

# Collaborative Mean Attraction 法 による一般画像分類

工学研究科 機械・情報系コース 情報システム工学分野

T1703009 荻原弘樹

指導教員 椋木雅之教授

副査 廿日出勇教授

副査 井上健太郎助教

# 画像分類

- 近年、画像分類の研究が盛んに行われている
- Deep Learning の手法が成果を上げている
- Deep Learningの手法では、**大量の学習用画像**を与えることで高性能な分類ができる

学習用画像が少数の場合  
十分に学習が出来ず良い成果を得られない

# 少数学習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

# 研究目的

一般画像分類においてCMA法が有効であるか調査

- 従来の疎・協働表現手法を調査
- スパース最適化を用いたSCMA法の提案
- 従来手法との比較実験


# 一般画像分類の定義

制約のない実世界で撮られた物体の画像に対して行う画像分類



テスト画像

分類



学習用画像

# 一般画像分類の流れ

## 1) 画像から特徴量を抽出



特徴抽出器



各画像の特徴量

# 一般画像分類の流れ

## 2) 特徴量を用いて識別器による分類



テストデータ




# 一般画像分類の流れ

## 2) 特徴量を用いて識別器による分類



識別器



識別器について比較評価を行う

テストデータ



# 本稿で扱う識別器

- Collaborative Mean Attraction (CMA)
- Sparse Collaborative Mean Attraction (SCMA)

## 従来手法

- Support Vector Machine (SVM)
- Deep Learning (DL) 手法

## 疎・協働表現の従来手法

- Collaborative Representation Classifier (CRC) [2]
- Sparse Representation Classifier (SRC) [3]
- Nonnegative Representation Classifier (NRC) [4]

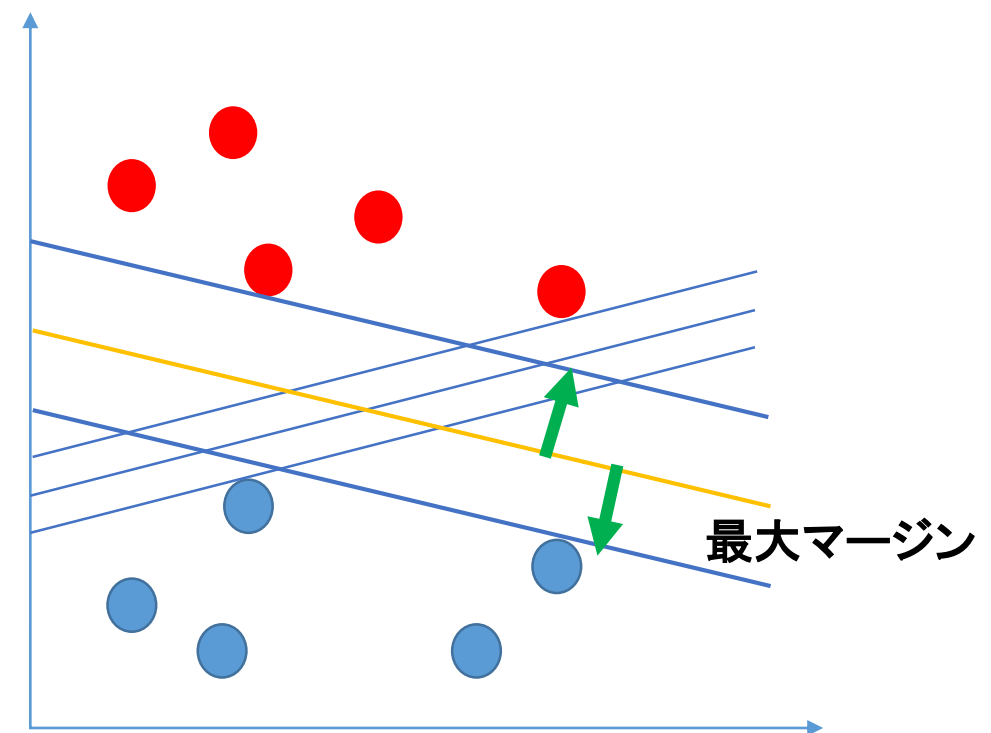
[2] L.Zhang, M.Yang, X.Feng, "Sparse Representation or collaborative representation: which helps face recognition?", ICCV, pp.471-478, 2011.

[3] J.Wright, A.Y. Yang, A. Ganesh, "Robust face recognition via sparse representation", Transactions on Pattern Analysis and Machine Intelligence, vol.31, issue2, pp.210-227, 2009

[4] J.Xu, W.An, L.Zhang, D.Zhang, "Sparse, Collaborative, or Nonnegative Representation: Which Helps Pattern Classification?", arXiv:1806.04329v2 [cs.CV], 2018

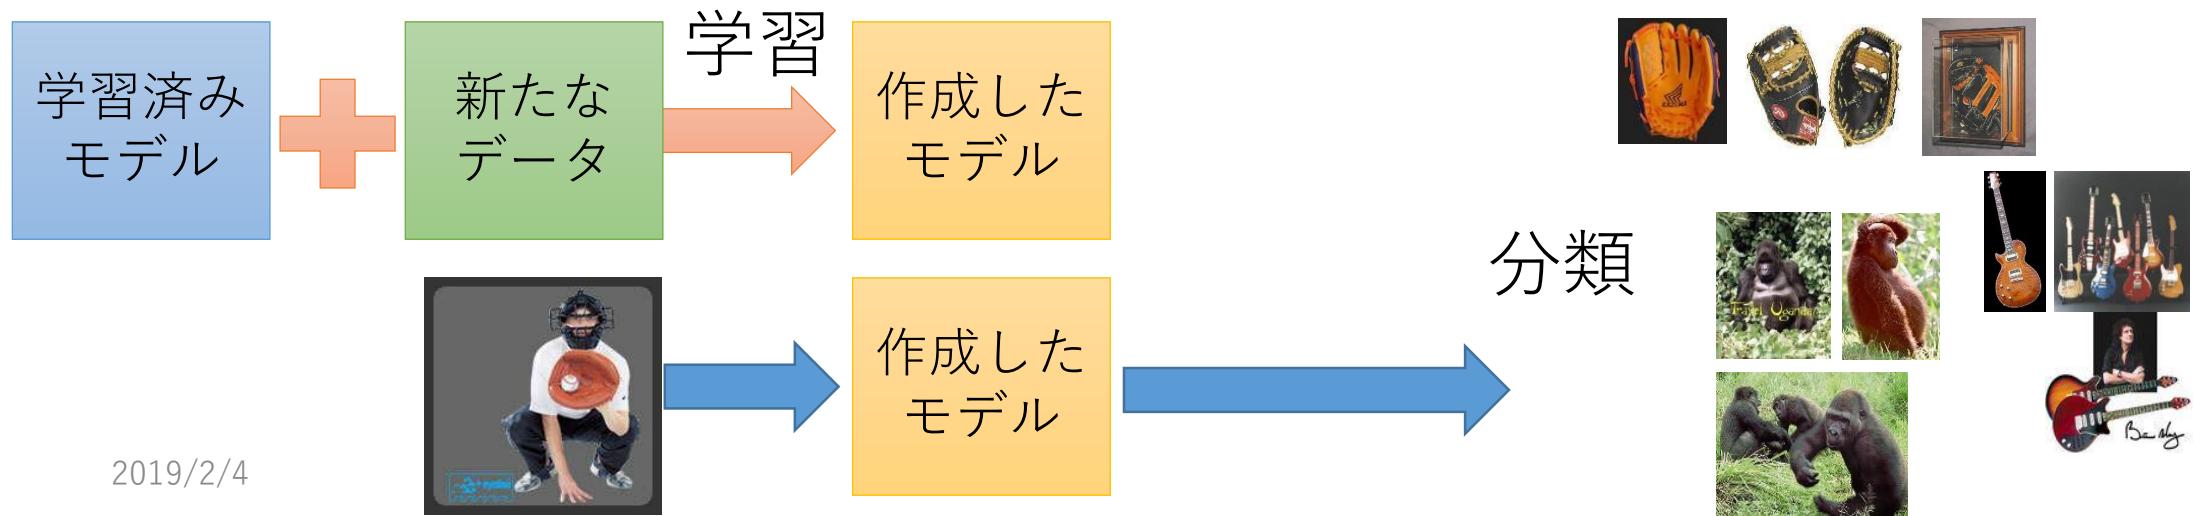
# 従来手法：SVM

- 学習用データから2クラスの識別境界を求める手法
- 2クラス間のデータのマージンが最大となるように境界線を引くことにより汎化能力を高める



# 従来手法：DL手法

- 学習済みモデル  
AlexNetにILSVRC2012の1000カテゴリ、120万画像データを学習させたもの
- ファインチューニング  
学習済みモデルに追加で新たなデータを学習させて、別の分野に適応させること



従来手法：SVM,DL

従来手法：SVM,DL  
学習用画像が大量にある場合に有効


疎・協働表現手法  
CRC, SRC, NRC, CMA, SCMA

各カテゴリの学習用画像数が  
少なくとも対処できると考えられる



# 疎・協働表現手法の流れ

## ◆最適化段階

## ◆分類段階



学習用画像



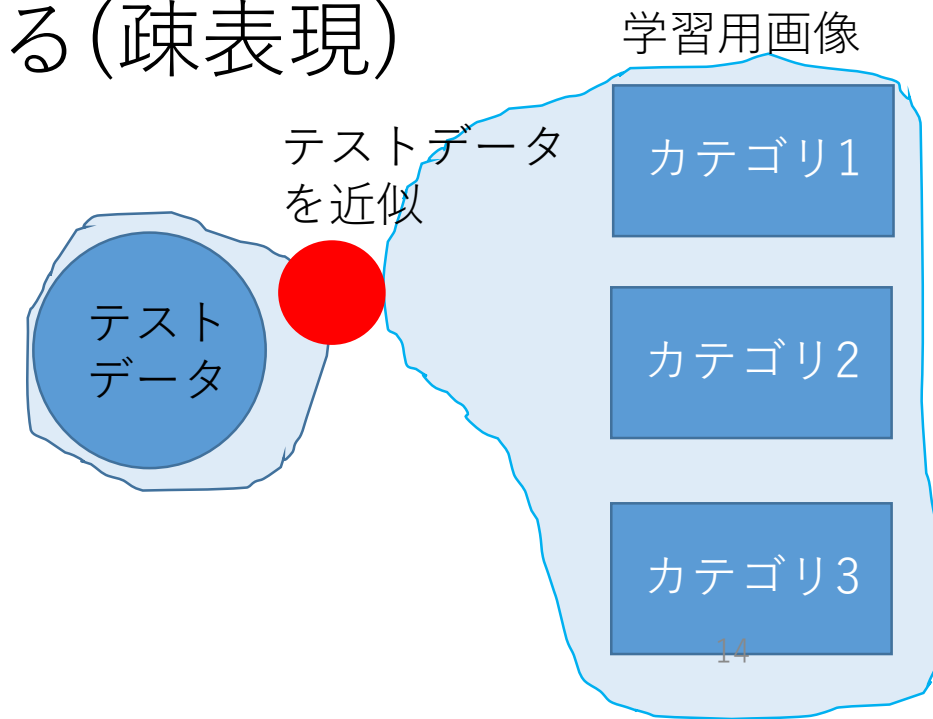
# 疎・協働表現手法の流れ

## ◆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 学習用画像で近似する(協働表現)
- 一部の有効な学習用画像で近似する(疎表現)

## ◆分類段階



# 疎・協働表現手法の流れ

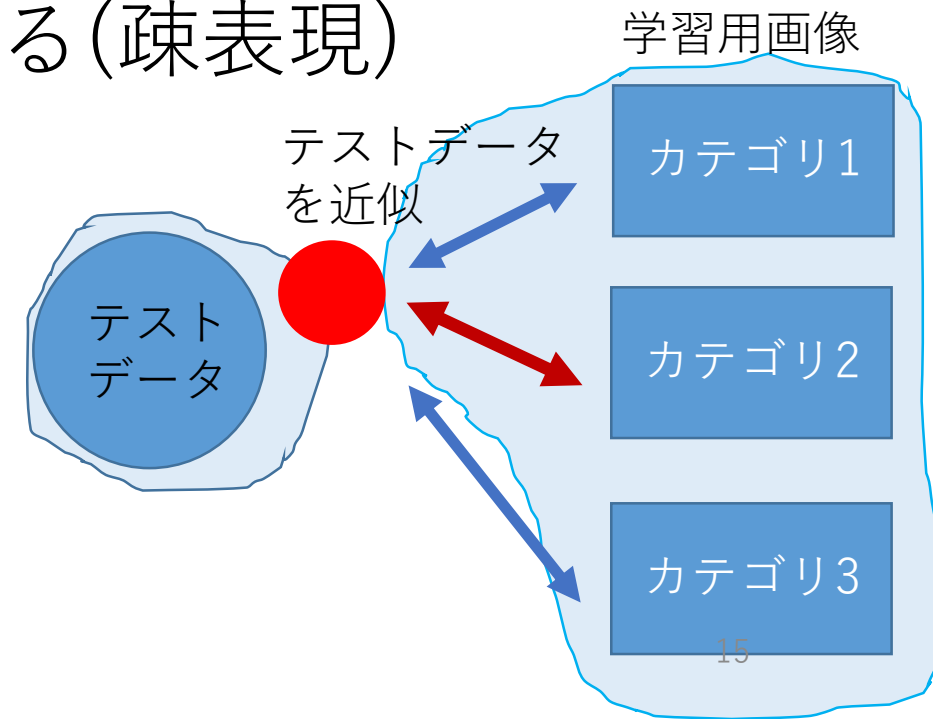
## ◆最適化段階

テストデータの代表点を既知のカテゴリ

- 全ての 学習用画像で近似する(協働表現)
- 一部の有効な学習用画像で近似する(疎表現)

## ◆分類段階

この近似に最も貢献した  
カテゴリにテストデータを分類



# 疎・協働表現手法の最適化段階

SRC法  $\min_{\boldsymbol{\beta}} \|\mathbf{y} - \mathbf{X}\boldsymbol{\beta}\|_2^2 + \lambda \|\boldsymbol{\beta}\|_1$  疎表現

CRC法  $\min_{\boldsymbol{\beta}} \|\mathbf{y} - \mathbf{X}\boldsymbol{\beta}\|_2^2 + \lambda \|\boldsymbol{\beta}\|_2^2$  協働表現

NRC法  $\min_{\boldsymbol{\beta}} \|\mathbf{y} - \mathbf{X}\boldsymbol{\beta}\|_2^2 \text{ s.t. } \boldsymbol{\beta} \geq 0$  疎表現

- $\mathbf{y} \in \mathbf{R}^m$  : テストデータ ( $m$  は特徴量次元数)
- $\mathbf{X} \in \mathbf{R}^{m \times N_x}$  : 全学習用データ ( $N_x$  : 全学習用データ枚数)
- $\boldsymbol{\beta} \in \mathbf{R}^{N_x}$  : 係数ベクトル
- $\lambda$  : 正則化項のパラメータ



# 疎・協働表現手法の最適化段階

SRC法  $\min_{\boldsymbol{\beta}} \|\mathbf{y} - \mathbf{X}\boldsymbol{\beta}\|_2^2 + \lambda \|\boldsymbol{\beta}\|_1$  疎表現

CRC法  $\min_{\boldsymbol{\beta}} \|\mathbf{y} - \mathbf{X}\boldsymbol{\beta}\|_2^2 + \lambda \|\boldsymbol{\beta}\|_2^2$  協働表現

NRC法  $\min_{\boldsymbol{\beta}} \|\mathbf{y} - \mathbf{X}\boldsymbol{\beta}\|_2^2 \text{ s.t. } \boldsymbol{\beta} \geq 0$  疎表現

➤  $\mathbf{y} \in \mathbf{R}^m$  : テストデータ ( $m$  は特徴数)

テストデータを学習用データの線形和で近似  
係数ベクトル  $\boldsymbol{\beta}$  にそれぞれの制約が課せられる

# 疎・協働表現手法の最適化段階

SRC法  $\min_{\boldsymbol{\beta}} \|\mathbf{y} - \mathbf{X}\boldsymbol{\beta}\|_2^2 + \lambda \|\boldsymbol{\beta}\|_1$  疎表現

CRC法  $\min_{\boldsymbol{\beta}} \|\mathbf{y} - \mathbf{X}\boldsymbol{\beta}\|_2^2 + \lambda \|\boldsymbol{\beta}\|_2^2$  協働表現

NRC法  $\min_{\boldsymbol{\beta}} \|\mathbf{y} - \mathbf{X}\boldsymbol{\beta}\|_2^2 \text{ s.t. } \boldsymbol{\beta} \geq 0$  疎表現

- $\mathbf{y} \in \mathbf{R}^m$  : テストデータ ( $m$  は特徴量次元数)
- $\mathbf{X} \in \mathbf{R}^{m \times N_x}$  : 全学習用データ ( $N_x$  : 全学習用データ枚数)
- $\boldsymbol{\beta} \in \mathbf{R}^{N_x}$  : 係数ベクトル
- $\lambda$  : 正則化項のパラメータ

# 疎・協働表現手法の最適化段階

SRC法  $\min_{\boldsymbol{\beta}} \|\mathbf{y} - \mathbf{X}\boldsymbol{\beta}\|_2^2 + \lambda \|\boldsymbol{\beta}\|_1$  疎表現

CRC法  $\min_{\boldsymbol{\beta}} \|\mathbf{y} - \mathbf{X}\boldsymbol{\beta}\|_2^2 + \lambda \|\boldsymbol{\beta}\|_2^2$  協働表現

NRC法  $\min_{\boldsymbol{\beta}} \|\mathbf{y} - \mathbf{X}\boldsymbol{\beta}\|_2^2 \text{ s.t. } \boldsymbol{\beta} \geq 0$  疎表現

- $\mathbf{y} \in \mathbf{R}^m$  : テストデータ ( $m$  は特徴量次元数)
- $\mathbf{X} \in \mathbf{R}^{m \times N_x}$  : 全学習用データ ( $N_x$  : 全学習用データ枚数)
- $\boldsymbol{\beta} \in \mathbf{R}^{N_x}$  : 係数ベクトル
- $\lambda$  : 正則化項のパラメータ

# 疎・協働表現手法の最適化段階

SRC法  $\min_{\boldsymbol{\beta}} \|\mathbf{y} - \mathbf{X}\boldsymbol{\beta}\|_2^2 + \lambda \|\boldsymbol{\beta}\|_1$  疎表現


CRC法  $\min_{\boldsymbol{\beta}} \|\mathbf{y} - \mathbf{X}\boldsymbol{\beta}\|_2^2 + \lambda \|\boldsymbol{\beta}\|_2^2$  協働表現

NRC法  $\min_{\boldsymbol{\beta}} \|\mathbf{y} - \mathbf{X}\boldsymbol{\beta}\|_2^2 \text{ s.t. } \boldsymbol{\beta} \geq 0$  疎表現

- $\mathbf{y} \in \mathbf{R}^m$  : テストデータ ( $m$  は特徴量次元数)
- $\mathbf{X} \in \mathbf{R}^{m \times N_x}$  : 全学習用データ ( $N_x$  : 全学習用データ枚数)
- $\boldsymbol{\beta} \in \mathbf{R}^{N_x}$  : 係数ベクトル
- $\lambda$  : 正則化項のパラメータ

# CMA法の最適化段階

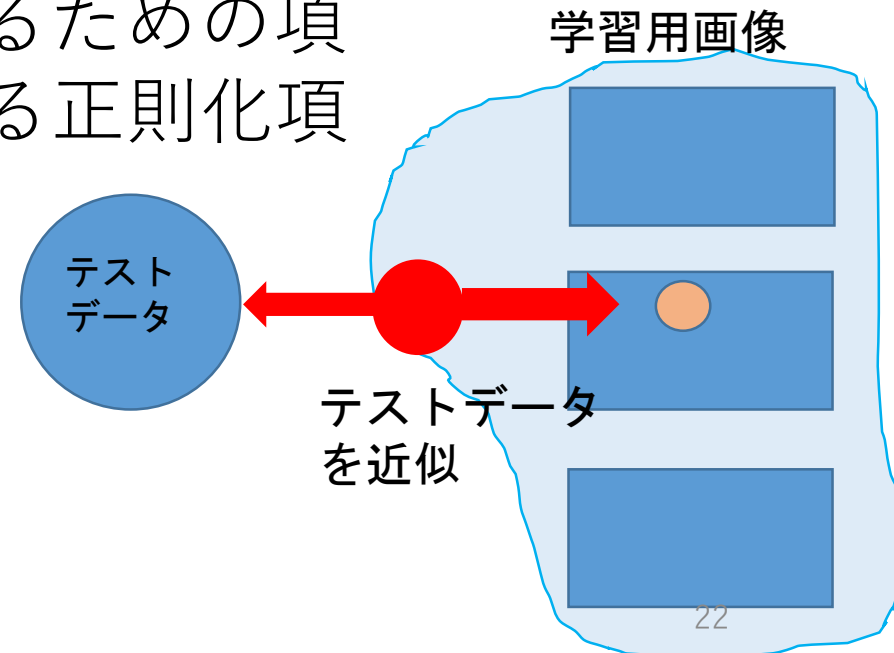
テストデータを近似する際に  
学習用データの平均から離れないようにする制約



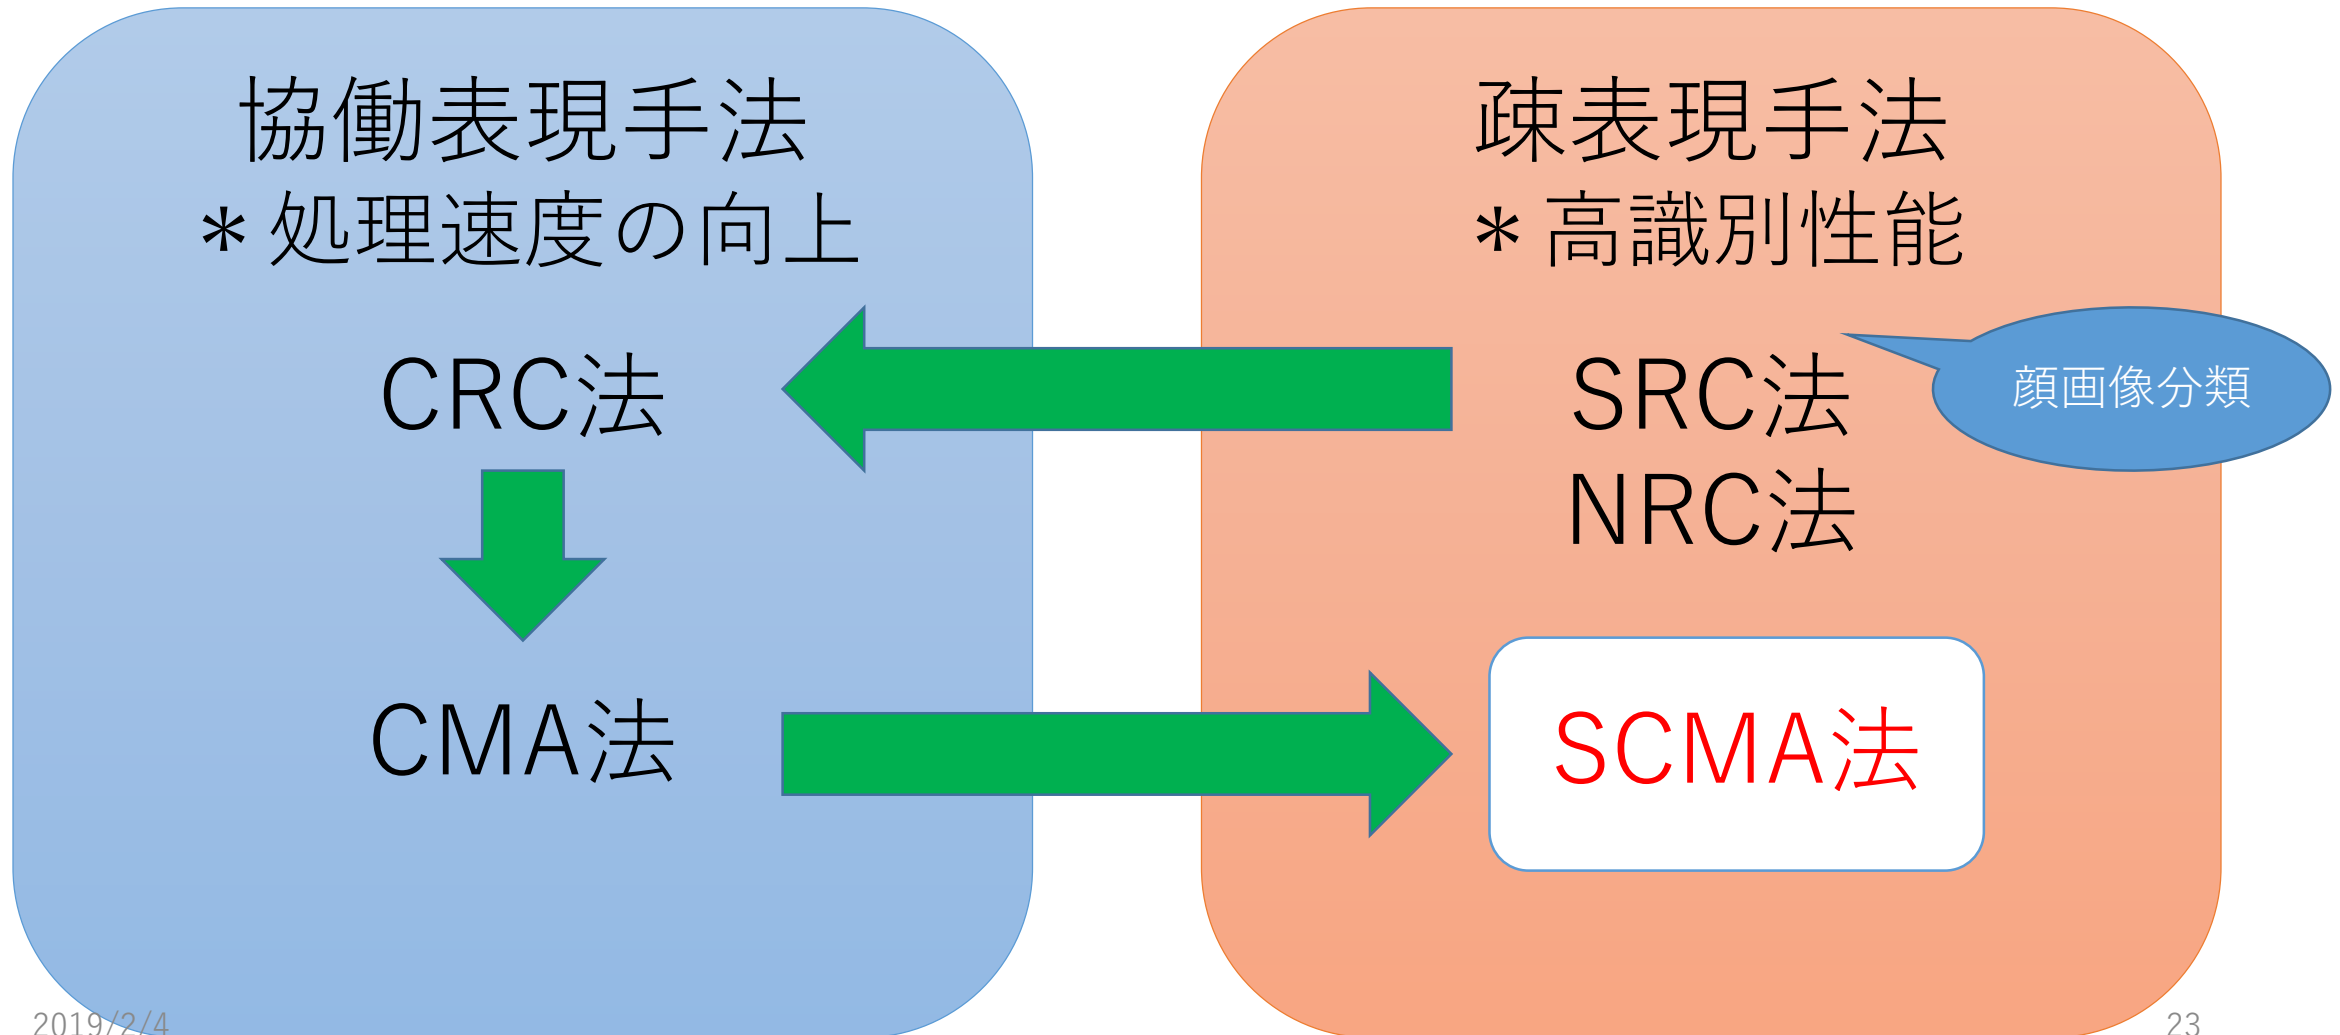
# CMA法の最適化段階

$$\min_{\boldsymbol{\beta}} \|\mathbf{y} - \mathbf{X}\boldsymbol{\beta}\|_2^2 + \lambda \left\| \boldsymbol{\beta} - \frac{\mathbf{1}_{N_x}}{N_x} \right\|^2$$

- 第1項：テストデータ $\mathbf{y}$ と近似点 $\mathbf{X}\boldsymbol{\beta}$ を近くするための項
- 第2項：近似点を平均から離れないようにする正則化項
- $\lambda$ は正則化項のパラメーター
- $\mathbf{1}_k$ ：各要素が1の $k$ 次元ベクトル



# 疎、協働表現手法



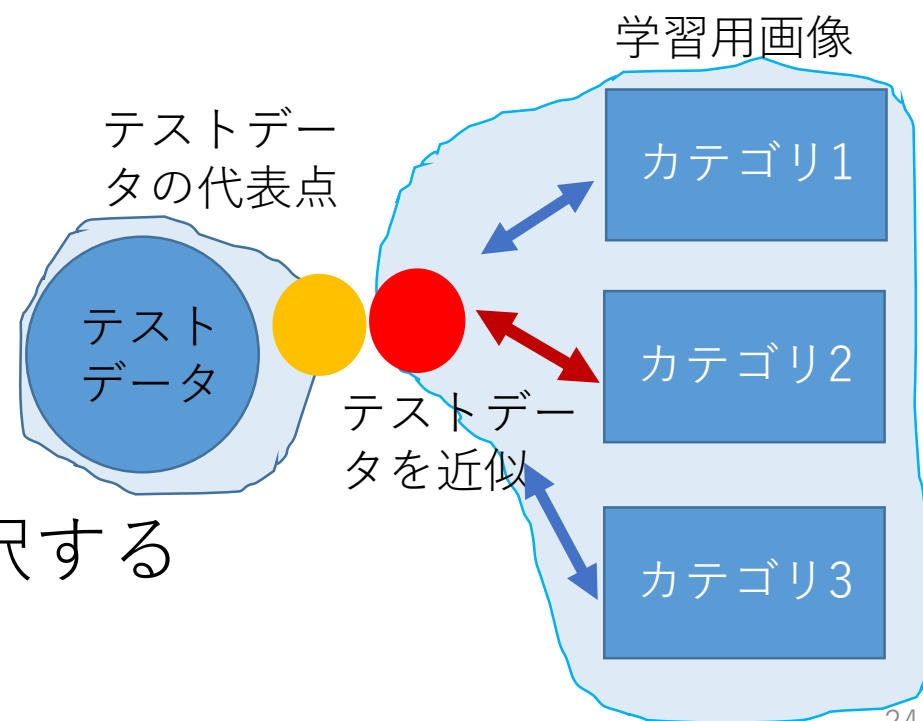
# 提案手法 Sparse Collaborative Mean attraction SCMA法

## • スパース最適化段階

テストデータを既知の全学習用画像の中から少数の適切な学習用画像で近似を行う

## • 分類段階

この近似に最も貢献したカテゴリを選択する





# SCMA法：スパース最適化段階

$$\min_{\boldsymbol{\beta}} \|\mathbf{y} - \{(\mathbf{X} - \bar{\mathbf{X}})\boldsymbol{\beta} + \bar{\mathbf{x}}\}\|_2^2 + \lambda \|\boldsymbol{\beta}\|_1$$

- $\mathbf{y} \in \mathbf{R}^m$  : テストデータ ( $m$  は特徴量次元数)
- $\mathbf{X} \in \mathbf{R}^{m \times N_x}$  : 全学習用データ ( $N_x$  : 全学習用データ枚数)
- $\lambda$  : 正則化項のパラメータ
- $\bar{\mathbf{x}}$  : 学習用データの平均列ベクトル
- $\bar{\mathbf{X}}$  :  $\bar{\mathbf{x}}$  を  $N_x$  個並べたもの

この式が最小となる  $\boldsymbol{\beta}$  を求める

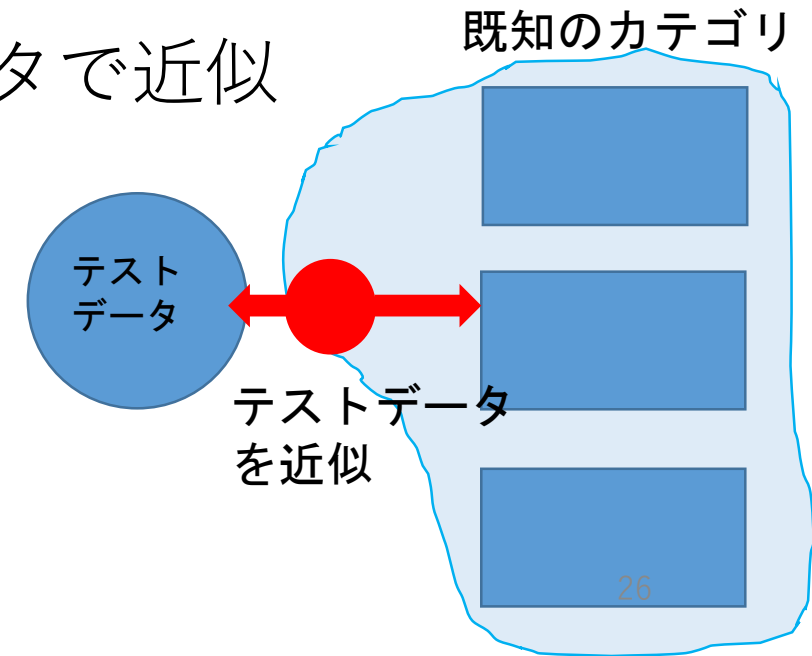
# SCMA法：スパース最適化段階

$$\min_{\boldsymbol{\beta}} \|\mathbf{y} - \{(\mathbf{X} - \bar{\mathbf{X}})\boldsymbol{\beta} + \bar{\mathbf{x}}\}\|_2^2 + \lambda \|\boldsymbol{\beta}\|_1$$

CMA法

$$\lambda \left\| \boldsymbol{\beta} - \frac{\mathbf{1}_{N_x}}{N_x} \right\|^2$$

- 第1項：テストデータを学習用データの線形和で近似
- 第2項：L1ノルム制約
- $\boldsymbol{\beta}$ がスパースになる：少数の適切な学習用データで近似
- $\boldsymbol{\beta}$ が0の時に平均値をとるように第1項が変形



# SCMA法：スパース最適化段階

$$\min_{\boldsymbol{\beta}} \|\mathbf{y} - \{(\mathbf{X} - \bar{\mathbf{X}})\boldsymbol{\beta} + \bar{\mathbf{x}}\}\|_2^2 + \lambda \|\boldsymbol{\beta}\|_1$$

CMA法

$$\lambda \left\| \boldsymbol{\beta} - \frac{\mathbf{1}_{N_x}}{N_x} \right\|^2$$

- 第1項：テストデータを学習用データの線形和で近似
- 第2項：L1ノルム制約

CMA法と同様に  
学習用データの平均から離れないようにする制約を持ちつつ  
少数の適切なデータで近似を行う

# 疎・協働表現手法の流れ

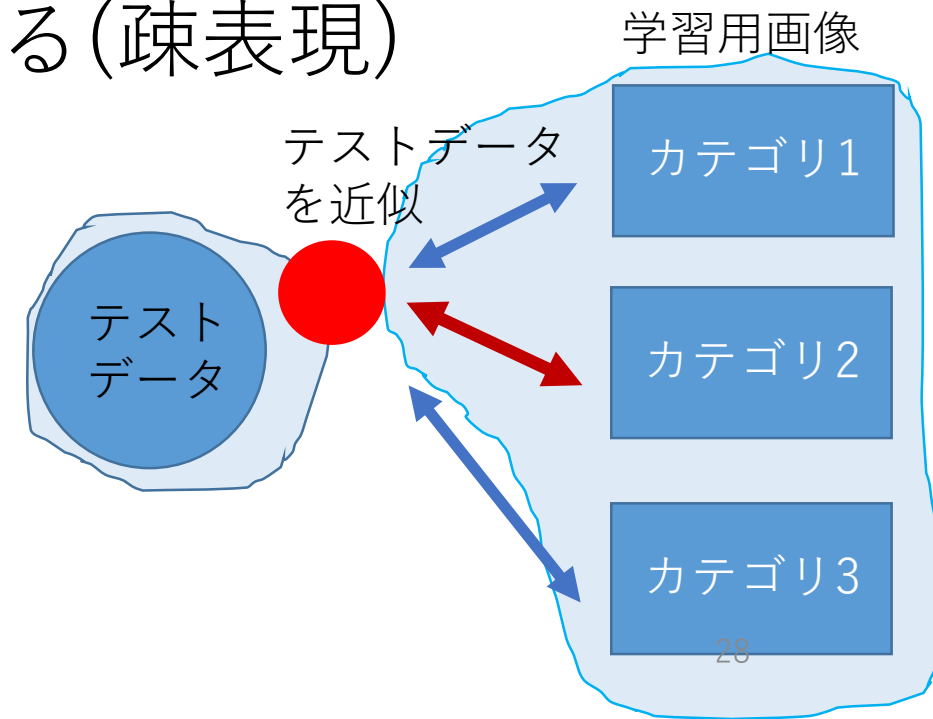
## ◆最適化段階

テストデータの代表点を既知のカテゴリ

- 全ての 学習用画像で近似する(協働表現)
- 一部の有効な学習用画像で近似する(疎表現)

## ◆分類段階

この近似に最も貢献した  
カテゴリを選択する



# 疎・協働表現の分類段階

SRC,CRC,NRC法	CMA法	SCMA法
$\ \mathbf{y} - \mathbf{X}_i\boldsymbol{\beta}_i\ ^2$	$(\ \mathbf{y}\ _* + \ \mathbf{X}_i\ _*) \cdot \ \mathbf{y} - \mathbf{X}_i\boldsymbol{\beta}_i\ ^2 \ \boldsymbol{\beta}\  / \ \boldsymbol{\beta}_i\ $	$-\sum_{j=1}^{N_x^i} \beta_j^i$

- 最適化段階で求めた、 $\boldsymbol{\beta}$ を用いる
- 近似点の係数 $\boldsymbol{\beta}$ の各次元が、学習用画像に対応している
- カテゴリ*i*の学習用画像の係数を $\boldsymbol{\beta}_i$ として $\boldsymbol{\beta}^T = (\boldsymbol{\beta}_1^T, \dots, \boldsymbol{\beta}_n^T)$ 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

# 疎・協働表現の分類段階

SRC,CRC,NRC法	CMA法	SCMA法
$\ \mathbf{y} - \mathbf{X}_i \boldsymbol{\beta}_i\ ^2$	$(\ \mathbf{y}\ _* + \ \mathbf{X}_i\ _*) \cdot \ \mathbf{y} - \mathbf{X}_i \boldsymbol{\beta}_i\ ^2 \ \boldsymbol{\beta}\  / \ \boldsymbol{\beta}_i\ $	$-\sum_{j=1}^{N_x^i} \beta_i^j$

➤ カテゴリ  $i$  のみの学習用データの線形和でテストデータとの近似を行っている

➤  $\|\mathbf{y} - \mathbf{X}_i \boldsymbol{\beta}_i\|^2$  小さいカテゴリほどテストデータを表現するのに貢献している

# 疎協働表現の分類段階

SRC,CRC,NRC法	CMA法	SCMA法
$\ \mathbf{y} - \mathbf{X}_i\boldsymbol{\beta}_i\ ^2$	$(\ \mathbf{y}\ _* + \ \mathbf{X}_i\ _*) \cdot \ \mathbf{y} - \mathbf{X}_i\boldsymbol{\beta}_i\ ^2 \ \boldsymbol{\beta}\  / \ \boldsymbol{\beta}_i\ $	$-\sum_{j=1}^{N_x^i} \beta_i^j$

➤  $\|\mathbf{y} - \mathbf{X}_i\boldsymbol{\beta}_i\|^2$ が小さいほど、カテゴリ*i*でテストデータの近似がよくおこなえている

➤  $\|\boldsymbol{\beta}\| / \|\boldsymbol{\beta}_i\|$ 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

# 疎協働表現の分類段階

SRC,CRC,NRC法	CMA法	SCMA法
$\ \mathbf{y} - \mathbf{X}_i \boldsymbol{\beta}_i\ ^2$	$(\ \mathbf{y}\ _* + \ \mathbf{X}_i\ _*) \cdot \ \mathbf{y} - \mathbf{X}_i \boldsymbol{\beta}_i\ ^2 \ \boldsymbol{\beta}\  / \ \boldsymbol{\beta}_i\ $	$-\sum_{j=1}^{N_x^i} \beta_i^j$

➤ カテゴリ  $i$  の学習用画像の係数を  $\boldsymbol{\beta}_i$  として  $\boldsymbol{\beta}_i^T = (\beta_i^1, \dots, \beta_i^{N_x^i})^T$  と分解できる

➤  $\sum_{j=1}^{N_x^i} \beta_i^j$  の値が高い学習用データほど、近似に貢献している

➤ カテゴリごとの  $\beta_i^j$  の和を用いて分類



# 実験



# 使用したデータセット：Caltech256

- 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

	<b>Caltech256</b>
画像総数	30,607枚
カテゴリ数	257カテゴリ
1カテゴリの 最小画像数	80枚
使用カテゴリ	257カテゴリ

ak47				
american-flag				
backpack				
baseball-bat				
baseball-glove				
basketball-hoop				

# 特徴抽出

## 特徴抽出器


大規模データセットで学習したCNNのモデル

- ILSVRCのデータセットで学習したもの
- 公開されている学習済みモデル2種類使用  
Aモデル：AlexNet      Bモデル：VGG19
- 全結合層の出力をその画像の特徴量とする
- 特徴量の次元数：4096次元

# 実験設定


	実験 1 従来手法	実験 2 疎・協働表現手法
比較手法	SVM,DL	CRC,SRC,NRC法
データセット	Caltech256	Caltech256
特徴量モデル	Aモデル	Bモデル

# 実験1：SVM,DLとの比較(Aモデル)




# SVM,DLとの比較

CMA法、SCMA法でk=1,2,4,8の時高い分類率をもつ



# SVM,DLとの比較

特に、 $k=1,2$ の時は約9,5ポイントの差がある



# SVM,DLとの比較


特に、 $k=1,2$ の時は約9.5ポイントの差がある



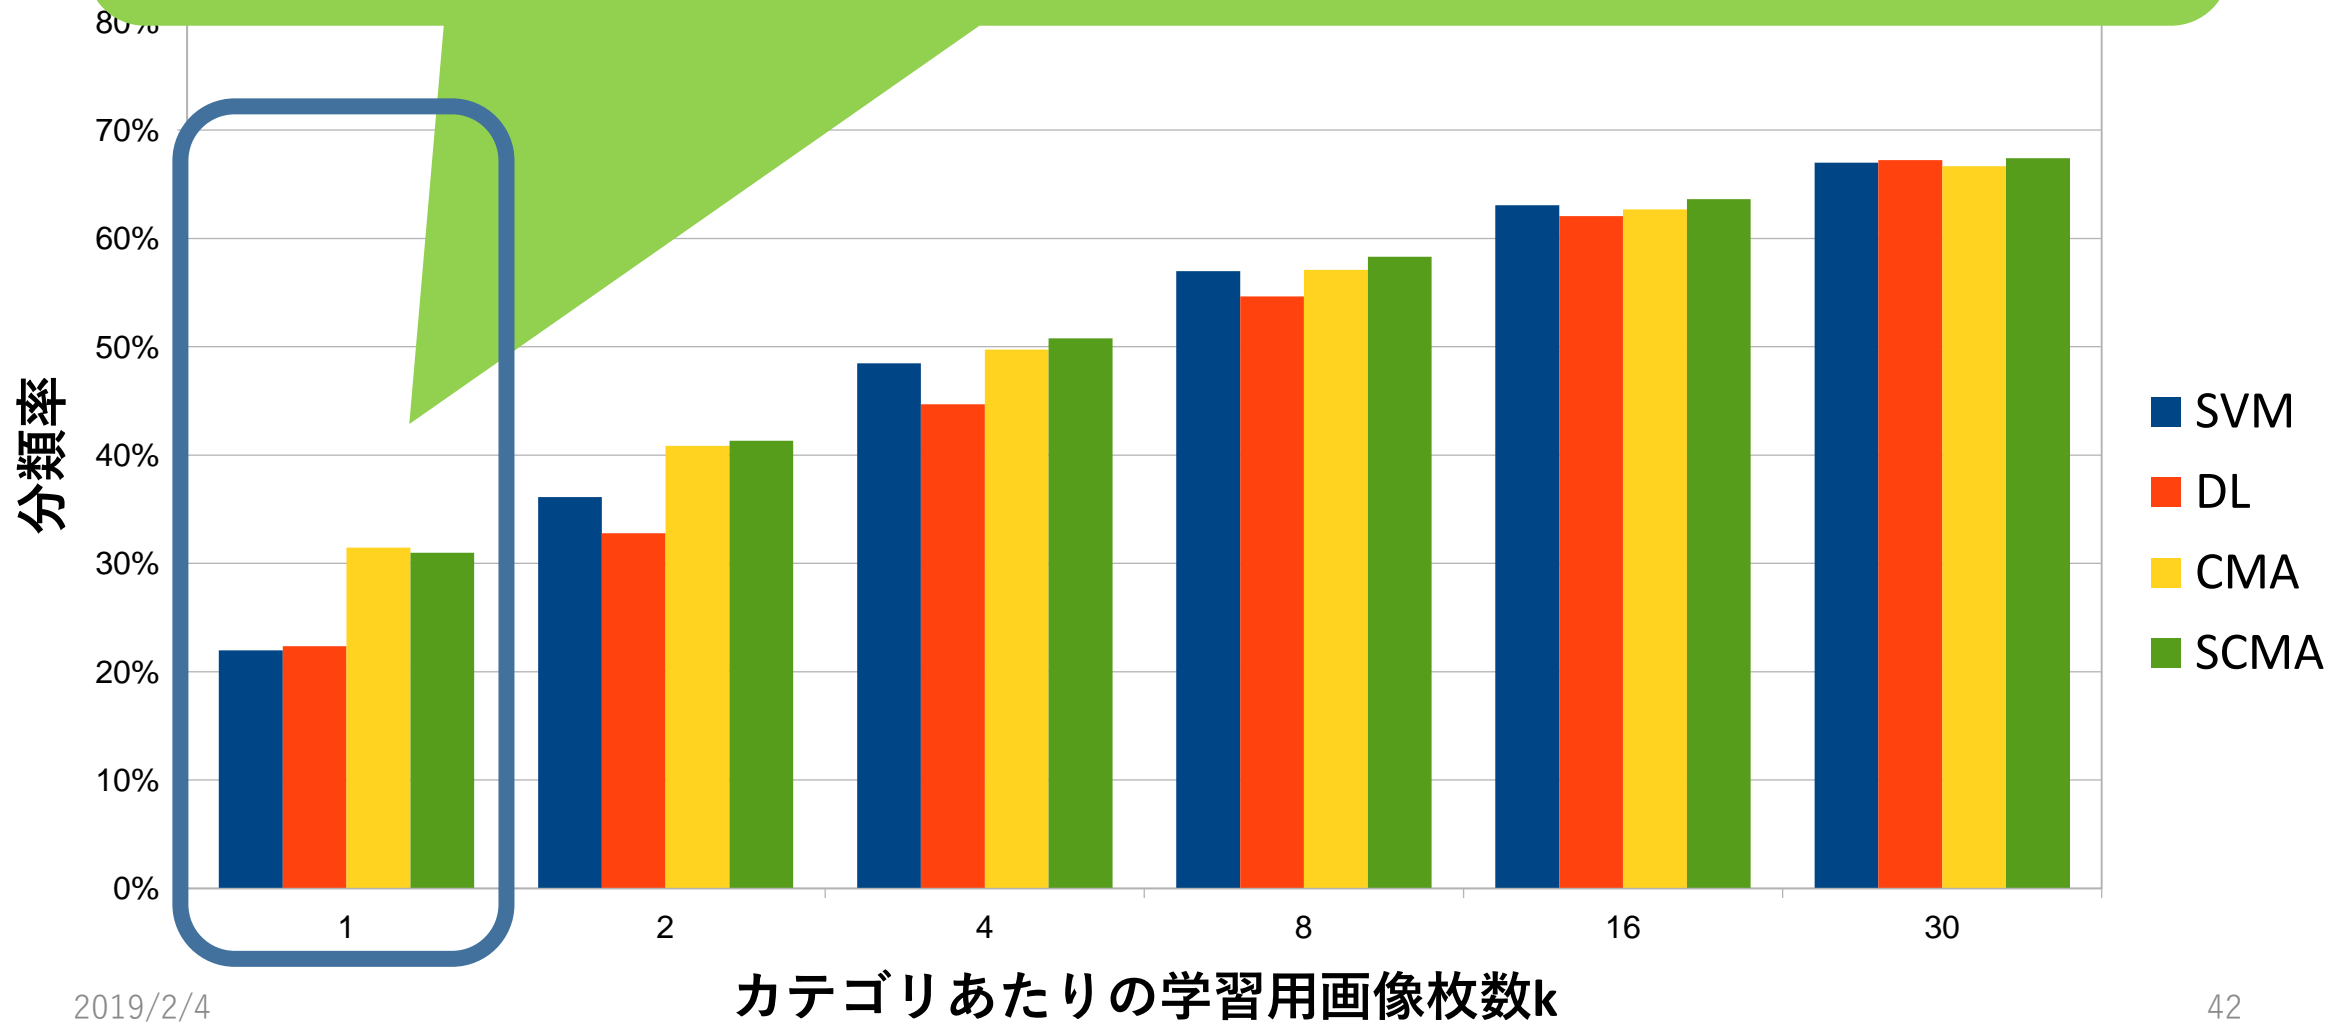


# SVM,DLとの比較

k=30の時はDL手法の分類率が**高くなるが差がない**




CMA法、SCMA法との比較  
k=1においてCMA法が分類率が高い



# CMA法、SCMA法との比較

k=2,4,8,16,30においてSCMA法が分類率が高い



# CMA法、SCMA法との比較

k=2,4,8,16,30においてSCMA法が分類率が高い

SCMA法はデータ枚数が多い場合  
分類率がより高い



# 実験設定

	実験 1 従来手法	実験 2 疎・協働表現手法
比較手法	SVM,DL	CRC,SRC,NRC法
データセット	Caltech256	Caltech256
特徴量モデル	Aモデル	Bモデル

## 実験 2 : 疎・協働表現手法(Bモデル)

手法 / 学習用画像枚数	1	30
CMA	37.75%	72.62%
CRC	37.33%	71.06%
SRC	37.20%	73.89%
NRC	37.23%	74.54%
SCMA	37.38%	74.76%

協働表現手法の比較(CMA,CRC)  
CMA法,CRC法は同程度の分類率である

手法 / 学習用画像枚数	1	10
CMA	37.75%	72.62%
CRC	37.33%	71.06%
SRC	37.20%	73.89%
NRC	37.23%	74.54%
SCMA	37.38%	74.76%

疎表現手法の比較(SRC,NRC,SCMA)  
疎表現手法では分類率は同程度

手法 / 学習用画像枚数	1	50
CMA	37.71%	72.62%
CRC	37.33%	71.06%
SRC	37.20%	73.89%
NRC	37.23%	74.54%
SCMA	37.38%	74.76%



疎表現手法と協働表現手法を比べると  
k=1の時、協働表現手法の分類率が高い

手法 / 学習用画像枚数	1	30
CMA	37.75%	72.62%
CRC	37.33%	71.06%
SRC	37.20%	73.89%
NRC	37.23%	74.54%
SCMA	37.38%	74.76%

疎表現手法と協働表現手法を比べると  
k=30の時、疎表現手法が高い

手法 / 学習用画像枚数	1	30
CMA	37.75%	72.62%
CRC	37.33%	71.06%
SRC	37.20%	73.89%
NRC	37.23%	74.54%
SCMA	37.38%	74.76%

# まとめ

- 一般画像分類においてCMA法が有効であるか調査
- スパース最適化を用いたSCMA法の提案
- 既存の従来手法との比較実験

- SCMA法はCMA法に対して学習用画像枚数が増えると分類率がより高くなることを示した
- 学習用画像が少ない状況ではSVMやDLより高い分類率を示した
- 従来の疎・協働表現手法とは同程度の分類率であることを示した

CMA法、SCMA法は一般画像分類に対しても有効

# 今後の課題

- 従来の疎・協働表現手法との違いを明らかにするために、データセットや特徴量を変更
- 疎・協働表現手法でのパラメータの最適化