

# Learning to Compress Images and Videos

von Li Cheng &  
S.V. N. Vishwanathan

vorgetragen von Michael Wächter

# Motivation

- Bild- & Video-Kompression
  - herkömmliche Verfahren sind frequenzbasiert
  - Aufsatz auf herkömmlichen Verfahren
  - zusätzlicher Platzgewinn ohne Qualitätsverlust
- SW-Bild- & SW-Video-Kolorierung
  - herkömmliche Verfahren zeitaufwändig und manuell
  - jetzt semiautomatisch

# Motivation

- Bild-Kompression
  - Auswahl repräsentativer Pixel
  - Lernen eines Farbvorhersage-Modells
  - Speichern des SW-Bilds + Farbpixel
  - Rekonstruktion des Farbbilds
- Video-Kompression analog

# Motivation

- SW-Bild- & SW-Video-Kolorierung
  - wie Kompression
  - automatische Pixelauswahl fällt weg
  - Farbinfos werden stattdessen vom Benutzer vorgegeben

# Überblick

- Motivation
- Begriffsklärung
- Funktionsweise
  - Kolorierung mit Semi-Supervised Learning
  - Farbpixelauswahl mit Active Learning
- Experimente
- Fazit
- Bemerkungen

# Begriffsklärung

- Semi-Supervised Learning

$X$  Beobachtungsraum

$Y \subset \mathbb{R}$  Labelraum

$\{(x_i, y_i)\}_{i=1}^m$  gelabelte Beispiele

$\{x_i\}_{i=m+1}^n \subset X$  ungelabelte Beispiele

$f \in H$  zu minimierende Zielfunktion

$l : X \times Y \times H \rightarrow \mathbb{R}$  Loss – Funktion

- Graph-basierte Methoden:
  - Beispiele als Knoten (gelabelte und ungelabelte)
  - Nachbarschaftsbeziehungen als Kanten
    - Achtung: Glattheitseigenschaften

# Begriffsklärung

- Graph

$$G = (V, E \subseteq V \times V)$$

– ungerichtet, gewichtet

- Adjazenz-Matrix

*W mit  $W_{ij} \in (0, \infty)$  falls  $(v_i, v_j) \in E$  und  $W_{ij} = 0$  sonst*

- Grad-Matrix

$$D \text{ mit } D_{ii} = \sum_j W_{ij}$$

# Begriffsklärung

- Laplace-Matrix

$$L = D - W$$

- normalisierte Laplace-Matrix

$$\Delta = D^{-1/2} L D^{-1/2}$$

# Funktionsweise - Kolorierung

$$\text{minimiere } \sum_{i=1}^n [f(x_i) - \sum_{i \sim j} w_{ij} f(x_j)]^2 + \sum_{i=1}^m l(f(x_i), y_i)$$

$l(f(x_i), y_i) = 0$  falls  $f(x_i) = y_i$  und  $\infty$  sonst

oder

$$l(f(x_i), y_i) = (f(x_i) - y_i)^2$$

$$\forall i: w_{ij} \geq 0 \text{ und } \sum_{i \sim j} w_{ij} = 1$$

- Kantengewichte:

- räumliche Nachbarschaft und Bildtextur
- rationale Funktion 2. Grades bzgl. Helligkeitsdifferenz
- ggf. zeitliche Nachbarschaft

# Funktionsweise - Kolorierung

- Laplacian Regularized Least Square algorithm:

$$\text{minimiere } J(f) = c \|f\|_H^2 + \frac{\lambda}{n^2} \|f\|_G^2 + \frac{1}{m} \sum_{i=1}^m l(x_i, y_i, f)$$

$$\text{mit } f = [f(x_1), \dots, f(x_m), \dots, f(x_n)],$$

$$\|f\|_G^2 = f^T \nabla_G f = f^T L^2 f \text{ oder } f^T \Delta f$$

# Funktionsweise - Kolorierung

- Lösung von LapRLS:

*es existieren  $\alpha_i$  so, dass  $f(x) = \sum_{i=1}^n \alpha_i k(x_i, x)$*

$$\alpha = \left( I_m K + cmI + \frac{\lambda m}{n^2} \nabla_g K \right)^{-1} y$$

*mit  $\alpha = (\alpha_1, \dots, \alpha_m, \dots, \alpha_n)^T$ ,*

*$I_m \in \mathbb{R}^{n,n}$  mit  $m \times m$ -Einheitsmatrix links oben und 0 sonst,*

*$K$  mit  $K_{ij} = k(x_i, x_j)$ ,*

*$\nabla_G = L^2$  oder  $\Delta$*

*und  $y = (y_1, \dots, y_m, 0, \dots, 0)^T$*

# Funktionsweise - Kolorierung

- Implementationsdetails:
  - YUV-Farbraum, Vorhersage von U und V getrennt
  - Kernel: standard Gaussian kernel (mit Parameter  $\sigma$ )
  - Mean Square Loss statt  $\partial$ -Loss
  - $\Delta$  statt  $L^2$
  - keine zeitliche Nachbarschaft!
  - Problem: Matrixinvertierung
    - Matrix zur Berechnung von  $\alpha$  groß und dicht
    - Berechnung einer Super-Pixel-Repräsentation des Ausgangsbilds ==> 1000-5000 Segmente

# Funktionsweise - Pixelauswahl

- automatische Pixelauswahl wird für Handkoloration abgeschaltet
- ansonsten per Active Learning:
  - Lerner wählt Beispiele aus und fragt nach Labels
  - muss dafür Kosten bezahlen (hier: Speicherplatz)
- Programmablauf:
  - Start mit ein paar zufälligen gelabelten Pixeln
  - Lernen des Modells

# Funktionsweise - Pixelauswahl

- Bild wird mit Modell vorhergesagt und mit Zielbild verglichen

- Qualitätsmaß:  $PSNR = 20 \log_{10} \frac{255}{\sqrt{MSE}}$

$$MSE = \frac{1}{n^2} \sum_{i,j=1}^n (I_{ij} - I'_{ij})^2$$

- Fehlerbereiche werden geclustert
  - aus jedem Fehlercluster wird ein Pixel gewählt, seine Farbinformation abgefragt und der Labelmenge hinzugefügt
  - Abbruchkriterium:
    - PSNR=38 oder 5000 abgefragte Pixel
    - außerdem möglich: PSNR in einem Plateau
-

# Experimente

- SW-Bild-Kolorierung



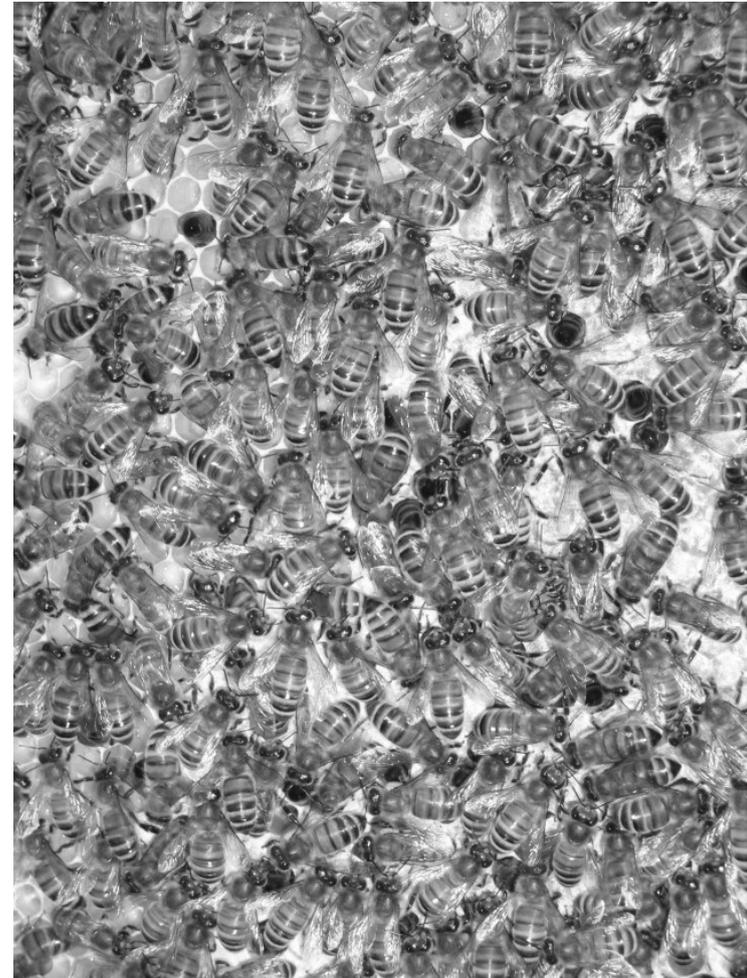
Input with partial color labels



Colorized Output

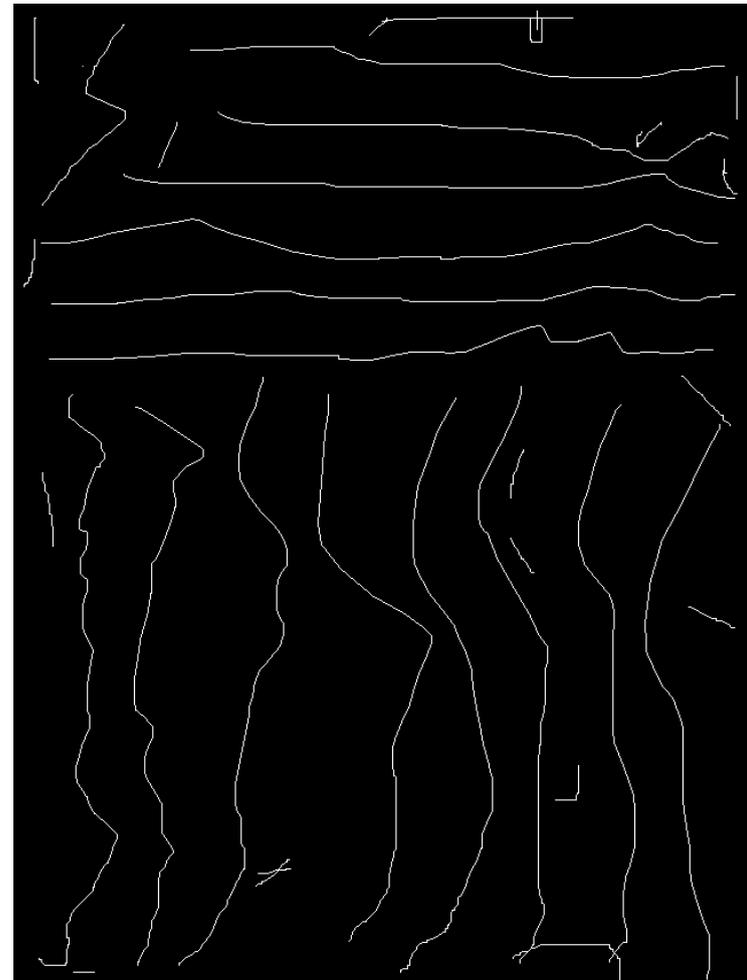
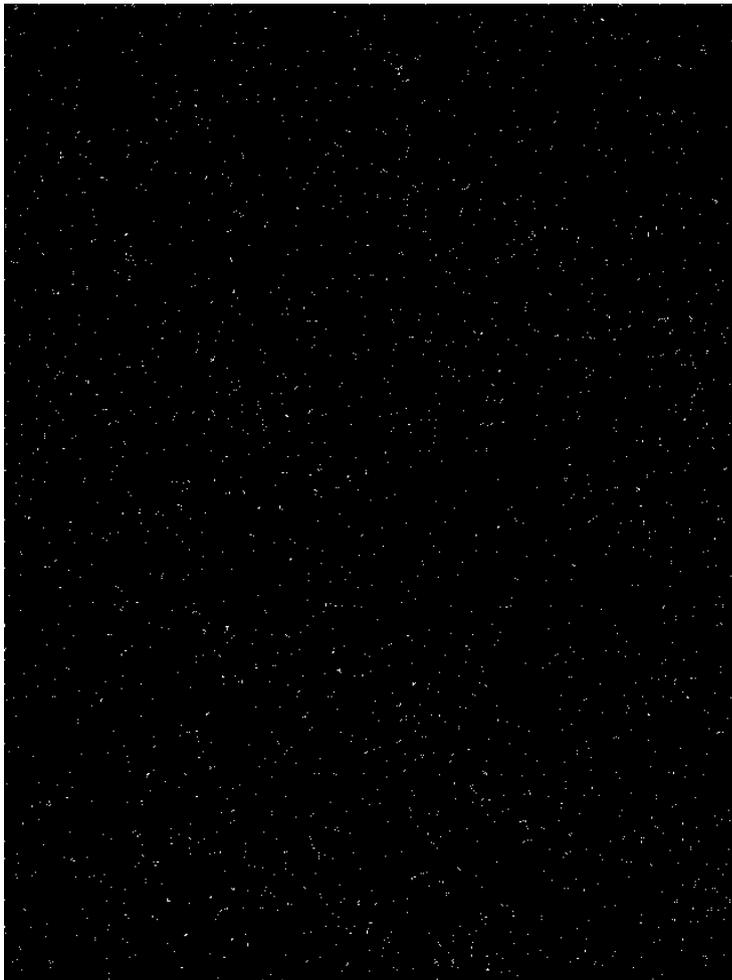
# Experimente

- Vergleich: Active Learning vs. manuelle Pixelauswahl



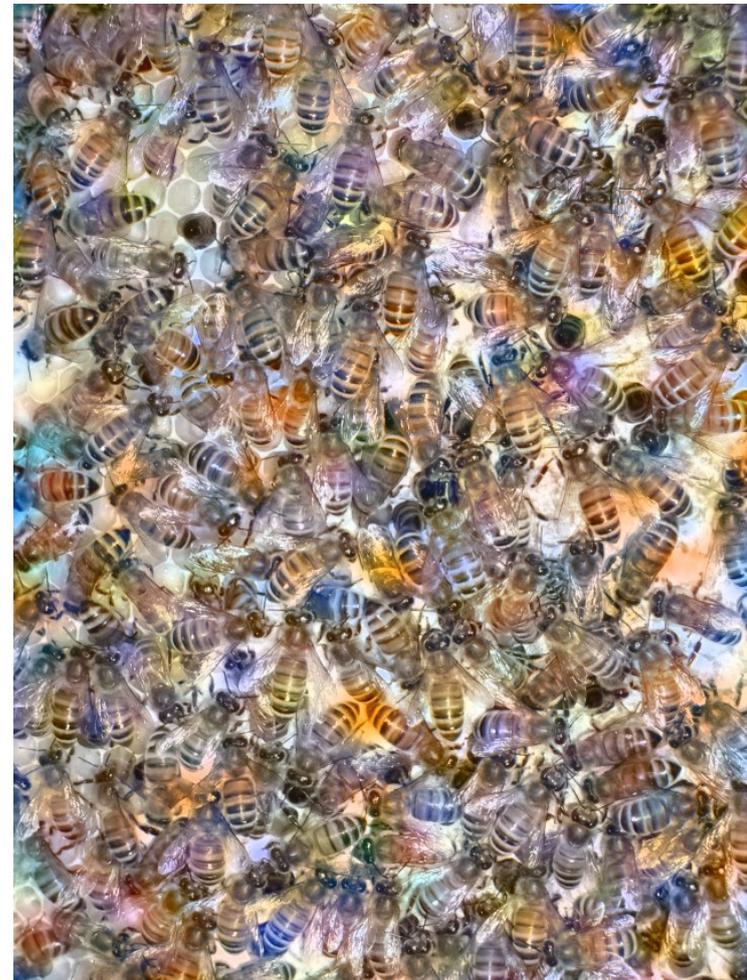
# Experimente

- Vergleich: Active Learning vs. manuelle Pixelauswahl



# Experimente

- Vergleich: Active Learning vs. manuelle Pixelauswahl



# Experimente

- Ergebnis Bienen:
  - Active Learning
    - PSNR = 31.49
    - 2534 Pixel
    - 7 Iterationen
  - manuell
    - PSNR = 27.00
    - 8558 Pixel

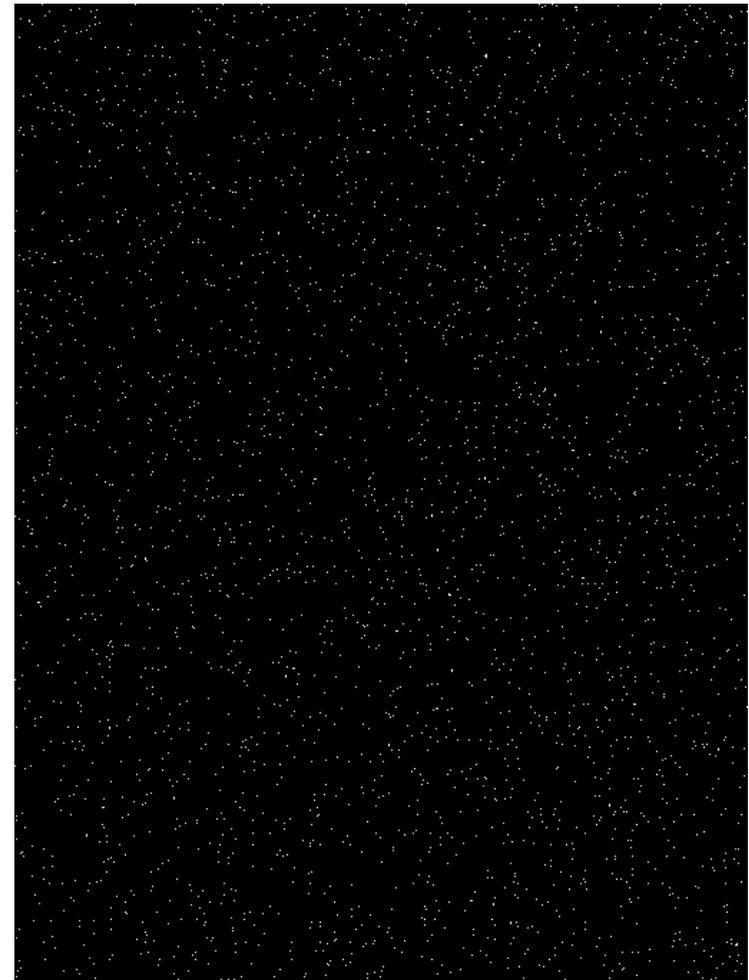
# Experimente

- Vergleich: Active Learning vs. zufällige Pixelauswahl



# Experimente

- Vergleich: Active Learning vs. zufällige Pixelauswahl



# Experimente

- Vergleich: Active Learning vs. zufällige Pixelauswahl



# Experimente

- Ergebnis Mädchen:
  - Active Learning
    - PSNR = 40.95
    - 2766 Pixel
    - 17 Iterationen
  - zufällig
    - PSNR = 38.41
    - 2976 Pixel

# Experimente

- Kompressionsraten:
  - Bienen: 0.754
  - Mädchen: 0.781

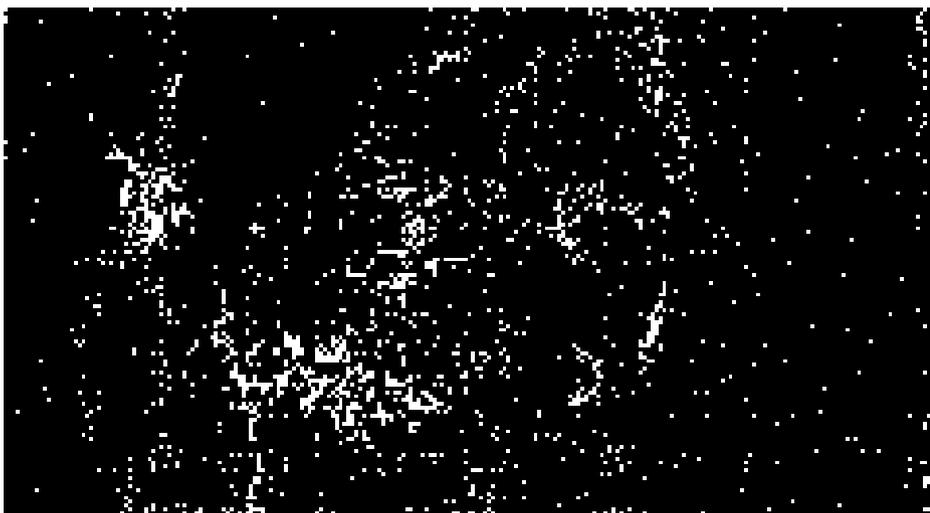
# Experimente

- Videokolorierung



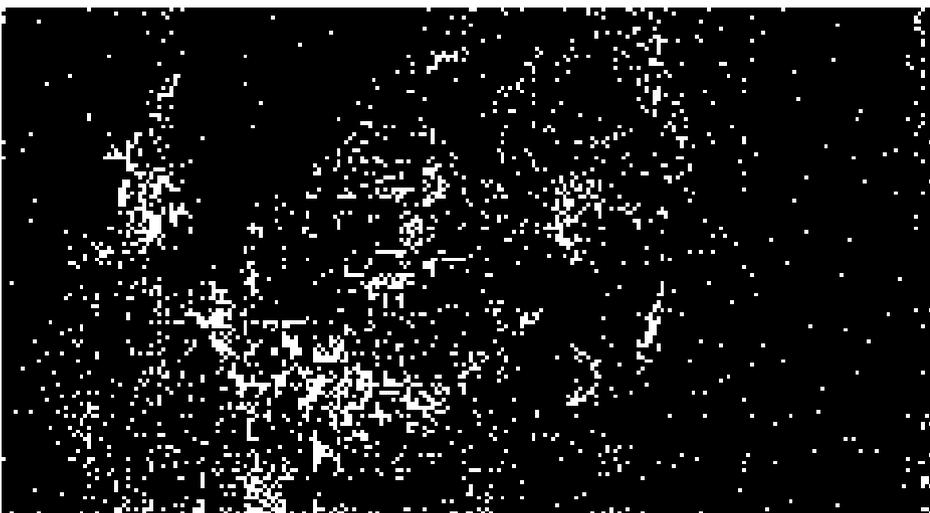
# Experimente

- Videokompression



# Experimente

- Videokompression



# Experimente

- Kompressionsrate 0.899
  - Berechnung allerdings unrealistisch, realistischer sind eher 0.925

# Fazit

- optisch ansprechende kolorierte Bilder und Videos
- Kompression mit guten Kompressionsraten als Aufsatz auf herkömmliche Verfahren
- Videokompression streaming-fähig
- mögliche Verbesserung:
  - „Vergessen“ von Labels ==> selber PSNR bei niedrigeren Kosten
  - Beweis von performance boundaries

# Bemerkungen

- weitere Verbesserungsmöglichkeiten:
  - evtl. Verwendung von spezialisierten SW-Kompressionsverfahren
- nach welchen Kriterien wurden die Bilder und Videos der Experimente ausgewählt?
  - „non-stationary video sequences“
- evtl. muss  $\alpha$  auch gespeichert werden

**Vielen Dank für Ihre Aufmerksamkeit!**

# Quellen

- sämtliche Bilder entstammen der Seite <http://sml.nicta.com.au/~licheng/LearnCompressImgVid/LearnCompressImgVid.html> oder dem Artikel „Learning to Compress Images and Videos“, welcher auch auf dieser Seite zu finden ist.