

物体検知および追跡手法を用いた大豆の花数計測システムの開発

○織部慧次朗 小澤誠一 (神戸大学)

Development of Flower Counting System for Soybeans Using Object Detection and Tracking

*Keijiro Oribe and Seiichi Ozawa (Kobe University)

Abstract— In this research, we develop a flower counting system for soybeans from a series of video frame images to capture the growth status under outdoor environments. After taking a video recording of a target soybean, the developed system can detect flowers on every frame images of the movie and track the same flowers across different frame images to count the unique number of flowers in a soybean stock. We adopt Cascade R-CNN for object detection and a hybrid of DSST and Kalman Filter for robust object tracking. The performance of the developed flower counting system was evaluated for 138 selected video recordings taken at 8 soybean fields. The error rate of flower counting is 48.5% on average and it should be improved further. However, we verified that the temporal transitions of flower blooming could be captured roughly.

Key Words: deep learning, object detection, object tracking, smart agriculture

1 はじめに

近年、国内農業従事者の減少と高齢化が問題となっているが、ICTを導入して農業の効率化を推進する「スマート農業」が注目されている。スマート農業では、センサやカメラなどから農作物の環境情報や生育情報を収集・蓄積し、適切な栽培環境になるよう制御することで農業の効率化、自動化が行われる。本研究では、農業の高効率化を目指して、大豆の生育情報取得を行うシステム開発を目標とする。

大豆の生育情報を収集するため、全国各地の農業研究センター協力のもと2015年から2019年にわたって、生育の様子を動画で撮影した。2015、16年は静止画、2017年以降は動画での撮影を行った。また、動画から一定間隔ごとにフレームを切り抜き、静止画も取得した。一株当たりの花数を得るには、株ごとに撮影することが理想だが、屋外圃場では株が互いに密集しており、動画内に複数株が写り込むことが多い。よって、一株当たりの花数計測は難しい問題に属する。

本研究では、屋外圃場で取得した大豆の動画から、一株あたりの花数を計測するシステムを提案する。提案システムでは、動画フレームに対して、物体検知で花を検知し、物体追跡実現することで花数計測を。物体検知では、大豆の花のような小物体も効率的に学習できる Cascade R-CNN¹⁾ を使用した。物体追跡には、花の特徴量やスケール変化に頑強な Discriminative Scale Space Tracker (DSST)²⁾ とオクルージョンがあっても位置や移動速度から追跡可能な Kalman Filter³⁾ を組合せた。

以下では、まず提案手法について述べ、静止画を用いた Cascade R-CNN の性能評価と動画での花数計測

の評価について説明する。

2 提案手法

提案手法では、物体検知と物体追跡を併用して一株当たりの花数計測を行う。

2.1 Cascade R-CNN

Cascade R-CNN は、two-stage detector の一種で、Faster R-CNN⁴⁾ に各段階で異なる IoU 閾値を利用することができるカスケード構造を追加したモデルとなっている。類似手法である RetinaNet⁵⁾ や Faster R-CNN、YOLO⁶⁾ などを上回る、高い検知性能をもった深層学習モデルである。Faster R-CNN と Cascade R-CNN の構造の違いを Fig. 1 に示す。

Fig. 1 の conv はバックボーンでの畳み込み、pool は領域ごとの特徴抽出、head はネットワークヘッド、cls は分類層、box はバウンディングボックス回帰層を表している。Fig. 1 は、Faster R-CNN にネットワークヘッドを二つ追加したものを一例として示しており、右に行くほど学習時の IoU 閾値は高くなる。ここで、ネットワークヘッドは、Anchor Box の中でも Ground Truth との IoU が一定以上のものを出力する役割をもつ。Faster R-CNN の場合、RPN から出力された候補領域に対して、特定の IoU でしか学習できないモデルになっている。特定の IoU でのみ学習をすると、低い IoU で学習した場合にはバウンディングボックスは多様化するが、ノイズの多い検出が多く発生する。逆に、高い IoU で学習した場合は、閾値が厳しいため検出数は少ないが、未検知数が増えることになる。このような問題を Cascade R-CNN では各段階で異なる IoU 閾値をもつネットワークヘッドを追加し、解決している。




Fig. 1: Faster R-CNN と Cascade R-CNN の構造




Fig. 2: 相関フィルタの例

Faster R-CNN とは異なり、複数のネットワークヘッドを経て段階的に学習することで、本研究で対象となっている花のような小物体も効率的に学習することができる。

2.2 DSST

Discriminative Scale Space Tracker (DSST) は物体追跡を行う機械学習手法である。物体追跡とは、動画内で指定した物体がどこに移動するか移動量を推定するタスクである。これには状態空間モデルやテンプレートマッチングなど様々なアプローチがあるが、DSSTは相関フィルタ⁸⁾という手法をベースにしている。

Fig. 2 に相関フィルタの一種である MOSSE フィルタ⁹⁾の例を示す。DSSTはこの MOSSE フィルタを多次元に拡張した上に、スケール変化も追跡する処理を追加した相関フィルタである。ここでは、移動追跡に関して説明する。移動追跡を行う際は、まず最初に指定したバウンディングボックス領域内のパッチ画像を元に相関フィルタの初期値を構築し、次フレームの同じ領域にフィルタを適用して移動量を推定する。移動先のパッチ画像をもとにフィルタを更新し、以後は移動とフィルタ更新を繰り返して追跡する。DSSTでは、追跡のロバスト性を上げるためにパッチ画像の HOG 特徴量¹⁰⁾をとったマルチチャンネル画像を用いてフィルタを構築する。

次フレームの同じ領域から得た HOG 特徴画像からフィルタを用いて、歪んだガウスピークを中心付近にもつ画像を得る。前フレームとのピークを中心からのずれが移動量の推定値となり、これをもとにして移動を繰り返す。さらに、このレスポンスに対して Peak to Side-lobe Ratio (PSR) という指標の値を求めること

で追跡の精度を評価することもできる。PSR はレスポンス画像 \vec{y} に対して 1 を適用して得られる。 $\max(\cdot)$, $\text{mean}(\cdot)$, $\text{std}(\cdot)$ はそれぞれ \vec{y} の全要素に対する最大値、平均値、標準偏差を表す。

$$PSR(\vec{y}) = \frac{\max(\vec{y}) - \text{mean}(\vec{y})}{\text{std}(\vec{y})} \quad (1)$$

この PSR が高いほど、安定して追跡ができていことになる。

2.3 Kalman Filter

観測値から得られた位置情報により、物体の位置や速度を推定し、安定に追跡する技術にはカルマンフィルタがよく用いられている。カルマンフィルタは、線形、ガウス型の雑音を仮定し、予め与えられた運動モデルにより次時刻の目標の状態を推定する。本研究で用いる動画は、ある方向に対して、一定の速度でスライドして撮影するため運動モデルには等速運動を用いている。ここで、状態を推定するために、対象のシステムに対して式 (3) のように状態空間モデルを与える。

$$\vec{x}_t = \vec{F}_t \vec{x}_{t-1} + \vec{w}_t \quad (2)$$

$$\vec{z}_t = \vec{H}_t \vec{x}_t + \vec{v}_t \quad (3)$$

式 (3) は目標の状態遷移を表わす運動モデルと目標と観測値との関係を表わす観測ベクトルを表している。 \vec{x}_t は目標の状態ベクトルで、位置と速度の情報をもつ。また、 \vec{F}_t は状態遷移行列であり、ここでは式 (4) の等速直線運動モデルを用いる。

$$\vec{F}_t = \begin{bmatrix} \vec{I} & \Delta t \vec{I} \\ \vec{O} & \vec{I} \end{bmatrix} \quad (4)$$

ただし Δt はサンプリング間隔、行列 \vec{I} は単位行列である。また、 \vec{H}_t は $\vec{H}_t = (\vec{O} \vec{I})$ で表わされる観測行列、 \vec{w}_t は平均 0、誤差共分散行列 \vec{Q}_t のシステム雑音ベクトルであり、 \vec{v}_t は平均 0 で誤差共分散行列 \vec{R}_t の観測雑音ベクトルである。こうして得た状態空間モデルをもとに物体の状態、誤差共分散を予測、更新することで物体を追跡する。

2.4 花数計測システム

本研究では、動画の中に写っている一株当たりの花の個数を計測することを目的とする。入力する動画は大豆の株を下から上までスライドしながら撮影した動画を用いる。提案手法の処理は主に、(1) 花、主茎の検知、(2) 検知領域の設定、(3) 花の追跡の三つで構成されている。まず、入力された動画の各フレームにおいて、Cascade R-CNN を用いて花、主茎の検知をする。ここで、フレームに写っている一株当たりの花の個数を計測するためには、複数の株の中から対象の株を見極める




Fig. 3: 対象とする株の例




Fig. 4: 検知領域の設定

必要がある。ここでの対象の株とは、Fig. 3(a)のように株の後ろに棒が刺さっているものやFig. 3(b)のように仕切りで囲われている株を対象としている。ここで、画像内に写っている花全てを計測しても求めている生育情報は得られないためFig. 4のように検知する範囲を定める。Fig. 4は、検知領域の範囲 $\mathbf{r} = (r_x, r_y, r_w, r_h)$ として、式 (5) で表される。

$$r_x = b_x, \quad r_y = b_y, \quad r_w = b_w + w/2, \quad r_h = h \quad (5)$$

ここで、主茎のバウンディングボックスを $\mathbf{b} = (b_x, b_y, b_w, b_h)$ 、入力画像の縦と横の大きさをそれぞれ h, w とする。また、 b_x, b_y, b_w, b_h はそれぞれ、中心の x, y 座標、横幅と高さを示す。これまでの処理をもとに、Cascade R-CNN から検知領域内に存在する花のバウンディングボックスを得る。次に、従来手法における棄却領域についての説明とともに Kalman Filter のメリットを述べる。従来手法では、追跡手法が DSST のみであったため簡単なオクルージョンで重複して計数してしまっていた。そこで、追跡手法に処理を追加するのではなく、検知結果から不要なものを削減するという後処理を追加することで重複計数を防いでいた。ここで、ある DSST の出力を $t = (tx_{min}, ty_{min}, tx_{max}, ty_{max})$ とする。全ての DSST の出力の中で ty_{min} が最小のものを選び、そのボックスの下底辺、つまり ty_{max} を軸とする境界線を引く。その境界線より下部の全領域を棄却領域と設定している。棄却領域内では、バウンディングボックスが得られても追跡せず、物体数にもカウントしない。しかし、この棄却領域によって検知されずに

未計測となる物体が課題となっていた。従来手法において、オクルージョンの原因となっているのは、DSST がバウンディングボックスの領域内のパッチ画像の特徴をもとに追跡を行っていたためである。オクルージョンが起きると、特徴が全く別の物体になることにより PSR が著しく下がり、追跡を終了してしまう。そこで、特徴による追跡に加え、Kalman Filter によるバウンディングボックスの位置情報をもとに追跡することによって、オクルージョンによる重複を防ぐ。Kalman Filter の追加によって、オクルージョンにより PSR が著しく下がり、DSST が追跡を終了しても位置情報をもとに追跡を継続することができる。また、棄却領域をなくしたことによって、未計測を従来手法よりも減らすことができる。この二つの追跡手法を用いて、得られたバウンディングボックスに対して、二つの処理を行う。

まず一つ目の処理では、前フレームからの DSST の追跡結果と花のバウンディングボックスの IoU がしきい値以下ならその追跡ボックスを花のバウンディングボックスに追加する。ここで、追跡結果を検知結果として、追加する理由としては、連続した検知がされない花を Kalman Filter にて追跡するためである。Kalman Filter には初期値を与えているのみで、最低でも状態の更新が 2 回なければその後、正常な追跡はできない。そのため、連続した検知がされない花の検知結果を補うために DSST の追跡結果を追加している。二つ目の処理では、得られたバウンディングボックスを Kalman Filter, DSST それぞれの追跡器に適用していく。花のバウンディングボックスと追跡器が出力したボックスがしきい値以上で重複しているなら、Cascade R-CNN の出力を受け取ってフィルタ初期値を再構築し、次のフレームから追跡を再開する。逆に、Cascade R-CNN のボックスがどの追跡器とも IoU がしきい値未満、つまり追跡されていない物体を検知したら、新たにボックスを用意して次のフレームから追跡を始める。DSST が新たな物体を追跡し始めるごとに物体数を +1 する。ここで、Kalman Filter は DSST の追跡を補助するものであり物体数には関係していない。

次に Kalman Filter, DSST が追跡を打ち切る条件について説明する。それぞれに共通した条件として、Cascade R-CNN の検知結果を受け取らずに長く追跡が続いている場合である。まずそれぞれの経過時間を計測するパラメータを追加する。このパラメータは初期値が 0 で、追跡結果がどの検知結果ともマッチしないフレームにおいて 1 ずつ加算していく。この経過時間がしきい値を超えた場合も追跡が打ち切られる。DSST に固有の条件として PSR のしきい値より PSR が小さくなった時である。本手法では、検知結果として、DSST

Table 1: 各年度の撮影方法

年度	データ	動力	カメラ台数	枚数 (枚/株)
2015	静止画	モーター	1	31
2016	静止画	なし	5	5
2017	動画	手動	1	7
2018	動画	手動	1	7
2019	動画	手動	1	7

Table 2: データセット構成

	訓練データ数	テストデータ数
花	30729	1711
子実	40898	3186
主茎	2255	265

の追跡結果を用いるため PSR を高めに設定し、誤追跡物体を検知結果として追加しないようにしている。こうして1つの動画の中で生成した DSST の総数を花数として、最終的な出力とする。

3 実験

実験では、動画に対する花数計測の評価を行い、提案手法がどの程度正確に一株当たりの花数を計測できるか検証する。また、個数計測は、検知精度と追跡精度の二つの精度が重要であるため先行実験において、Cascade R-CNN の有効性を検証する。

3.1 データセット

本研究で用いるデータは、2015 年度から 2019 年度にかけて、全国各地の農業研究センターの協力のもと撮影を行って収集した。大豆の株は、通常の屋外圃場に植えられたものを撮影対象としている。花は上空からは確認できないため、直接圃場に立ち入る必要がある。また、十分に捉えるためにはある程度の近距離で撮影する必要があり、一枚の写真では株全体を収めることができない。そこで、株全体を収められるような撮影装置を用いて撮影した。Table 1 に各年度の撮影方法をまとめた。2015、16 年は静止画で、2017 年以降は動画で撮影している。動画からは一定間隔のフレームで静止画を切り抜くことで静止画データセットも同時に収集している。Table 3 に今回用いたデータセットを示す。静止画をアノテーションするには、成熟していながらはっきりと写っている物体を正解に記録した。アノテーションによって得られた各年度、各圃場における花のデータセットの情報について、Table 3 に示す。花動画、花画像とは、花が存在する動画数、画像数を示す。選定動画は花動画の中から対象の株のみの計測が困難な動画を花動画から除き、花数推移を得るためにできる限り同じ区画から選定した動画数を示す。

Table 3: データセット

年度	地点	花動画	選定動画	花画像
2015 年	A	—	—	1193
2016 年	A	—	—	654
	B	—	—	1503
	C	—	—	550
2017 年	A	128	16	850
	B	195	12	436
	C	188	16	755
2018 年	A	237	12	682
	C	54	0	755
	D	30	0	94
	E	167	10	556
	F	118	15	404
	G	24	0	168
	H	55	0	191
2019 年	A	80	15	172
	B	19	4	96
	C	27	8	76
	D	48	8	423
	E	169	0	769
	F	34	6	404
	H	72	16	150
合計		1648	138	10148

3.2 物体検知の評価

花検知の評価は Average Precision で行った。Average Precision は、モデルの Recall-Precision 曲線と取り、曲線とグラフの縦軸・横軸がなす図形の面積とした。Cascade R-CNN の性能評価にあたり、比較対象として RetinaNet⁷⁾、Faster R-CNN⁷⁾ を用いた。backbone は層数が 50 層の Residual Net50 と層数が 101 層の Residual Net101 を用いた場合の 2 通りを比較した。まず、各モデルの Precision-Recall 曲線を AP^{50} 、 AP^{75} それぞれについて Fig. 5、Fig. 6 に示す。Fig. 5、Fig. 6 から、IoU のしきい値を下げると、Precision-Recall 曲線は全体的にグラフの右側に伸びていくことが分かる。これは、IoU のしきい値を下げていくほど検知成功と判定される検知結果の数が単調増加し、Precision と Recall の性能が良くなっていくためである。しかし、しきい値が低すぎると検知しているように見えないのに検知成功と判定されてしまう場合があるので、高いしきい値でも良い曲線を得られるモデルが理想とされる。Cascade R-CNN50 は、 AP^{50} においては、Faster R-CNN101 に精度で劣っているが、 AP^{75} では曲線下面積の差が大きくなっていることから精度で優っていることがわかる。これは、Cascade R-CNN のバウンディ




Fig. 5: 各モデルの Precision-Recall 曲線 (AP^{50})




Fig. 6: 各モデルの Precision-Recall 曲線 (AP^{75})

ングボックスが他のモデルに比べてより Ground Truth に近いことを意味している。

3.3 花数計測の評価

花数計測では定量的な評価指標がないため、提案手法で得られた花数と実際の花数との比較を行う。実際の花数は動画を各フレームについて目視で確認し数え上げて取得した。Table 3 の選定動画について、計測を行い、結果を考察する。ここで、より定量的かつ再現性を高めるために一つの動画全てのフレームをアノテーションを行い、計測することが望ましい。しかし、各動画 60fps で 10 秒を超える動画が多くを占めるため目視によって評価を行う。花数推移のデータに関しては、より信憑性を高めるためにアノテーション同様複数人による目視での計測を行っている。各年度の圃場全体において、花数計測を行った結果を Table 4 に示す。Table 4 の各項目について、ここで定義する。以下の定義において、それぞれの値は圃場ごとの平均数を示している。正解、推定はそれぞれ、実際の花数、推定結果の花数を示している。また未計測、重複計測はそれぞれ、目視で確認した結果、花数推定の際に計測できていない花数、目視で確認した際に推定結果が花を重複して計測した花数を示している。加えて、Table 5

Table 4: 花数計測結果

手法	正解	推定	誤差率	未計測	重複計測
M1	6.42	7.13	10.12	0	0.56
M2	6.42	20.38	191.07	0	13.25
M3	6.42	6.5	-7.14	2.38	1.75
M4	6.42	4.63	-33.93	3.63	1.13

Table 5: 各手法の構成要素技術

手法	構成要素技術
M1	Cascade R-CNN, DSST, Kalman Filter
M2	Cascade R-CNN, DSST
M3	Cascade R-CNN, DSST, 棄却領域
M4	RetinaNet, DSST, 棄却領域

のように省略のため手法を番号で表記している。

Table 4 の結果についてそれぞれ見ていく。まず、誤差に関しては、提案手法である M1 より既存の追跡手法である M3 の方が誤差が少ない。これは、重複計測数と未計測数が打ち消しあっていることが大きい。そのため、M3 と M4 は棄却領域により重複計測を抑えることができていた一方で、未計測数が非常に多いことがわかる。次に、提案手法である M1 と M2 を比べると、誤差は少なくなっている。これは、Kalman Filter によってオクルージョンに対しての追跡ができたことが大きい。そのため重複計測数が減少している。また、M3 と M4 の未計測数を比べると M3 の方が少なく、重複計測数が多いことから Cascade R-CNN によって

Table 6: 花数計測結果

(a) 2017 年 B

手法	正解	推定	誤差率	未計測	重複計測
M1	12.11	19.11	57.8	0	6.44
M2	12.11	26.11	115.6	0	13.44

(b) 2017 年 C

手法	正解	推定	誤差率	未計測	重複計測
M1	7	7.5	7.14	0	0.38
M2	7	20.38	191.07	0	13.25

(c) 2018 年 A

手法	正解	推定	誤差率	未計測	重複計測
M1	10.75	15.5	44.19	0	4.75
M2	10.75	20.75	93.02	0	10

(d) 2019 年 C

手法	正解	推定	誤差率	未計測	重複計測
M1	4.33	9.17	111.54	0	4
M2	4.33	10.83	150	0	5.67

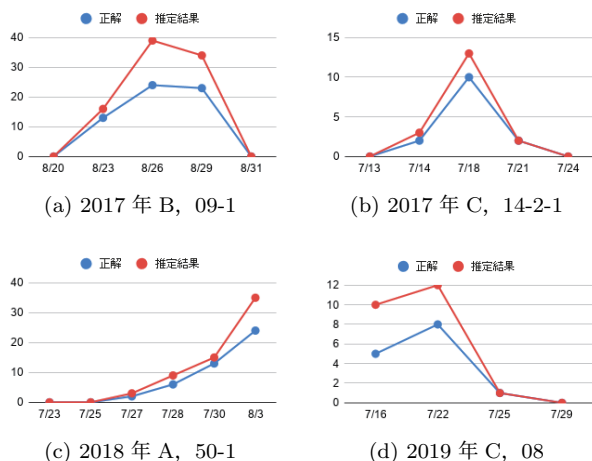


Fig. 7: 各区画における花数の推移

検知精度が向上していることがわかる。次に特定の年度、圃場ごとにまとめたものを Table ??(a)-(d) にそれぞれ示す。また、またそれぞれの圃場における区画ごとの花数推移の結果を Fig. 7 に示す。圃場ごとに精度にばらつきが見られた。よく計測できたのは 2017 年 C だった。Fig. 7(b) を見ても正解数と推定結果に正の相関が見られる。特徴として、オクルージョンは多いが 1 秒以下と短いこと、また撮影装置を一定の速度で引き上げていたことである。提案手法 M1 に対して、M2 の精度が悪いことからオクルージョンの多さがわかる。これは、DSST が短いオクルージョンにも対応できていないことが顕著に現れている。M1 の精度が良い要因として、比較的に大きい花が多くオクルージョン後にすぐに検知し Kalman Filter を補正ができていたことも大きい。一方で、他の圃場では重複計測が多かった。要因としては、長いオクルージョンやスライダーを引き上げる際の横揺れ、速度が不安定なケースが多かった。

4 おわりに

本論文では、動画から一株当たりの花数を自動で計測するために、Cascade R-CNN の物体検知と DSST, Kalman Filter の物体追跡を組み合わせた花数計測手法を提案した。実験では、花数計測の性能評価に加えて、先行実験として Cascade R-CNN の物体検知の性能評価を行った。物体検知の評価では、テストデータに対して Cascade R-CNN, RetinaNet, Faster R-CNN の検知性能を評価した。結果、Cascade R-CNN が AP^{50} , AP^{75} において他モデルに比べて高い性能を示した。目視で数えた花数と提案手法による推定結果を比較したところ、一株当たりの平均花数 14.2 個に対して誤差は 6.8 個 (48.5%) だった。特に長いオクルージョンや、撮影の際の横揺れに対して、重複計測が増加する傾向にあった。限られた圃場においては、一株当たりの平均

花数は 7.0 個に対して誤差は 0.5 個 (7.1%) だった。計測結果より、限られた圃場においては生育情報の収集に有効であることが確認できた。今後は、小物体の検知性能を向上させ、重複検知と未検知をさらに抑えた個数計測手法を考案し、動画からより正確な個数計測ができるようにしたい。

5 謝辞

本研究は、平成 27~令和元年度農林水産省委託プロジェクト研究「多収阻害要因の診断法及び対策技術の開発」の助成を得て行われた。

参考文献

- 1) Zhaowei Cai and Nuno Vasconcelos. Cascade r-cnn: Delving into high quality object detection. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 6154–6162, 2018.
- 2) Martin Danelljan, Gustav Hager, Fahad Shahbaz Khan, and Michael Felsberg. Accurate Scale Estimation for Robust Visual Tracking. In *Proceedings of the British Machine Vision Conference*. BMVA Press, 2014.
- 3) Greg Welch, Gary Bishop, et al. An introduction to the kalman filter. 1995.
- 4) Shaoqing Ren, Kaiming He, Ross Girshick, and Jian Sun. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. In *Advances in Neural Information Processing Systems 28*.
- 5) Tsung-Yi Lin, Priya Goyal, Ross B. Girshick, Kaiming He, and Piotr Dollár. Focal Loss for Dense Object Detection. In *IEEE International Conference on Computer Vision, ICCV 2017, Venice, Italy, October 22-29, 2017*, pp. 2999–3007, 2017.
- 6) Joseph Redmon, Santosh Kumar Divvala, Ross B. Girshick, and Ali Farhadi. You Only Look Once: Unified, Real-Time Object Detection. In *2016 IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2016, Las Vegas, NV, USA, June 27-30, 2016*, pp. 779–788, 2016.
- 7) Wei Liu, Dragomir Anguelov, Dumitru Erhan, Christian Szegedy, Scott E. Reed, Cheng-Yang Fu, and Alexander C. Berg. SSD: Single Shot Multibox Detector. *CoRR*, Vol. abs/1512.02325, 2015.
- 8) B. V. K. Vijaya Kumar and Abhijit Mahalanobis, and Richard D. Juday. *Correlation Pattern Recognition*. Cambridge University Press, 2005.
- 9) David S. Bolme, J. Ross Beveridge, Bruce A. Draper, and Yui Man Lui.
- 10) N. Dalal and B. Triggs. Histograms of Oriented Gradients for Human Detection. *Computer Vision and Pattern Recognition, 2005. CVPR 2005. IEEE Computer Society Conference on*, Vol. 1, pp. 886–893, 2005.