

Beyond Convolutions in Deep Learning

Outline



- Проблемы простых сверток
- Spatial Transformer Networks (STN)
- Capsule Networks (CapsNet)

Пара определений


Инвариантность: $f(T(x)) = f(x)$



Conv
→




Conv
→





Пара определений


Эквивариантность: $f(T(x)) = T(f(x))$



Conv
→

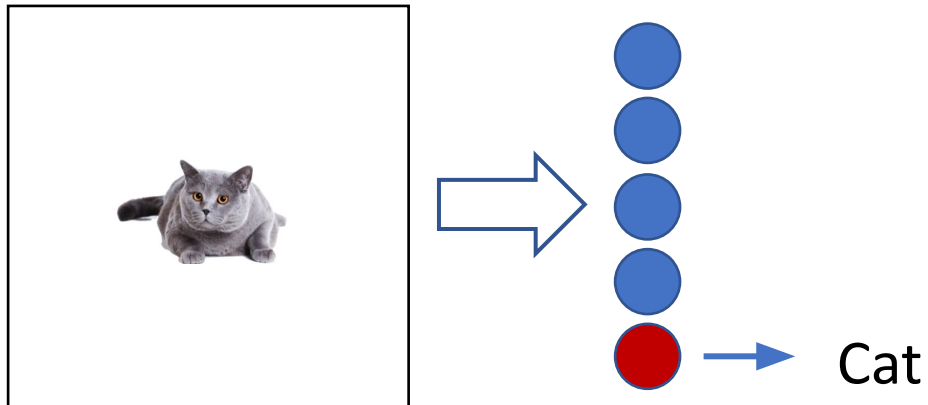


Conv
→




Зачем нам инвариантность / эквивариантность?

Чтобы **классифицировать** объект
нужна **инвариантность**.



Чтобы **сегментировать** объект
нужна **эквивариантность**.



Проблемы простых сверток


Свертки эквивариантны к сдвигам.

Q: Как сделать свертки инвариантными к малым сдвигам?


Использовать Pooling.

Проблемы простых сверток

Повороты




Cat





???

Проблемы простых сверток

Изменение масштаба



Cat



???

Проблемы простых сверток


Сети инварианты к сдвигам, но не инвариантны к поворотам и изменению масштаба.

Q: Как сделать сети инвариантными к поворотам и изменению масштаба?

Использовать Data Augmentation.

Проблемы простых сверток

Изменение позиций компонентов
объекта относительно друг друга



Source:

<https://medium.com/ai³-theory-practice-business/understanding-hintons-capsule-networks-part-i-intuition-b4b559d1159b>

Spatial Transformer Networks

Идея:



Давайте прикрутим еще одну сеть, которая будет учиться трансформировать изображение таким образом, чтобы минимизировать ошибку классификации.

Суть:

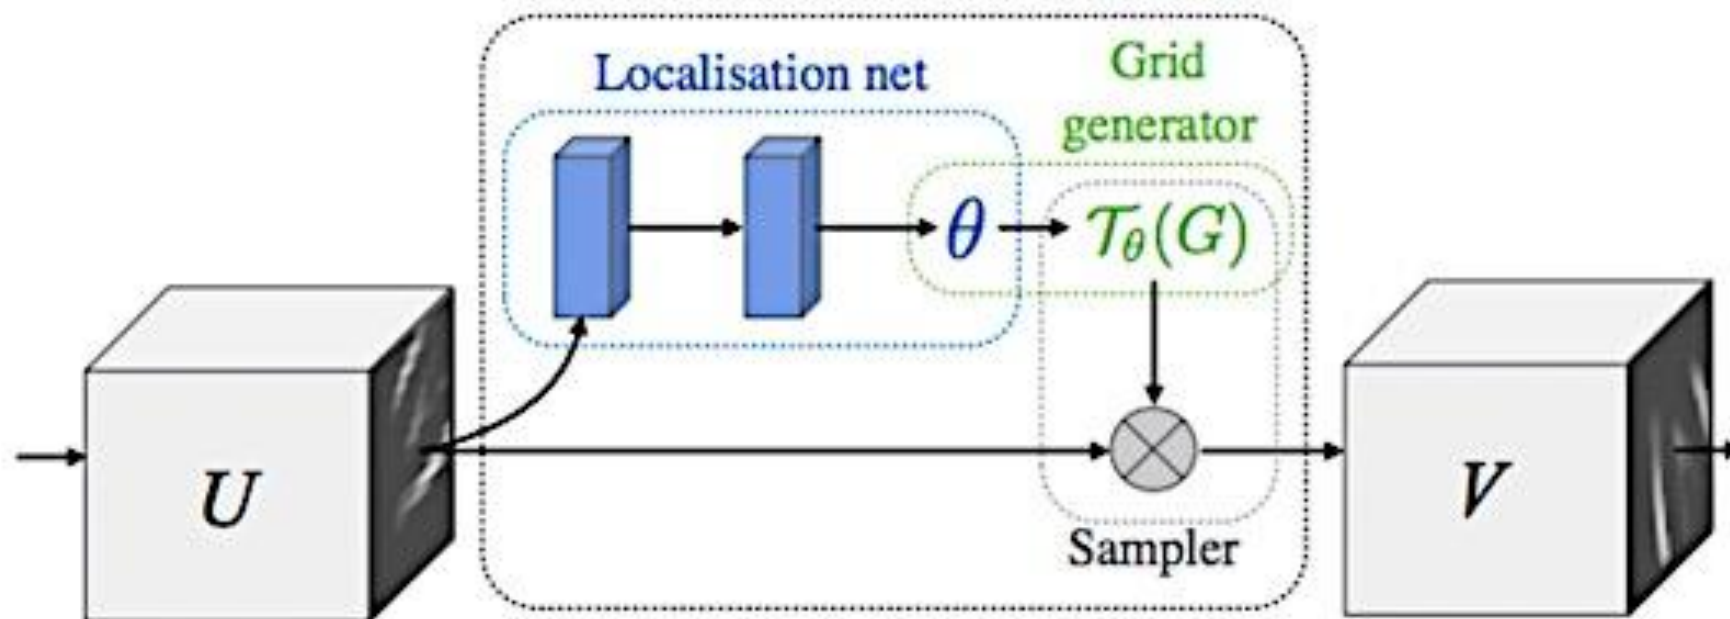
Такой подход позволяет сделать сеть асимптотически инвариантной к поворотам и изменению масштаба.



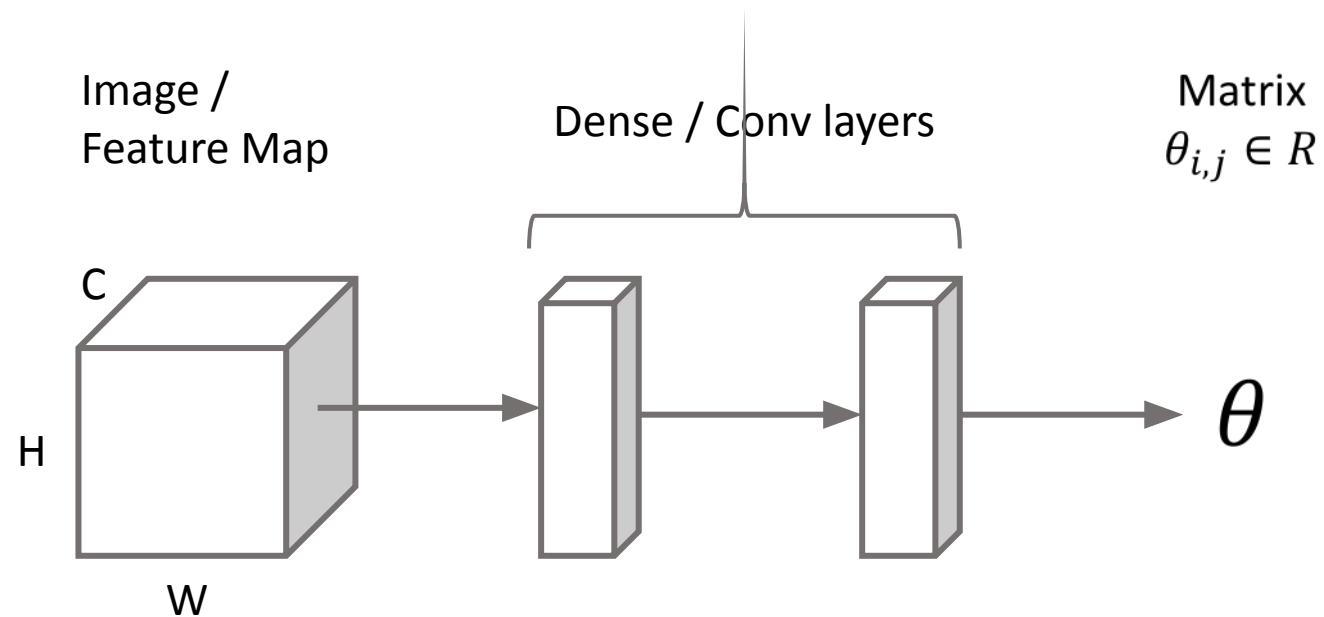
Spatial Transformer Networks



ST \ Архитектура



ST \ Localization Net



In: изображение или Feature Map размера (H, W, C) .

Out: матрица θ размера $(6,)$.

ST \ Grid Generator

Output from Localization Net

$$\begin{bmatrix} x^s \\ y^s \end{bmatrix} = \begin{bmatrix} \theta_{11} & \theta_{12} & \theta_{13} \\ \theta_{21} & \theta_{22} & \theta_{23} \end{bmatrix} \begin{bmatrix} x^t \\ y^t \\ 1 \end{bmatrix}$$

s – source image/FM, t – target image/FM

Для каждого пикселя в выходном изображении мы получаем координаты пикселя во входном изображении, которые нам понадобятся на следующем шаге.

ST \ Image Sampler


$$\textit{pixel value at } (x^t, y^t) = \textit{pixel value at } (k(x^s, y^s))$$

k – интерполяция (например,
билинейная).

Для каждого из пикселя (x^t, y^t) мы берем пиксель (x^s, y^s) и каким-нибудь хитрым образом (k) вычисляем значение, которое присвоим пикселю (x^t, y^t) .

Главное - операция присвоения значения пикселю (интерполяция) должна быть дифференцируема.

ST \ Результаты



ST \ Результаты

batch = 0/200 theta = $\begin{matrix} 1.02 & 0.02 & -0.02 \\ -0.02 & 1.02 & -0.02 \end{matrix}$



Spatial Transformer Networks

Q: Что можно делать с помощью ST?

поворачивать

обрезать


повышать/понижать размерность

Q: Что самое приятное в ST

То, что сеть сама поймет что и как ей делать. Все учится end-to-end без дополнительных функций потерь и т.п.

Capsule Networks

Что если мы хотим, чтобы сеть в классификации **опиралась не только на присутствие компонентов** какого-либо объекта, но и **использовала информацию о взаимном расположении этих компонентов?**



Capsule Networks \ Капсулы

Капсула – группа нейронов, чей вектор характеризует:

- Уверенность сети в том, что объект (или его часть) присутствует в какой-то части картинки.
- Параметры расположения этого объекта относительно других объектов.
- Параметры освещения, деформации, поворота и т.п.

Вообще, капсулы можно делать по-разному, но мы посмотрим на то, как это делает Geoffrey Hinton в оригинальной статье.



Capsule Networks \ Капсулы

В имплементации Хинтона:

- Длина вектора капсулы ($|v_j|$) – вероятность того, что объект присутствует на картинке.
- Значения вектора капсулы (v_j) – все остальные параметры объекта.

Capsule Networks \ Нелинейность

$$\mathbf{v}_j = \frac{\|\mathbf{s}_j\|^2}{1 + \|\mathbf{s}_j\|^2} \frac{\mathbf{s}_j}{\|\mathbf{s}_j\|}$$

s_j – вход капсулы j , v_j – вектор капсулы j

Такая нелинейность приводит очень длинный вектор к длине около 1, а очень маленький к длине около 0.

Capsule Networks \ Вход капсулы

$$\mathbf{s}_j = \sum_i c_{ij} \hat{\mathbf{u}}_{j|i} , \quad \hat{\mathbf{u}}_{j|i} = \mathbf{W}_{ij} \mathbf{u}_i$$

s_j – вход капсулы j

u_i – вектор капсулы i с предыдущего слоя

W_{ij} – матрица весов, которая учится backprop'ом

c_{ij} – особый коэффициент, который вычисляется алгоритмом со следующего слайда

Capsule Networks \ Dynamic Routing

Procedure 1 Routing algorithm.

```
1: procedure ROUTING( $\hat{\mathbf{u}}_{j|i}, r, l$ )
2:   for all capsule  $i$  in layer  $l$  and capsule  $j$  in layer  $(l + 1)$ :  $b_{ij} \leftarrow 0$ .
3:   for  $r$  iterations do
4:     for all capsule  $i$  in layer  $l$ :  $\mathbf{c}_i \leftarrow \text{softmax}(\mathbf{b}_i)$ 
5:     for all capsule  $j$  in layer  $(l + 1)$ :  $\mathbf{s}_j \leftarrow \sum_i c_{ij} \hat{\mathbf{u}}_{j|i}$ 
6:     for all capsule  $j$  in layer  $(l + 1)$ :  $\mathbf{v}_j \leftarrow \text{squash}(\mathbf{s}_j)$ 
7:     for all capsule  $i$  in layer  $l$  and capsule  $j$  in layer  $(l + 1)$ :  $b_{ij} \leftarrow b_{ij} + \hat{\mathbf{u}}_{j|i} \cdot \mathbf{v}_j$ 
return  $\mathbf{v}_j$ 
```

$$\text{squash}(s_j) = \frac{\|\mathbf{s}_j\|^2}{1 + \|\mathbf{s}_j\|^2} \frac{\mathbf{s}_j}{\|\mathbf{s}_j\|}$$

Capsule Networks \ Loss

$$L_k = T_k \max(0, m^+ - \|\mathbf{v}_k\|)^2 + \lambda (1 - T_k) \max(0, \|\mathbf{v}_k\| - m^-)^2$$

Давайте разберемся что это значит!

Capsule Networks \ Loss

loss term for one DigitCap

calculated for correct DigitCap

calculated for incorrect DigitCaps

$$L_c = T_c \max(0, m^+ - \|\mathbf{v}_c\|)^2 + \lambda (1 - T_c) \max(0, \|\mathbf{v}_c\| - m^-)^2$$

1 when correct DigitCap, 0 when incorrect

zero loss when correct prediction with probability greater than 0.9, non-zero otherwise

0.5 constant used for numerical stability

1 when incorrect DigitCap, 0 when correct


zero loss when incorrect prediction with probability less than 0.1, non-zero otherwise

L2 norm

L2 norm

Note: correct DigitCap is one that matches training label, for each training example there will be 1 correct and 9 incorrect DigitCaps


Capsule Networks \ Архитектура



Все учится backprop'ом.













Dynamic routing делается только во время forward prop'а.

Capsule Networks \ Реконструкция



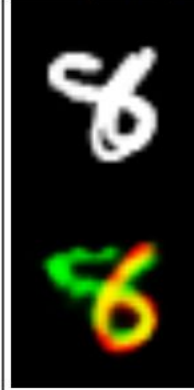
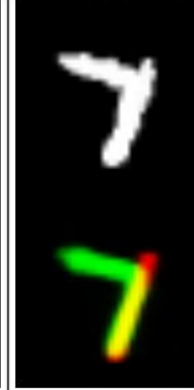
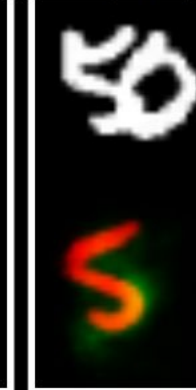



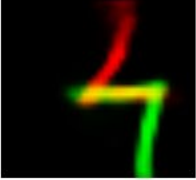
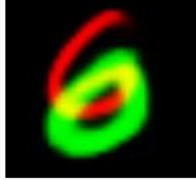

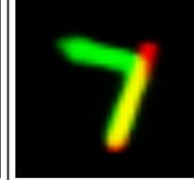
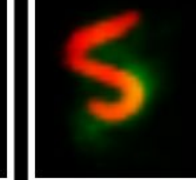
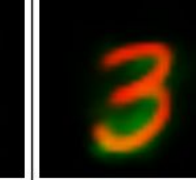
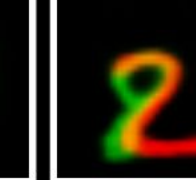






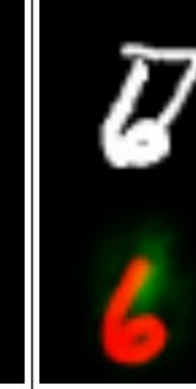

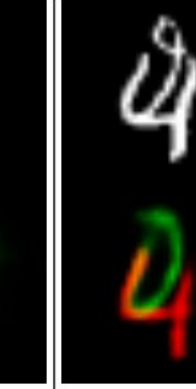




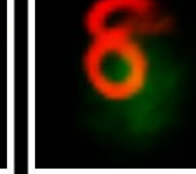
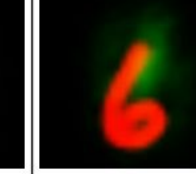
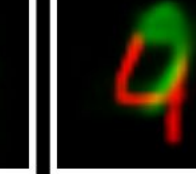
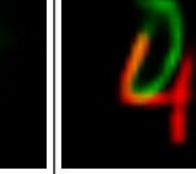


Source: <http://papers.nips.cc/paper/6975-dynamic-routing-between-capsules.pdf>







Capsule Networks \ Результаты

(l, p, r)	$(2, 2, 2)$	$(5, 5, 5)$	$(8, 8, 8)$	$(9, 9, 9)$	$(5, 3, 5)$	$(5, 3, 3)$
Input						
Output						

Capsule Networks \ Результаты

R:(2, 7) L:(2, 7)	R:(6, 0) L:(6, 0)	R:(6, 8) L:(6, 8)	R:(7, 1) L:(7, 1)	*R:(5, 7) L:(5, 0)	*R:(2, 3) L:(4, 3)	R:(2, 8) L:(2, 8)	R:P:(2, 7) L:(2, 8)
							
							
R:(8, 7) L:(8, 7)	R:(9, 4) L:(9, 4)	R:(9, 5) L:(9, 5)	R:(8, 4) L:(8, 4)	*R:(0, 8) L:(1, 8)	*R:(1, 6) L:(7, 6)	R:(4, 9) L:(4, 9)	R:P:(4, 0) L:(4, 9)
							
							

Capsule Networks \ Результаты

Scale and thickness	
Localized part	
Stroke thickness	
Localized skew	
Width and translation	
Localized part	

Ресар

1. У сверток есть **недостатки**

- Они не инвариантны к поворотам
- Они не инвариантны к изменению масштаба
- Они плохо справляются с изменением взаимных позиций компонентов объекта

Recap

2. **Spatial Transformer** дает инвариантность к поворотам и изменению масштаба. А также, позволяет дифференцируемо обрезать, растягивать и вращать изображения.

Recap

3. **Capsule Network** помогает справиться с проблемой изменения взаимных позиций компонентов объекта. Еще капсулы получают очень хорошие и иногда даже интерпретируемые репрезентации изображений.

Немного полезных материалов

Базовый tutorial по ST:

http://pytorch.org/tutorials/intermediate/spatial_transformer_tutorial

Объяснение ST на русском:

<https://habrahabr.ru/company/newprolab/blog/339484/>

Отличный tutorial по CapsNet:

<https://github.com/higgsfield/Capsule-Network-Tutorial>

Объяснение CapsNet в 4-х частях:

<https://medium.com/ai³-theory-practice-business/understanding-hintons-capsule-networks-part-i-intuition-b4b559d1159b>

Страничка с тысячей ресурсов по CapsNet:

<https://github.com/aisummary/awesome-capsule-networks>

Оригинальные статьи:

ST

<http://papers.nips.cc/paper/5854-spatial-transformer-networks.pdf>

CapsNet

<http://papers.nips.cc/paper/6975-dynamic-routing-between-capsules.pdf>