

MIRU2019

自己教師あり学習による 変化領域の推論を活用した 弱教師あり領域分割

2019年8月1日

電気通信大学 博士課程後期

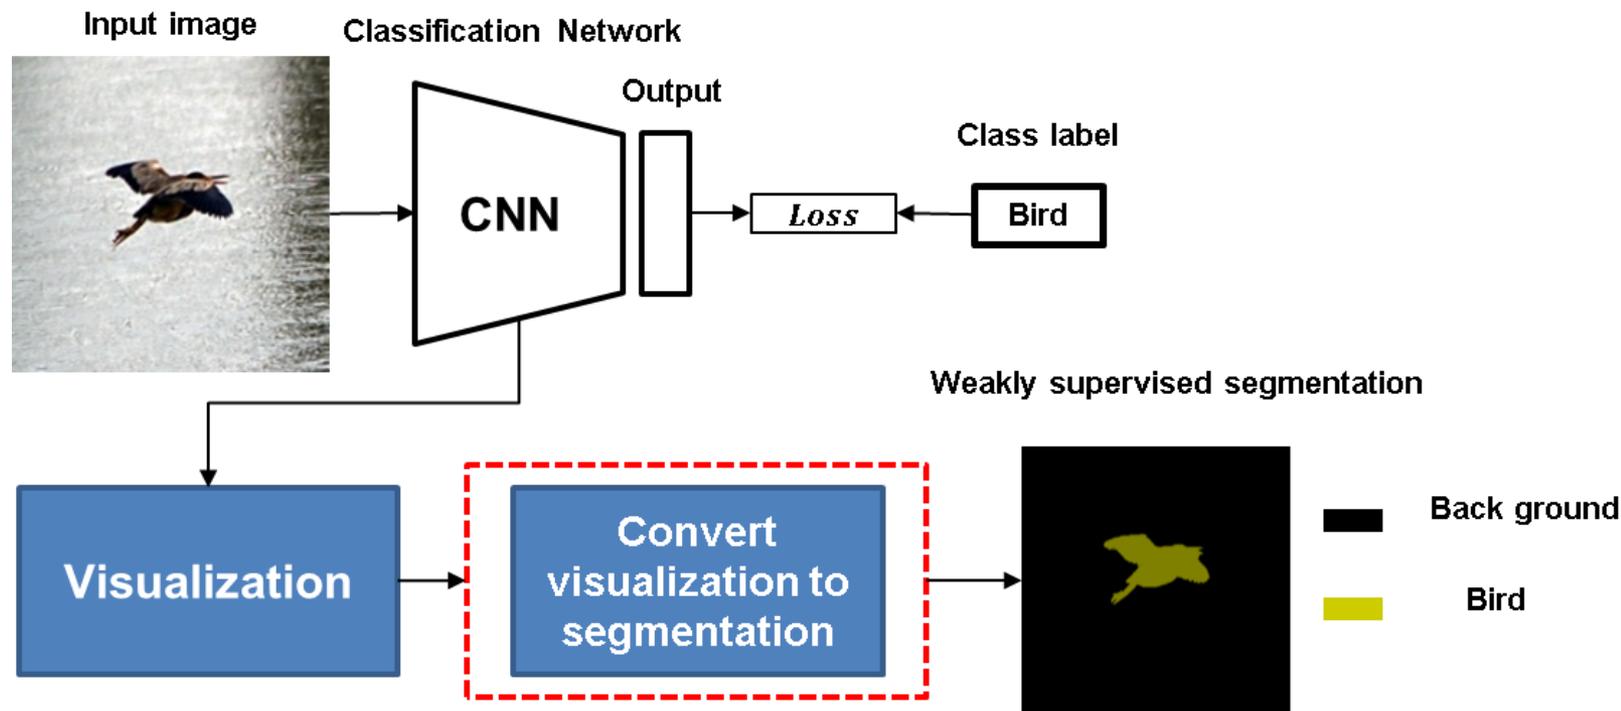
下田 和, 柳井啓司

研究の目的

- 弱教師あり学習による領域分割の精度向上
- 弱教師あり領域分割
 - 領域分割のアノテーションコストは高コスト
 - 教師情報のコスト削減

弱教師あり領域分割

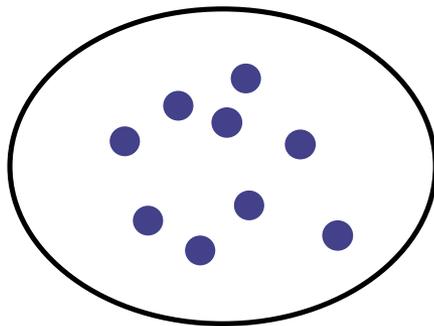
- クラスラベルを用いて領域分割ラベルを求める
 - クラス分類識別器の可視化を活用



認識の可視化を用いた 弱教師あり領域分割

- 可視化結果 \neq 領域分割
 - 可視化結果から領域分割へと変換するための写像を考える必要がある

可視化結果

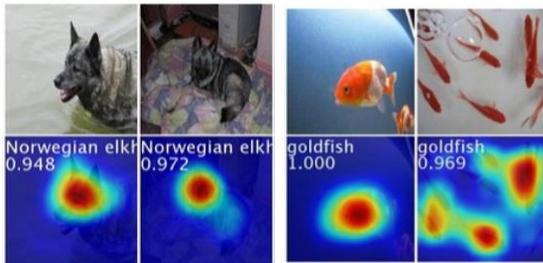
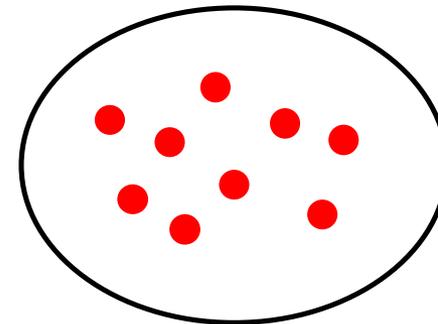


写像: Θ



人による知見

領域分割

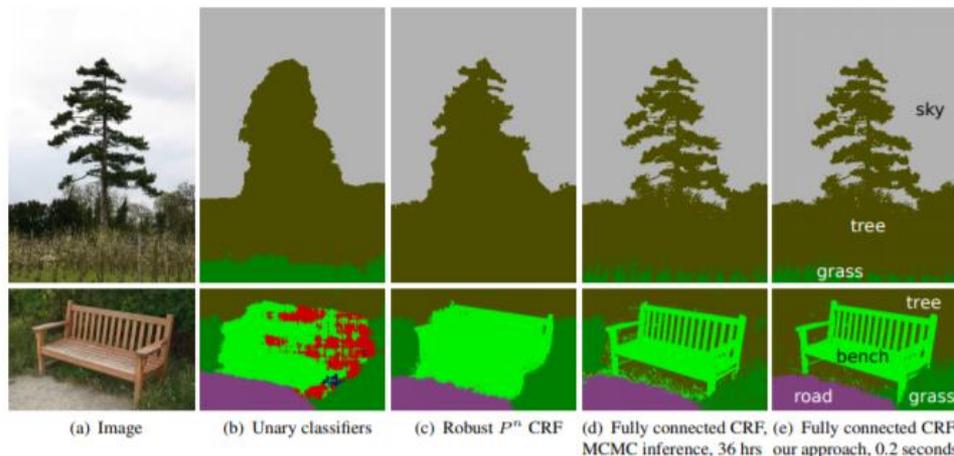


[CVPR 2016]



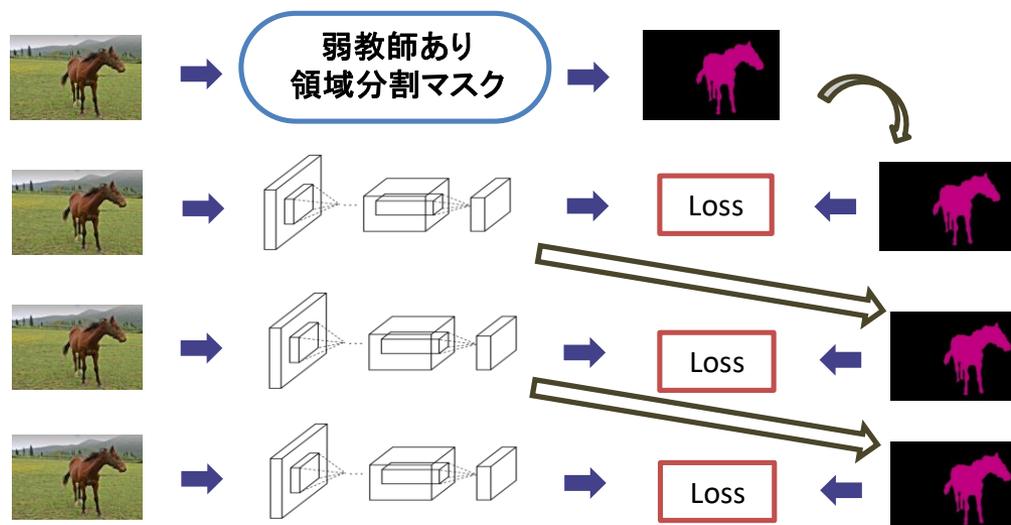
汎用性の高い弱教師あり領域分割の精度向上手法①

- Conditional Random Field(CRF) [NIPS 2012]
 - ピクセルの色特徴、位置関係からピクセル間の結びつきの強さを推論



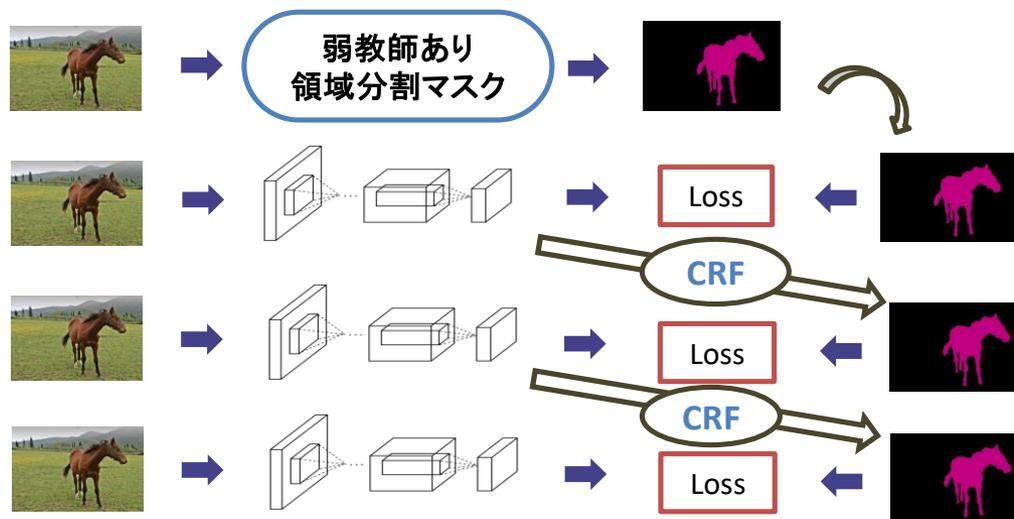
汎用性の高い弱教師あり領域分割の精度向上手法②

- 領域分割モデルの繰り返し学習 [PAMI 2016]
 - 仮の教師情報で教師あり領域分割モデルを学習
 - 学習した領域分割モデルの出力を使って再学習
 - 教師情報の外れ値が吸収され精度が向上



繰り返し学習の限界

- 再学習 + CRFを続ければ精度は無限によくなる？
→どこかで精度が向上しなくなる、または精度が下がるようになる



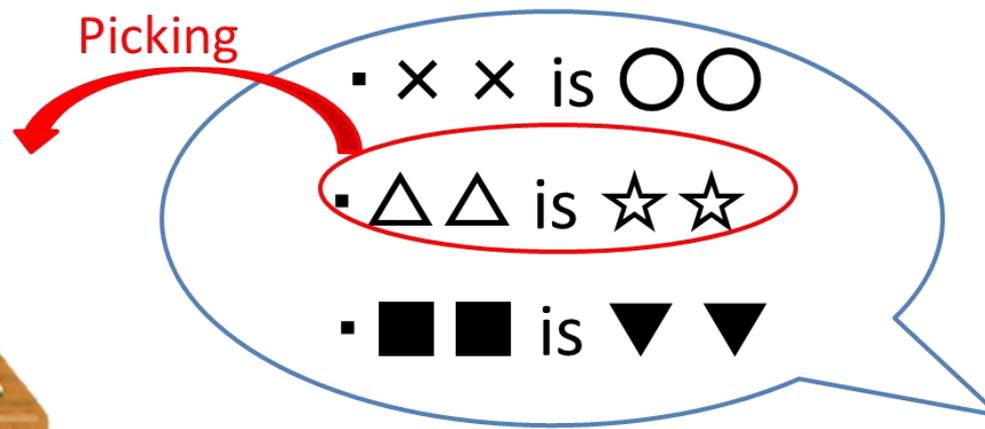
- 理由: ノイズを含む教師情報を使って学習する場合、ノイズも学習してしまうため

ノイズを含む教師情報からの学習

- 教師情報をTeacherではなくAdviserとして活用したい
 - Teacher: 全面的に信頼できる情報を提供
 - Adviser: 部分的に信頼できる情報を提供



Picking



Adviser

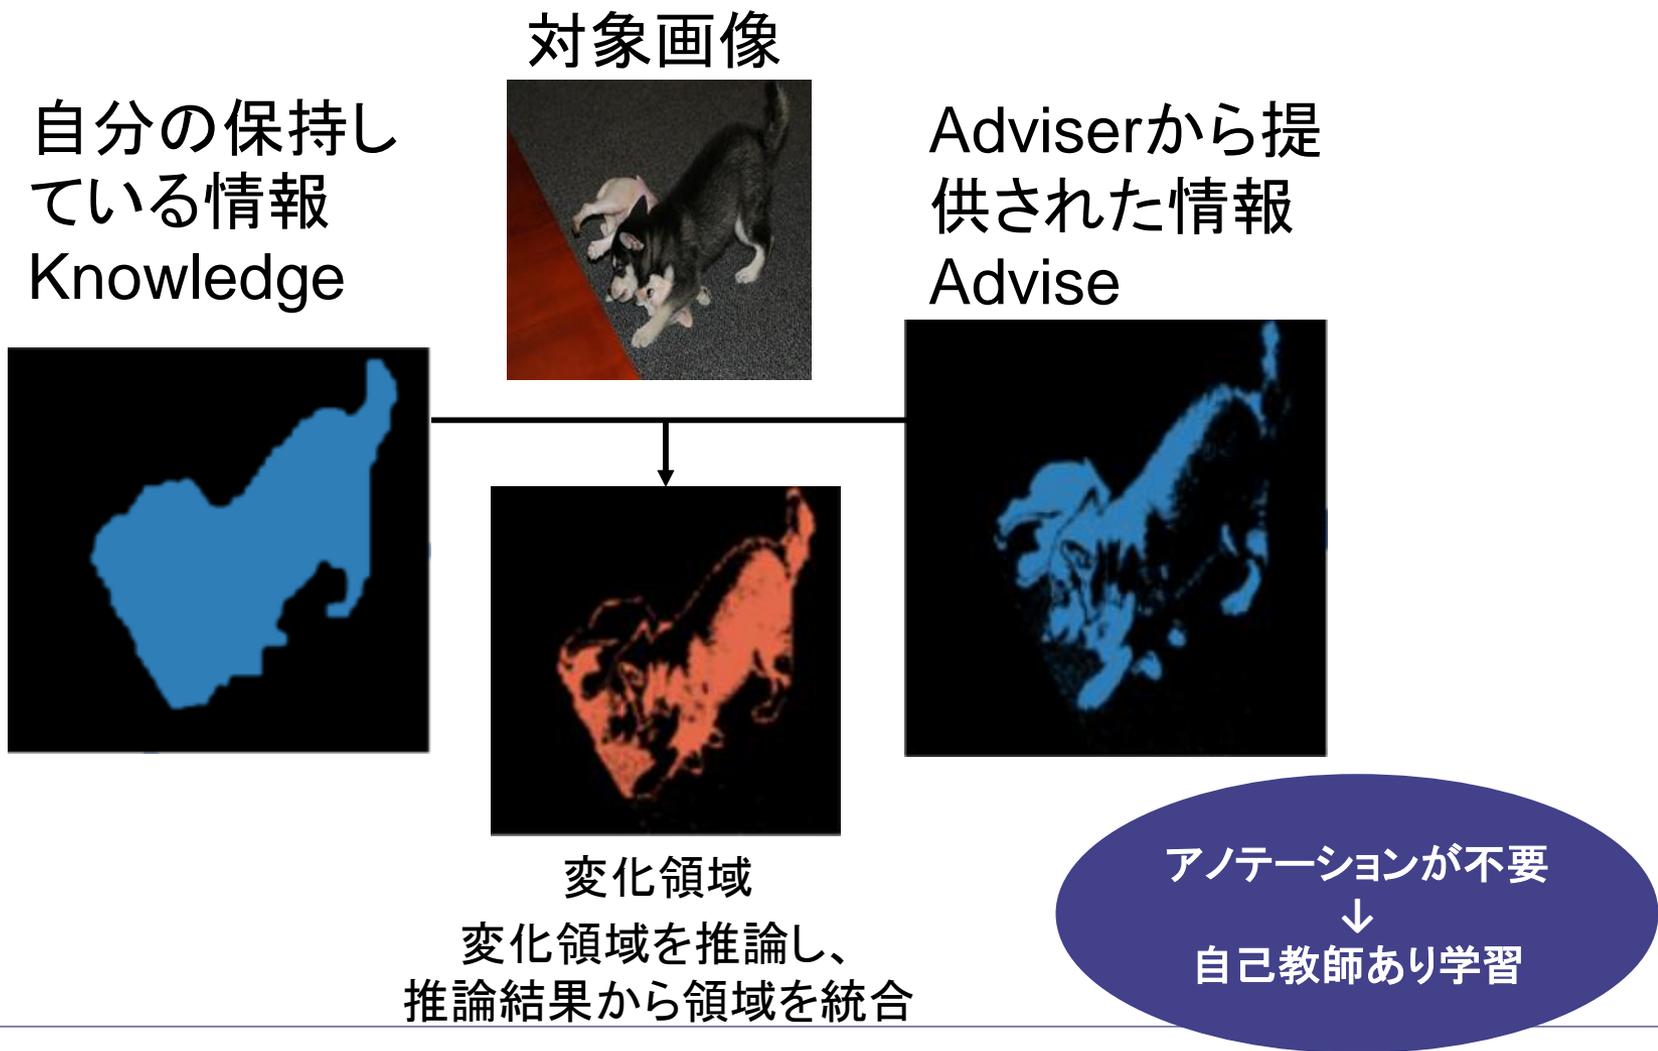
変化領域の推論によるモデル化

- 人がAdviserの意見を参考にする際の思考の傾向
 - 多数派の証言は正しい可能性が高い
 - 自分の知識とかけ離れていれば信頼できない

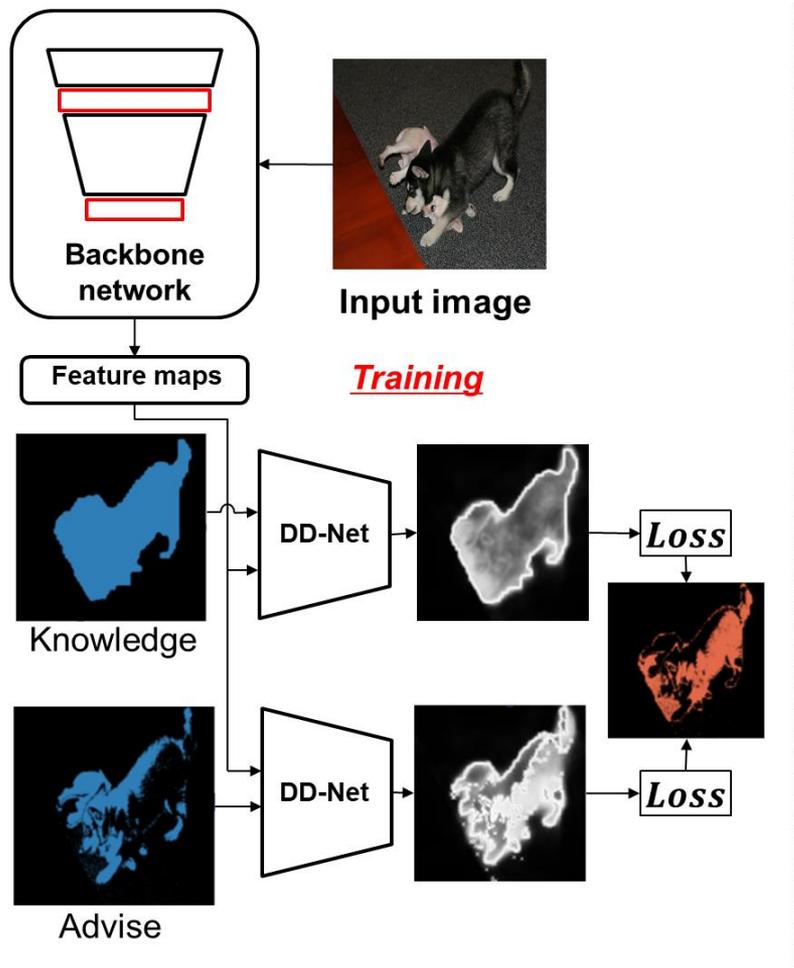


- 自分の保持している情報と、Adviserからの情報を照らし合っている
- モデル化
 - AdviserのAdviseを事前に予測する
 - 変化領域の推論

自己教師あり学習による 変化領域の推論

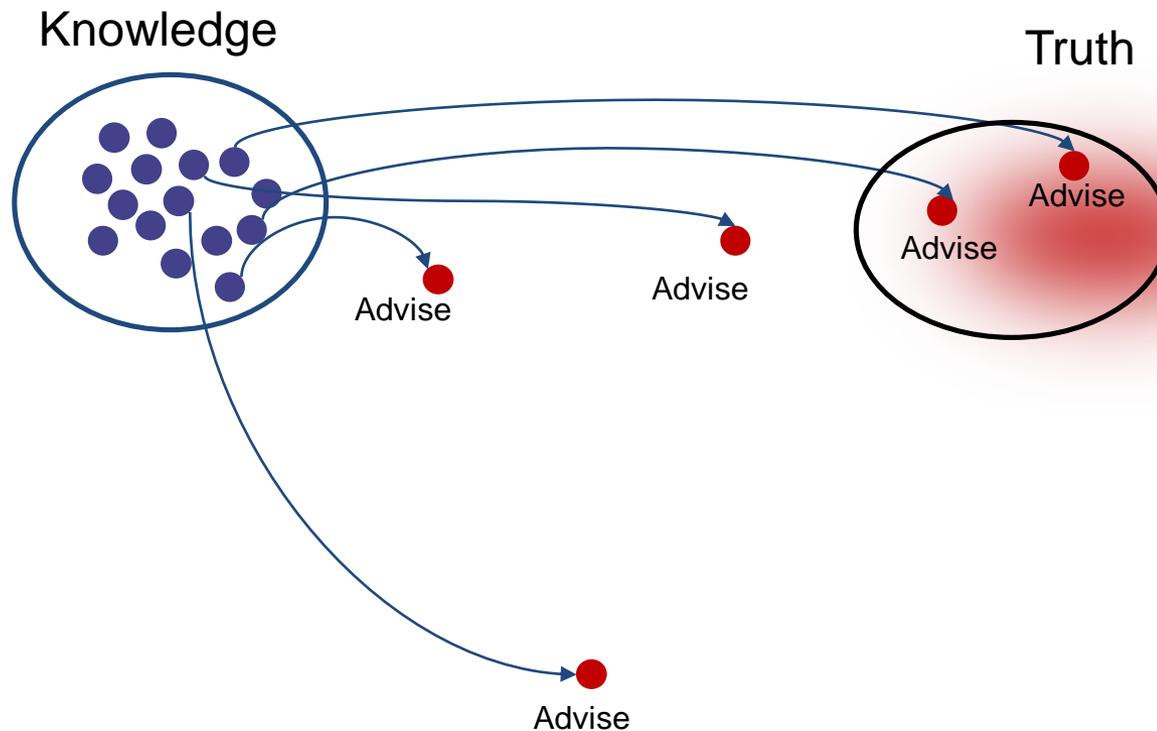


提案手法の概略図



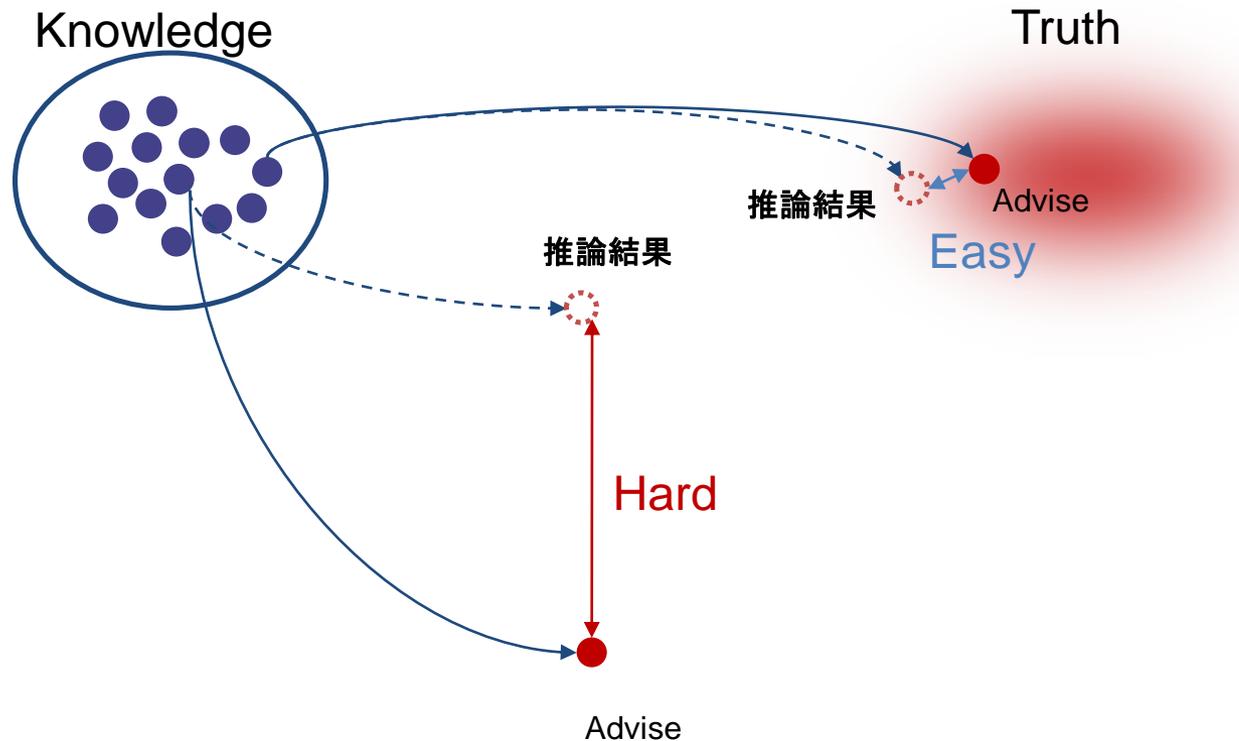
変化の推論を活用した よい推論候補の選択

- Truthに近いAdviseのみを取り入れたい



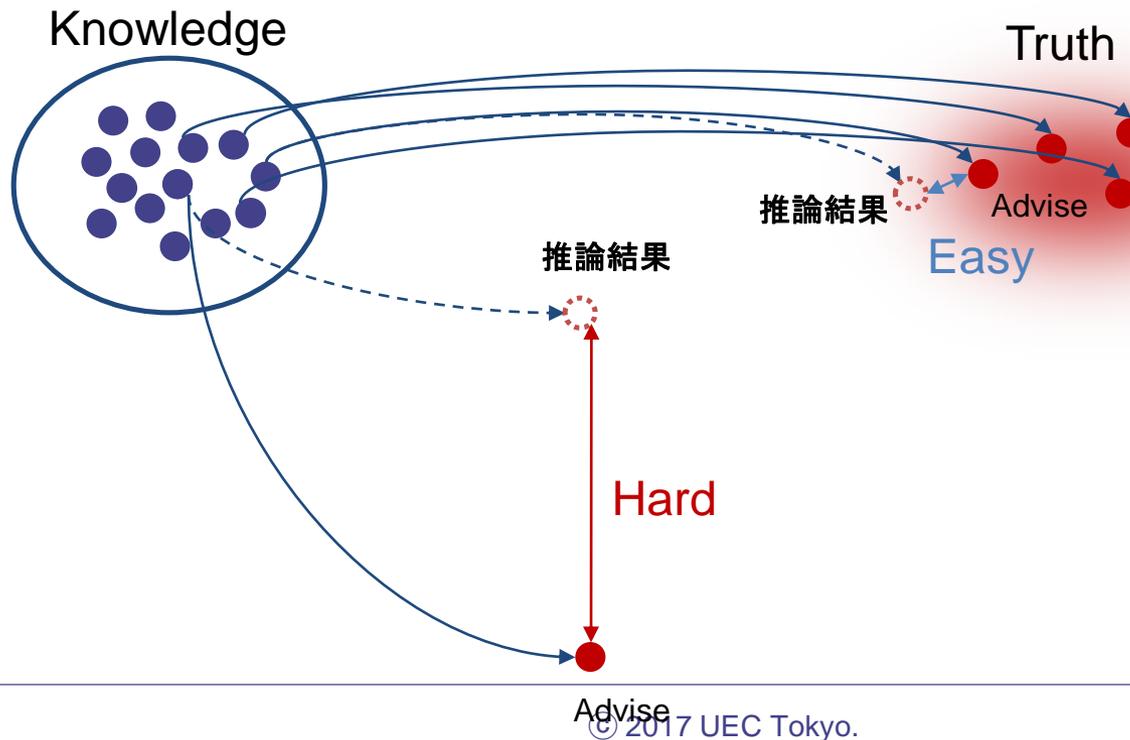
変化の推論を活用した よい推論候補の選択

- アドバイスを事前に推論する
 - 推論が容易なサンプル、難解なサンプルが存在



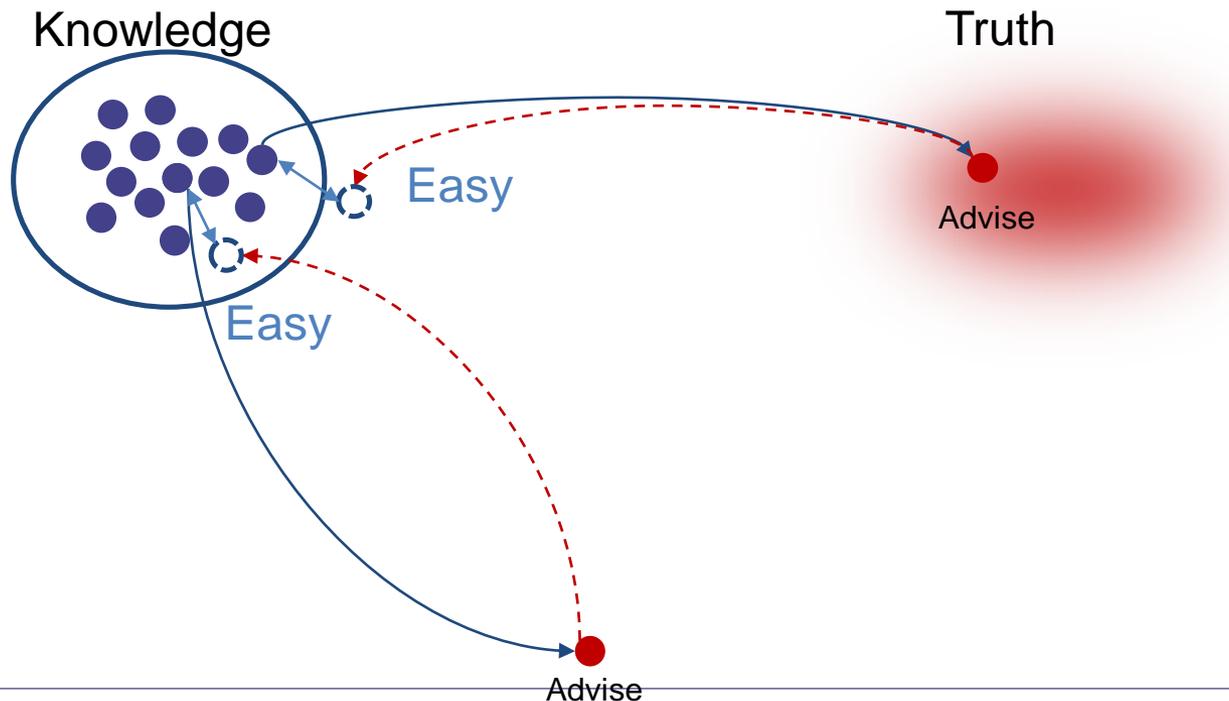
変化の推論を活用した よい推論候補の選択

- 学習に多く含まれる傾向のサンプルは推論しやすい
- よいアドバイスが多数派であれば、変化が推論しやすいほどよいサンプルということに
 - 推論が容易なサンプルを選べばよさそう
 - 単純な閾値で処理？(サンプルごとに閾値は異なるはず)



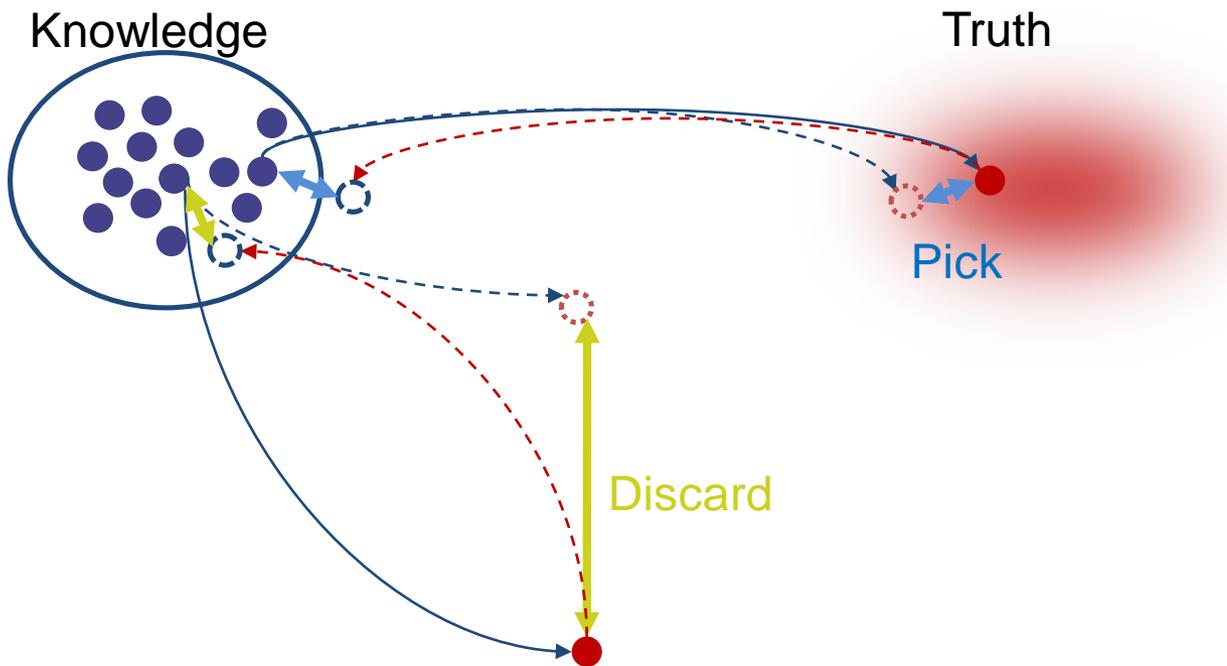
変化の推論を活用した よい推論候補の選択

- AdviseからKnowledgeを推論
 - 基本的に推論が容易
 - Knowledgeの分布においては大きなずれが少ない
 - 閾値に活用



変化の推論を活用した サンプルの取捨選択

- AdviseとKnowledgeから双方向に変化を推論
 - Adviseの推論とKnowledgeの推論の容易さについての差を閾値に活用



変化の推論による領域の統合

特徴量: $e^h(x), e^l(x)$

マスク: m

変化の推論結果 d

ピクセルの位置: u

K: Knowledge, A: Advise

$$d_u^K = DDnet(e^h(x), e^l(x), m_u^K)$$

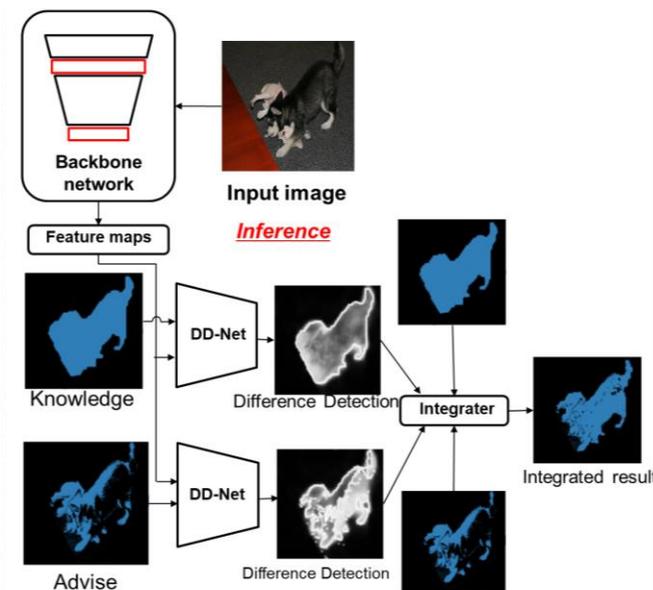
$$d_u^A = DDnet(e^h(x), e^l(x), m_u^A)$$

領域についての重み w

$$w_u = d_u^K - d_u^A + bias$$

統合された領域分割結果 m_u^R

$$m_u^R \begin{cases} m_u^K & \text{if } (w_u \geq 0) \\ m_u^A & \text{if } (w_u < 0) \end{cases}$$



Self-Supervised

Difference

Detection(SSDD) module

としてモジュール化

$$m^R = SSDD(e(x; \theta_e), m^K, m^A; \theta_d)$$

二つの応用方法

- PSA, PSA+CRFの变化領域の推論と領域の統合①

自分の保持している情報
Knowledge



Pixel-level Semantic Affinity(PSA) [CVPR 2018]



Picking



Adviser

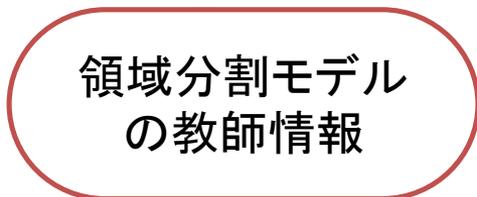
Adviserから提供された情報
Advise



Conditional Random Field(CRF) [NIPS 2012]

Pixel-level Semantic Affinity(PSA)の教師情報, 領域分割モデルの出力の变化
最高精度の領域分割手法
領域の推論と領域の統合②

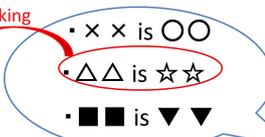
自分の保持している情報
Knowledge



①の統合結果

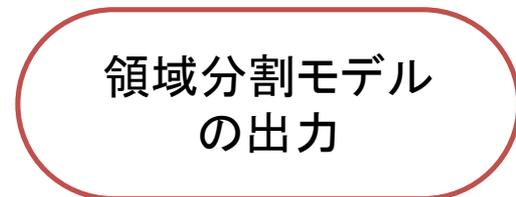


Picking



Adviser

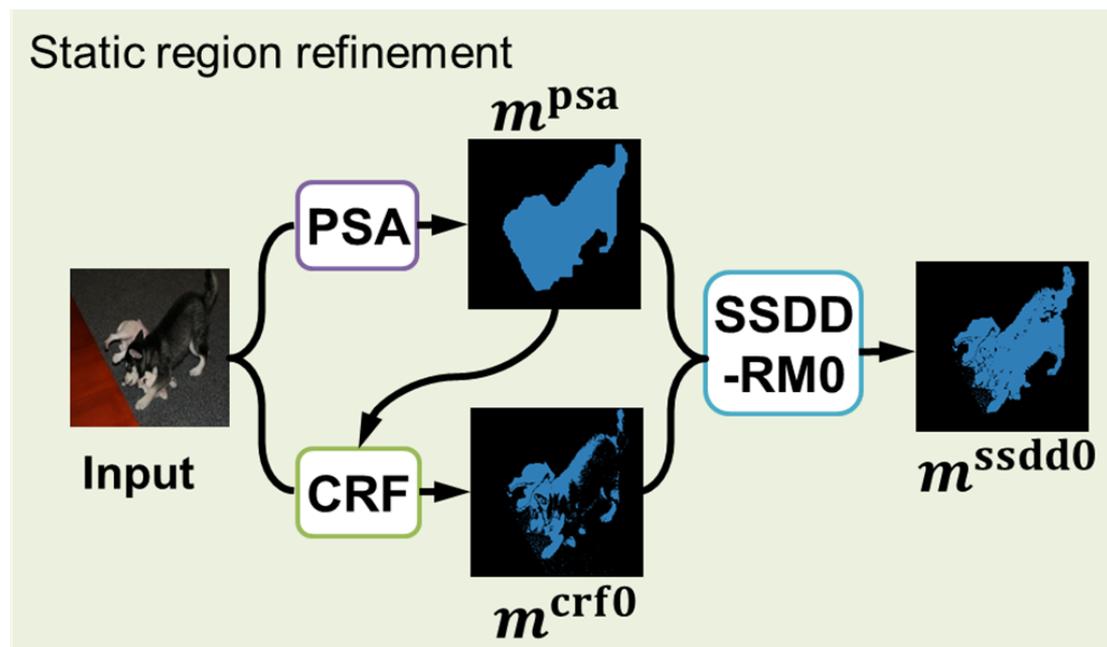
Adviserから提供された情報
Advise



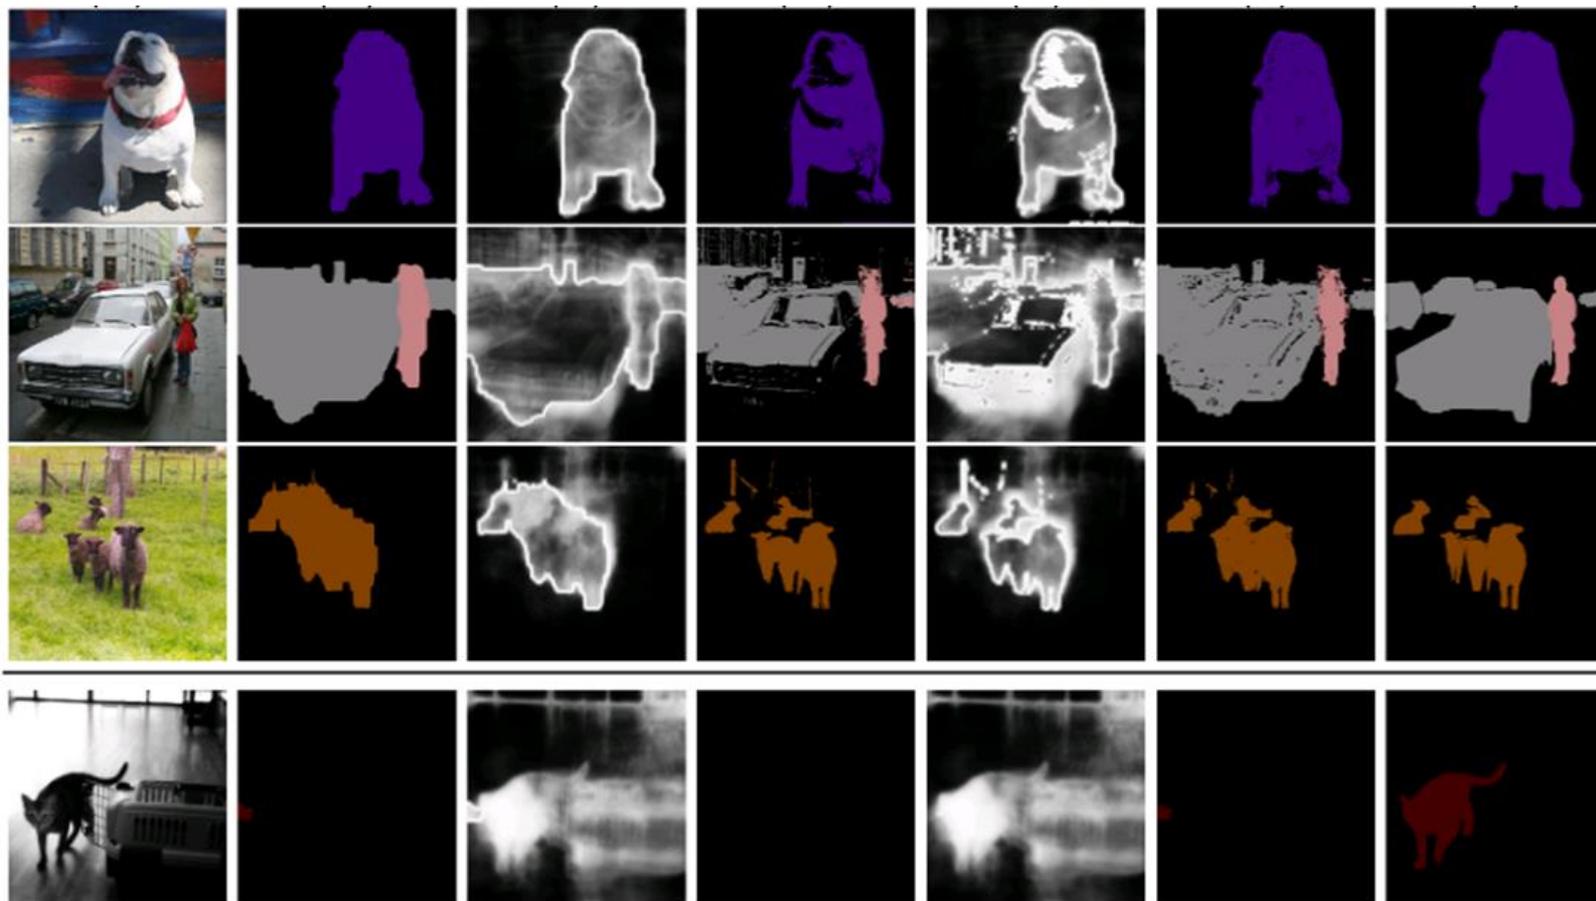
領域分割モデルの繰り返し学習 [PAMI 2016]

PSA, PSA+CRFの変化領域の推論と領域の統合①

- Pixel-level Semantic Affinity(PSA) [CVPR 2018]
 - 最高精度の領域分割手法
- PSAとPSAにCRFを適用した結果に提案手法を適用



適用結果



入力

Knowledge

変化の
推論結果
(K)

Advise

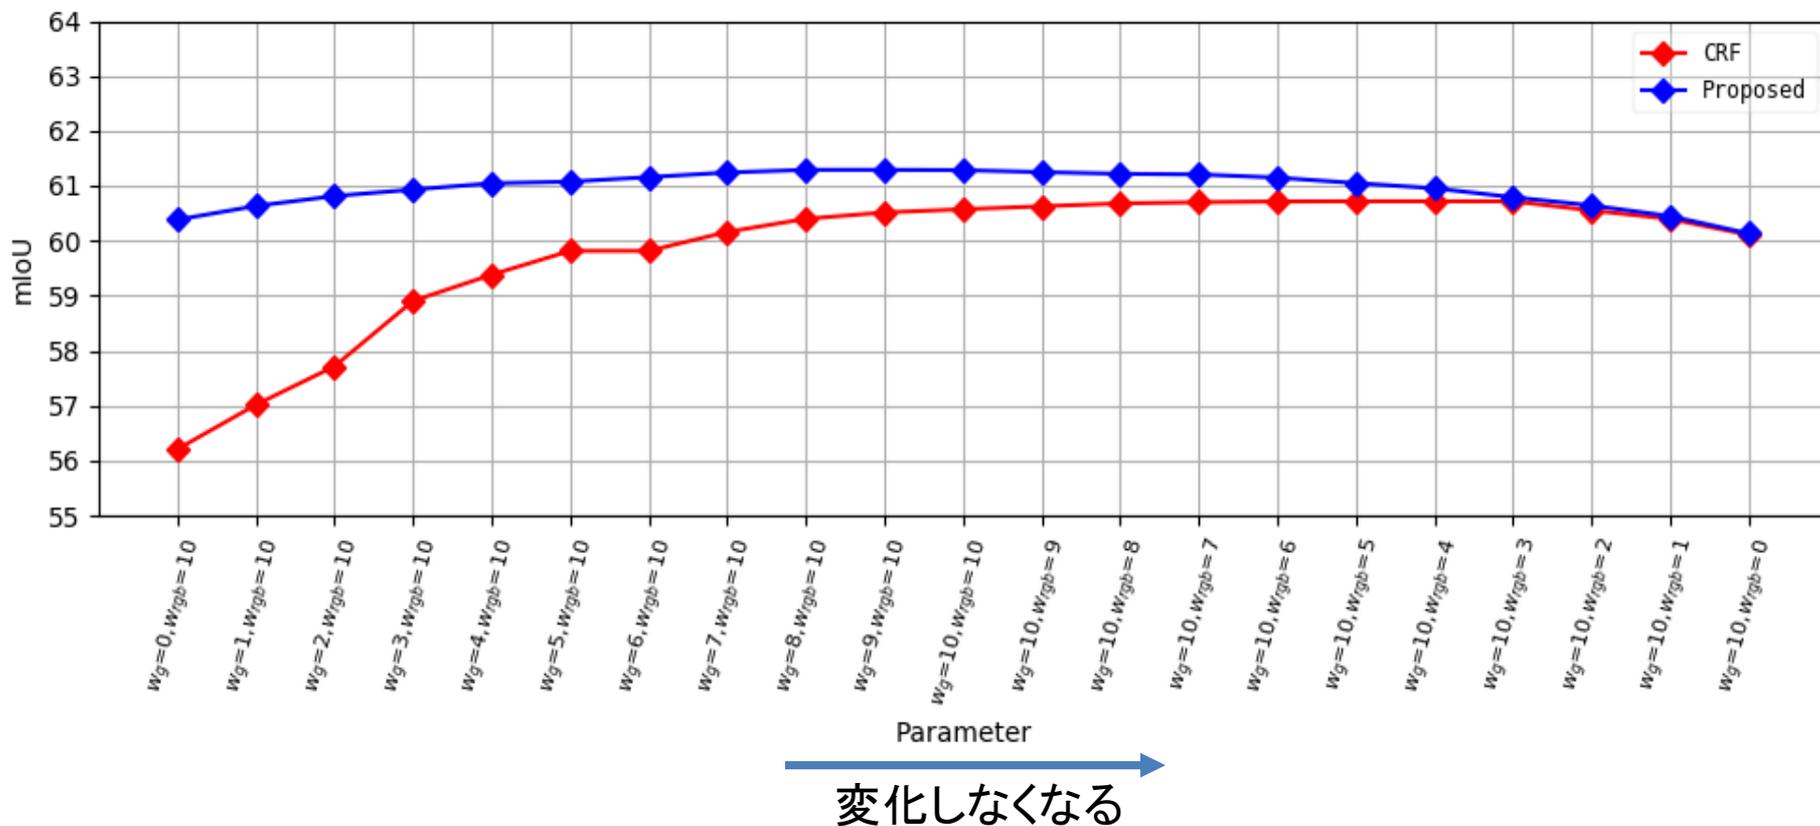
変化の
推論結果
(A)

統合結果

正解領域

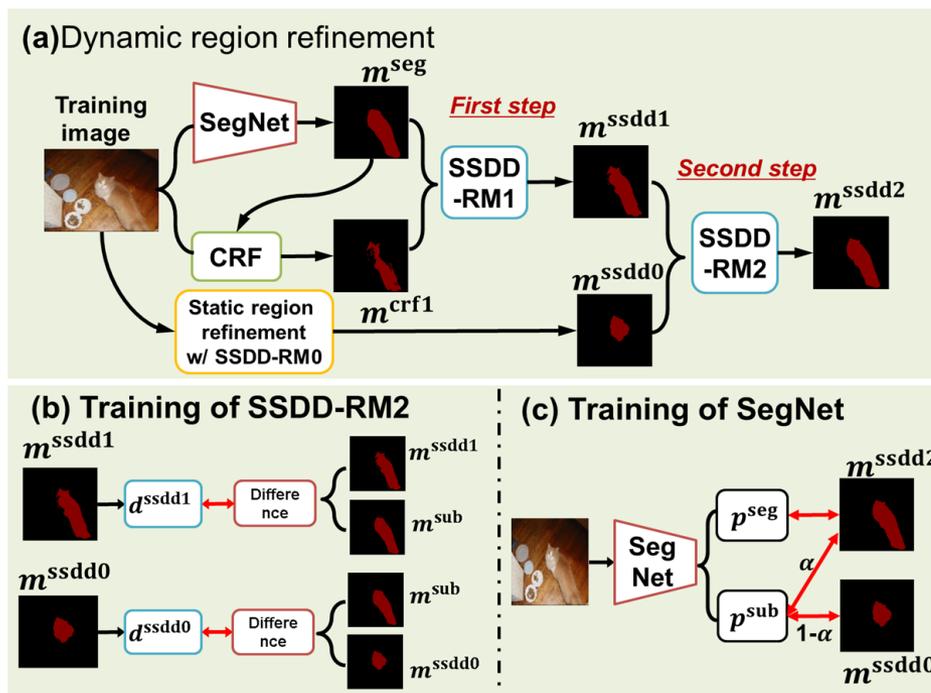
実験結果

- CRFのハイパーパラメータの変化についてのCRFの精度と提案手法の適用結果の精度



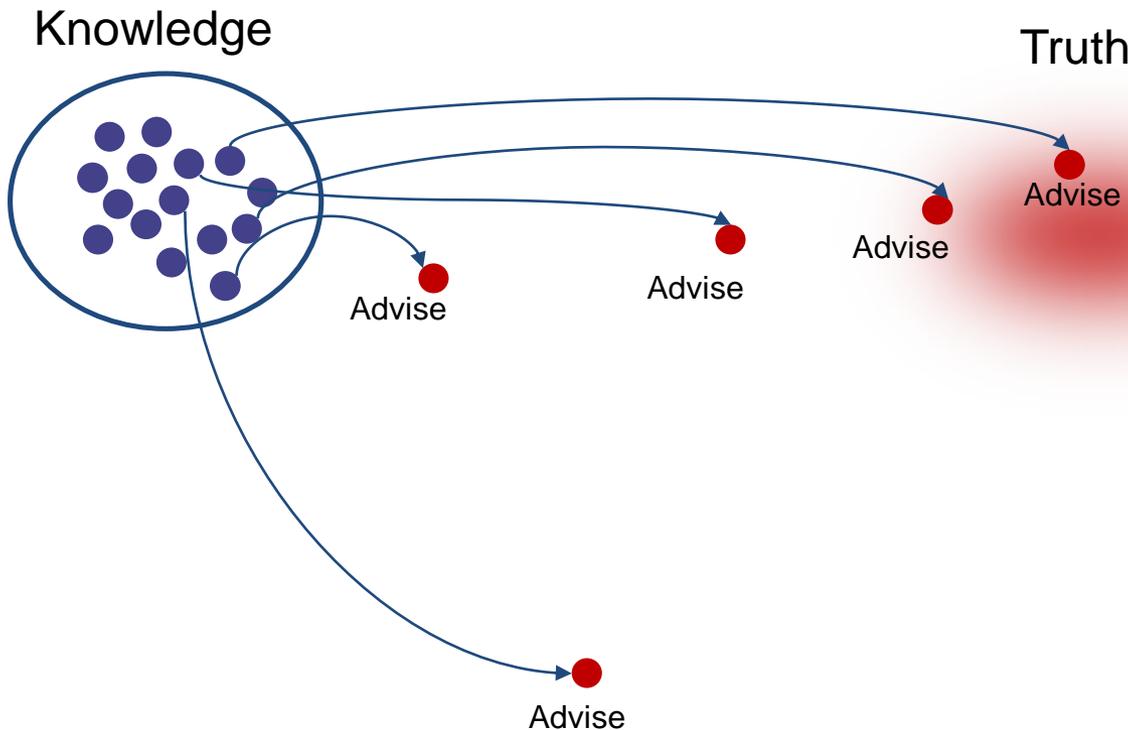
領域分割の学習への組み込み②

- 領域分割モデルを動的に学習
 - 教師情報と領域分割モデルの出力の変化を推論
 - 統合した領域を用いて学習



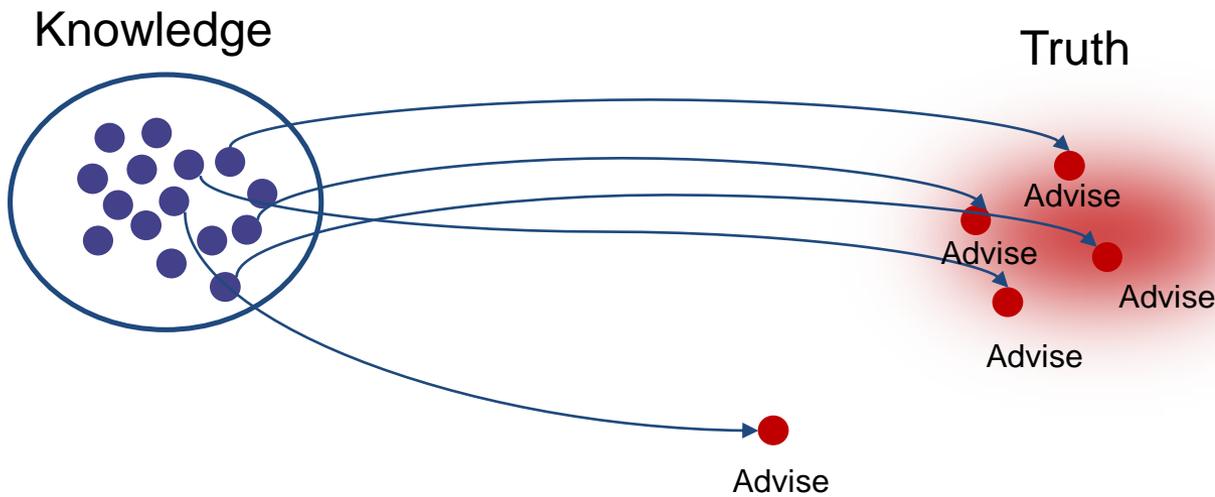
領域分割の学習への組み込み

- アドバイス部分を学習することにつながる
 – よりよいアドバイスを生成



領域分割の学習への組み込み

- アドバイス部分を学習することにつながる
 – よりよいアドバイスを生成



他の領域分割手法との比較

自分の三年前の研究 20%精度up! State-of-the-artを達成

Methods	Val set	Test set
FCN-MIL(ICLR2015)	25.7	24.9
CCNN(ICCV2015)	35.3	35.6
EM-Adapt(ICCV2015)	38.2	39.6
DCSM(ECCV2016)	44.1	45.1
BFBP(ECCV2016)	46.6	48.0
SEC (ECCV2016)	50.7	51.7
TPL(ICCV2016)	53.1	53.8
CBTS(CVPR2017)	52.8	53.7
PSA(CVPR2018)	61.7	63.7
提案手法	64.9	65.5

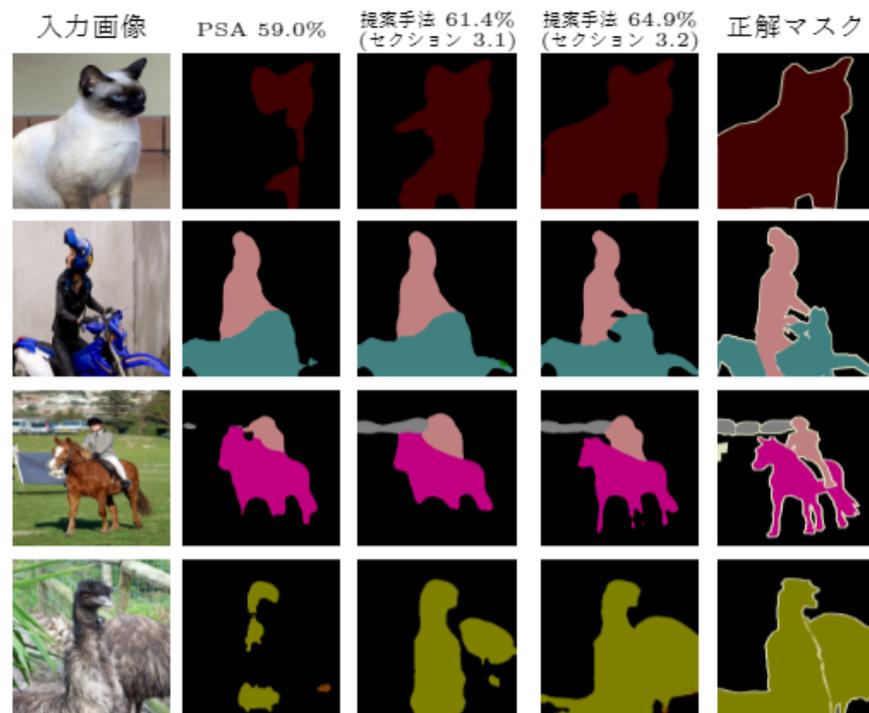


図 7 Pascal VOC 2012 における領域分割結果.

各クラスについての精度の分析

Results on PASCAL VOC 2012 val set.

Meth ods	BG	Aero	Bike	Bird	Boat	Bottl e	Bus	Car	Cat	chair	Cow
PSA[1]	88.2	68.2	30.6	81.1	49.6	61.0	77.8	66.1	75.1	29.0	66.0
SSDD	89.0	62.5	28.9	83.7	52.9	59.5	77.6	73.7	87.0	34.0	83.7
<i>Gain</i>	<i>+0.8</i>	<i>-5.7</i>	<i>-1.7</i>	<i>+2.6</i>	<i>+3.3</i>	<i>-1.5</i>	<i>-0.2</i>	<i>+7.6</i>	<i>+11.9</i>	<i>+5.0</i>	<i>+17.7</i>
	Table	Dog	Horse	Motor	Person	Plant	Sheep	Sofa	Train	Tv	mIoU
PSA[1]	40.2	80.4	62.0	70.4	73.7	42.5	70.7	42.6	68.1	51.6	61.7
SSDD	47.6	84.1	77.0	73.9	69.6	29.8	84.0	43.2	68.0	53.4	64.9
<i>Gain</i>	<i>+7.4</i>	<i>+3.7</i>	<i>+15.0</i>	<i>+3.5</i>	<i>-4.1</i>	<i>-12.7</i>	<i>+13.3</i>	<i>+0.6</i>	<i>-0.1</i>	<i>+1.8</i>	<i>+3.2</i>

まとめ

- 自己教師あり学習による変化の推論を活用した弱教師あり領域分割手法を提案
- PASCAL VOC 2012において最高精度を達成
- 今後の課題
 - CRF、再学習以外の手法についての適用

ICCV 2019 **accept** !!



ICCV 2019
 Seoul, Korea