固有の特徴を学習することが難しかったと推測される。そのため、カテゴリごとの特徴を詳細に学習することが困難であったため、本実験の結果では、図 11 のような、やや歪んだ画像や細部が描ききれていない画像、および複数の同じような画像が生成されるという結果が見られた。これは学習時の勾配消失や勾配爆発によるものと考えられる。

そこで、WGAN を導入して実験を行った結果、図 12 のような画像が得られた。WGAN を導入した結果、導入していないものと比較して様々な画像が生成された。このことから、WGAN によって生成画像の質が向上したと考えられる。

### 7.3 生成画像の評価

また、生成された食事画像が本物の食事画像に近いかどうかを評価するために、生成画像と生成に用いたカテゴリ名を用いて画像検索を行った場合に、どのようなレシピが検索結果とし



図 11 通常の Conditional GAN を用いて生成された画像の例 (上段: ピーマン料理 中段: トマト料理 下段: 鶏肉料理)



図 12 Conditional WGAN-GP を用いて生成された画像の例 (上段: ピーマン料理 中段: トマト料理 下段: 鶏肉料理)

て表示されるかを見た。生成された画像を用い、クックパッドに対して、指定キーワードを食材として含むような類似料理画像検索を行った。

まず、Conditional GAN を用いて生成された画像を用いて検索を行った結果、図 13 のようなレシピが得られた。検索に用いた画像よりも、用いた単語が強く反映される結果となった。

次に、Conditional WGAN-GP を用いて生成された画像を用いて検索を行った結果、図 14 のようなレシピが得られた。先の結果と比較して、生成画像に似た画像が検索結果として現れていることがわかった。このことから、WGAN によってより本物らしい画像を生成することができていると言える。

## 8. まとめと今後の課題

### 8.1 まとめ

本研究では深層学習を用いた画像生成の手法である GAN による、食事画像を用いた画像生成を行った。ラーメン画像のような、カテゴリがある程度決まっている画像群を用いて学習を行い、画像生成を行ったほか、レシピ画像のような、一般的な食事画像を用いた汎用的なデータセットからも画像生成を行った。また、画像生成に用いたネットワークを改良し、より質の高い画像の生成を試みた。

### 8.2 今後の課題

一般食事画像の生成において、学習時に細かい特徴を捉えることができなかったため、綺麗な画像を生成することができなかった。そのため今後は、より詳細なカテゴリ分けを行うなど、ラベルごとの特徴がはっきりと現れるような形でデータセット作成を行いたいと考えている。また、用いた WGAN の層の数を増やす、Progressive GAN など他の GAN の手法を用いるなどして、大きな画像を生成できるようにしたい。

また、定量的な評価の方法が定まっていないため、今回は手



図 13 Conditional GAN を用いて生成された画像を用いて画像検索を行った結果



図 14 Conditional WGAN-GP を用いて生成された画像を用いて画像検索を行った結果

法毎の比較による主観的な評価のみを行っている。今後は Salimans らの研究 [11] で提案されている評価手法である Inception score を用いたり、作成した画像が同一ラベルの画像に正しく分類されている確率を求めたりするなどして、客観的かつ定量的な評価を行いたい。

謝辞: 本研究では、クックパッド株式会社と国立情報学研究所が提供する「クックパッドデータ」を利用した。本研究は科研費 (17H01745) の助成を受けたものである。

## 文 献

- [1] I. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville and Y. Bengio, Generative Adversarial Nets, Advances in Neural Information Processing Systems, pp. 2672–2680, 2014.
- [2] M. Mirza and S. Osindero, Conditional Generative Adversarial Nets, arXiv:1411.1784, 2014.
- [3] E. Denton, S. Chintala, A. Szlam and R. Fergus, Deep Generative Image Models using a Laplacian Pyramid of Adversarial Networks, Advances in Neural Information Processing Systems, 1486–1494, 2015.
- [4] A. Radford, L. Metz and S. Chintala, Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks, Proc. of International Conference on Learning Representations, 2016.
- [5] S. Nowozin, B. Cseke and R. Tomioka, f-GAN: Training Generative Neural Samplers using Variational Divergence Minimization, Advances in Neural Information Processing Systems, 271–279, 2016.
- [6] X. Mao, Q. Li, H. Xie, R. Y. Lau, Z. Wang and S. P. Smolley, Least Squares Generative Adversarial Networks, Proc. of IEEE International Conference on Computer Vision, 2813–2821, 2017.
- [7] M. Arjovsky, S. Chintala and L. Bottou, Wasserstein GAN, arXiv:1701.07875, 2017.
- [8] I. Gulrajani, F. Ahmed, M. Arjovsky, V. Dumoulin and A. C. Courville, Improved Training of Wasserstein GANs, Advances in Neural Information Processing Systems, 2769–2779, 2017.
- [9] T. Karras, S. Laine and J. Lehtinen, Progressive Growing of GANs for Improved Quality, Stability, and Variation, arXiv:1710.10196, 2017.
- [10] Y. Matsuda, H. Hoashi and K. Yanai, Recognition of Multiple-Food Images by Detecting Candidate Regions, Proc. of IEEE International Conference on Multimedia and Expo (ICME), 2012.
- [11] T. Salimans, I. Goodfellow, W. Zaremba, V. Cheung, A. Radford and X. Chen, Improved Techniques for Training GANs, Advances in Neural Information Processing Systems, 2234–2242, 2016.