

# Comprendre les données visuelles à grande échelle

**ENSIMAG**  
**2022-2023**



Karteek Alahari & Diane Larlus

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



# Informations

- Site web : <https://project.inria.fr/bigvisdata>
- Intervenants :
  - Karteek Alahari, chargé de recherche, Inria  
[karteek.alahari@inria.fr](mailto:karteek.alahari@inria.fr)
  - Diane Larlus, Principal scientist, Naver Labs  
[diane.larlus@naverlabs.com](mailto:diane.larlus@naverlabs.com)
- $12 \times 1h30 = 18h$  de cours



# Informations

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

# Les données à grande échelle



*Wikipedia*

## Le *big data*

- littéralement « grosses données »
- **méga données**
- **données massives**

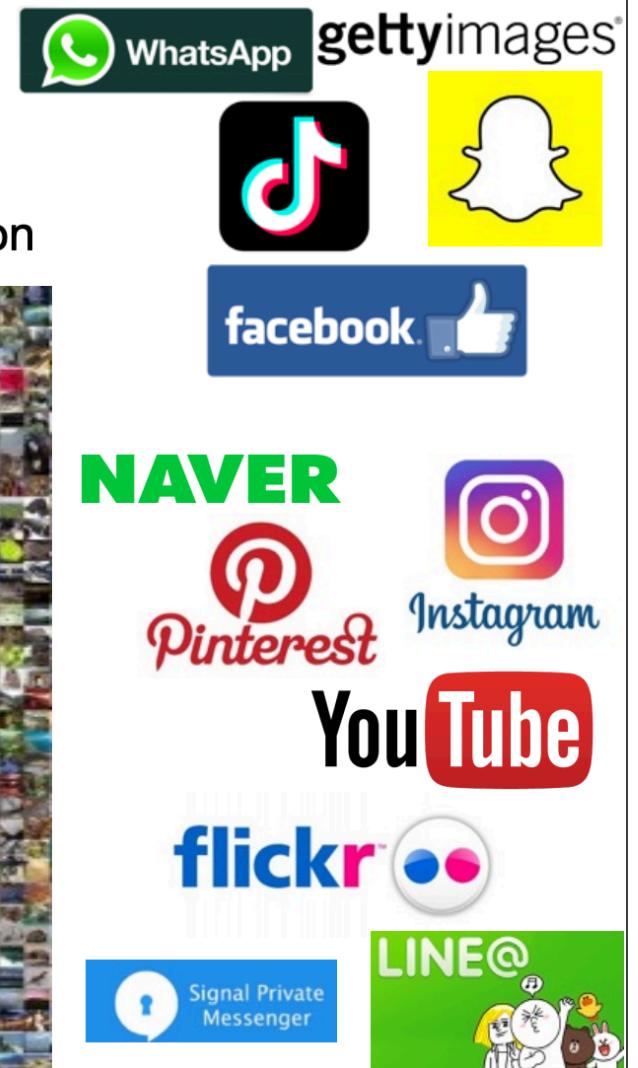
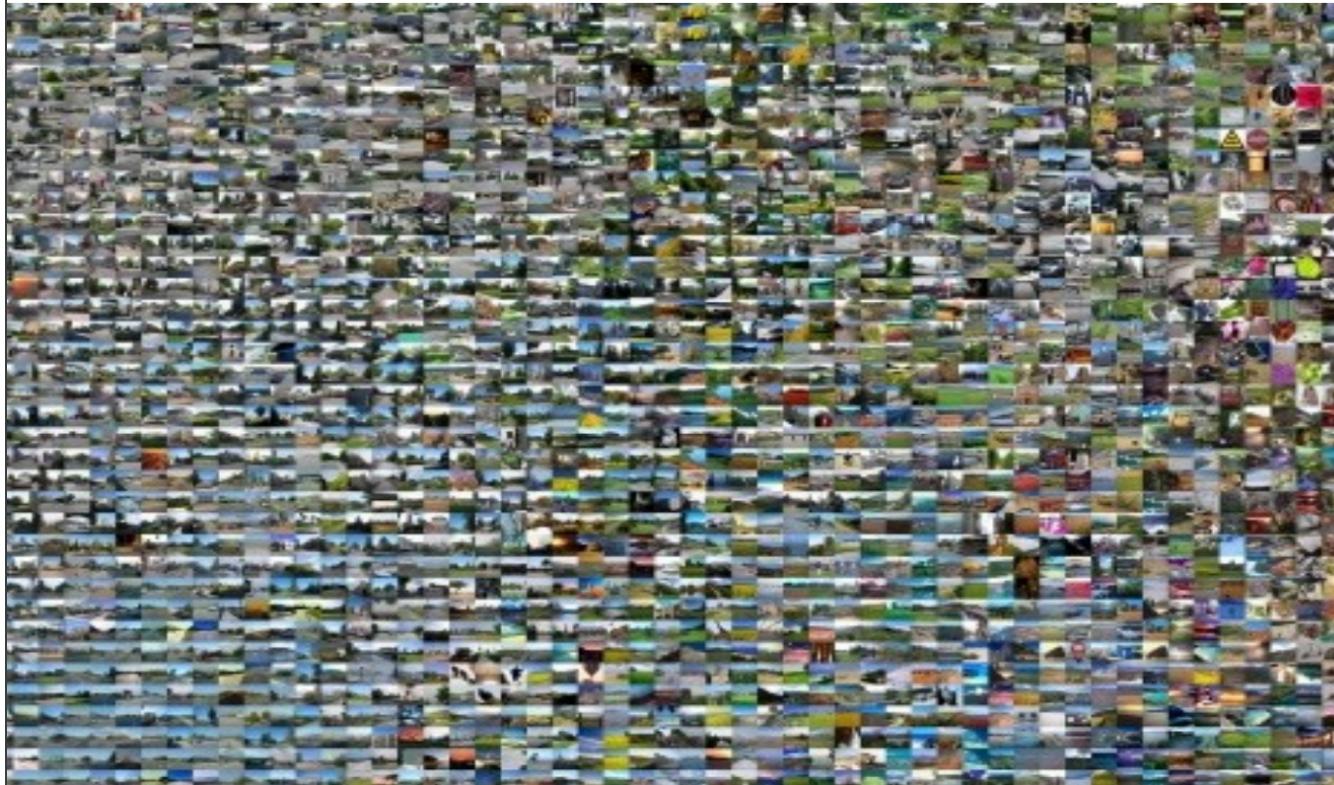
désigne un ensemble de données qui sont tellement volumineuses qu'elles en deviennent difficiles à travailler avec des outils classiques de gestion de base de données

- Nécessite le développement d'outils spécifiques

# Les données visuelles à grande échelle

ou *Big Visual Data*

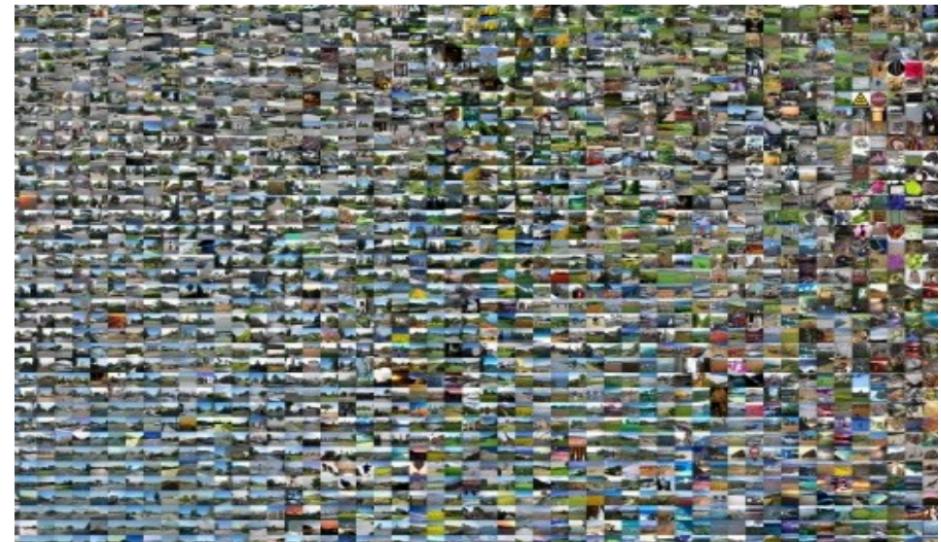
sont devenues une façon majeure de transférer l'information



# Quelques chiffres

- Croissance très importante, en raison de l'accumulation des contenus numériques auto-produits par le grand public

- ▶ **ImDb** recense plus de 400 000 films
- ▶ Images (semi-)pro : **Corbis, Getty, Fotolia**
  - ▶ centaines de milliers d' images
- ▶ **Facebook** – chiffres de 2013
  - ▶ 350 millions de nouvelles photos / jour
  - ▶ 250 milliards de photos stockées
  - ▶ 3,000 années de vidéo générées chaque jour
- ▶ **Flickr** – novembre 2016
  - ▶ 13 milliards de photos
- ▶ **Youtube**
  - ▶ 35h / min uploaded in 2011
  - ▶ 100h / min uploaded in 2014



2022 : Flickr – 25 milliards, Youtube – 400h / min

# Exemples d'applications du Big Visual Data

- News/Films à la demande
- Commerce électronique
- Informations médicales
- Systèmes d'informations géographiques
- Architecture/Design
- Protection du copyright / traçage de contenu
- Géolocalisation, système de navigation
- Enquêtes policières
- Militaire
- Expérimentations scientifiques
- Enseignement
- Archivage, gestion des bases de données de contenu (personnelles ou professionnelles)
- Moteur de recherche (Internet, collections personnelles)
- Voitures et autres véhicules autonomes
- Robotique, plateformes d'intelligence ambiante
- Autres applications industrielles
- Etc.

Slide courtesy : D. Larlus

# Chaîne du Big Visual Data

1. Génération
  - Outils de production et de création
2. Représentation
  - Utilisation de formats de représentation différents
3. Stockage
4. Transmission
  - Problème de réseaux, architecture
5. Recherche d'information
  - Taches d'analyse d'images
6. Distribution
  - Conception de serveur de streaming, interfaces d'application, etc.

# Chaîne du Big Visual Data

## 1. Génération

- Outils de production et de création

## 2. Représentation

- Utilisation de formats de représentation différents

## 3. Stockage

## 4. Transmission

- Problème de réseaux, architecture

## 5. Recherche d'information

- Taches d'analyse d'images

## 6. Distribution

- Conception de serveur de streaming, interfaces d'application, etc.

# 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

# 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

# Supervised Learning

- Input:  $x$  (images, text, emails...)
- Output:  $y$  (spam or non-spam...)
- (Unknown) Target Function
  - $f: X \rightarrow Y$  (the “true” mapping / reality)
- Data
  - $(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)$
- Model / Hypothesis Class
  - $g: X \rightarrow Y$
  - $y = g(x) = \text{sign}(w^T x)$
- Learning = Search in hypothesis space
  - Find best  $g$  in model class

# Basic Steps of Supervised Learning

- **Set up** a supervised learning problem
- **Data collection**
  - Start with training data for which we know the correct outcome provided by a teacher or oracle
- **Representation**
  - Choose how to represent the data
- **Modeling**
  - Choose a hypothesis class:  $H = \{g: X \rightarrow Y\}$
- **Learning/Estimation**
  - Find best hypothesis you can in the chosen class
- **Model Selection**
  - Try different models. Picks the best one. (More on this later)
- **If happy stop**
  - Else refine one or more of the above

Slide courtesy : D. Batra

# Basic Steps of Supervised Learning

- Set up a supervised learning problem
- **Data collection**
  - Start with training data for which we know the correct outcome provided by a teacher or oracle
- **Representation**
  - Choose how to represent the data
- **Modeling**
  - Choose a hypothesis class:  $H = \{g: X \rightarrow Y\}$
- **Learning/Estimation**
  - Find best hypothesis you can in the chosen class
- **Model Selection**
  - Try different models. Picks the best one. (More on this later)
- If happy stop
  - Else refine one or more of the above

Slide courtesy : D. Batra

# Annotation d'images : difficulté et ambiguïté

- Contenu de métadonnées
  - Les données “brutes” (fichier image, fichier son) contiennent des informations sémantiques = directement compréhensibles pour l'utilisateur
- Ces métadonnées proviennent
  - Soit de propriétés de descripteurs d'objets (ex. Couleur moyenne d'une image)
  - Soit de données d'autres médias (ex. GPS)
  - Soit d'annotations manuelles (ex. Tags)

# Exemple : Exchangeable image file format (Exif)

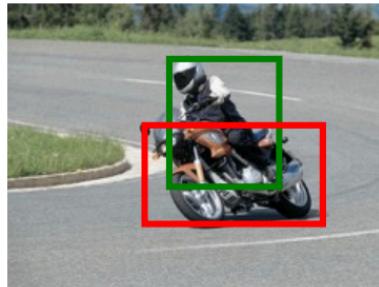
- Spécification pour les formats d'images des appareils numériques
  - ▶ non uniformisé, mais largement utilisé
- Pour JPEG, TIFF, RIFF, ne supporte pas, PNG ou GIF
- Le format supporte souvent
  - ▶ Date et heure, enregistrés par l'appareil
  - ▶ Les paramètres de l'appareil
    - Dépendent du modèle : inclus la marque et des informations diverses telles que le temps d'ouverture, l'orientation, la focale, l'ISO, etc.
  - ▶ Une vignette de prévisualisation
  - ▶ La description et les informations de copyright
  - ▶ Les coordonnées GPS
- Ce format est supporté par de nombreuses applications

# Contenu et métadonnées ... vs acquisitions d'annotations spécifiques

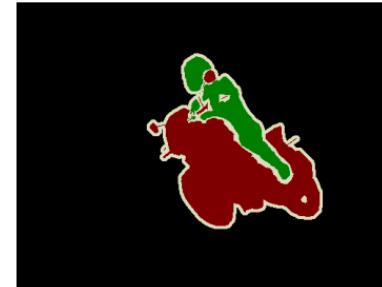
- Il est parfois nécessaire d'acquérir des annotations spécifiques à la tâche qui nous intéresse
- On parle de données labélisées
- Elles sont souvent associées à l'apprentissage supervisé
  - Dans ce cas elles sont utilisées comme données d'apprentissage pour apprendre un modèle de prédiction utile à la tâche à résoudre  
(Des exemples de tâches automatisables seront données juste après)
- L'apprentissage supervisé est un exemple d'apprentissage machine

# Annotation d'images

- Il faut choisir un type d'annotation
  - Ensemble de *tags* / étiquettes (une ou plusieurs étiquettes par image)
  - Position approximative de tous les objets (boîtes englobantes)
  - Position précise de tous les objets (masques de segmentation)
  - Phrases descriptives
- Il faut une cohérence des annotations sur toute une base



people    motorbike



people    motorbike



motorcyclist turning right

# Ambiguïté de l'annotation d'images

- Difficile de se mettre d'accord sur les annotations
- Exemple: Instructions pour la création d'une vérité terrain pour la compétition PASCAL 2009

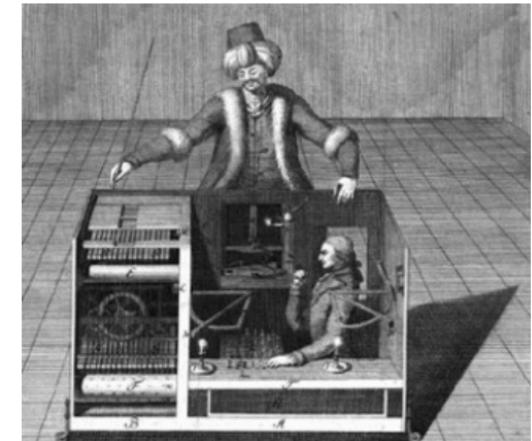
<b>What to label</b>	<p><i>All objects of the defined categories, unless:</i> you are unsure what the object is. the object is very small (at your discretion). less than 10-20% of the object is visible. If this is not possible because too many objects, mark image as bad.</p>
<b>Viewpoint</b>	Record the viewpoint of the 'bulk' of the object e.g. the body rather than the head. Allow viewpoints within 10-20 degrees. If ambiguous, leave as 'Unspecified'. Unusually rotated objects e.g. upside-down people should be left as 'Unspecified'.
<b>Bounding box</b>	Mark the bounding box of the visible area of the object ( <i>not</i> the estimated total extent of the object). Bounding box should contain all visible pixels, except where the bounding box would have to be made excessively large to include a few additional pixels (<5%) e.g. a car aerial.
<b>Truncation</b>	If more than 15-20% of the object lies outside the bounding box mark as Truncated. The flag indicates that the bounding box does not cover the total extent of the object.
<b>Occlusion</b>	If more than 5% of the object is occluded within the bounding box, mark as Occluded. The flag indicates that the object is not totally visible within the bounding box.



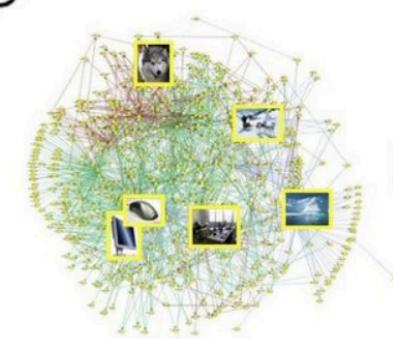
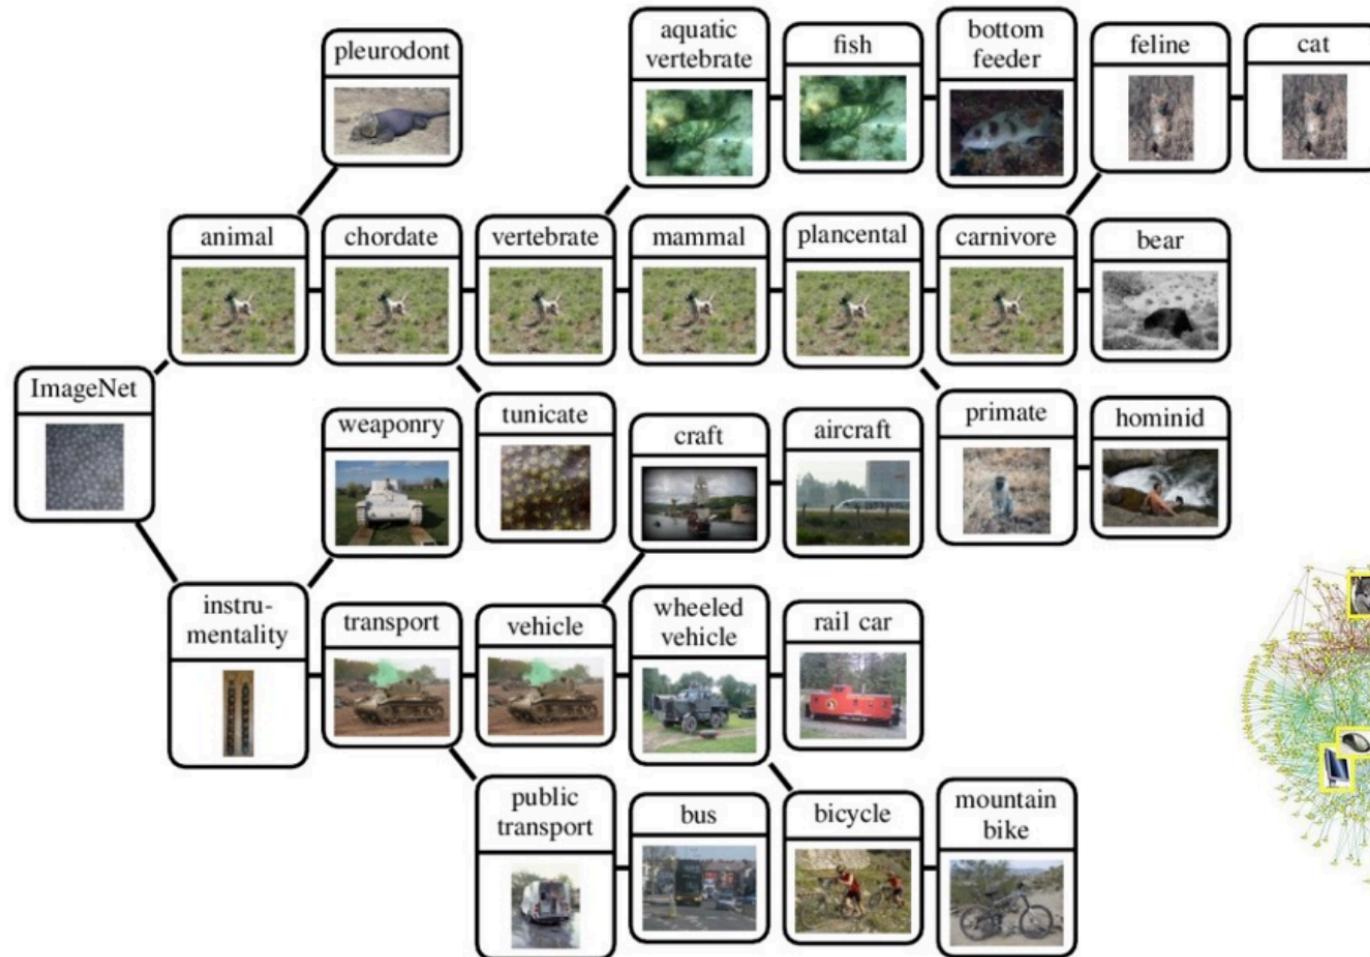
➤ Malgré ces instructions,  
on observe tout de même  
des incohérences  
dans les annotations

# Ambiguïté de l'annotation d'images

- Obtenir des annotations précises est une tâche fastidieuse
- Une solution courante: plateformes de **crowdsourcing**, comme Amazon Mechanical Turk
  - *Crowdsourcing : externalisation ouverte ou production participative en français*
- *Amazon Mechanical Turk* (AMT)
  - Origine du nom : le **Turc mécanique** ou **l'automate joueur d'échecs** est un célèbre canular construit à la fin du XVIII<sup>e</sup> siècle : il s'agissait d'un prétendu automate doté de la faculté de jouer aux échecs
- L'utilisation d'*Amazon Mechanical Turk* a permis la construction de bases d'images annotées qui ont grandement participé à l'avancée de la recherche en vision par ordinateur, par exemple:
  - ImageNet (<http://image-net.org/>)
  - MS Coco (<http://mscoco.org/>)
  - Visual Genome (<https://visualgenome.org/>)
  - Base VQA (<http://www.visualqa.org/>)



# ImageNet

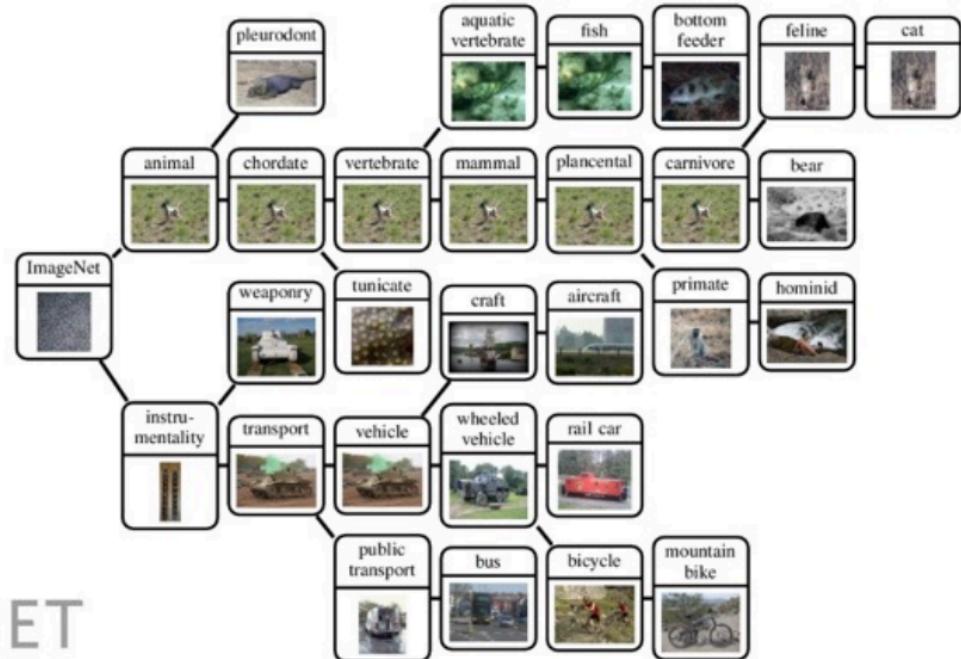
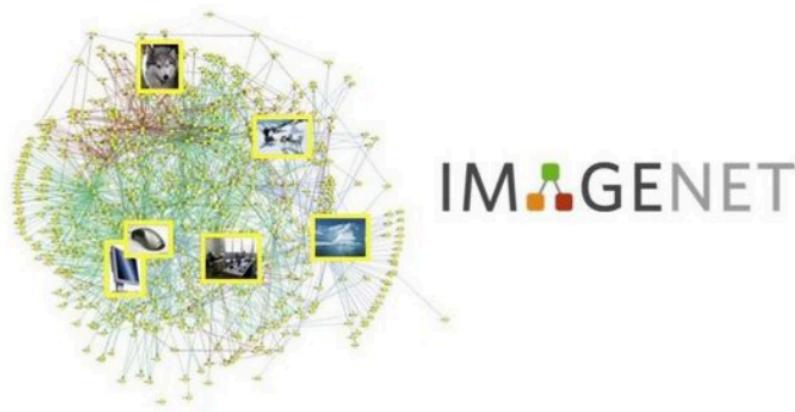


IMAGENET

Slide courtesy : D. Larlus

# ImageNet : pushing the state of the art

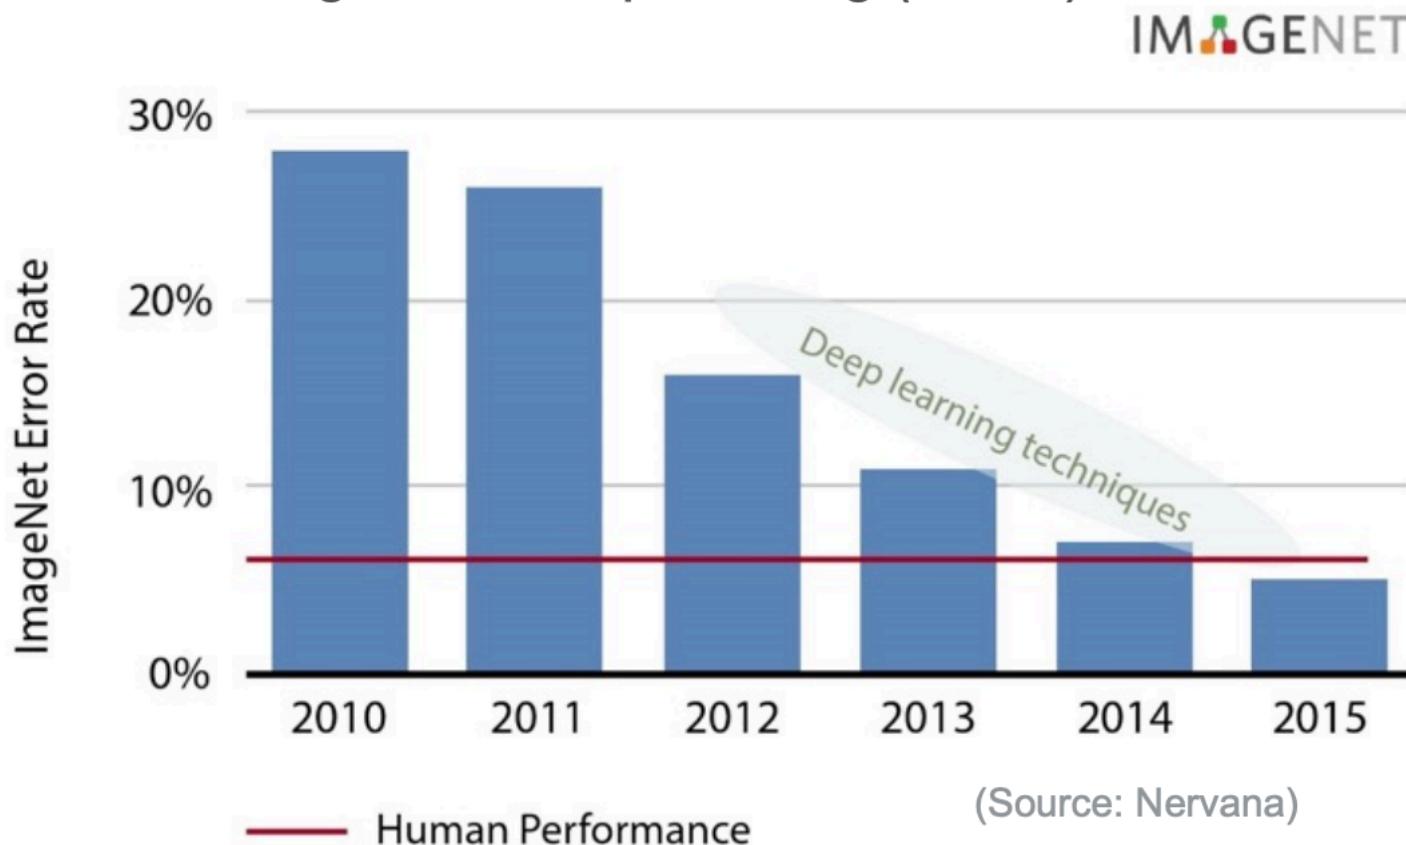
- ImageNet challenge:
  - Task: Categorize images into 1000 classes



Slide courtesy : D. Larlus

# ImageNet : pushing the state of the art

- ImageNet challenge:
  - Task: Categorize images into 1000 classes
  - Until 2011: “standard” techniques (Fisher Vector)
  - Starting 2012: deep learning (CNNs)



# MS COCO

- *Common Objects in Contexts*

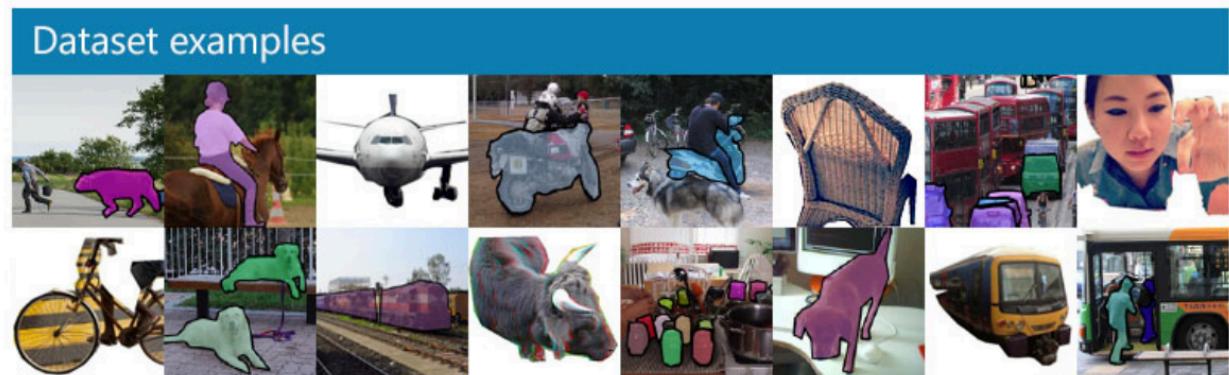


“What is COCO?” from its webpage

COCO is a large-scale object detection, segmentation, and captioning dataset

COCO has several features:

- Object segmentation
- Recognition in context
- Superpixel stuff segmentation
- 330K images (>200K labeled)
- 1.5 million object instances
- 80 object categories
- 91 stuff categories
- 5 captions per image
- 250,000 people with keypoints

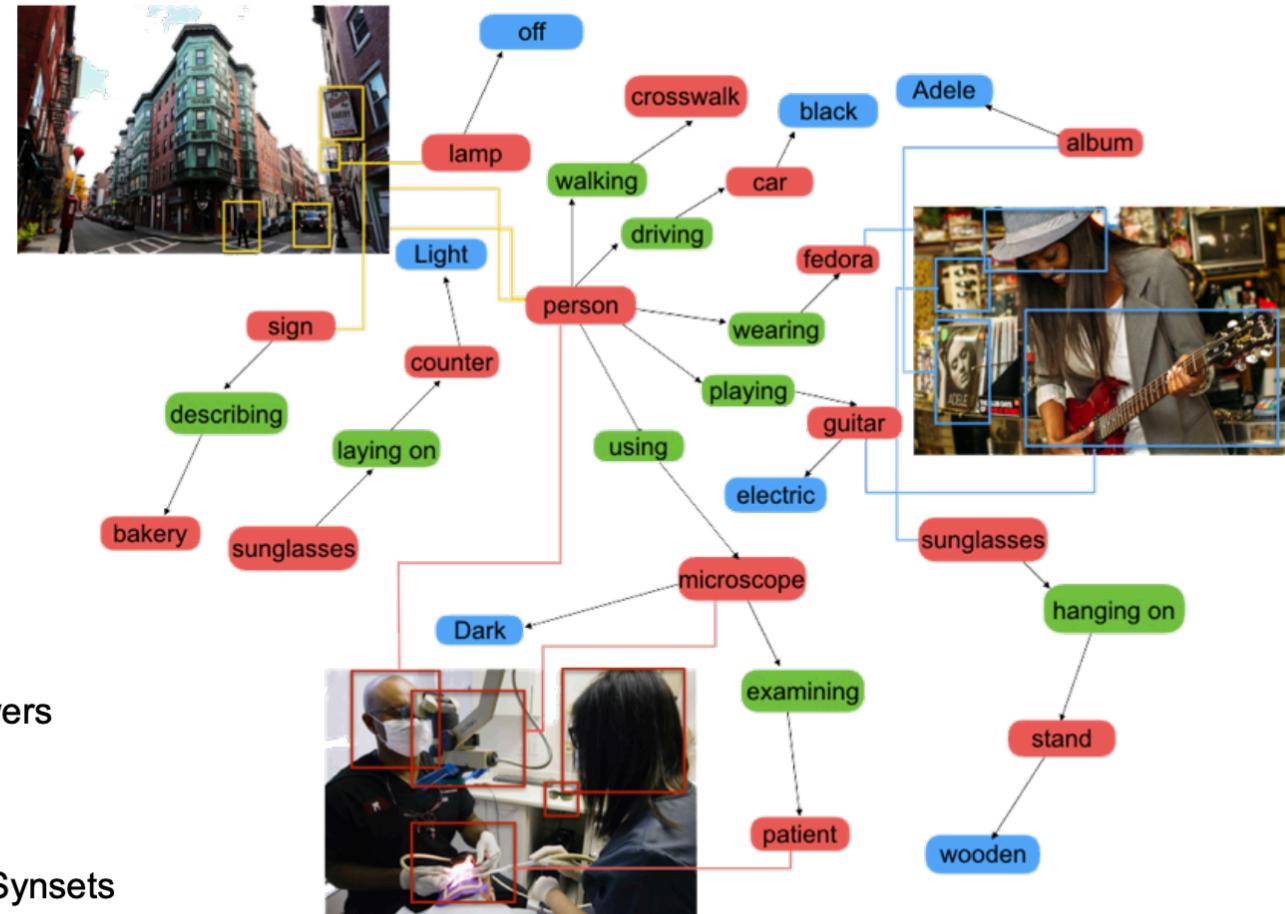


<http://cocodataset.org>

Slide courtesy : D. Larlus

# Visual Genome

- 108,077 Images
- 5.4 Million Region Descriptions
- 1.7 Million Visual Question Answers
- 3.8 Million Object Instances
- 2.8 Million Attributes
- 2.3 Million Relationships
- Everything Mapped to Wordnet Synsets



## [Visual Genome: Connecting Language and Vision Using Crowdsourced Dense Image Annotations](#)

Ranjay Krishna, Yuke Zhu, Oliver Groth, Justin Johnson, Kenji Hata, Joshua Kravitz, Stephanie Chen, Yannis Kalantidis, Li Jia-Li, David Ayman Shamma, Michael Bernstein, Li Fei-Fei

# Basic Steps of Supervised Learning

- **Set up** a supervised learning problem
- **Data collection**
  - Start with training data for which we know the correct outcome provided by a teacher or oracle
- **Representation**
  - Choose how to represent the data
- **Modeling**
  - Choose a hypothesis class:  $H = \{g: X \rightarrow Y\}$
- **Learning/Estimation**
  - Find best hypothesis you can in the chosen class
- **Model Selection**
  - Try different models. Picks the best one. (More on this later)
- **If happy stop**
  - Else refine one or more of the above

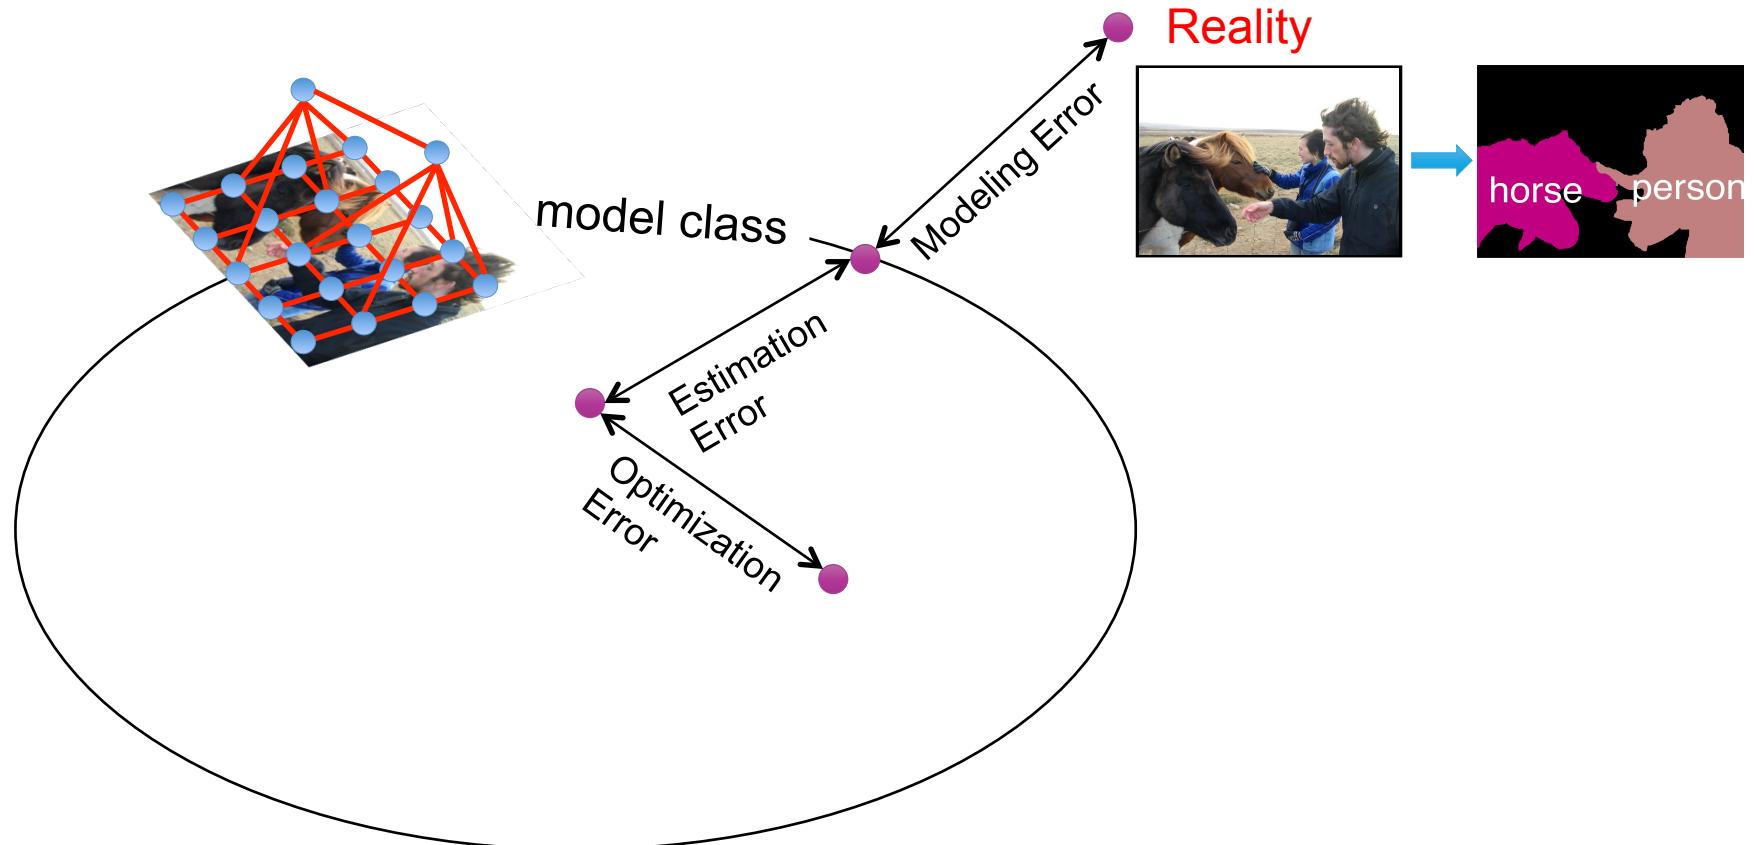
Slide courtesy : D. Batra

# Basic Steps of Supervised Learning

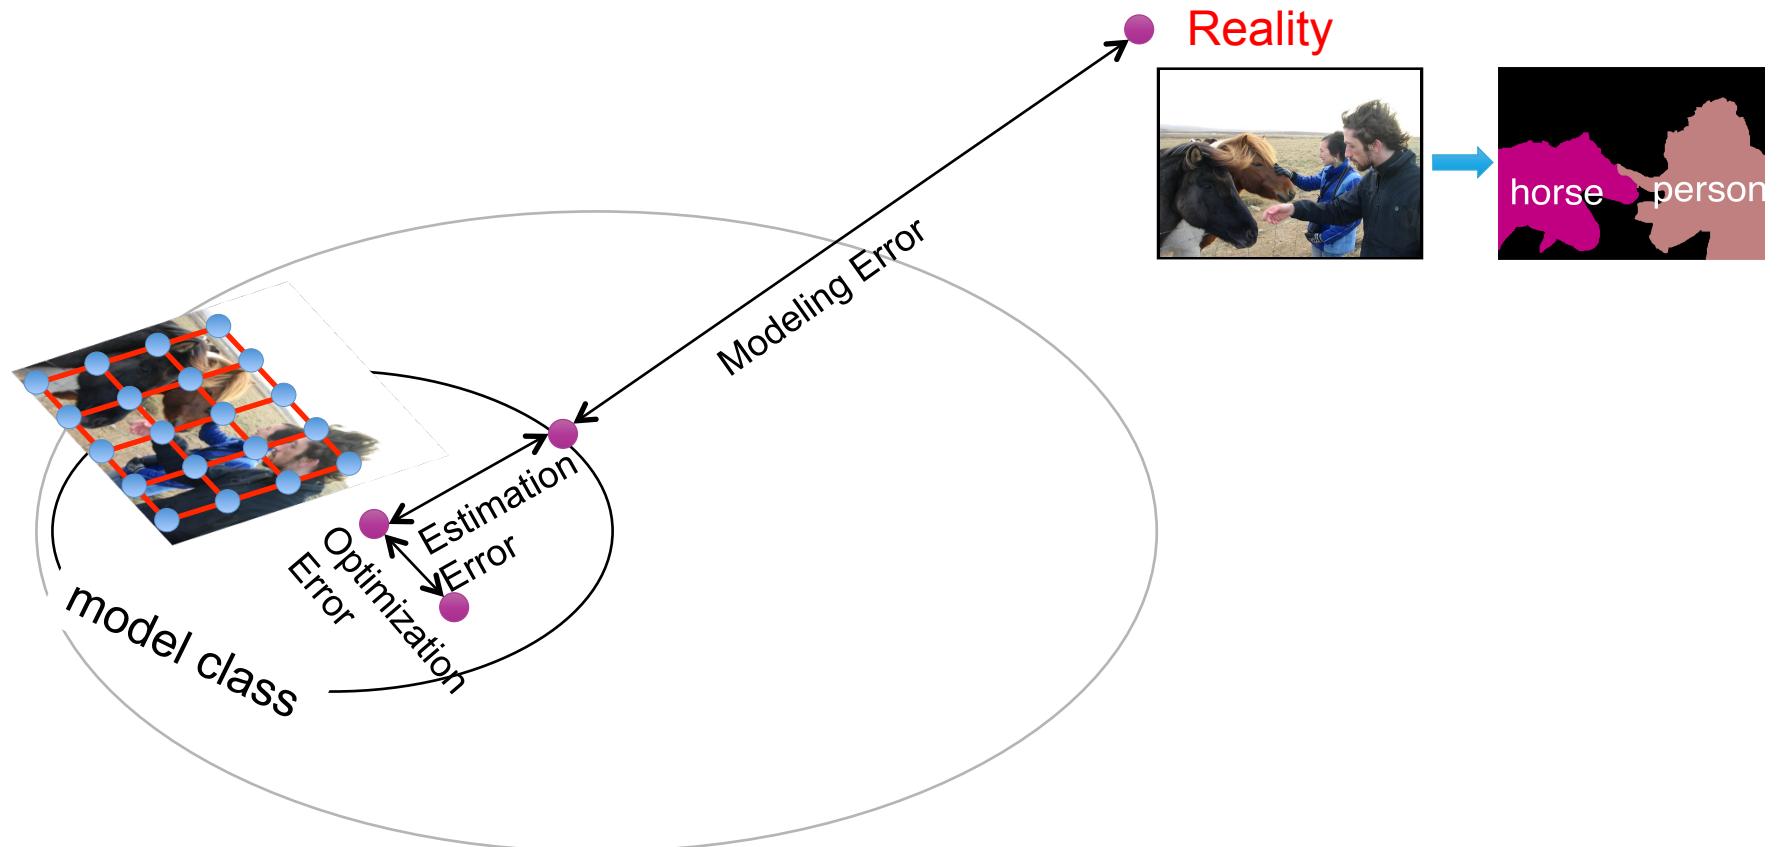
- **Set up** a supervised learning problem
- **Data collection**
  - Start with training data for which we know the correct outcome provided by a teacher or oracle
- **Representation**
  - Choose how to represent the data
- **Modeling**
  - Choose a hypothesis class:  $H = \{g: X \rightarrow Y\}$
- **Learning/Estimation**
  - Find best hypothesis you can in the chosen class
- **Model Selection**
  - Try different models. Picks the best one. (More on this later)
- If happy stop
  - Else refine one or more of the above

Slide courtesy : D. Batra

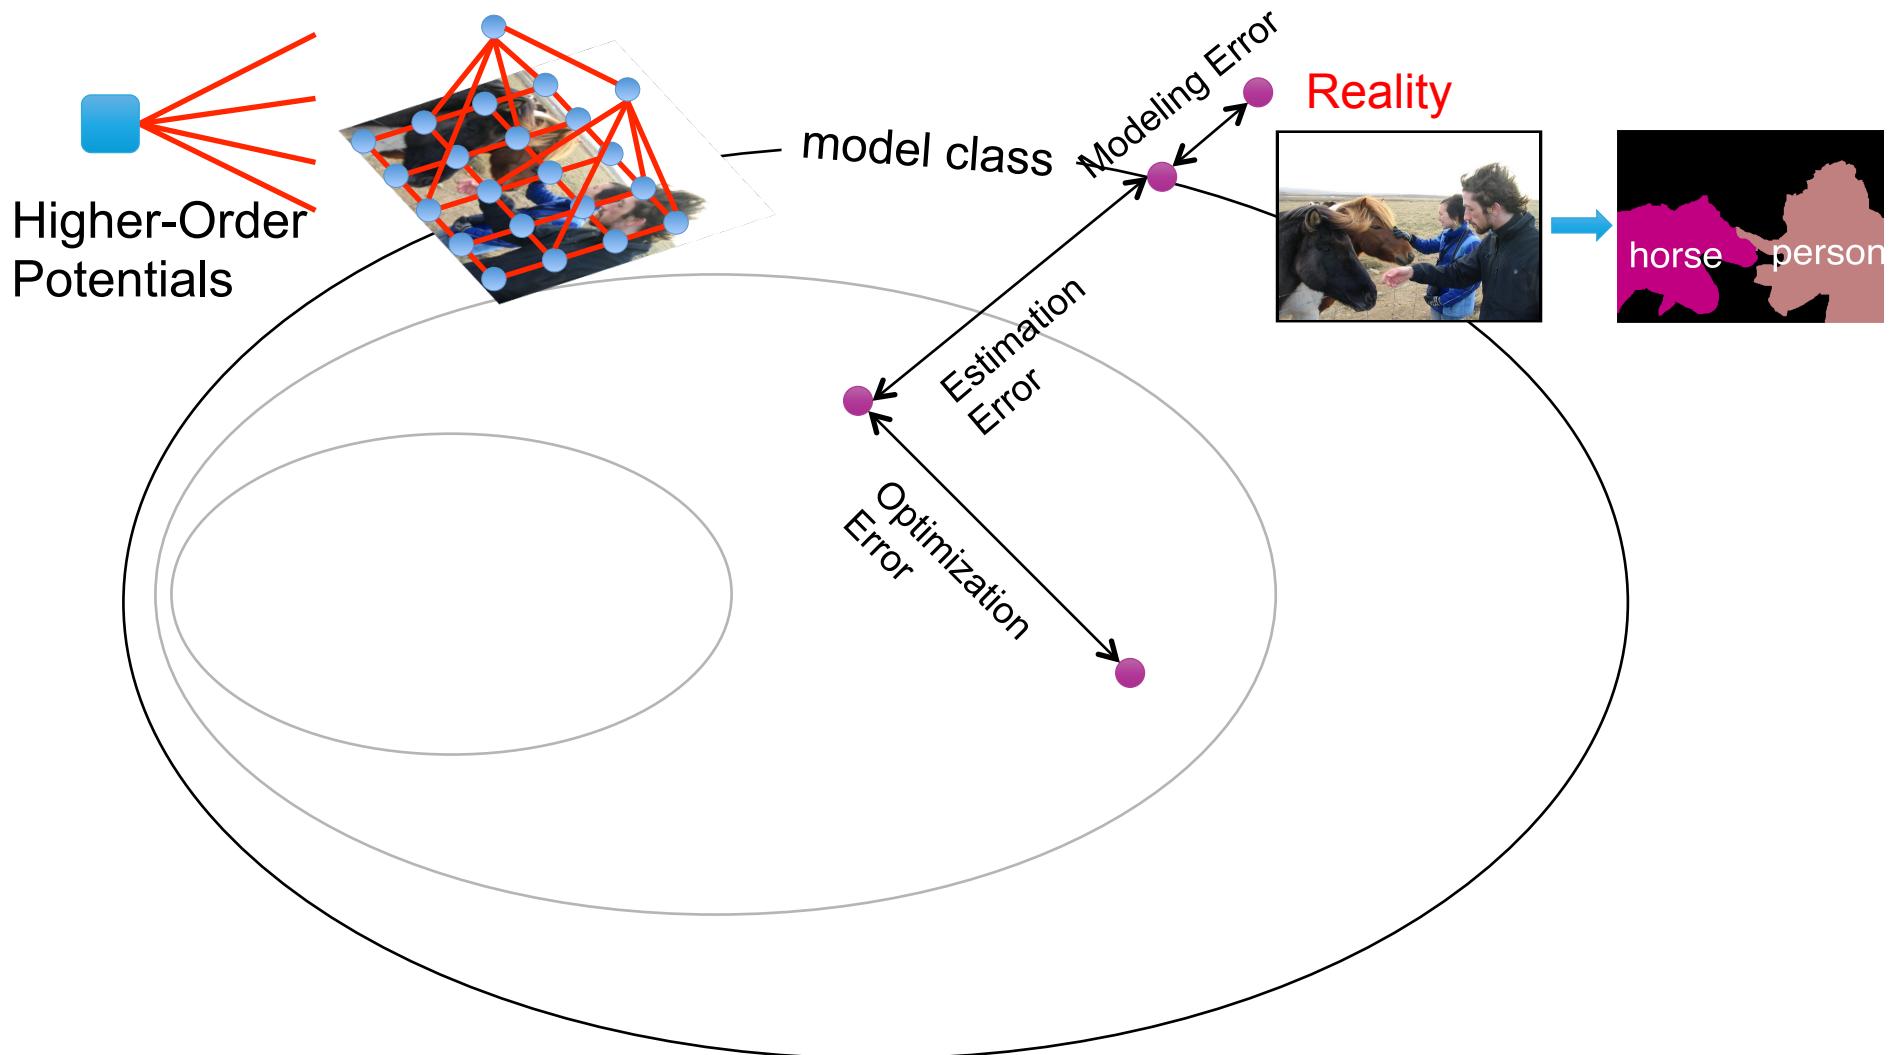
# Error Decomposition



# Error Decomposition



# Error Decomposition

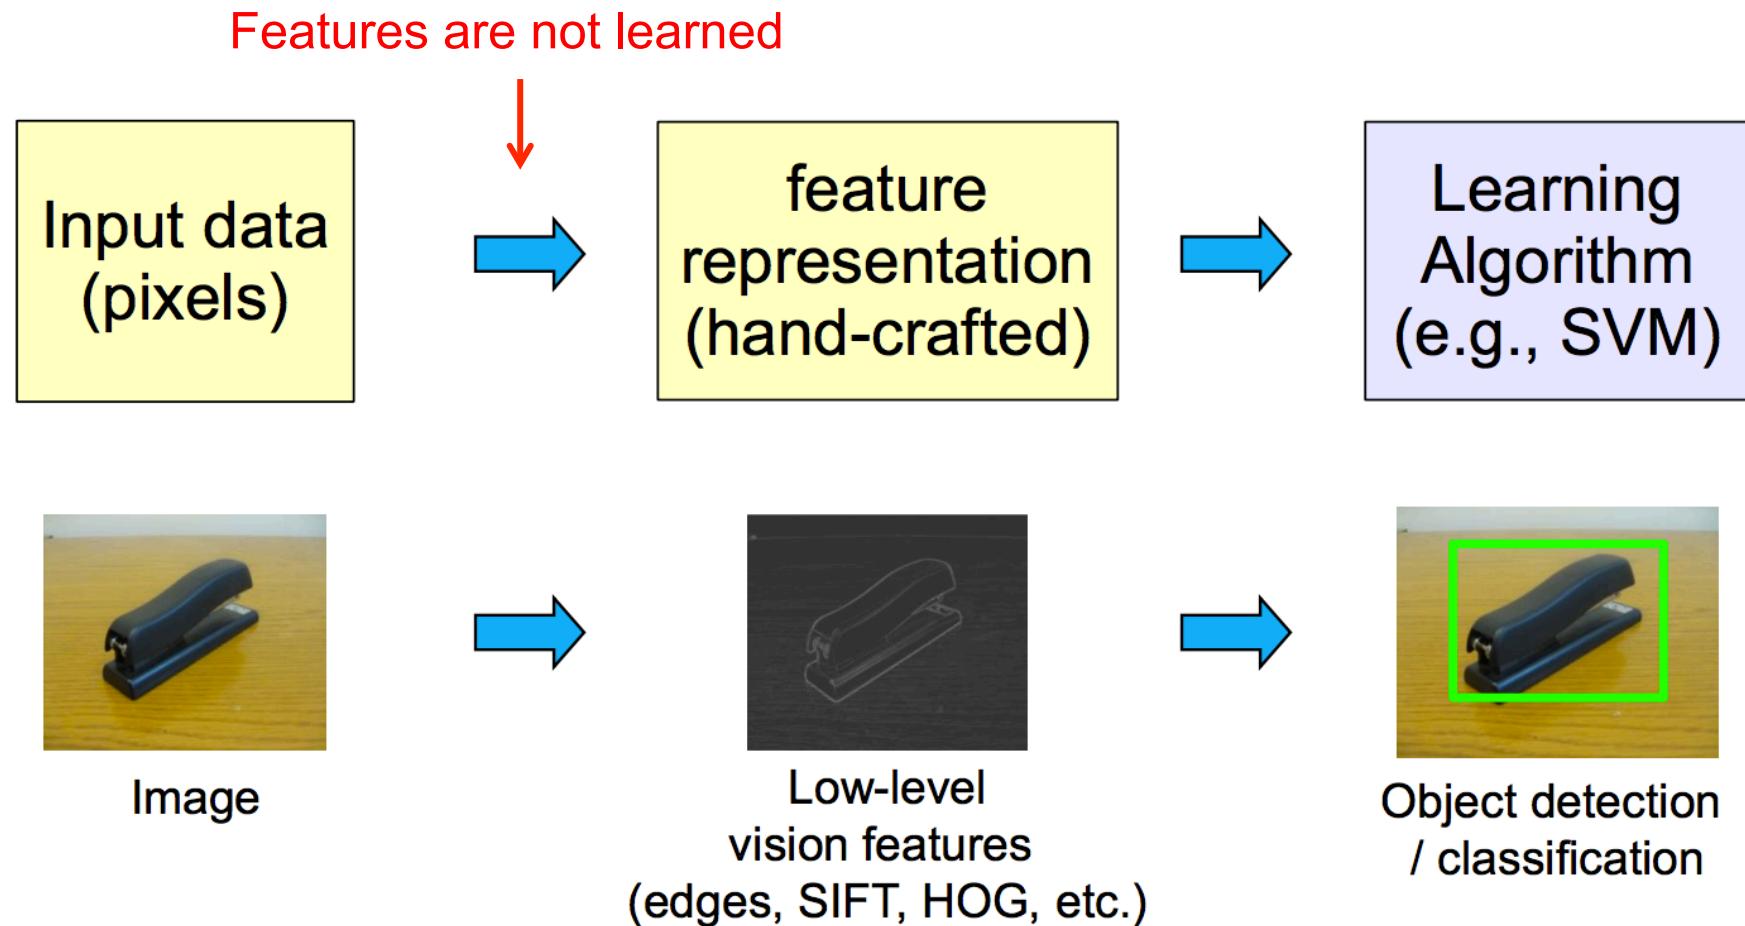


# Recall: Basic Steps of Supervised Learning

- Set up a supervised learning problem
- **Data collection**
  - Start with training data for which we know the correct outcome provided by a teacher or oracle
- **Representation**
  - Choose how to represent the data
- **Modeling**
  - Choose a hypothesis class:  $H = \{g: X \rightarrow Y\}$
- **Learning/Estimation**
  - Find best hypothesis you can in the chosen class
- **Model Selection**
  - Try different models. Picks the best one. (More on this later)
- If happy stop
  - Else refine one or more of the above

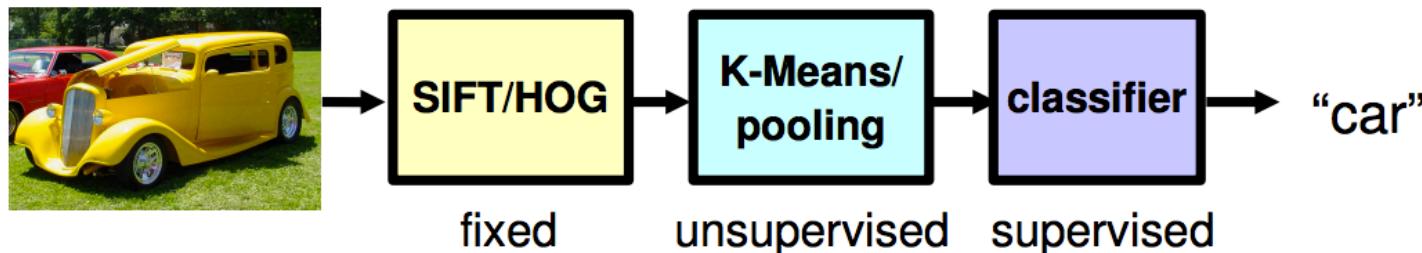
Slide courtesy : D. Batra

# Traditional Approaches for Recognition

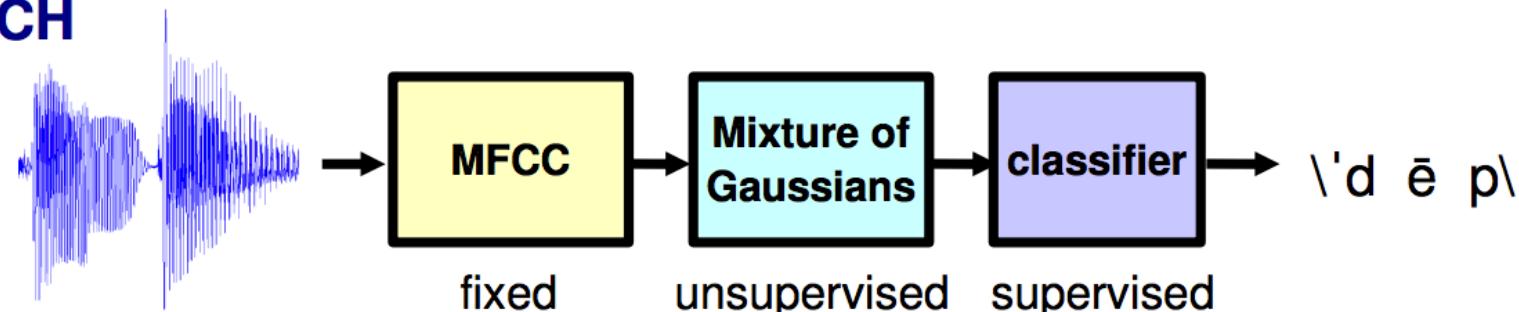


# Traditional Approaches for Recognition

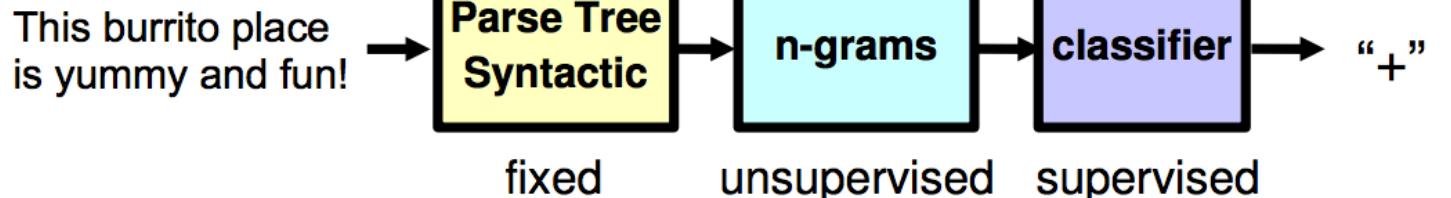
## VISION



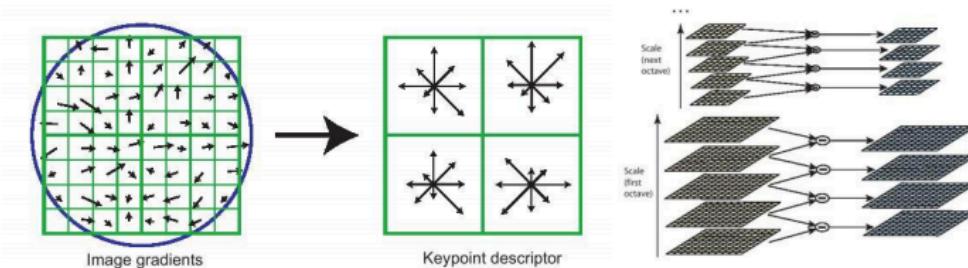
## SPEECH



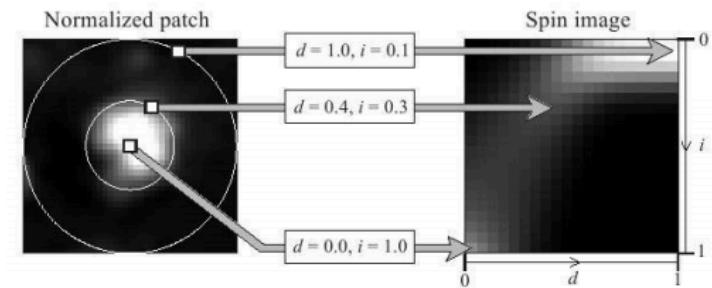
## NLP



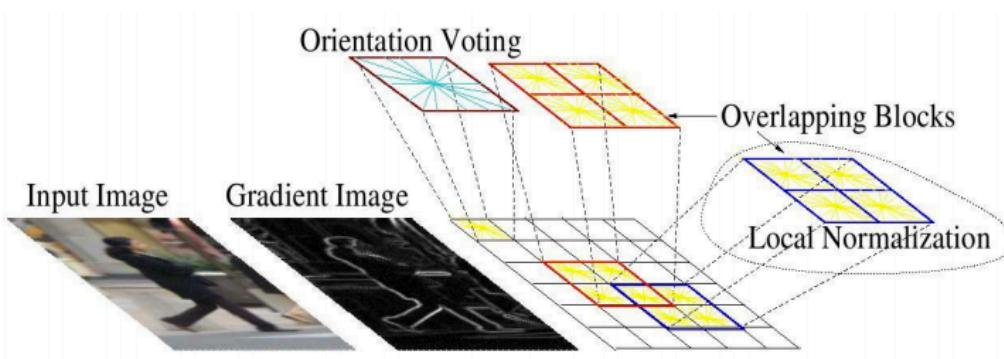
# Computer Vision Features



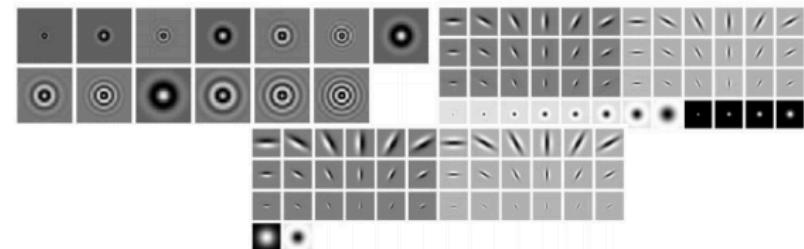
SIFT



Spin image



HoG



Textons

and many others:

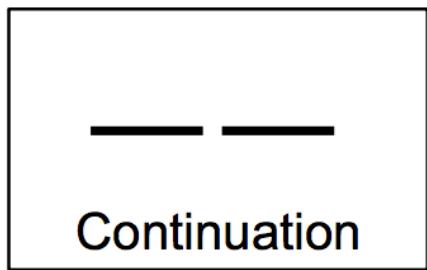
**SURF, MSER, LBP, Color-SIFT, Color histogram, GLOH, .....**

# Computer Vision Features

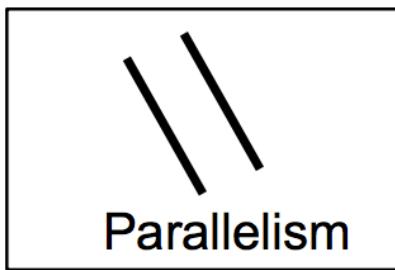
- Features are key to progress
- Have led to impressive results in various competitions (e.g., PASCAL VOC)
- Where do we go from here? Better features?  
Better classifiers?

# Mid-level Representations

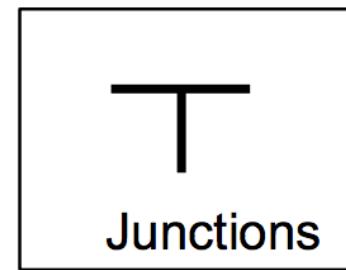
- Mid-level cues



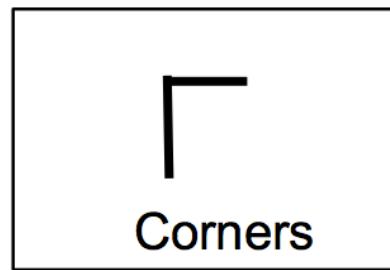
Continuation



Parallelism



Junctions



Corners

“Tokens” from Vision by D.Marr:



- 
- Object parts:



# Mid-level Representations

## VISION

pixels → edge → texton → motif → part → object

## SPEECH

sample → spectral  
band → formant → motif → phone → word

## NLP

character → word → NP/VP/.. → clause → sentence → story

Difficult to hand-engineer → What about learning them?

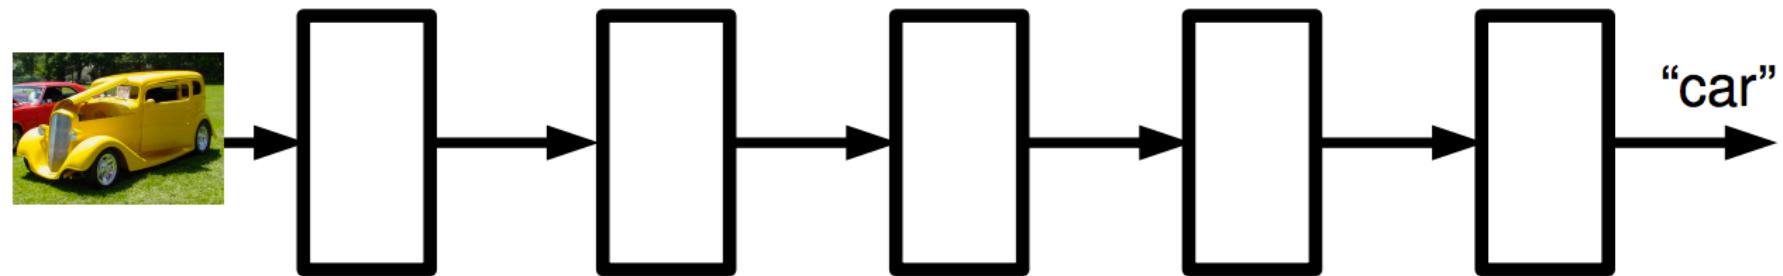
# Learning Feature Hierarchy

- Learn hierarchy
- All the way from pixels → classifier
- One layer extracts features from output of previous layer



- Train all layers jointly

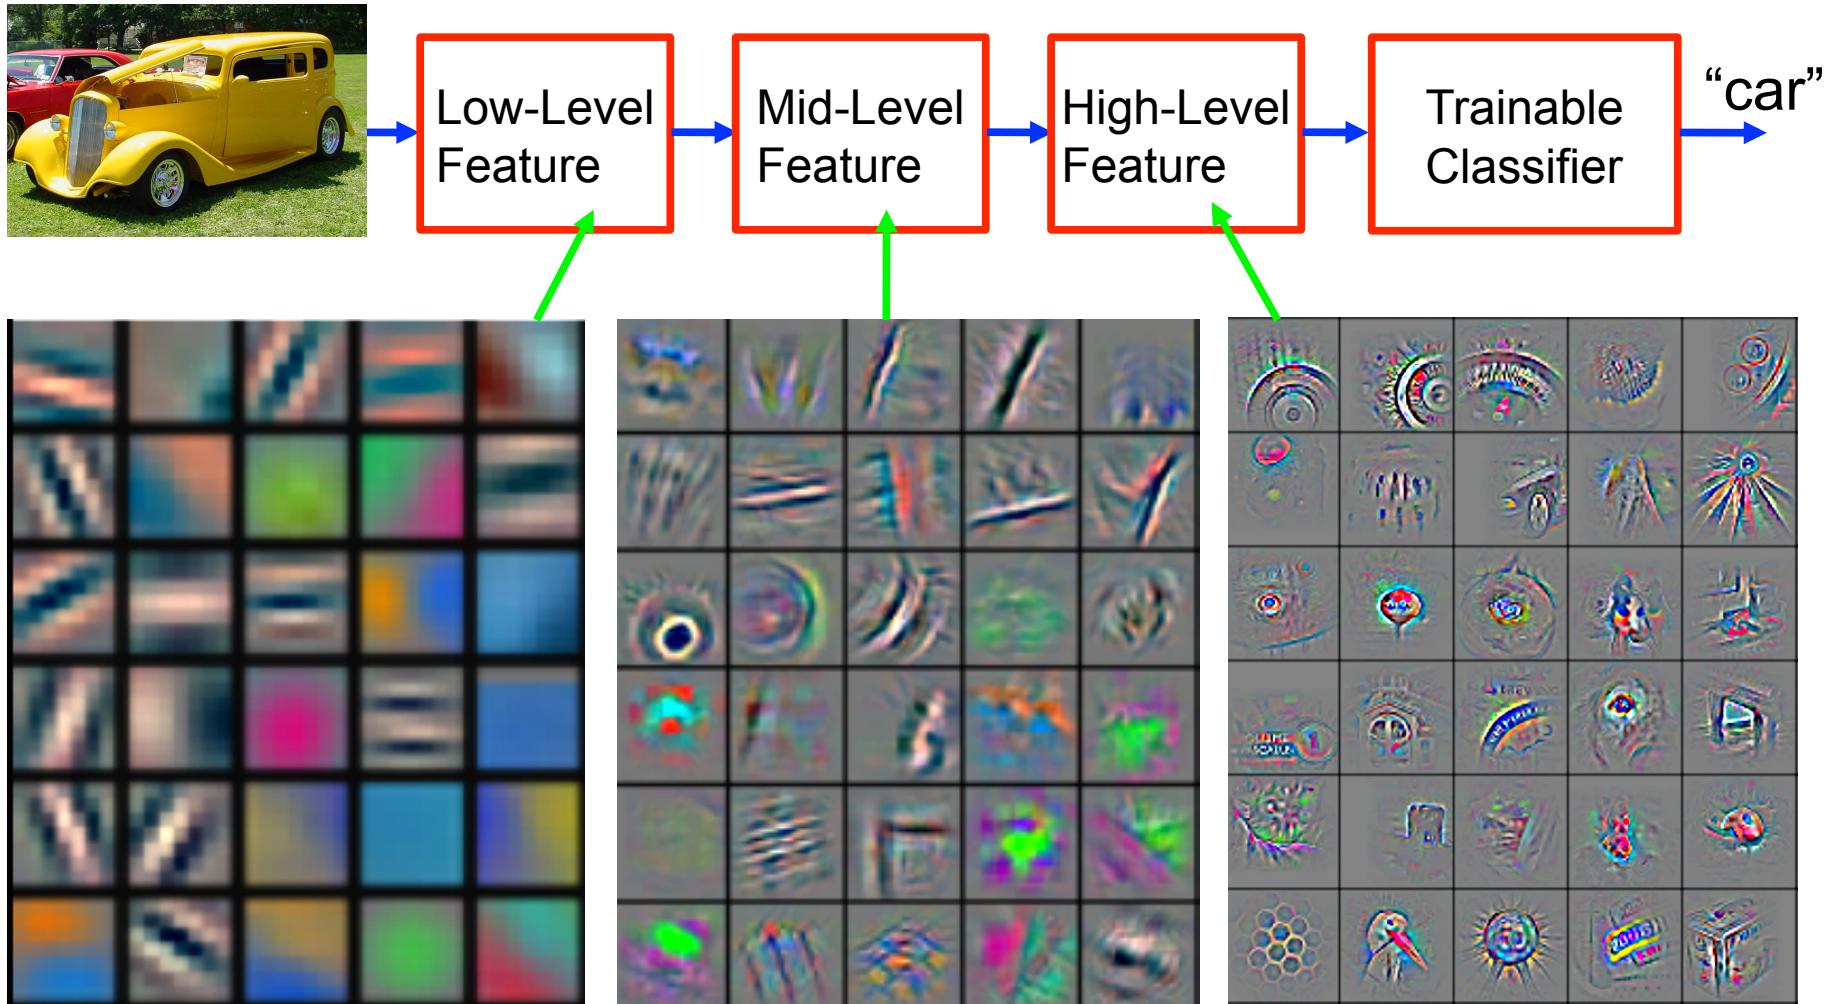
# Deep Learning



## What is Deep Learning

- Cascade of non-linear transformations
- End to end learning
- General framework (any hierarchical model is deep)

# Deep Learning = Hierarchical Compositionality



Feature visualization of convolutional net trained on ImageNet from [Zeiler & Fergus 2013]