

Apprentissage continu de représentations visuelles

ENSIMAG
2023-2024



KartEEK Alahari & Diane Larlus

<https://project.inria.fr/bigvisdata/>



Informations : Rappel

- Évaluation
 - Examen final écrit
 - Quizz sur des articles de recherche
 - <https://project.inria.fr/bigvisdata/grading>
- Points bonus
 - Presentation de papier
 - Voir la liste : <https://project.inria.fr/bigvisdata/presentations>
 - Votre choix par email

Aperçu du cours

Cours 1 : introduction

- Définition 'Big Data', applications, la chaîne, lien avec la recherche d'information par le contenu
- Liste des thèmes abordés: apprentissage supervisé, auto-supervisé, adaptation de domaine, apprentissage continu, problèmes en vidéos
- Définition de l'apprentissage supervisé et de ses étapes majeures: collection des données, choix d'une représentation, choix d'un modèle, apprentissage, sélection d'un modèle
- Collection des données: difficulté et ambiguïté de l'annotation d'images, exemples de grandes bases d'images standard
- Décomposition de l'erreur
- Représentation des données: approches traditionnelles: représentations puis apprentissage, *mid-level representations*, apprentissage de bout-en-bout
- Définition de l'apprentissage profond

Aperçu du cours

Cours 1 : introduction

- Définition 'Big Data', applications, la chaîne, lien avec la recherche d'information par le contenu
- Liste des thèmes abordés: apprentissage supervisé, auto-supervisé, adaptation de domaine, apprentissage continu, problèmes en vidéos
- Définition de l'apprentissage supervisé et de ses étapes majeures: collection des données, choix d'une représentation, choix d'un modèle, apprentissage, sélection d'un modèle
- Collection des données: difficulté et ambiguïté de l'annotation d'images, exemples de grandes bases d'images standard
- Décomposition de l'erreur
- Représentation des données: approches traditionnelles: représentations puis apprentissage, *mid-level representations*, apprentissage de bout-en-bout
- Définition de l'apprentissage profond

Cours 2 : introduction + adaptation de domaine

Quelques notions utiles

Comment créer des représentations visuelles ?

- Entraîner un modèle sur de grandes quantités de données annotées
- Utiliser ce modèle pour produire une représentation vectorielle pour chaque image proposée en entrée du modèle

Comment réutiliser des représentations visuelles ?

- Utiliser des représentations visuelles directement, optionnellement apprendre un modèle de décision par-dessus
- Utiliser le modèle précédent comme point de départ pour l'apprentissage et l'ajuster (*fine-tuning*) pour la tâche cible
- Appliquer une méthode d'adaptation, par exemple: adaptation de domaine

Comment créer des représentations visuelles quand on n'a pas d'annotations ?

- Introduction à l'apprentissage auto-supervisé

Dans ce cours

- Apprentissage supervisé (*supervised learning*)
 - Variantes, ex. Semi-supervisé (*semi-supervised*)
- Apprentissage auto-supervisé (*self-supervised*)
- L'adaptation de domaine (*domain adaptation*)
- Apprentissage continu (*continual learning*)
- **Problèmes en vidéos**

Reconnaissance d'actions

Action classification in videos



- Space-time interest points [Laptev, IJCV'05]
- Dense trajectories [Wang and Schmid, ICCV'13]
- Video-level CNN features

Space-time interest points (STIP)

- Space-time corner detector
[Laptev, IJCV 2005]


$$H = \det(\mu) + k \operatorname{tr}^3(\mu)$$

$$\mu = \begin{pmatrix} I_x I_x & I_x I_y & I_x I_t \\ I_x I_y & I_y I_y & I_y I_t \\ I_x I_t & I_y I_t & I_t I_t \end{pmatrix} * g(\cdot; \sigma, \tau)$$




STIP descriptors

Space-time interest points





Action classification

- Bag of space-time features + SVM [Schuldt'04, Niebles'06, Zhang'07]




Collection of space-time patches



HOG & HOF
patch
descriptors




Histogram of visual words



SVM
Classifier

State of the art for video description


- Dense trajectories [Wang et al., IJCV'13] and Fisher vector encoding [Perronnin et al. ECCV'10]



- Orderless representation


Dense trajectories [Wang et al., IJCV'13]

- Dense sampling at several scales
- Feature tracking based on optical flow for several scales
- Length 15 frames, to avoid drift





Descriptors for dense trajectory

- Histogram of gradients (HOG: 2x2x3x8)
- Histogram of optical flow (HOF: 2x2x3x9)



Descriptors for dense trajectory

- Motion-boundary histogram (MBHx + MBHy: 2x2x3x8)
 - spatial derivatives are calculated separately for optical flow in x and y, quantized into a histogram
 - captures relative dynamics of different regions
 - suppresses constant motions




Dense trajectories

- Advantages:
 - Captures the intrinsic dynamic structures in videos
 - MBH is robust to certain camera motion
- Disadvantages:
 - Generates irrelevant trajectories in background due to camera motion
 - Motion descriptors are modified by camera motion, e.g., HOF, MBH


Improved dense trajectories

- Improve dense trajectories by explicit camera motion estimation
- Detect humans to remove outlier matches for homography estimation
- Stabilize optical flow to eliminate camera motion





Recent CNN methods

Two-Stream Convolutional Networks for Action Recognition in Videos
[Simonyan and Zisserman NIPS14]



Learning Spatiotemporal Features with 3D Convolutional Networks
[Tran et al. ICCV15]



Quo vadis action recognition? A new model and the Kinetics dataset
[Carreira et al. CVPR17]

Inception Module (Inc.)

