

# 卒業論文発表

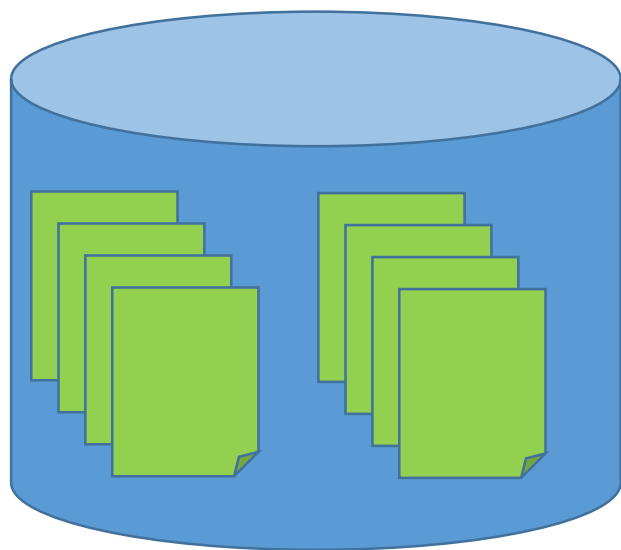
## Collaborative Mean Attraction法による 画像分類の特性調査

平成29年2月16日

67130150 荻原弘樹  
指導教員 椋木雅之

# 研究の背景

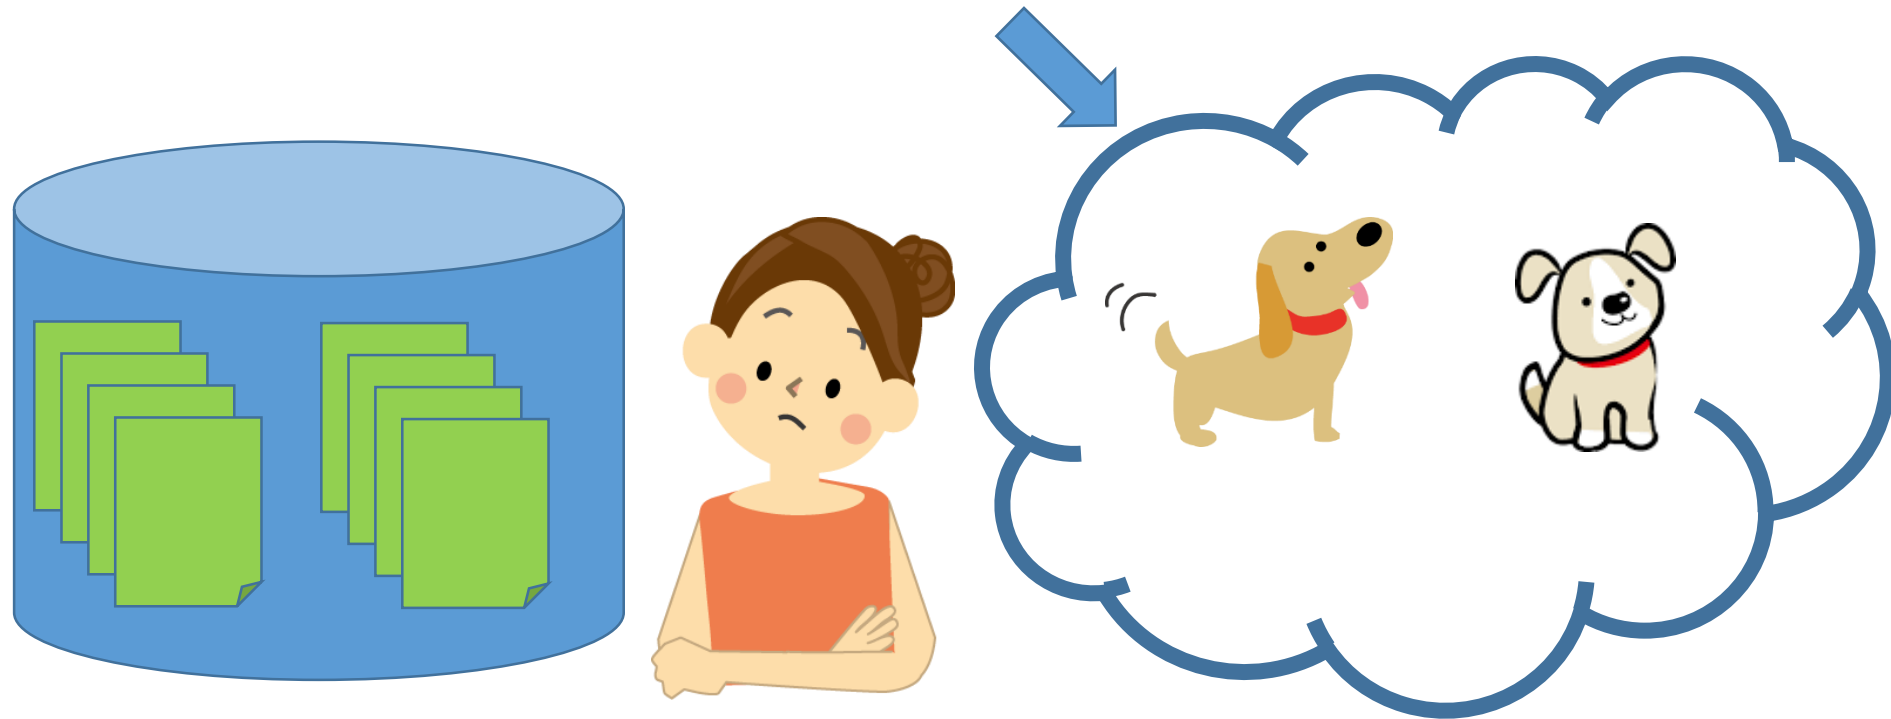
携帯端末の普及により個人が多数の画像を所有するようになってきた



個人の観点に基づいて  
自動分類したいという  
要望が生じている

# 個人の観点に基づいて自動分類する場合

少数の訓練用画像をもとにカテゴリ分類を行いたい



少数の訓練用画像で自動分類ができればコストが低く有用である

# 少数訓練用画像で分類を行う類似の問題

## カメラ間人物照合

この問題に対して Collaborative Mean Attraction (CMA) 法<sup>[1]</sup>が提案された

カメラ間人物照合

対象: 人物像



本論文 (画像分類)

対象: 一般物体

カテゴリ間の多様性:  
見えの変化



カテゴリ間の多様性:  
対象物体自体

画像分類とカメラ間人物照合では性質が異なる

# 研究の目的

CMA法が、一般物体識別の一種である画像分類でも有効であるか調査

- CMA法と他の手法を公開データセットに適用して画像分類を行い結果を比較
- パラメータの調整を行い、CMA法の特性を調査

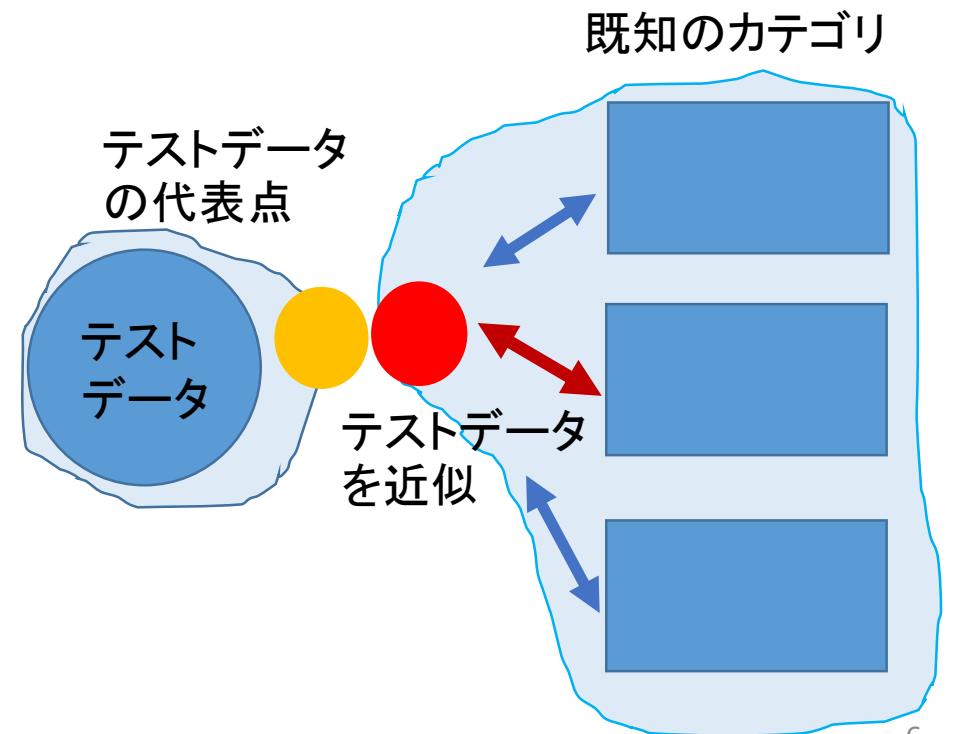
# CMA法の大まかな流れ

## ◆最適化段階

テストデータの代表点を既知のカテゴリ全ての訓練用画像で近似する

## ◆分類段階

この近似に最も貢献したカテゴリを選択する



# 最適化段階

$$f(\boldsymbol{\alpha}, \boldsymbol{\beta}) = \|\mathbf{Q}\boldsymbol{\alpha} - \mathbf{X}\boldsymbol{\beta}\|^2 + \lambda_1 \left\| \boldsymbol{\alpha} - \frac{1_{N_q}}{N_q} \right\|^2 + \lambda_2 \left\| \boldsymbol{\beta} - \frac{1_{N_x}}{N_x} \right\|^2$$

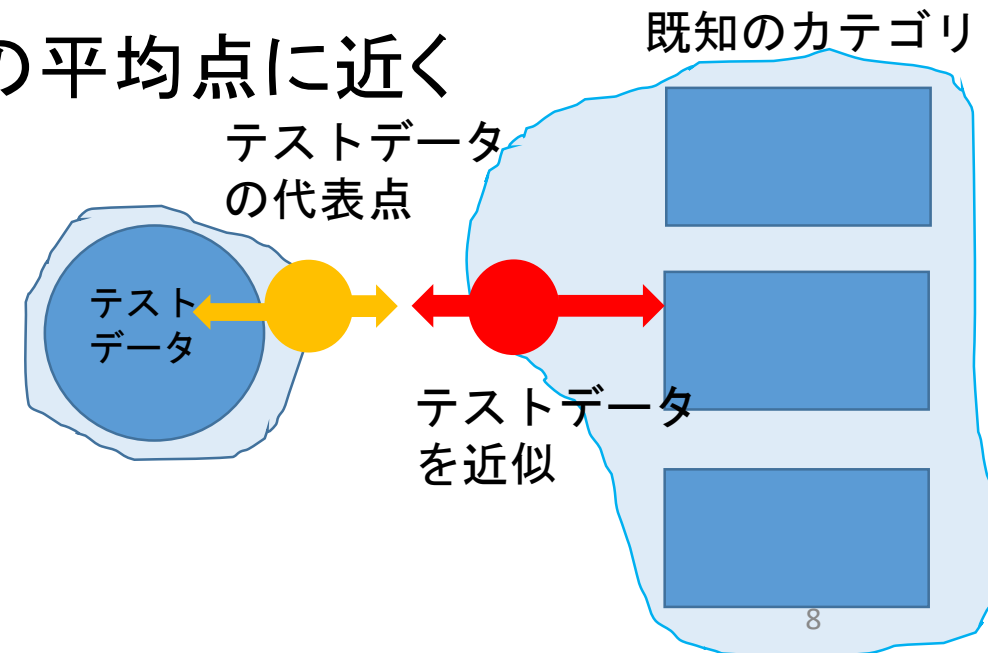
- $\mathbf{Q} \in R^{m \times N_q}$  : テスト画像の特徴ベクトルを並べた行列
- $\mathbf{X}_i \in R^{m \times N_x}$  : 訓練用画像の特徴ベクトルを並べた行列
- $\mathbf{X} := (\mathbf{X}_1 \mathbf{X}_2 \dots \mathbf{X}_n) \in R^{m \times N_x}$  :  $n$  はカテゴリ数
- $1_N$  : 各要素が1の $N$ 次元ベクトル
- $\|\cdot\|$  : ベクトルの $L_2$ ノルム

$f(\boldsymbol{\alpha}, \boldsymbol{\beta})$ を最小化する係数ベクトル $\boldsymbol{\alpha}, \boldsymbol{\beta}$ を求める

# 最適化段階

$$f(\alpha, \beta) = \|Q\alpha - X\beta\|^2 + \lambda_1 \left\| \alpha - \frac{1}{N_q} \right\|^2 + \lambda_2 \left\| \beta - \frac{1}{N_x} \right\|^2$$

- 第1項は、代表点 $Q\alpha$ と近似点 $X\beta$ を近くするための項である
- 第2項と、第3項は代表点と近似点それぞれの平均点に近くするための正則化項である
- $\lambda_1, \lambda_2$ は正則化項の重みパラメータである





# 分類段階

$$d^i = (\|Q\|_* + \|X_i\|_*) \cdot \|Q\alpha - X_i\beta_i\|^2 \|\beta\| / \|\beta_i\|$$

- 最適化段階で求めた、 $\alpha, \beta$ を用いる
- 近似点の係数 $\beta$ の各次元が、訓練用画像に対応している
- カテゴリ $i$ の訓練用画像の係数を $\beta_i$ として $\beta^T = (\beta_1^T, \dots, \beta_n^T)$ と分解できる

各カテゴリについて上式を求め、最小となるカテゴリに分類する

# 分類段階

$$d^i = (\|Q\|_* + \|X_i\|_*) \cdot \|Q\alpha - X_i\beta_i\|^2 \|\beta\| / \|\beta_i\|$$

- $\|Q\alpha - X_i\beta_i\|^2$ が小さい程、カテゴリ*i*のみで代表点の近似がよく行えている
- $\|\beta\|/\|\beta_i\|$ が小さい程、カテゴリ*i*の係数がカテゴリ全体の中で大きな役割を果たしている
- $\|\cdot\|_*$ は行列の核ノルム（行列の特異値の和）
  - データのばらつきが大きい程、この値は大きくなる。
  - カテゴリ間のばらつきの違いを考慮するための重み付けに利用している

# 画像分類

# 使用したデータセット: Caltech101, Caltech256

- Caltechデータセットはカリフォルニア工科大学で作成された公開データセット
- Caltech101はCaltech256に比べ比較的分類が容易で小規模で扱いやすい

	Caltech101	Caltech256
画像総数	9144枚	30607枚
カテゴリ数	101カテゴリ	257カテゴリ
1カテゴリの 最小画像数	31枚	80枚
使用カテゴリ	100カテゴリ	257カテゴリ




# 比較手法

CMA法を3つの従来手法と比較を行う

◆ SVM (Support Vector Machine)

◆ CPD (Center Point Distance): 重心間距離

◆ MPD (Minimum Point Distance): 最近傍距離



# 実験

## 単独テストデータ

- テストデータ: 1枚の画像
- 訓練用画像の枚数  $k$   
( $k = 1, 2, 4, 8, 16, 30$ )

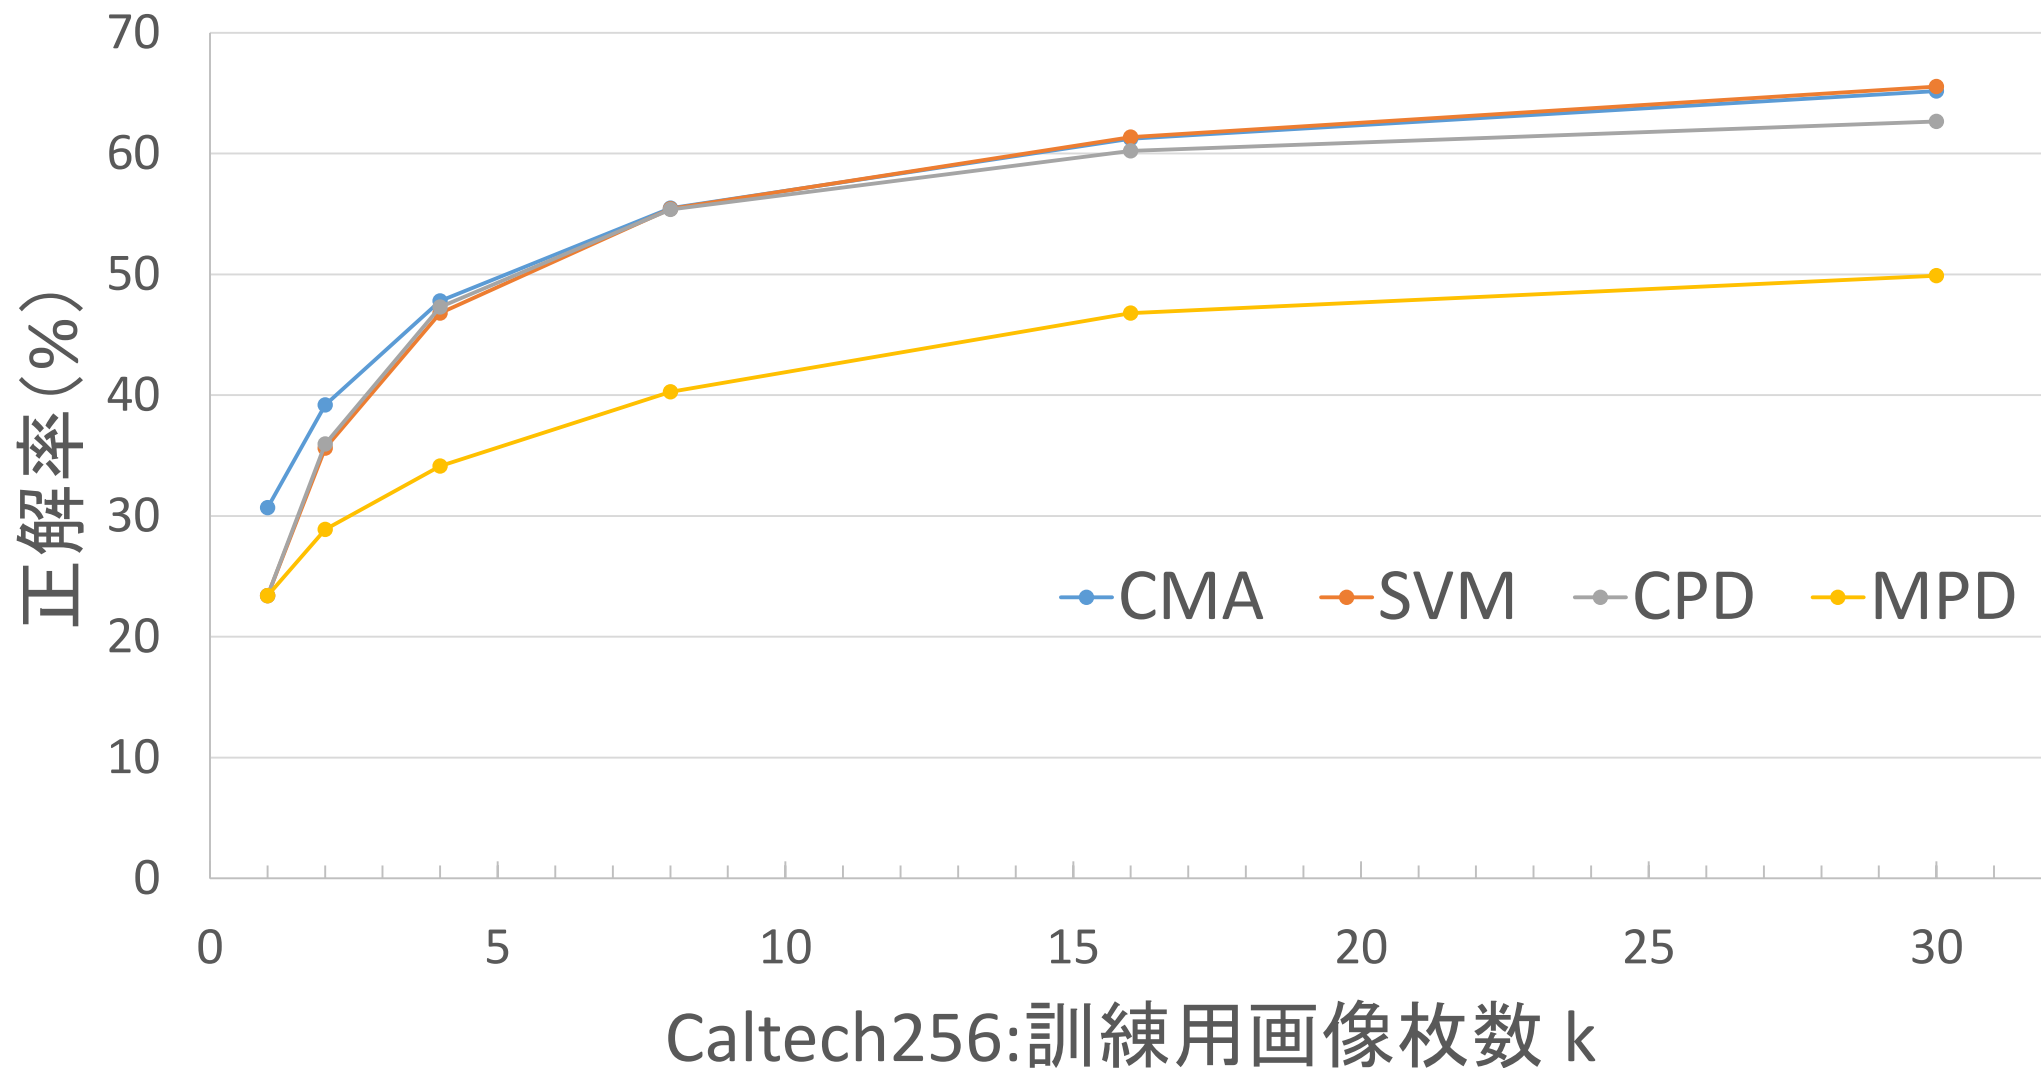
## 複数テストデータ

- テストデータ:  $\ell$ 枚の画像  
( $\ell = 2, 4, 8, 16, 30$ )
- 訓練用画像の枚数  $k$   
( $k = 1, 2, 4, 8, 16, 30$ )


正則化項の重み  $\lambda_1 = 16.0, \lambda_2 = 16.0$

分類の正解率がどのように変化するか調査

# 単独テストデータでの実験結果 (Caltech256)



# 単独テストデータでの実験結果 (Caltech256)



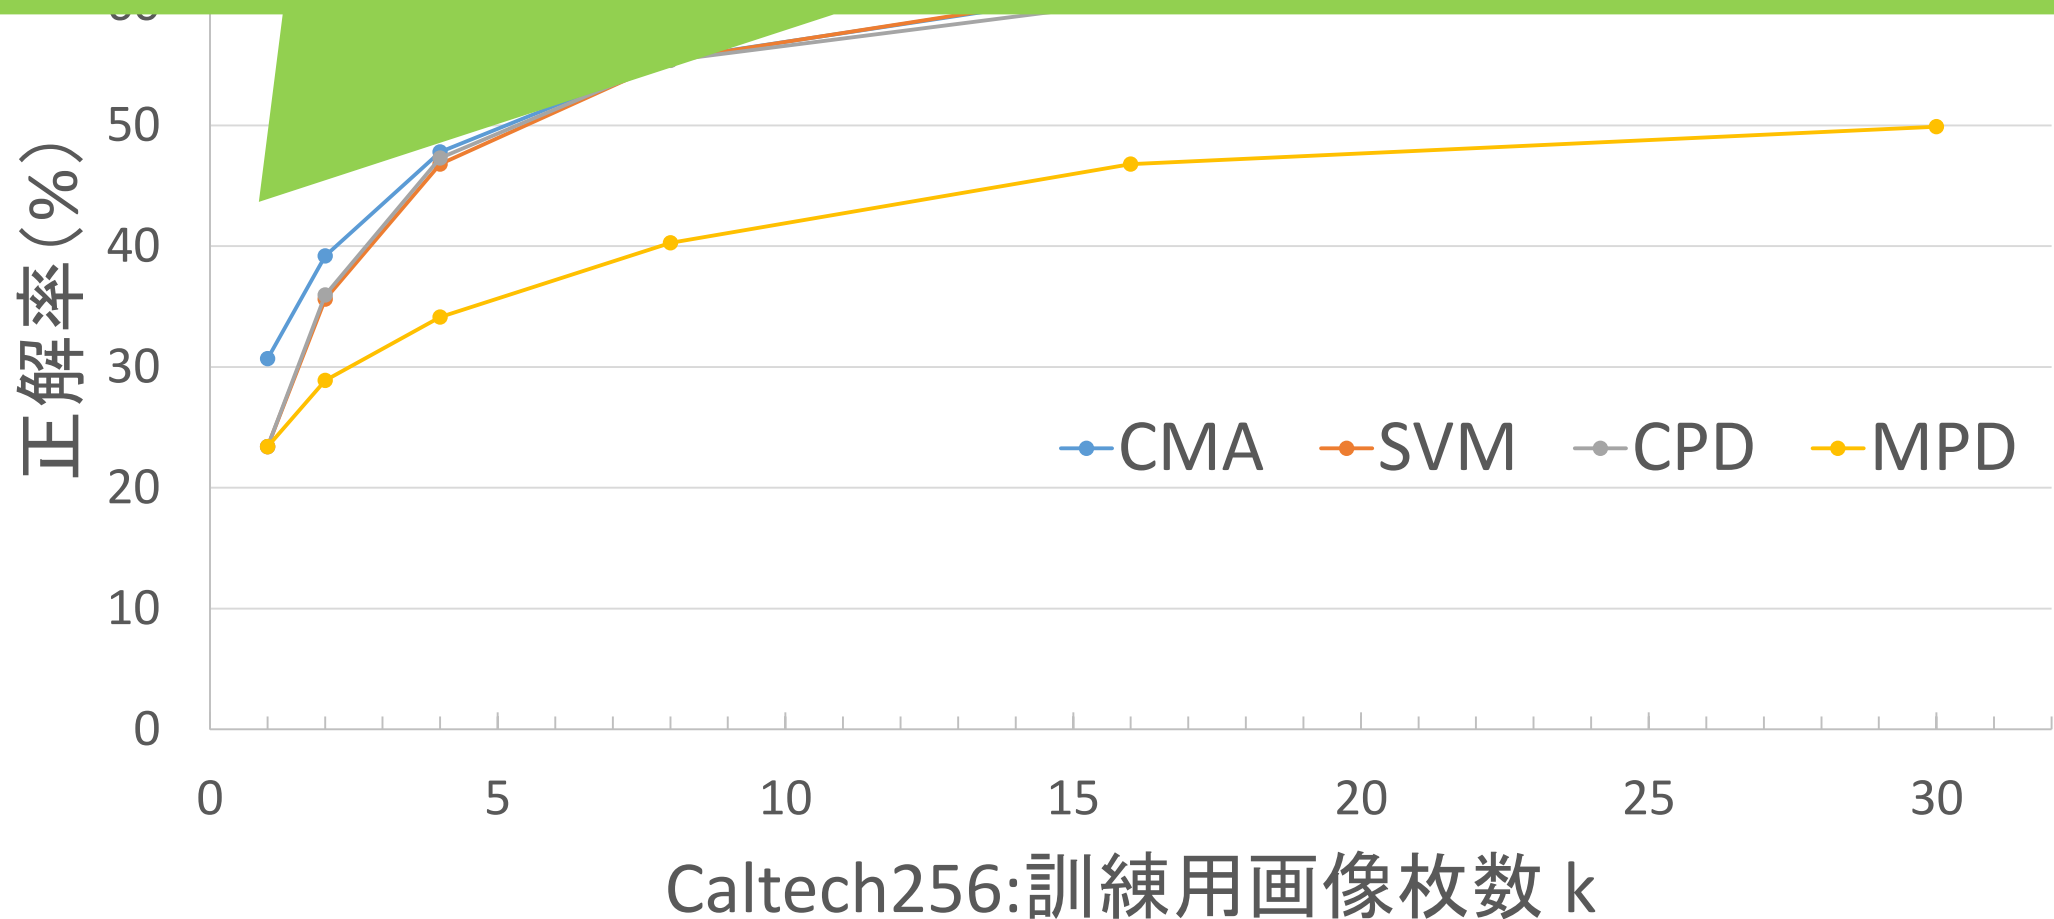
いずれの $k$ の値においてもCMA法が比較手法より高い正解率を示した

Caltech256:訓練用画像枚数  $k$

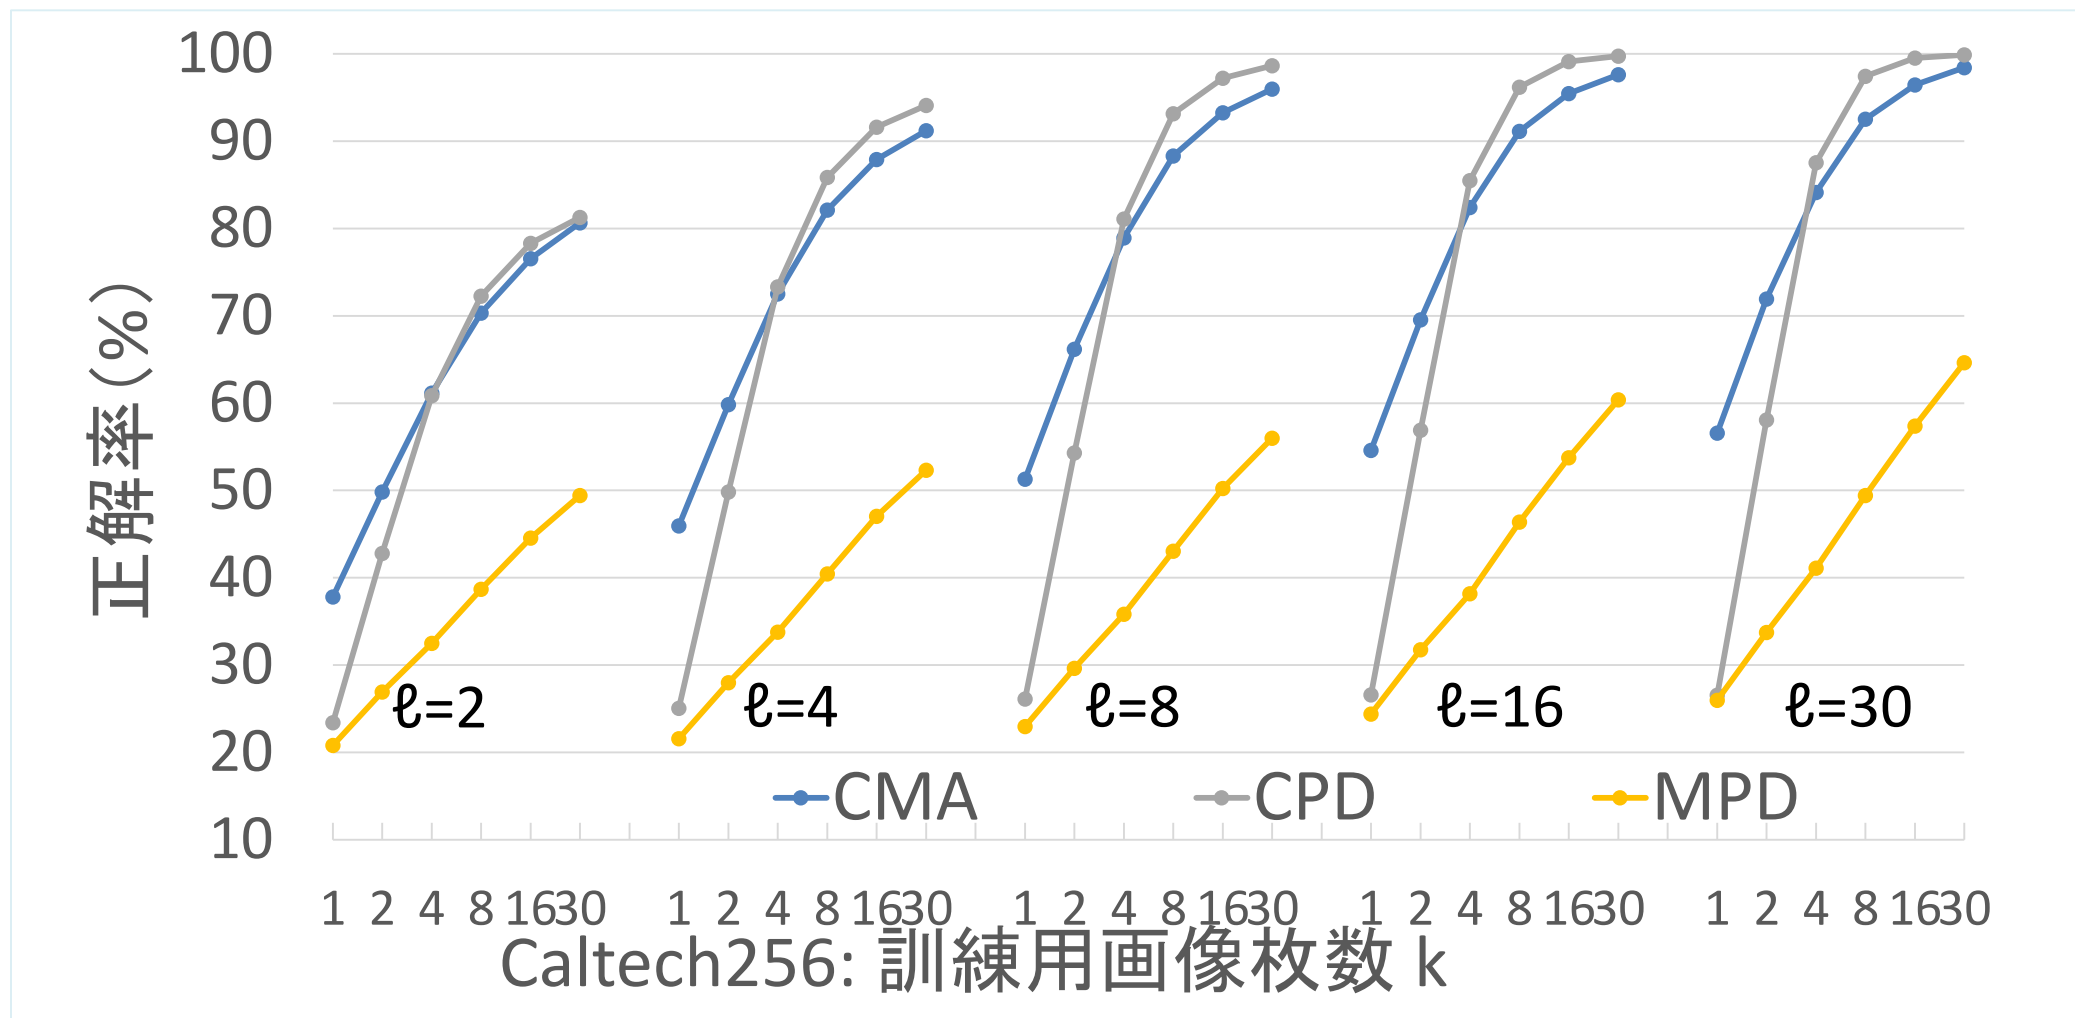


# 単独テストデータでの実験結果 (Caltech256)

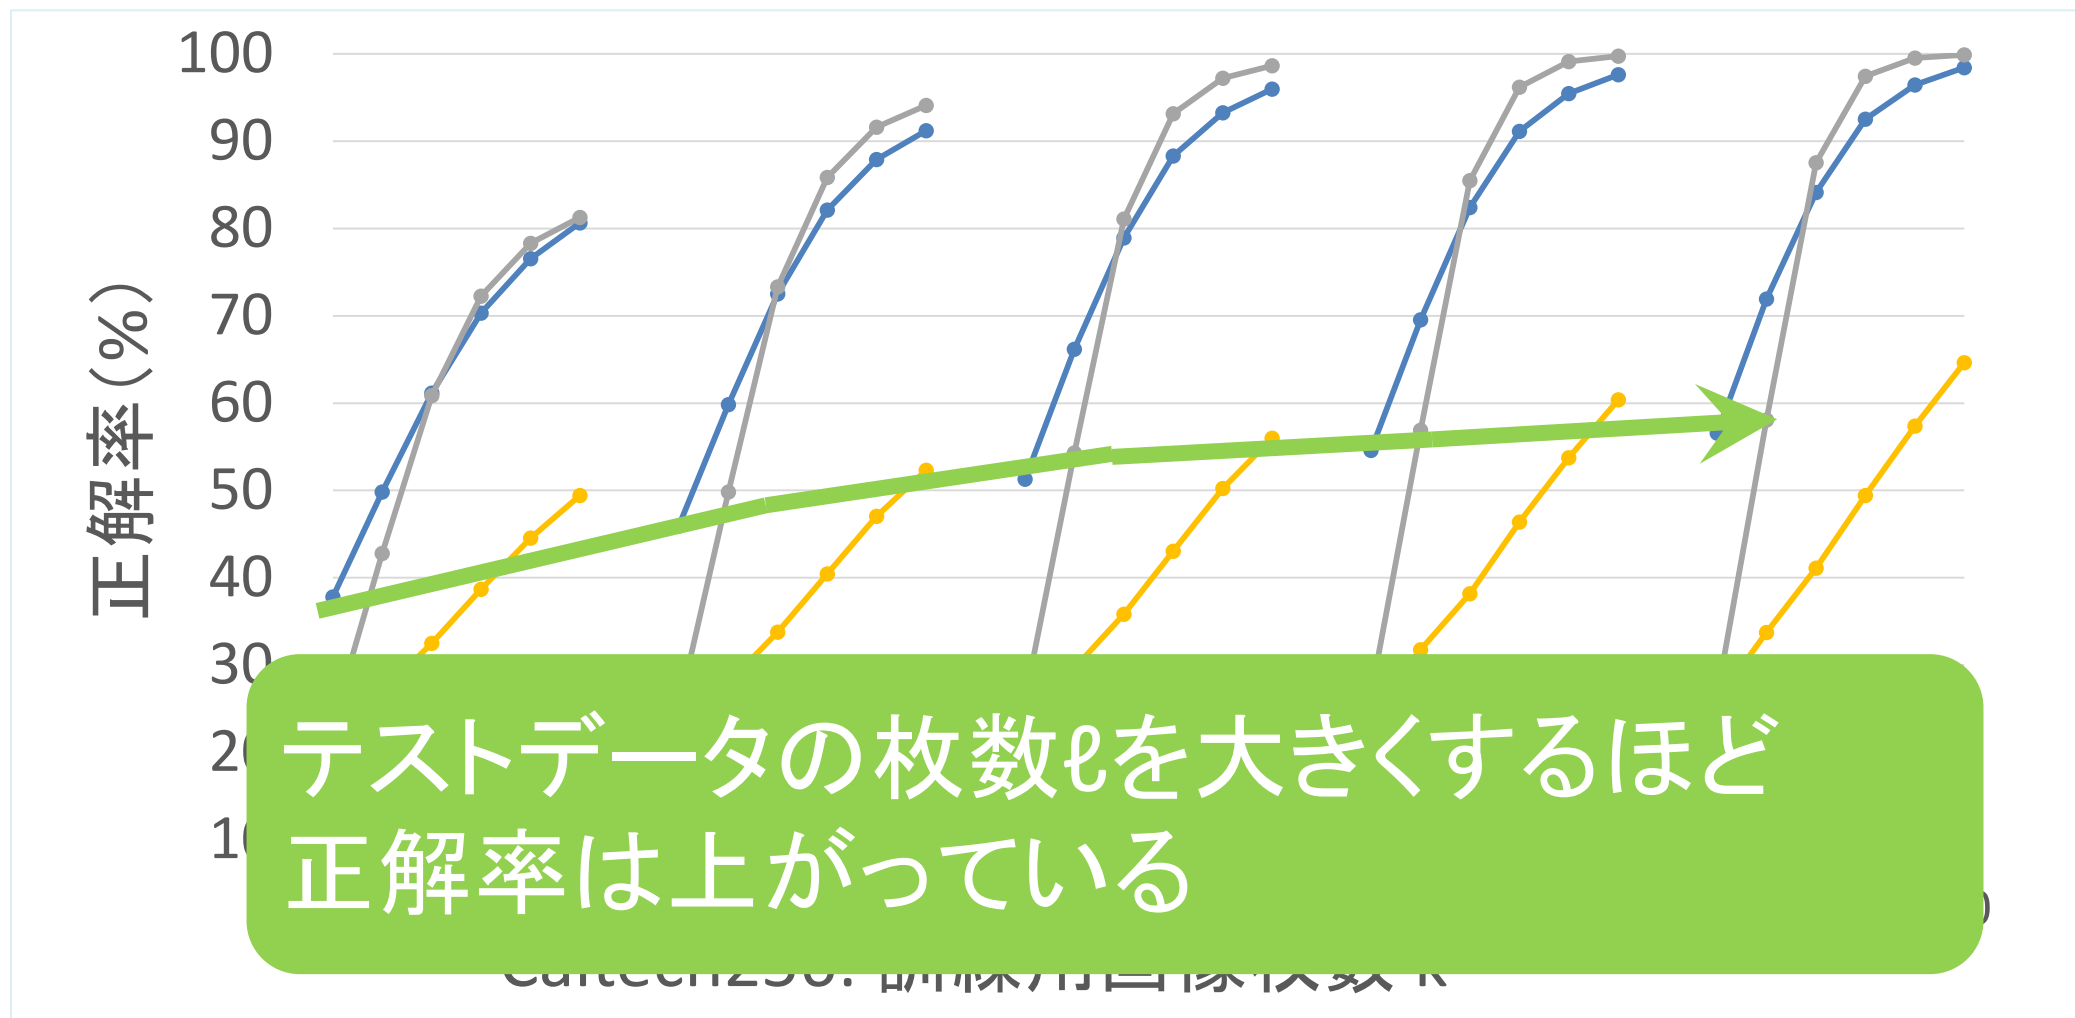
$k=1$ では,比較手法より約7ポイント高い正解率を示した



# 複数テストデータでの実験結果 (Caltech256)




# 複数テストデータでの実験結果 (Caltech256)



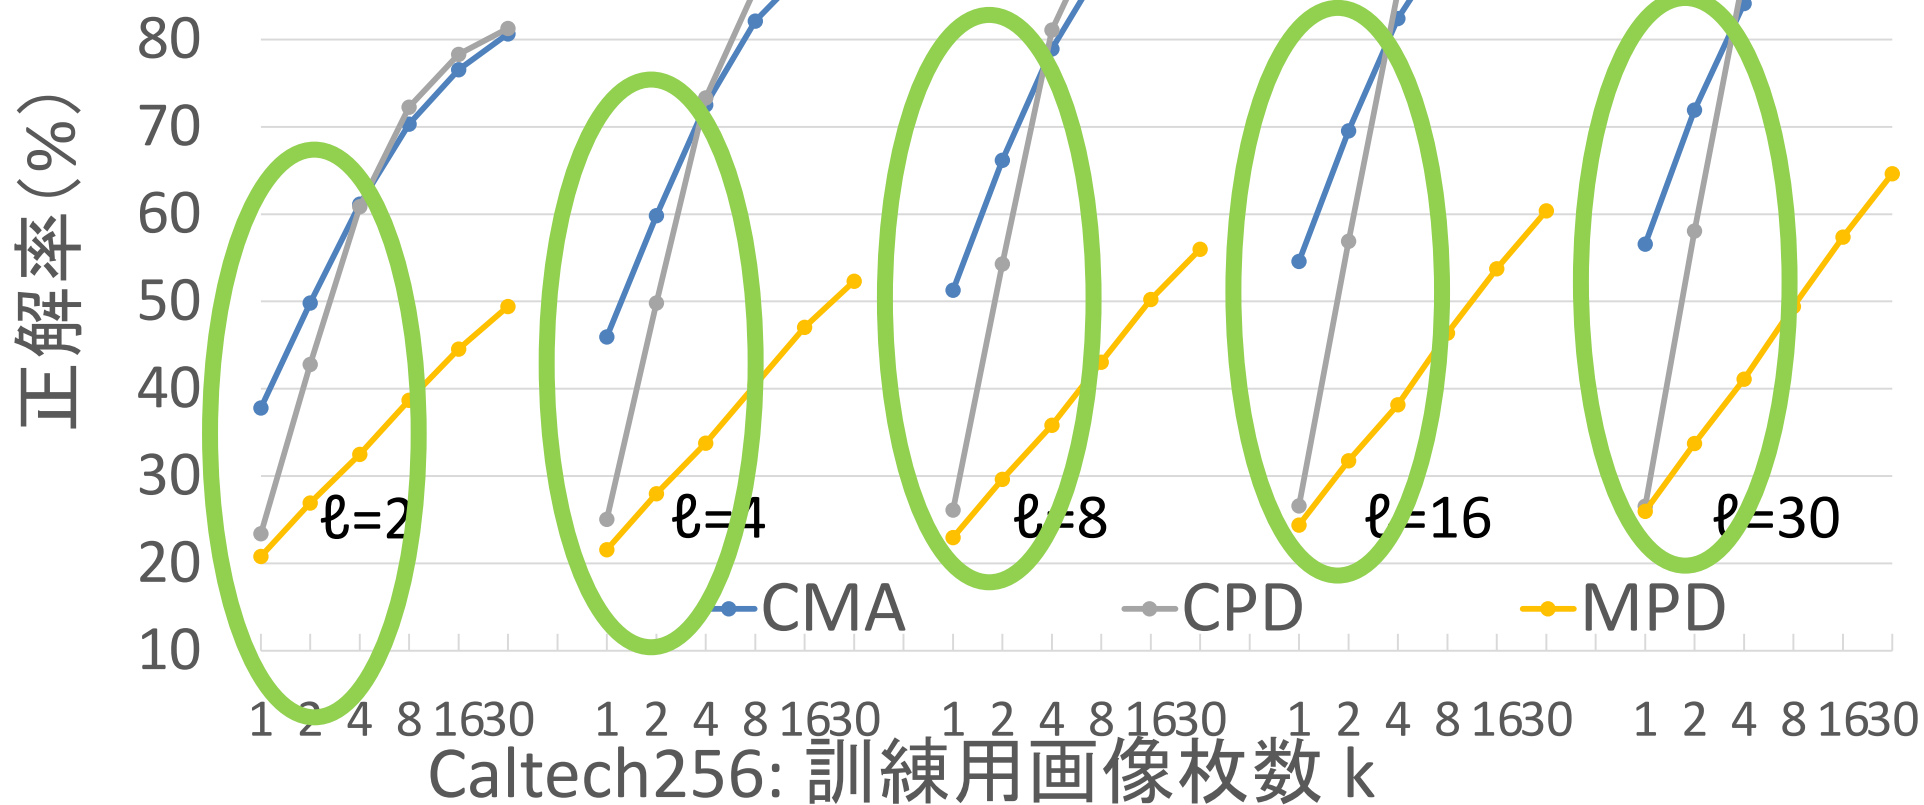
テストデータの枚数 $l$ を大きくするほど  
正解率は上がっている

# 複数テストデータでの実験結果 (Caltech256)



# 複数テストデータでの実験結果 (Caltech256)

$k = 1, 2$  の範囲ではCMA法が比較手法より高い正解率を示している




# パラメータの調整実験

$$f(\alpha, \beta) = \|Q\alpha - X\beta\|^2 + \lambda_1 \left\| \alpha - \frac{1}{N_q} \right\|^2 + \lambda_2 \left\| \beta - \frac{1}{N_x} \right\|^2$$

$\lambda$ の値が大きい  $\rightarrow$  平均点に近づく  
 $\lambda$ の値が小さい  $\rightarrow$  近似点と代表点が近づく

これまでの実験では $\lambda$ の値は  
両方とも16.0で設定してあった



# 実験結果

## 単独テストデータ実験結果

$\lambda_2$	k=1(%)	k=30(%)
32	30.7	64.2
16	31.1	65.2
8	31.4	65.7

## 複数テストデータ実験結果

$\lambda_1$	$\lambda_2$	k=1(%)	k=30(%)
32	32	53.4	97.7
32	16	55.1	98.7
32	8	55.7	98.9
16	32	54.7	97.9
16	16	55.4	98.6
16	8	56.6	99.2
8	32	54.8	98.1
8	16	55.9	98.5
8	8	56.3	98.9

\* 単独テストデータでは $\lambda_1$ の影響がない為結果を除く

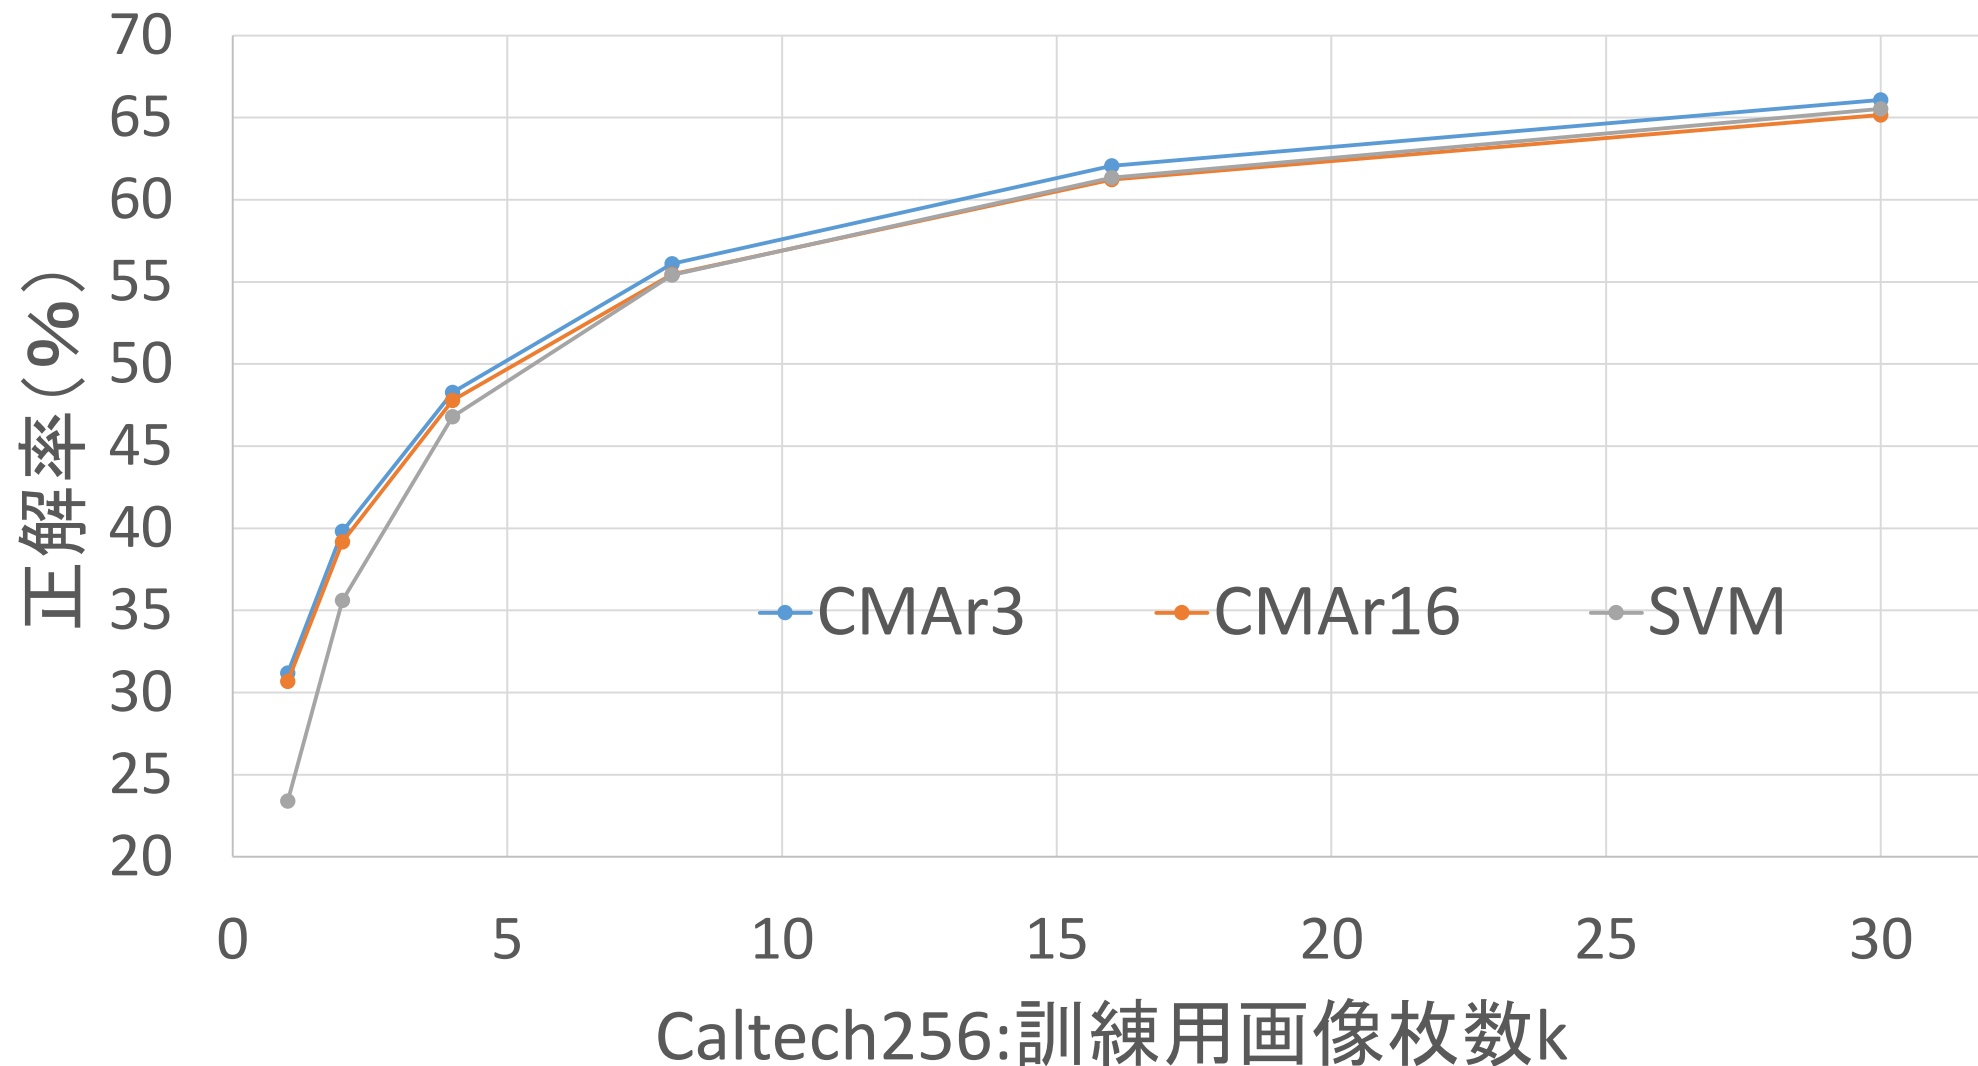
$\lambda_2$ の値が低い時には比較的に正解率が上がる

32	30.7	64.2	32	16	55.1	98.7
			32	8	55.7	98.9
			16	32	54.7	97.9
16	31.1	65.2	16	16	55.4	98.6
			16	8	56.6	99.2
8	31.4	65.7	8	32	54.8	98.1
			8	16	55.9	98.5
			8	8	56.3	98.9

\* 単独テストデータでは $\lambda_1$ の影響がない為結果を除く

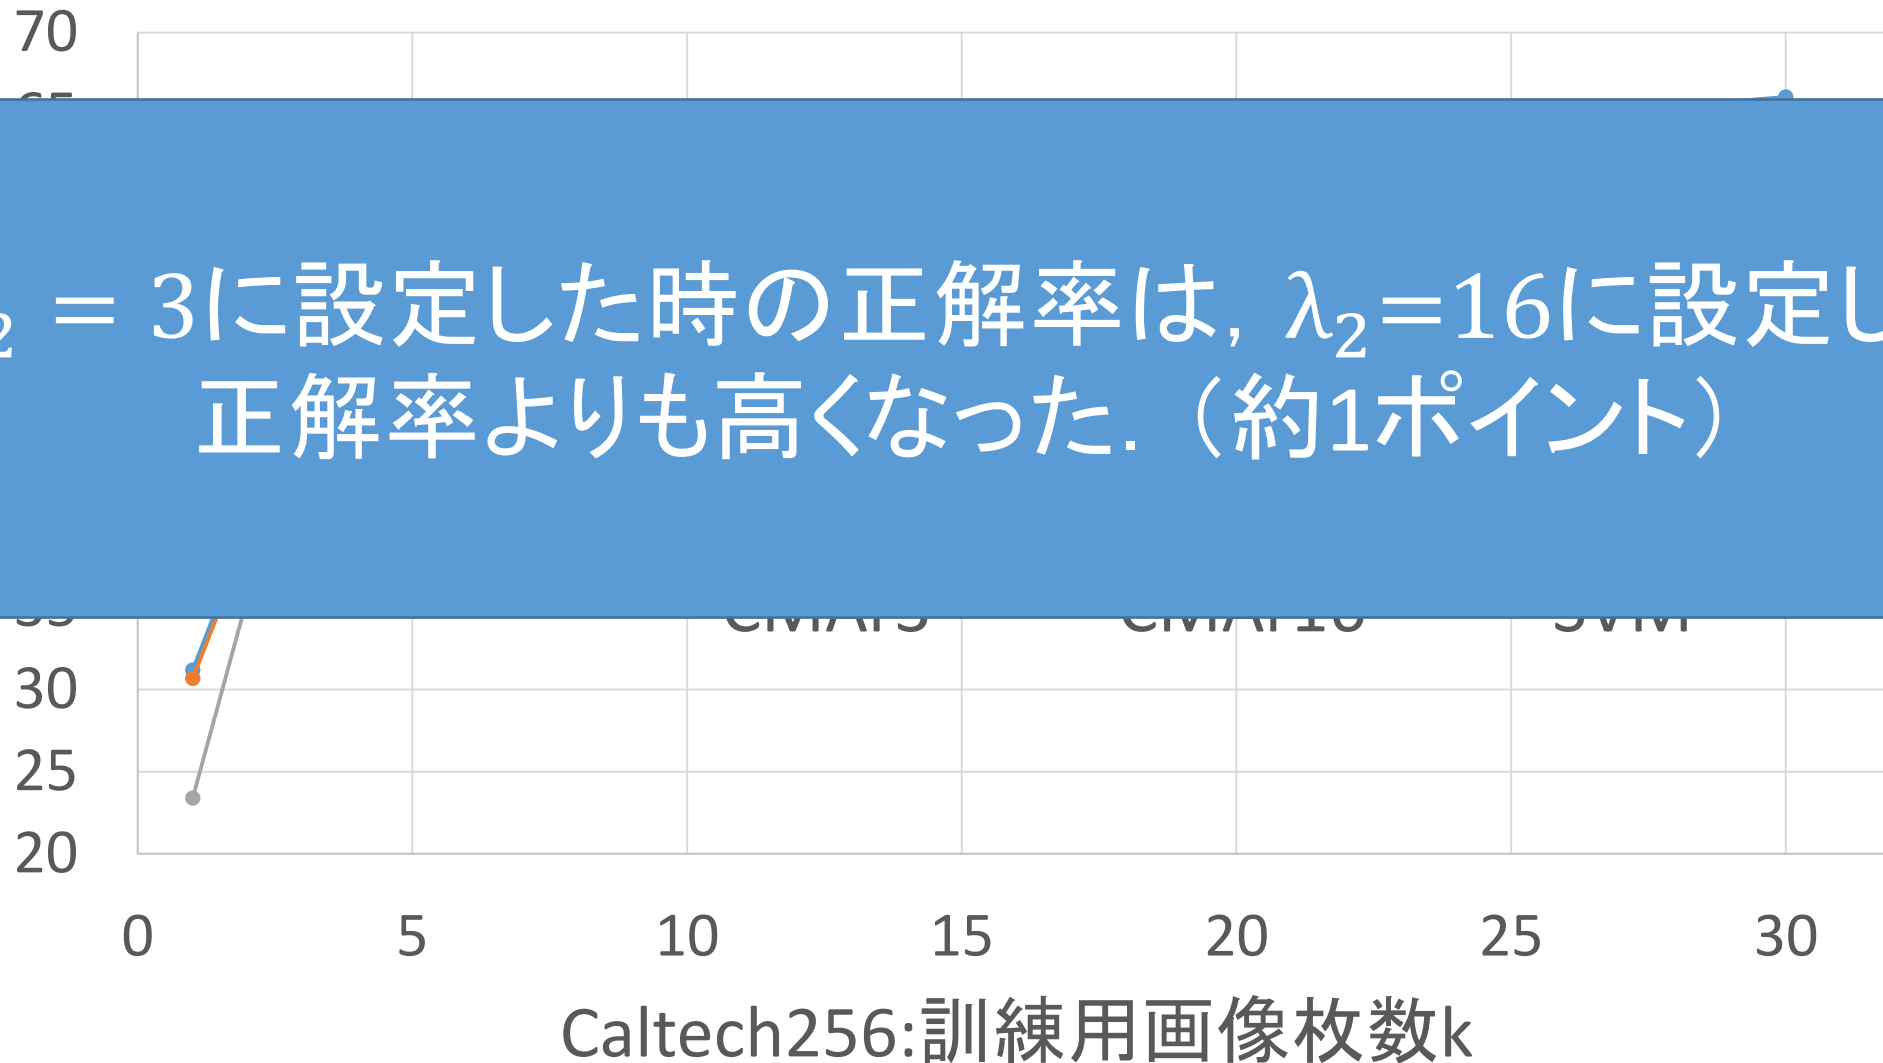


# $\lambda_2 = 3$ との比較実験(単独テストデータ)




# $\lambda_2 = 3$ との比較実験(単独テストデータ)

$\lambda_2 = 3$ に設定した時の正解率は,  $\lambda_2 = 16$ に設定した正解率よりも高くなった。(約1ポイント)



# $\lambda_2 = 3$ との比較実験(単独テストデータ)

訓練用データの平均から離れた近似点を設定した方が  
正解率が向上する



# おわりに

## CMA法が、画像分類でも有効であるか調査

- CMA法は画像分類に対して有効であることを示した
- 特に訓練用画像が少ない状況では比較手法より高い正解率を示した
- 正則化パラメータを調整することで、正解率が約1ポイント高くなった

## 今後の課題

画像に対象物が含まれているかの判定への拡張