

## 理研AIP-NEC連携センター設立の狙い

AIの社会実装を加速させ、安全・安心で効率的な社会を実現



### 実現に向けた課題



### 課題解決に向けた“基盤技術”を開発

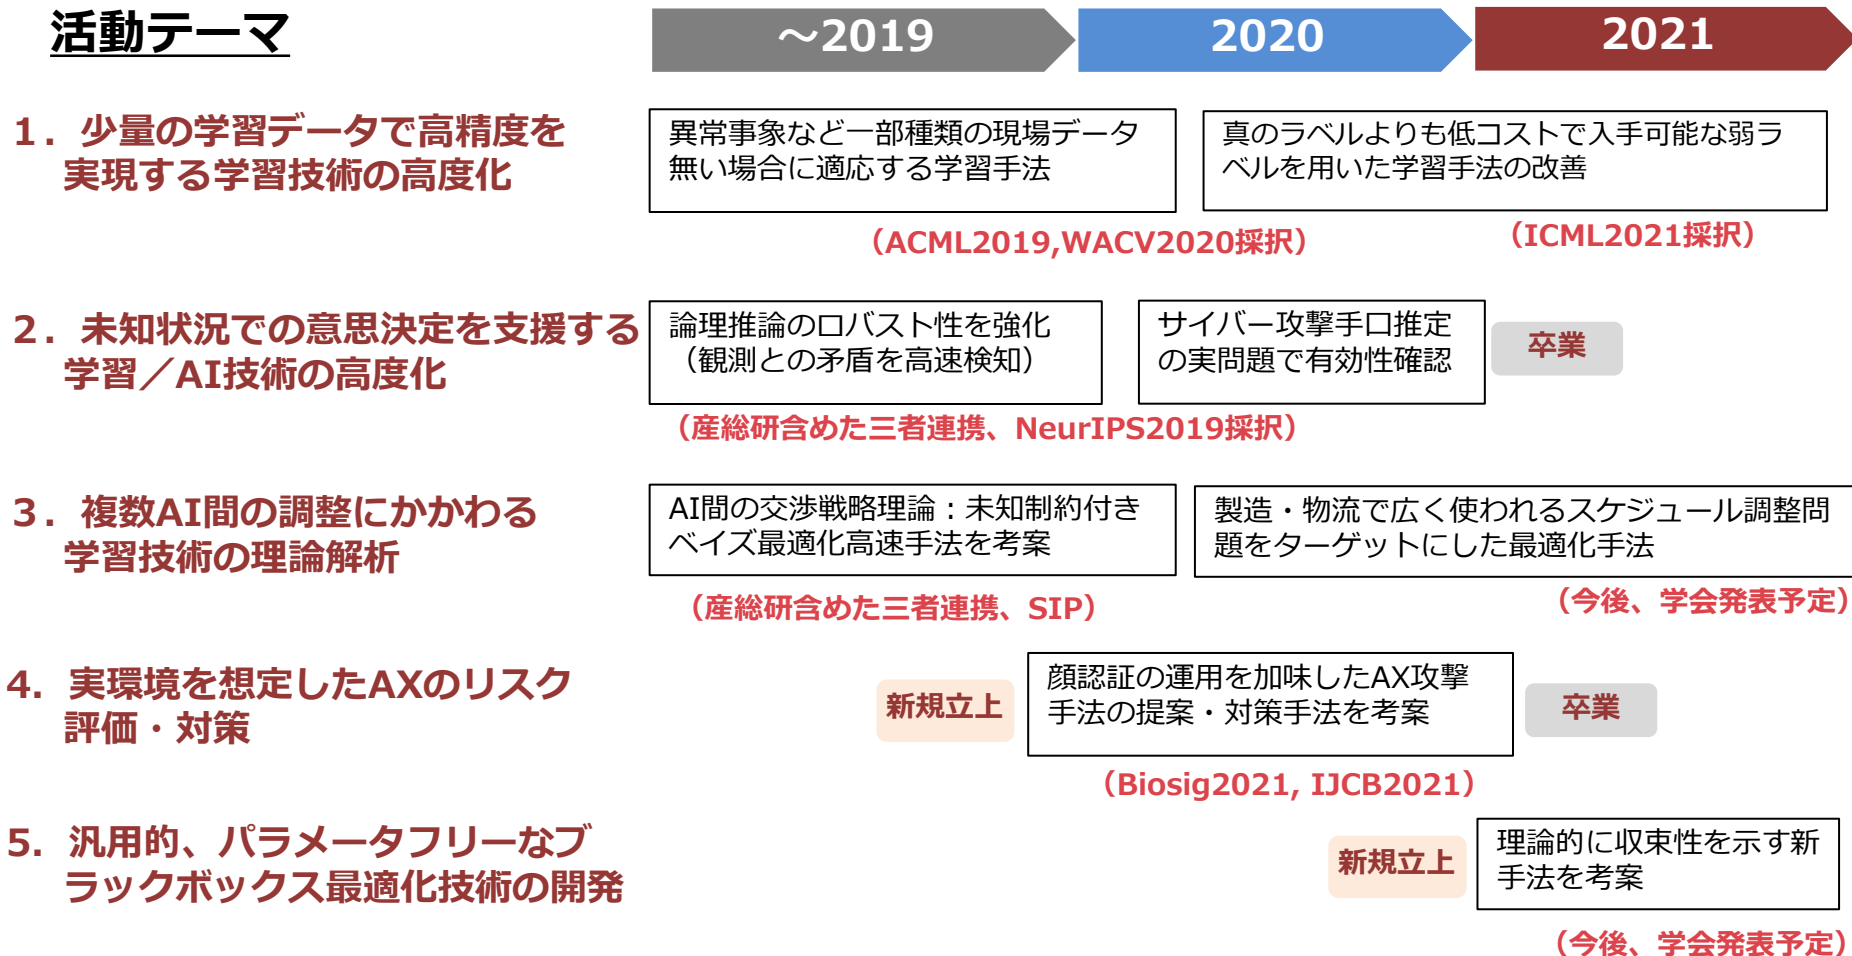
- AIの社会実装加速に大きな壁となる大量学習データの不要化 → 活動テーマ1、2
- AI活用による自動化が進み、複数AI間での競合がある中での最適化 → 活動テーマ3
- 社会実装の加速に向けたAIの社会受容性の考慮 → 活動テーマ4
- AIのチューニング（ハイパーパラメータ最適化）手間削減 → 活動テーマ5

# 活動 5 テーマと活動期間・内容サマリ



- 3テーマで活動を開始し、社会動向やAIの技術進展動向に応じてテーマを新設・変更しながら成果を創出

## 活動テーマ



# テーマ1 少量の学習データで高精度を実現する学習技術の高度化



- 産業応用上重要となる学習データ獲得困難な事例（例：異常検知、エキスパートの代替、新規事象への迅速対応、特殊センサの認識）に対応
- ターゲットとしては画像認識のアプリケーションを想定するが、本連携活動では、特定アプリに特化しない、汎用的な機械学習技術の構築を目指す
  
- 3タイプの学習データ獲得困難事例
  - ①現場の多様なニーズ（新たな事象）への対応が必要な場合
    - 毎回、大量の学習データを作成しては、時間的・人的コストがかかりすぎる
    - ニーズへの迅速な対応ができない
  - ②データの発生頻度が少ない場合
    - 異常データなどは、データ収集に時間がかかる  
例) 1日1件発生しても、5,000件集まるまでに13年以上かかる
  - ③正解付けコストが非常に高い場合
    - 医療データなどは、専門家でないと正解がつけられない

# テーマ1：成果概要



## 活動の振り返り

- 深層学習の実用化に向けた問題を設定して、それぞれ基盤技術を開発

2017                  2018                  2019                  2020                  2021

① 少ないデータで  
別ドメインに適応

ゼロショットドメイン適応

★ACML2019採択

部分的ゼロショットドメイン適応

★WACV2020採択

② 異常などの希少事象  
を高精度に認識

適応的AUC最大化学習

③ 低コストで入手可能な  
曖昧なラベルで学習

弱ラベル学習の高精度化

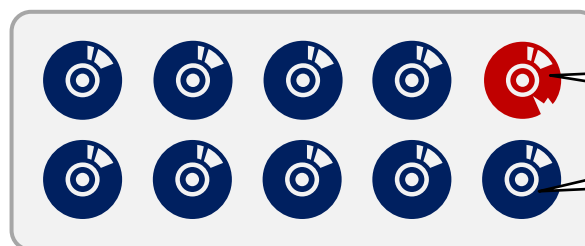
★ICML2021採択

# テーマ1：適応的AUC最大化学習

**背景：異常などの希少事象のデータは、正常データに比べて非常に少ない**

⇒ クラス間でデータ数が大きく異なる状況（クラス不均衡）

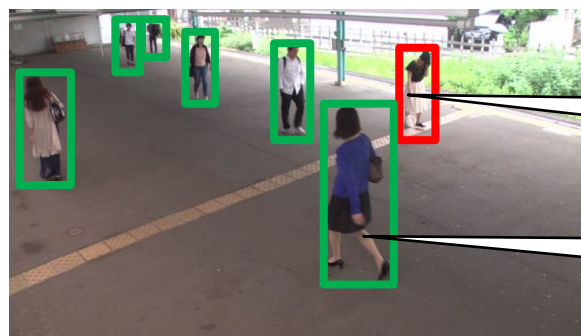
工業製品の検査検品



不良品（異常）のデータは**非常に少ない**

正常な製品のデータは**非常に多い**

監視カメラ映像からの  
ふらつき歩行検知



ふらつき歩行（異常）のデータは**非常に少ない**

通常歩行（正常）のデータは**非常に多い**

**従来の「誤り最小化」に基づく学習では、識別モデルの学習が困難**

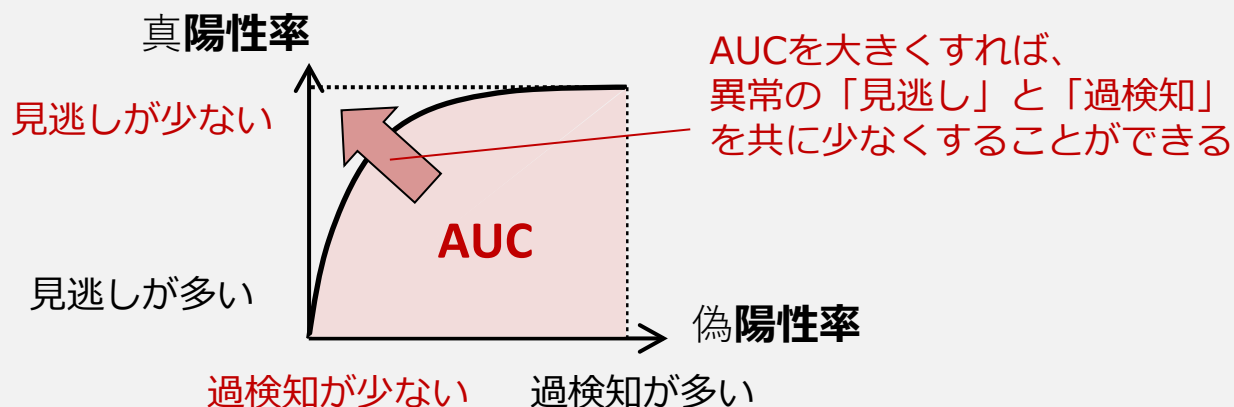
（少ない異常データを無視して、全データを正常と判定すれば高精度を達成できるため）

# テーマ1：適応的AUC最大化学習 (提案手法)


## ■ 学習サンプル選別に基づく、AUC最大化学習

- ① AUC最大化により、少ない異常クラスを無視せずに学習
- ② 識別が難しいサンプルのみを選別することで、効率よく学習

### ① AUC最大化



### ② 識別困難なサンプルで学習

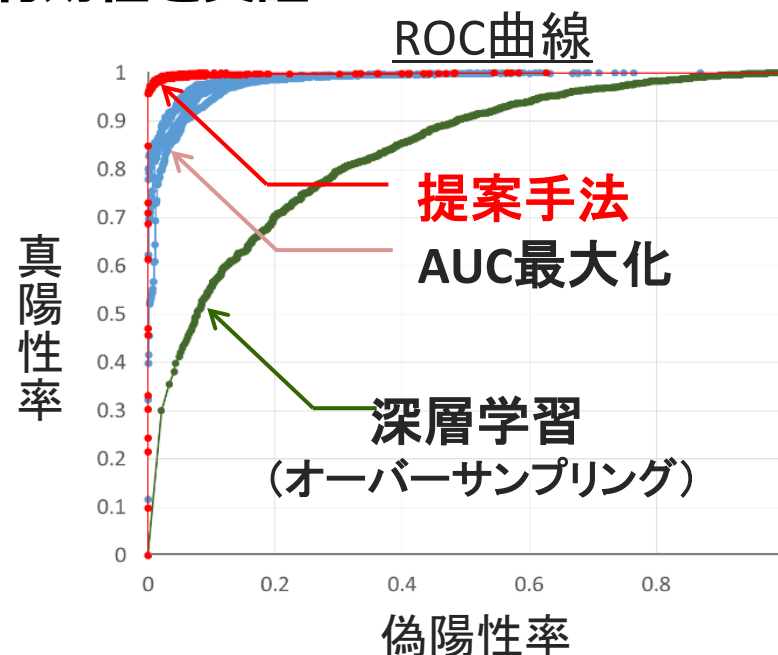


# テーマ1：適応的AUC最大化学習 (提案手法)

## ■ 不均衡なデータに対して、提案手法の有効性を実証

CIFAR-10 (物体認識)  
1クラス500枚を異常とし、残りの  
全クラス4500枚を正常として学習


	見逃し率	過検知率
通常学習	0.5%	93%
AUC最大化	0.5%	27%
提案手法	0.5%	3%



## ■ 工業部品の異常検知など、実データでも有効性を確認

### 外観検査向けのNECの機械学習エンジン「RAPID」に搭載

例) 屋外インフラ検査



例) 精密素材の検品



※画像はgettyimagesの素材画像であり、あくまでイメージです。

# テーマ1：弱ラベル学習の高精度化



**背景：真のラベルよりも情報量が少ないが、低コストで入手可能な弱ラベルから学習できれば、学習データ作成のコストを大幅削減可能**


一般的に知られている弱ラベル学習の例

## 曖昧ラベル学習



曖昧なラベルで学習

## PU学習



一部の正例のラベルのみで学習

## 補ラベル学習



「～ではない」というラベルで学習

⇒ 物体検知への新クラス追加、部品の検査検品などに応用可能

## 弱ラベル学習の課題

- 弱ラベルを用いて、真のラベルに対する損失を再構成すると、**訓練損失が下に非有界であるために過学習が生じ、精度が大幅に低下**



# テーマ1：弱ラベル学習の高精度化 (理論的な成果)



## アプローチ

- 1)弱ラベル学習を成功させる「良い」損失関数の条件を設定し、  
2)それを満たすような損失関数を設計することで、高精度な学習を実現

## 「良さ」の基準

- ① **Properであること** (クラスの事後確率を正しく推定できること)
  - ・ 弱ラベル学習を実現するための十分条件
- ② **下に有界であること**
  - ・ 深層学習のような複雑なモデルで過学習を軽減するために必要

## 上記①②を満たす損失関数の十分条件を理論導出

$F(\vec{v})$  を凸関数としたとき、 $F(\vec{v}) - \max_y (R\vec{v})_y$  が下に有界ならば、  
次の形をした損失関数は良い性質①②を満たす：

$$l(\vec{p}, y) = -(R^T \nabla F^*(\vec{p}))_y + F(\nabla F^*(\vec{p}))$$

ただし、 $\vec{p}$  はクラス事後確率分布のベクトル表示、 $F^*(\vec{p})$  は  $F(\vec{v})$  の共役関数。

# テーマ1：弱ラベル学習の高精度化 (実験結果)



導出した条件を満たすように損失関数を補正する正則化手法  
**Generalized Logit Squeezing (gLS)**を考案し、**実験的に有効性を確認**

●gLSは弱ラベル学習だけではなく、教師あり学習にも適用可能

弱ラベル学習

	CIFAR-10
従来手法① (BC)	29.6%
従来手法② (BC+GA)	36.9%
<b>提案手法 (BC+gLS)</b>	<b>50.5%</b>

BC: Backward Correction  
GA: Gradient Ascent

教師あり学習

	CIFAR-100	CUB-200	商品認識 (実データ)
正則化なし	72.3%	46.6%	84.1%
重み減衰	78.8%	63.2%	85.2%
<b>提案手法 (gLS)</b>	<b>79.3% (※)</b>	<b>64.2% (※)</b>	<b>91.2%</b>

(※) 重み減衰 + gLS

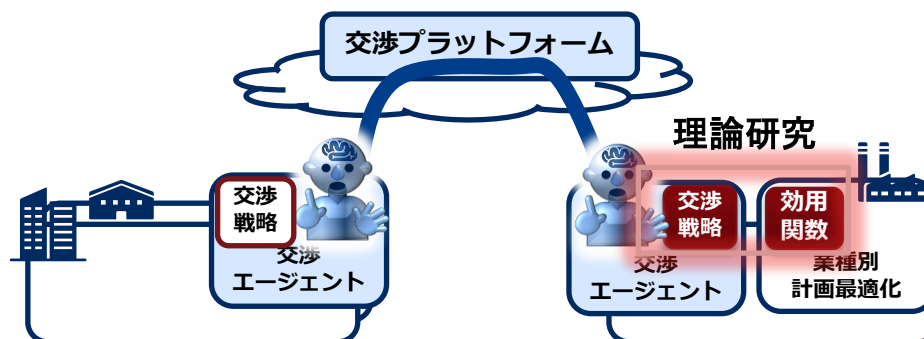
⇒ **大幅に精度向上**

⇒ **教師あり学習でも精度向上**

**弱ラベル学習から一般の教師あり学習まで幅広い応用場面で活用**

# テーマ3：複数AI間の調整にかかわる 学習技術の理論解析

- AIが普及した社会において、個別企業内の最適化だけでなく、**AI間での交渉・連携を通して、社会全体を最適化**
- **事業上利用可能**であり、**汎用的に展開可能**な技術の理論研究を進める
- 活動振り返り・成果概要



FY2018-19

**様々な事業に適用可能な**交渉戦略のための、相互情報量に基づく未知制約付きベイズ最適化

↓  
具体的な事業で利用するために、ターゲットを限定

FY2020-21

**製造・物流で広く使われる**スケジュール調整をターゲット設定  
交渉の良さを測る効用関数のためのオンライン意思決定

# テーマ3：製造・物流で典型的な商取引パターン



## 2020年度課題

### 製造に多い



#### オンライン複数ナップザック問題

・到来した商談の良さを判定するために、自社の資源、使用日を加味し、商談の受理／拒否を判断する。ユーザとのシームレスな対話のために、高速な効用値計算も必要。

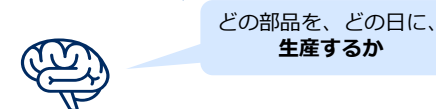


#### 課題例

10/4までに作って



	10/1	10/2	10/3
ハンドル	10	30	10
シート	5	9	
タイヤ	20	3	10



## 2021年度課題

### 物流に多い




#### オンラインレベニュー最大化問題

・需要を**未知**とし、在庫、終了時間（消費期限）が決まっている商品に対して逐次的に価格提示を行って、需要を予測し、利益を最大化する



#### 課題例

未知の需要



出発日	10/1
空席	10

# テーマ3：製造をターゲットにした最適化



- 製造に多い、不定期に複数到来する（ $\times$ 切も異なる）顧客要望に対応すべく、オンライン複数ナップザック問題として定式化・解法を考案

## 2020年度課題

### 製造に多い



#### オンライン複数ナップザック問題

・到来した商談の良さを判定するために、自社の資源、使用日を加味し、商談の受理／拒否を判断する。ユーザとのシームレスな対話のために、高速な効用値計算も必要。



#### 課題例

10/4までに作って

30日前

	10/1	10/2	10/3
ハンドル	10	30	10
シート	5	20	9
タイヤ	20	3	10




どの部品を、どの日に、生産するか

## 2020年度成果

- 効用関数を確率的ナップザック問題の拡張として定式化
  - ・到来する要望・種類が確率的・対応できる容量が可変な場合に対応
- 最適化手法の算出法、高速な近似解導出手法を考案
- ルールベース手法（空いている便に順に詰め込む）と比較し開発手法の優位性を確認

ルールベース（青）／開発手法（赤）  
効用関数値が大きかったものの割合




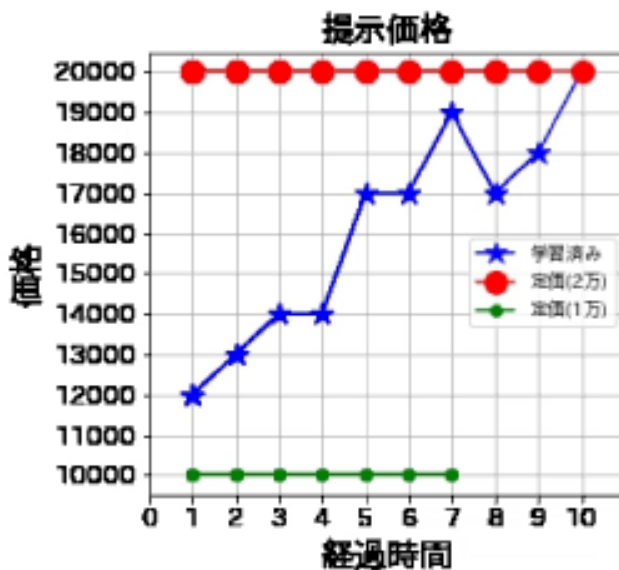

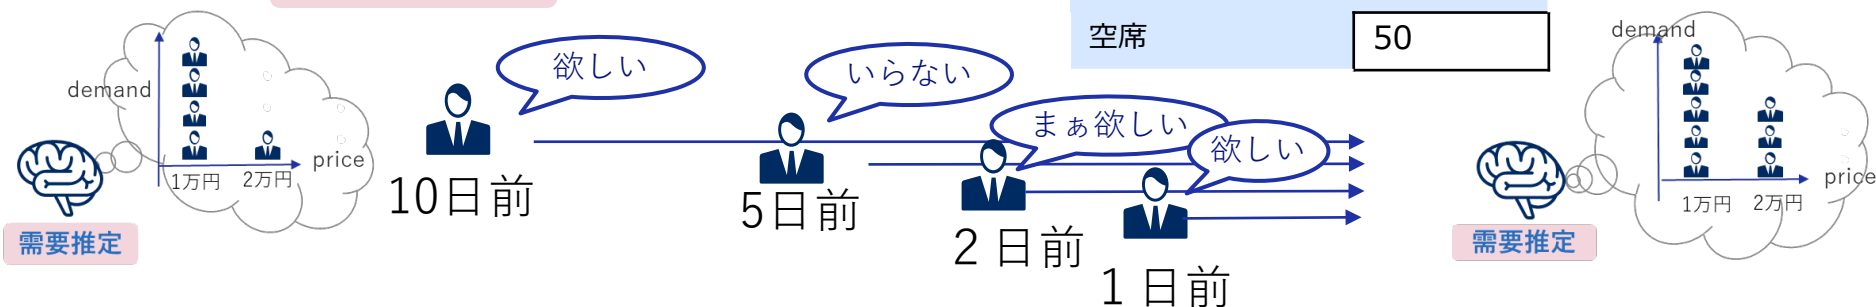
# テーマ3：物流をターゲットにした最適化



- 物流に多い需要が未知の場合に対応すべく、動的需要下でのオンラインレベニュー最大化問題として定式化・解法を考案

## 未知の需要

出発日	10/1
空席	50



# テーマ5：汎用的、パラメータフリーなブラックボックス最適化技術の開発




## ■ 様々な実問題で必要とされるブラックボックス最適化の高度化

- **ブラックボックス最適化：具体形が未知（ブラックボックス）な目的関数に対する最適化問題**

関数 $f(x)$ の関数形は未知

$x$ の値を決めれば $f(x)$ は観測可能

できるだけ少ない観測回数で  $f(x)$ を最小化する最適解 $x$ に近い解を見出したい



- **機械学習におけるハイパーパラメータ最適化・モデル選択、実験計画、分子構造解析、創薬、推薦システム、マーケティング自動化など多くのアプリケーションが存在**


## ■ 2021年度テーマを立ち上げ、活動を開始

## ■ Zeroth-order optimizationと呼ばれるブラックボックス最適化を解く1つの枠組みを拡張した手法：single loop Gaussian homotopy (SLGH) 法を考案



- 様々な問題クラスに対し、理論的に収束性を証明
- 「ブラックボックス分類モデルに対する敵対的攻撃」タスクで有効性を確認

# テーマ5：活動成果概要


## ■ 提案手法の考え方




元問題: 非凸、非滑らか  
そのまま解くのは難しい



スムージングにより  
やさしい問題に変換



解の探索と同時にスムージングを弱める  
→ 徐々に元問題の解に収束



## ■ 有効性評価

「ブラックボックス分類モデルに対する敵対的攻撃」タスクで有効性を確認



「自動車」と判定

+  $\epsilon$



↑このノイズを発見したい

=



「飛行機」と誤判定

Table 2. Performance of a per-image attack over 100 images of CIFAR-10 under  $T = 10000$  iterations. “Succ. rate” indicates the ratio of success attack, “Avg. iters to 1st succ.” is the average number of iterations to reach the first successful attack, “Avg.  $L_2$  (succ.)” is the average of  $L_2$  distortion taken among successful attacks, and “Avg. total loss” is the average of total loss  $f(x)$  over 100 samples.

	Methods	Succ. rate	Avg. iters to 1st succ.	Avg. $L_2$ (succ.)	Avg. total loss
SGD algo.	ZOSGD	88%	<b>835</b>	0.076	27.70
	ZOAdaMM	85%	3335	<b>0.050</b>	19.15
GH algo.	ZOGradOpt	65%	6789	0.249	39.05
	ZOSLGH <sub>r</sub> ( $\gamma = 0.999$ )	<b>93%</b>	4971	0.248	<b>14.28</b>
	ZOSLGH <sub>d</sub> ( $\gamma = 0.999$ )	<b>93%</b>	4365	0.188	<b>14.23</b>

提案手法