

# Gaussian Mixture Modell alapú Fisher vektor számolás GPGPU-n

**Daróczy Bálint és**

**András Benczúr, Bodzsár Erik, Petrás István,  
Siklósi Dávid, Nikházy László, Pethes Róbert**

Adatbányászat és Webes Keresés Kutatócsoport

MTA SZTAKI

A csoport elsősorban egyedi, nagy méretű, különösen összetett rendszerek (nagy intranetek, nagy forgalmú tartalomszolgáltatók, publikus Web, tudományos adatbázisok) számára kínál webes keresési, ill. adatbányászati megoldásokat. <https://dms.sztaki.hu>

Kereső motorok

„Big Data” üzleti intelligencia    Laborvezető: Benczúr András



Gépi tanulás



Ajánló rendszerek

Gráf vizualizáció

Azonosság feloldás

Bioinformatika

Web spam szűrés



## **GPGPU:** General-purpose computing on graphics processing units

Miért jó számunkra:

- sok egyszerű, egyben lassú számoló egység (>100) → gyakorlatban fp32....
- kicsi cserébe nagyon gyors memória (>100GB/sec)

vs. CPU:

- kevés (<20), de komplex és gyors számoló egység
- arányaiban lassú memória (<25GB/sec)

Pl.: Nvidia Tesla c2075 : 448 CUDA cores with 6GB (144GB/sec)

## **Hatékony architektúra erősen párhuzamosítható algoritmusokhoz kis memória igényvel (Nvidia Denver?):**

- matrix műveletek, DFT, wavelet, rendezés, gráf alg. stb.
- titkosítás, tömörítés, stb.

Eddig adoptált Adatbányászati és képi algoritmusok:

- **SVD számolás ajánló rendszerekhez:** túl sok a memória mozgás!
- **Képszegmentálás:** optimális vágás megvalósítható nagyságrendben gyorsabban
- **Képleírók készítése: Fisher vektor és GMM**

Terveinkben:

- alacsony szintű leírók számolása: jelenleg ~10-15 sec képenként egy szálon (videó?)
- gépi tanulás: regresszió és Support Vector Machine, MKL
- **Hasonlóság számolás: memória korlátok?**

Képi annotáció feladata egy ismeretlen képről eldönteni, hogy melyek a rá jellemző fogalmak.


Pl. nappal, ég, hajó, tó (tenger?) stb.



Adott:

- maga a kép
- a képhez szorosan kapcsolódó szöveges információk  
pl. Flickr, honlap, kép neve, exif stb.

# Low-level feature-ök



Szegmens alapú  
~10..100




ROI alapú  
~600..2000




Grid alapú  
~5..30 ezer

# PI. Scale-Invariant Feature Transform – SIFT [1]

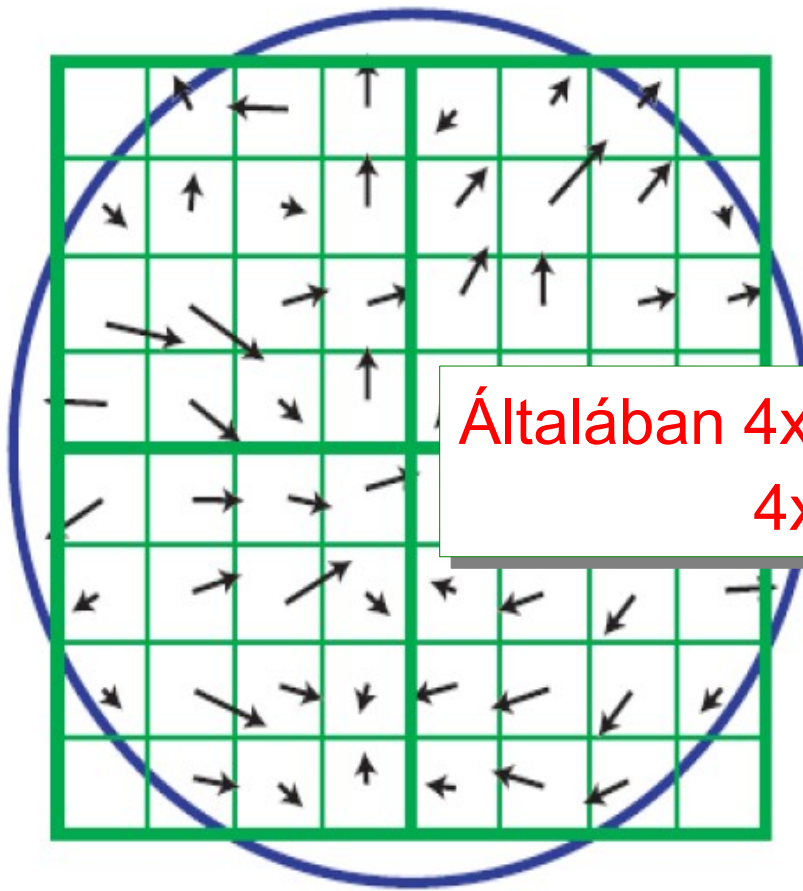


Kép orientációk ( $n=8 \rightarrow 8 \times 8$ )



$m=2$ ,  $2 \times 2$ -es sub-block orientáció hisztogram

# PI. Scale-Invariant Feature Transform – SIFT [1]



Általában 4x4 block és 45 fokos felbontás  
 $4 \times 4 \times 8 = 128$  dimenzió



Kép orientációk ( $n=8 \rightarrow 8 \times 8$ )

$m=2$ , 2x2-es sub-block orientáció  
hisztogram

# Gaussian Mixture Model

## EM algoritmus

- nem hierarchikus ellentétben a gyakori megoldásokkal [2,3,6]
- nagy dimenziós térben könnyen alulcsordul
- nem megfelelő előkészítés esetén kiürülnek a klaszterek

---

### Algorithm 1 The GPU GMM algorithm

**Input:** data points  $\{x_i\}_{i=1}^N$ , dimension  $D$ , mixture number  $K$ .

**Output:**  $\{P_i\}_{i=1}^K$ ,  $\{\mu_i\}_{i=1}^K$ ,  $\{\sigma_i\}_{i=1}^K$ , where  $\mathcal{N}_i$  is normally distributed with parameters  $(\mu_i, \sigma_i)$  and  $\sigma_i$  is assumed to be diagonal.

---

Initialize the Gaussian distributions with random parameters

**repeat**

**for all**  $n$  and  $k$  **do**

Expectation: Compute likelihood  $p_{nk} = \frac{f_k(x_n)P_k}{\sum_{i=1}^K f_i(x_n)P_i}$  where  $f_i$  is the density of  $\mathcal{N}_i$

**for all**  $k$  and  $d$  **do**

Maximization: compute  $P_k = \frac{\sum_{n=1}^N p_{nk}}{N}$ ,  $\mu_{kd} = \frac{\sum_{n=1}^N p_{nk}x_{nd}}{\sum_{n=1}^N p_{nk}}$  and  $\sigma_{kd}^2 = \frac{\sum_{n=1}^N p_{nk}(x_{nd} - \mu_{kd})^2}{\sum_{n=1}^N p_{nk}}$

**until** until converge

---



# GPU implementáció [6]

Numerikus hibák:


- Egy naiv megvalósítás gyakran alulcsordul a sűrűség meghatározásakor  $\sigma_{kd}^2$
- Feloldható logaritmusok és úgynevezett „bucket”-ek használatával

$$\log(p_{nk}) = \log(f_k(x_n)) + \log(P_k) - \log \sum_{i=1}^K \exp(\log(f_i(x_n)) + \log(P_i))$$

$$\log(P_k) = \log \sum_{n=1}^N \exp \log(p_{nk}) - \log N$$

$$\mu_{kd} = \frac{\sum_{n=1}^N \exp(\log(p_{nk}) + \log(x_{nd}))}{\sum_{n=1}^N \exp \log(p_{nk})}$$

$$\sigma_{kd}^2 = \frac{\sum_{n=1}^N \exp(\log(p_{nk}) + 2 \log(x_{nd} - \mu_{kd}))}{\sum_{n=1}^N \exp \log(p_{nk})}$$



# Fisher vektor modellek

Legyen  $\lambda$  egy Gaussian Mixture Modell (k eloszlás):

$$\lambda = [p_{1,\dots}, p_k, \mu_{1,\dots}, \mu_k, \Sigma_{1,\dots}, \Sigma_k]$$

The idea is to describe the low-level features with the gradient of the log-likelihood of their conditional probability [2,3]:

$$F_X(\lambda) = \nabla_{\lambda} \log P(X|\lambda) = \frac{\partial L(X|\lambda)}{\partial \lambda} \quad \text{ahol} \quad p(\mathbf{x}_n|\lambda) = \sum_{k=1}^K p_k g(\mathbf{x}_n; \mu_k, \sigma_k)$$

$$L(X|\lambda) = \sum_{n=1}^N \log p(\mathbf{x}_n|\lambda)$$

$$\frac{\partial L(X|\lambda)}{\partial p_k} = \sum_{n=1}^N \left( \frac{p(k|\mathbf{x}_n)}{p_k} - \frac{p(1|\mathbf{x}_n)}{p_1} \right), \quad k = 2 \dots K$$

$$\frac{\partial L(X|\lambda)}{\partial \mu_k^d} = \sum_{n=1}^N p(k|\mathbf{x}_n) \left( \frac{x_n^d - \mu_k^d}{(\sigma_k^d)^2} \right), \quad k = 1 \dots K, d = 1 \dots D$$

$$\frac{\partial L(X|\lambda)}{\partial \sigma_k^d} = \sum_{n=1}^N p(k|\mathbf{x}_n) \left( \frac{(x_n^d - \mu_k^d)^2}{(\sigma_k^d)^3} - \frac{1}{\sigma_k^d} \right), \quad k = 1 \dots K, d = 1 \dots D$$


# Fisher vektor modellek

Probléma:

- Igazán hatékony GMM: legalább 256 eloszlás
- Túl sok számítás:
  - független számítások száma nagy
    - GPU
    - Kis adatmennyiség sok párhuzamos számítás (egyetlen kép alacsony szintű leírói: ~30MB)
  - egyetlen gradiensnél a Fisher vektor dimenziója  $N-1+2*D*N$ , ahol  $N$  az eloszlások száma,  $D$  az alacsony szintű leíró dimenziója:
    - SIFT:  $127+2*128*256 = 65,663$  dimenzió

Ötletek Fisher vektor közelítésére[2,3]:

- diagonális kovariancia mátrix
- csak a legjobban illeszkedő eloszlásokat vesszük figyelembe, ebben az esetben a dimenzió  $K+2*K*D$



# Fisher vektor modellek

Három példa:

→ ritka, gyors: **approxFV** csak a top x illeszkedő eloszlást vesszük figyelembe, cserébe túl ritka fp32 mellett [2,3]

→ Módosított Fisher információ mátrix a ritkaság feloldására: az eloszlások előfordulásával arányosan normálunk, nem a képen található elemek számával [2,3], „ha előfordult mennyire biztosan fordult elő „ **locFV**

$$f_{\omega_i} = T_i \frac{1}{\omega_i},$$


$$f_{\mu_i^d} = T_i \frac{\omega_i}{(\sigma_i^d)^2},$$

$$f_{\sigma_i^d} = 2T_i \frac{\omega_i}{(\sigma_i^d)^2},$$

→ Használjuk mindegyik eloszlást: sűrű Fisher vektor **dFV (CUDA)**  
~44..70x gyorsulás GTX285 vs. Intel E5620 egy szálon

A GMM modell tapasztalati alapján tudjuk számolni a feltételes valószínűségeket

- $D \cdot N$  független számítás
- Majd egy összegzés: már csak  $N$  elem



# Gépi tanulás

SVM[4], Fisher vektorokon értelmezett „természetes magfüggvény”[2]:

$$K_{Fisher}(X, X) = F_X F_{Information}^{-1} F_X = F_{Information}^{-1/2} F_X F_{Information}^{-1/2} F_X(\lambda) = F_{norm}(X, \lambda) F_{norm}(X, \lambda)$$

ahol  $F_{Information}(\lambda) = E[\nabla_{\lambda} \log P(X|\lambda) \nabla_{\lambda} \log P(X|\lambda)^T]$

Multiple-Kernel probléma[4,5]:

Maximalizáljuk  $L(\alpha_c, \beta_c) = \sum_{i=1}^n \alpha_{ci} - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_{ci} \alpha_{cj} y_{ci} y_{cj} \sum_{n=1}^N \beta_{cn} K_n(x_j, x_i)$

ahol  $\sum_{i=1}^n \alpha_i y_i = 0$  és  $\forall \alpha_i \geq 0$

Unified representation[7,8]:

Kombináljuk a különböző modalitásokból származó információkat még a klasszifikáció előtt (pl.: szín, textúra, szöveges környezet, link adatok stb.):

- adott egy B referencia képhalmaz
- minden elemre értelmezzünk R reprezentációt

$$L_R(X, B) = \left[ \sum_{r=1}^R \beta_r \text{dist}_r(X_r, B_{r1}), \dots, \sum_{r=1}^R \beta_r \text{dist}_r(X_r, B_{rb}) \right]$$

# Gépi tanulás

## Számítási problémák:

- Képenként  $|B| \cdot |R|$  reprezentáció adaptív hasonlóság számítás: túl sok számítás, túl nagy **memória** igény  
Pl. szöveges hasonlóság

$$K_{k_{tag}}(X, I_t) = \text{dist}_{\text{Jensen-Shannon}}(X_{tags}, I_{t_{tags}}) = \frac{1}{2} D(P|M) + \frac{1}{2} D(Q|M)$$

- SVM modell kiértékelése: függ a tanulás után megmaradt support vektorok számától, sok esetben több ezer (**memória**)
- Bi-klaszterezés[8]: dokumentumok együttes csoportosítása többféle szöveges és /vagy képi hasonlóságok alapján
- Osztályonként különböző optimális arányok:
  - Súlyok meghatározása
  - **Minden válaszhoz külön unified vektor?**

# Összefoglalás

## Váltás:

- **GPU vs. CPU** : memória , PCIe sávszélesség, virtuális memória
- **Nvida vs. AMD/Ati**: OpenCL-re váltás a korábban használt GPU-khoz képest nem tűnik veszteségnek
- **CPU vs. OpenCL**: POSIX thread vs. OpenCL
- **Cloud**: új api-k?
- **Mobil applikációk**: kamerával felvett képinformációk előfeldolgozása vs. nyers adat átküldése

## Megoldandó problémák:

- Alacsony szintű képfeldolgozás: alacsony memória igény, bizonyítottan működik pl. szegmentálás
- Koherencia miatt OpenCL
- Gépi tanulás gyorsítása (ritka adat?), vagy legalább a modell kiértékelése
- Mozgóképekre 40-50x-es gyorsulás lenne legalább szükséges
- Egyéb adatbányászati problémák: bi-klaszterezés [8], bioinformatika

# Eredmények1: Yahoo MIRFLickr dataset: ImageCLEF 2011 Photo Annotation Task

			MAP	EER	AUC
	<b>Egységes súly: dFV + Jensen-Shannon</b>	IMG+TXT	<b>0.4512</b>	0.233511	0.8378
1.	TUBFI - Technische Universität Berlin + Fraunhofer	IMG+TXT	<b>0.443449</b>	0.233690	0.835753
2.	LIRIS - Universite de Lyon, CNRS, Ecole Centrale de Lyon	IMG+TXT	0.436968	0.232860	0.836570
<b>3.</b>	<b>BPACAD - SZTAKI</b>	IMG+TXT	<b>0.436294</b>	0.241691	0.827747
4.	ISIS - University of Amsterdam	IMG+TXT	0.432758	0.245721	0.821462
5.	MLKD - Department of Informatics, Aristotle University of Thessaloniki	IMG+TXT	0.401642	0.253232	0.817084
6.	CEALIST - Laboratoire d'Intégration des Systèmes et des Technologies	IMG+TXT	0.383528	0.250714	0.819797
7.	CAEN – University of Caen	IMG	0.382403	0.262823	0.805420
8.	MRIM - Laboratoire d'Informatique de Grenoble	IMG+TXT	0.377179	0.260416	0.809472
9.	IDMT – Fraunhofer	IMG+TXT	0.370975	0.303458	0.751788
...					



# Eredmények2: Pascal VOC 2011 Classification

		Előre adott boxok használata nélkül	Előre megadott mintaboxok használata mellett
<b>1.</b>	NUS - National University of Singapore	-	0,7856
<b>2.</b>	NLPR - National Laboratory of Pattern Recognition, Institute of Automation Chinese Academy of Sciences	0,6108	0,7823
<b>3.</b>	ISIS - University of Amsterdam, University of Trento	-	0,7335
<b>4.</b>	MSR - Microsoft Research Asia & University of Science and Technology of China	-	0,7049
<b>5.</b>	LIRIS - LIRIS, Ecole Centrale de Lyon, CNRS, UMR5205, France	0,6094	0,6681
<b>6.</b>	<b>DMWS, MTA SZTAKI</b>	<b>0,6139</b>	-
<b>7.</b>	SJT - Shanghai Jiao Tong Univeristy	0,5485	0,604
<b>8.</b>	JDL - Institute of Computing Technology, Chinese Academy of Sciences	0,5478	-
<b>9.</b>	KUL - University of Leuven	0,4512	-
<b>...</b>			

## Referenciák

1. D. Lowe: “Object recognition from local scale-invariant features”, in: International Conference on Computer Vision, volume 2, pp. 1150–1157.
2. F. Perronnin, C. Dance: “Fisher kernels on visual vocabularies for image categorization”, in: IEEE Conference on Computer Vision and Pattern Recognition, 2007. CVPR’07, pp. 1–8.
3. F. Perronnin, J. Sanchez, T. Mensink, “Improving the fisher kernel for large-scale image classification”, in: 11th ECCV, 2010.
4. C. Cortes, V. Vapnik: “Support-vector networks”, Machine Learning 20 (1995) 273–297.
5. M. Kloft, U. Brefeld, S. Sonnenburg, A. Zien: “lp-norm multiple kernel learning”, Journal of Machine Learning Research 12 (2011) 953–997.
6. E. Bodzsár, B. Daróczy, I. Petrás, A. A. Benczúr: “GMM based fisher vector calculation on GPGPU” (2011). <http://datamining.sztaki.hu/?q=en/GPU-GMM>.
7. B. Daróczy, R. Pethes, A. Benczúr: „SZTAKI @ ImageCLEF 2011”, In Working Notes for ImageCLEF Workshop at CLEF Amsterdam, Nederland, 2011
8. Dávid Siklósi, Bálint Daróczy, András A. Benczúr: “Content-Based Trust and Bias Classification via Biclustering”, WWW’12 Lyon, France, Proceedings of the 2nd Joint WICOW/AIRWeb Workshop on Web Quality , Pages 41-47 ACM, New York, NY, USA ©2012 ISBN: 978-1-4503-1237-0

**Köszönöm a figyelmet!**