

Generative Adversarial Networks

Inhalt

- whoami
- Überblick
- Was ist ein GAN?
- Originale Idee
- Mathematische Idee
- Training Prozess
- Geschichte
- Probleme
- Anwendung

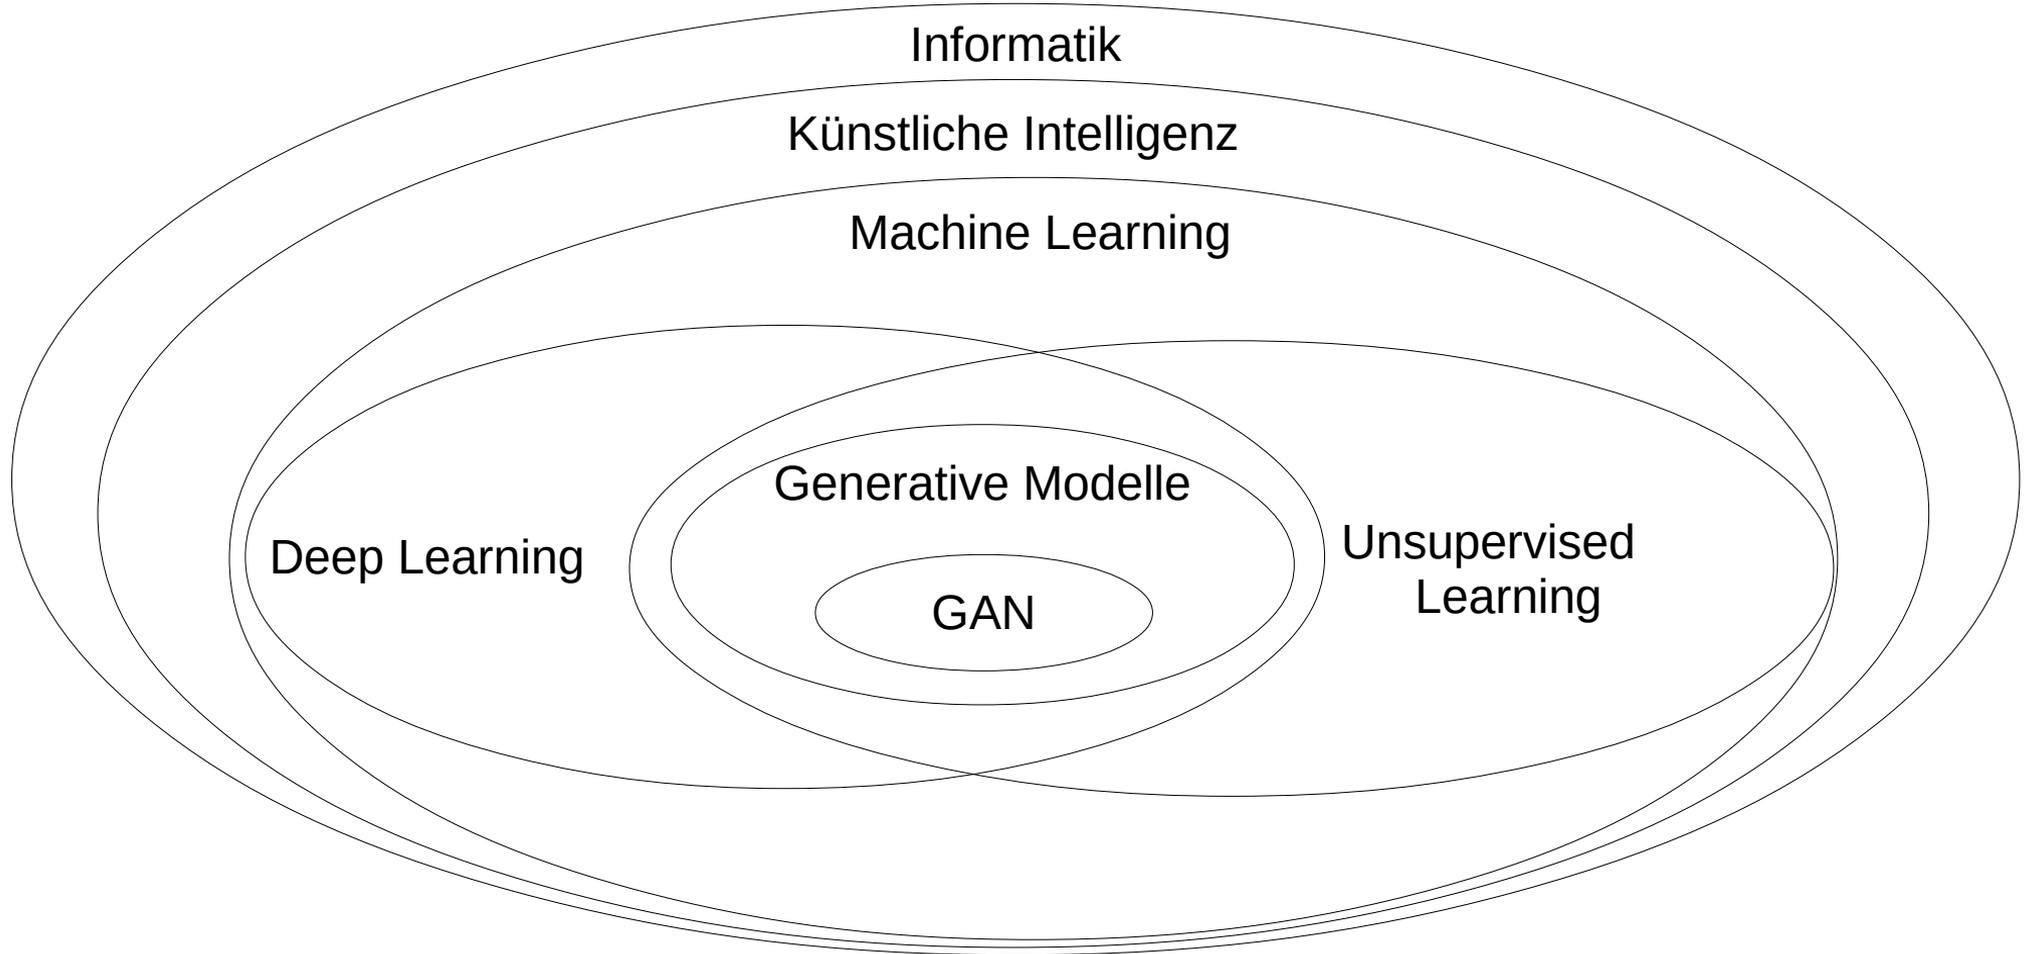
Whoami

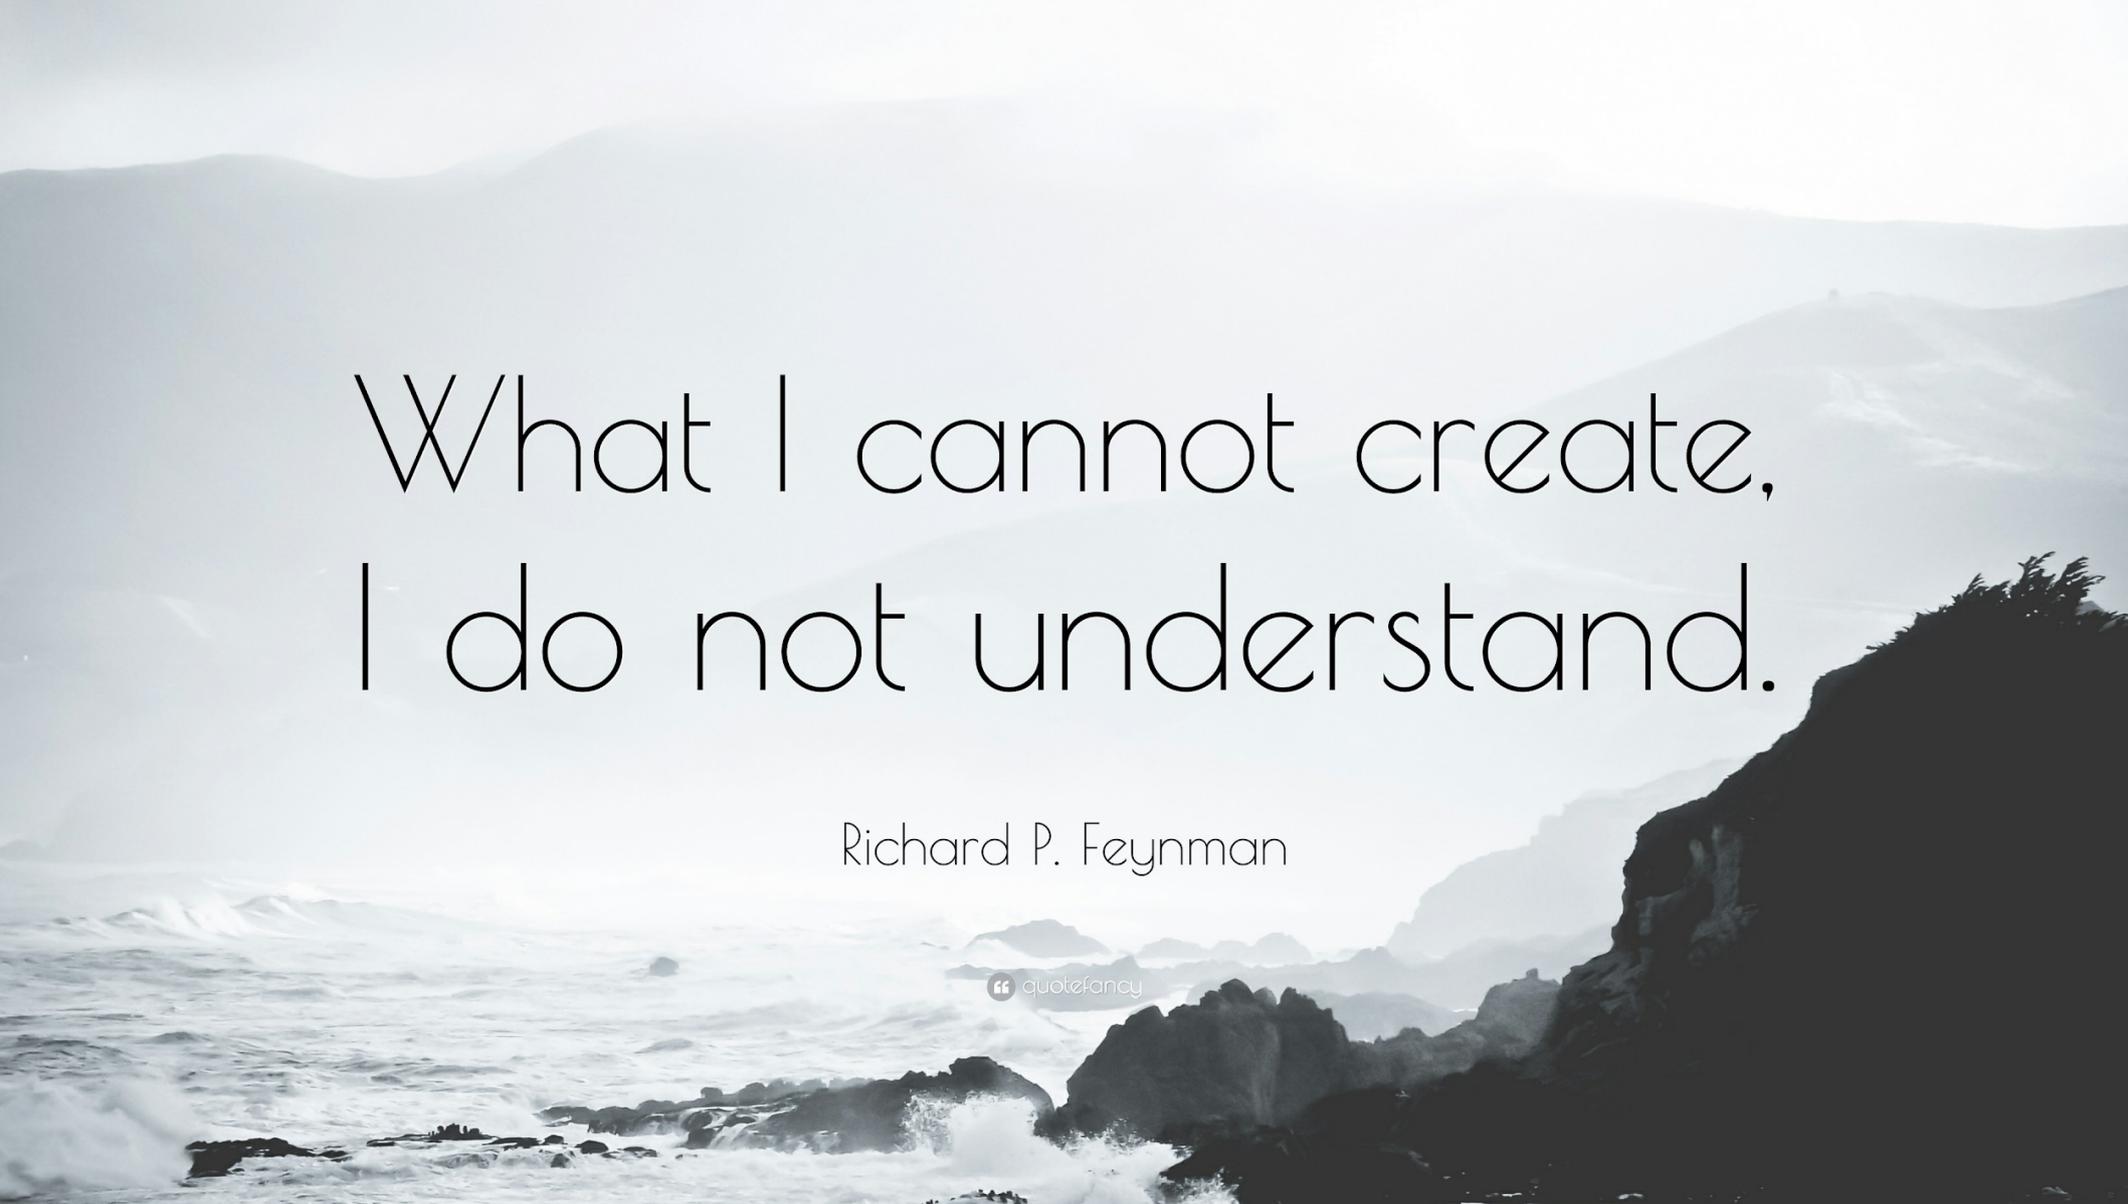


- whoami
m (Markus V.)
- groups
jku-at catalyts-cc programmer ai
security oeh-jku-at ctf-sigflag gan-
seminar-paper
- echo \$LANG
at-en.UTF-8 (Österenglisch)

SIGFLAG

Überblick





What I cannot create,
I do not understand.

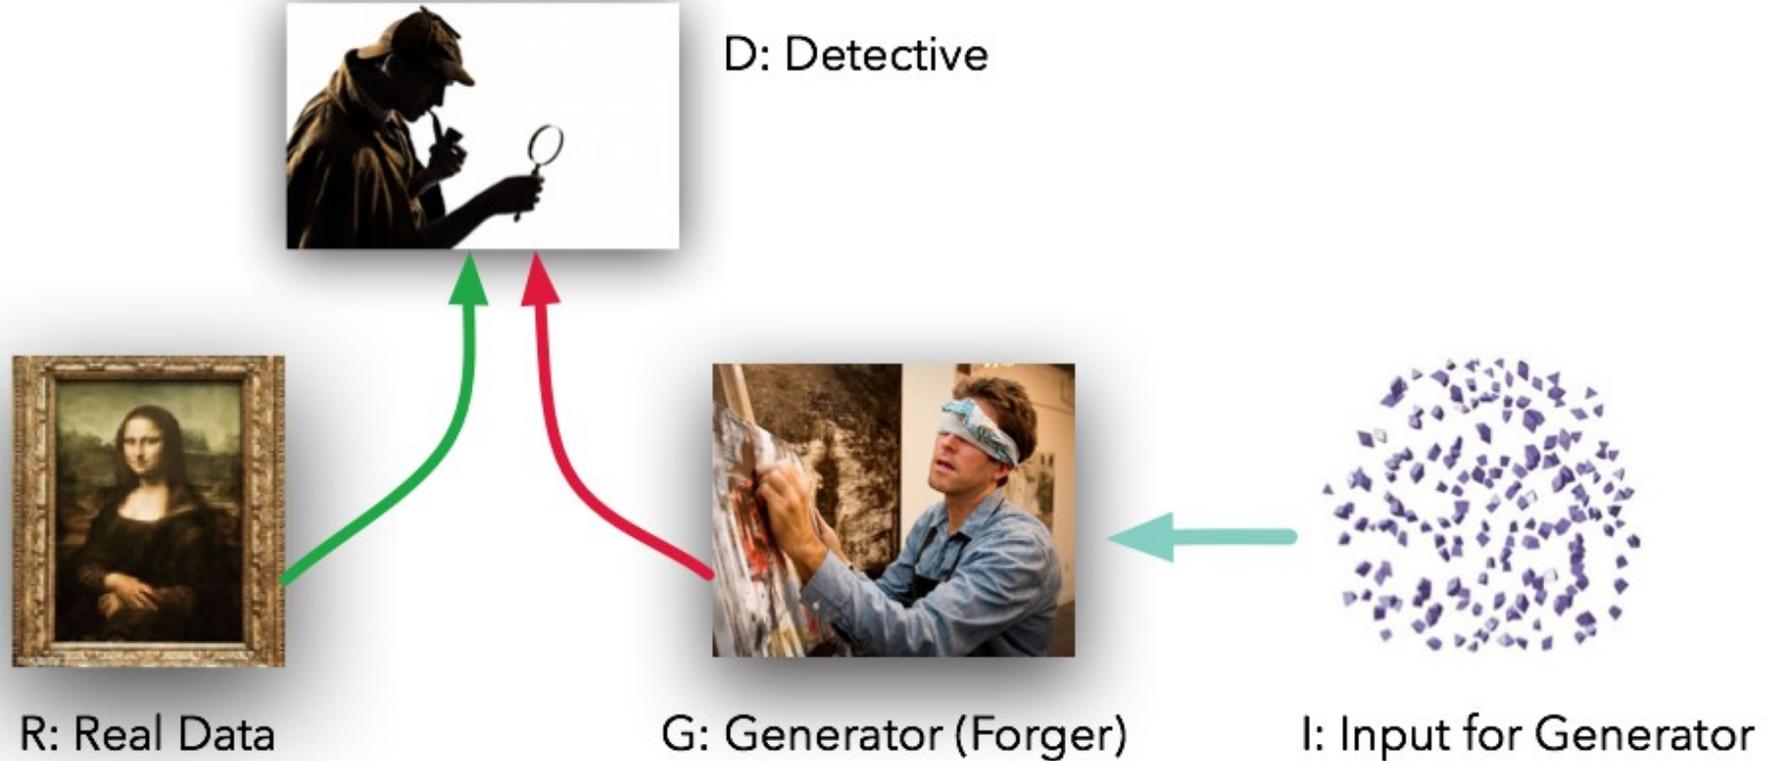
Richard P. Feynman

“ quote fancy

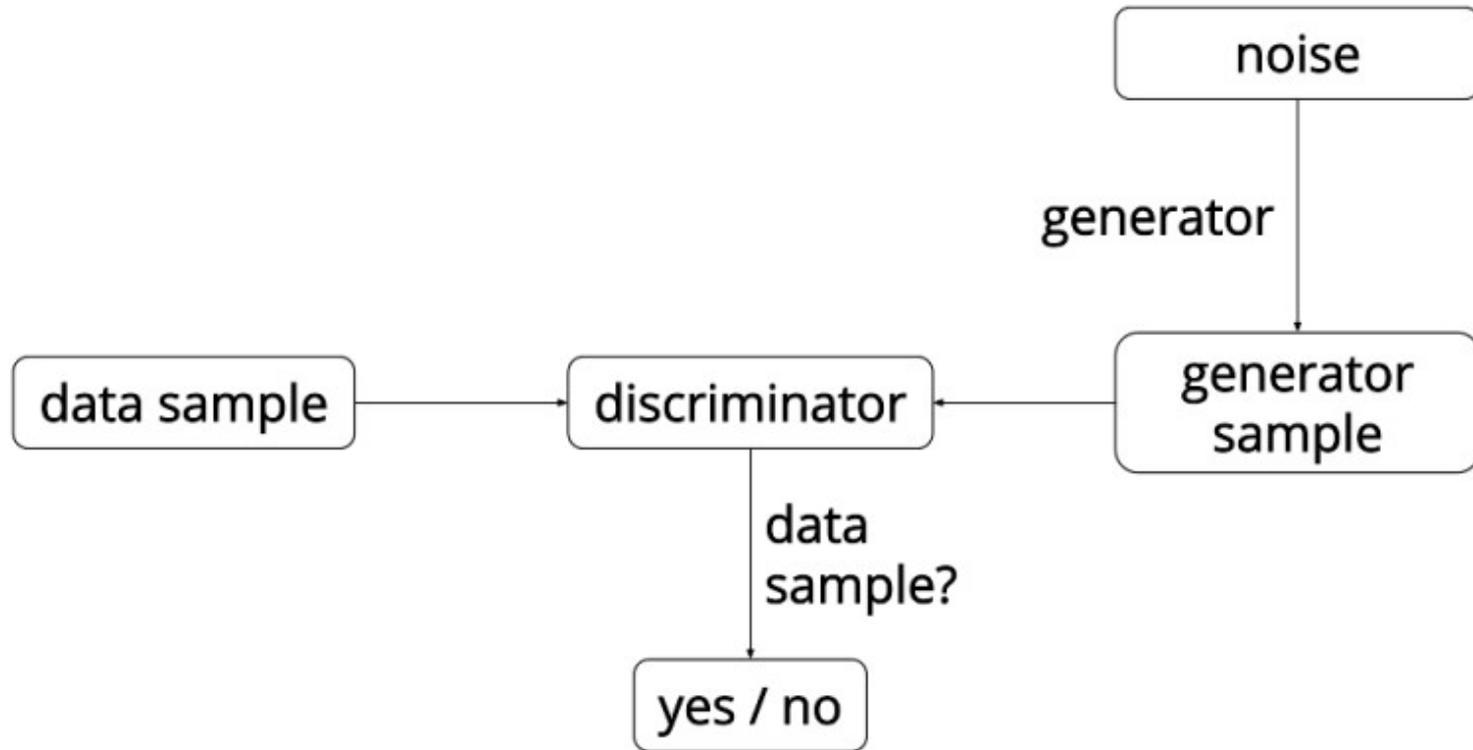
Was ist ein GAN?

- **Unsupervised deep** learning Modell
 - Lernt Daten mit ähnlicher **Verteilung** zu reproduzieren
 - Semi-Supervised Variante: Conditional GAN
- Zwei **konkurrierende** Netze (min-max Spiel)
 - Diskriminator-Netzwerk (“Unterscheider”)
 - Generator-Netzwerk
- Discriminator: Lernt **Unterschied** zwischen echten und generierten Daten
- Generator: Versucht den Discriminator **auszutricksen**
- Zusammenfassung: G wird belohnt wenn D falsch liegt;
D wird belohnt wenn es richtig liegt

Analogie



Datenfluss



Mathematischer Hintergrund

- Variablen:
 - \hat{x} : Stichprobe aus echten Daten X , z.B. Bild, Molekül, Zahl
 - x : Generierte Stichprobe gleicher Struktur/Dimension
 - z : Zufälliger Vektor, meist beschränkt 1d-[0, 1] und len(100) – latent space representation
- Der Generator $G(z)$ ist eine nonlineare Funktion von z nach x
- Der Diskriminator $D(x)$ ist eine nonlinear Funktion von x / \hat{x} zu einem einzelnen Echtheits-Wert, z.B. [0, 1], [-1, 1] oder $[-\infty, \infty]$
- GAN's formulation:
 - $\text{minimiere}_G (\text{maximiere}_D (D (G (z) \text{ concat } X))))$

Algorithm 1 Minibatch stochastic gradient descent training of generative adversarial nets. The number of steps to apply to the discriminator, k , is a hyperparameter. We used $k = 1$, the least expensive option, in our experiments.

for number of training iterations **do**

for k steps **do**

- Sample minibatch of m noise samples $\{z^{(1)}, \dots, z^{(m)}\}$ from noise prior $p_g(z)$.
- Sample minibatch of m examples $\{x^{(1)}, \dots, x^{(m)}\}$ from data generating distribution $p_{\text{data}}(x)$.
- Update the discriminator by ascending its stochastic gradient:

$$\nabla_{\theta_d} \frac{1}{m} \sum_{i=1}^m \left[\log D(x^{(i)}) + \log \left(1 - D(G(z^{(i)})) \right) \right].$$

end for

- Sample minibatch of m noise samples $\{z^{(1)}, \dots, z^{(m)}\}$ from noise prior $p_g(z)$.
- Update the generator by descending its stochastic gradient:

$$\nabla_{\theta_g} \frac{1}{m} \sum_{i=1}^m \log \left(1 - D(G(z^{(i)})) \right).$$

end for

The gradient-based updates can use any standard gradient-based learning rule. We used momentum in our experiments.

Discriminator
updates

Generator
updates

Geschichte

- 2014: [Generative Adversarial Networks, Ian Goodfellow et. al.](#)
- 2015: [Conditional Generative Adversarial Nets, Mehdi Mirza, Simon Osindero](#)
- 2015: [Unsupervised Representation Learning with DCGANs, A. Radford et. al](#)
- 2016: [Improved Techniques for Training GANs, Tim Salimans, Ian Goodfellow, et. al.](#)
- 2017: [Wasserstein GAN, Martin Arjovsky, et. al.](#)
- 2017: [Improved Training of Wasserstein GANs, Ishaan Gulrajani et. al.](#)

Figure 1: Number of GAN-Papers in The-GAN-Zoo per month since 6/2014

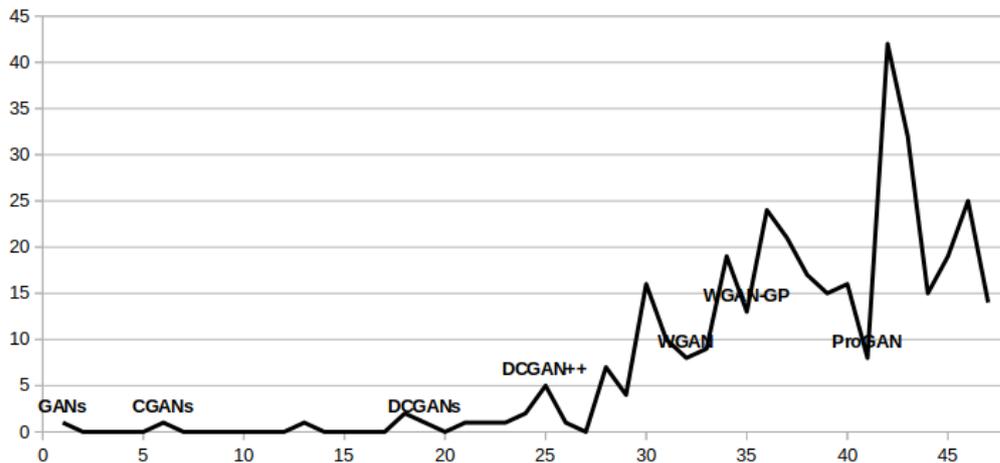
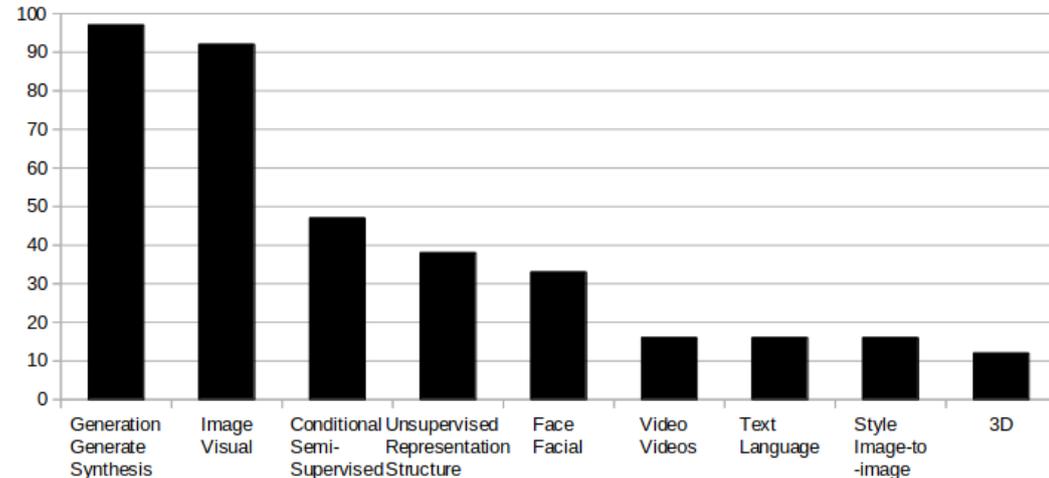
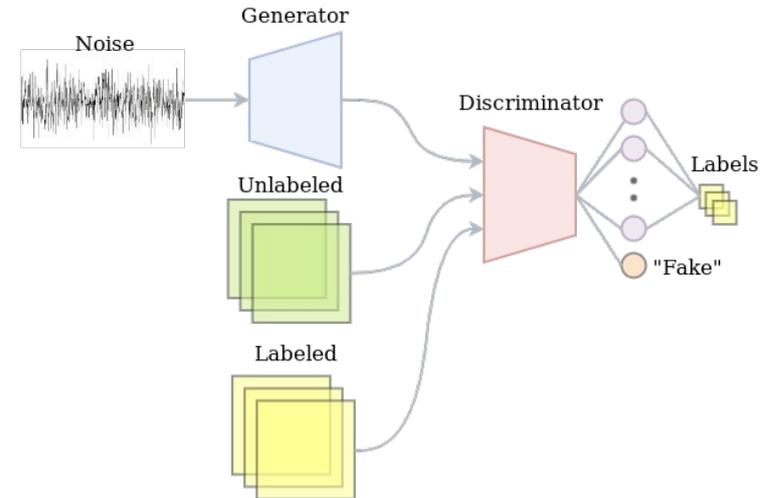


Figure 2: Number of papers containing the topic



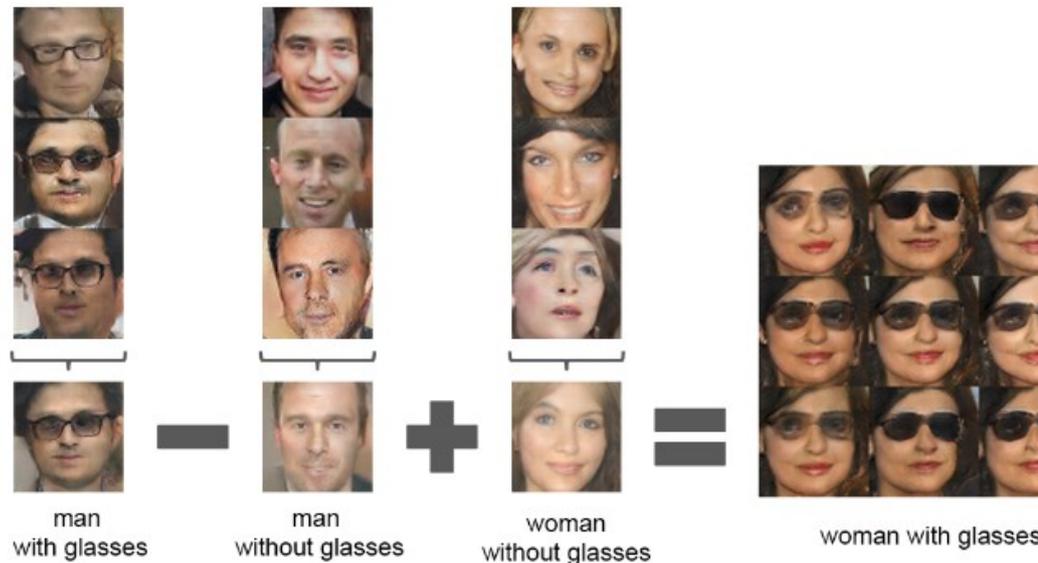
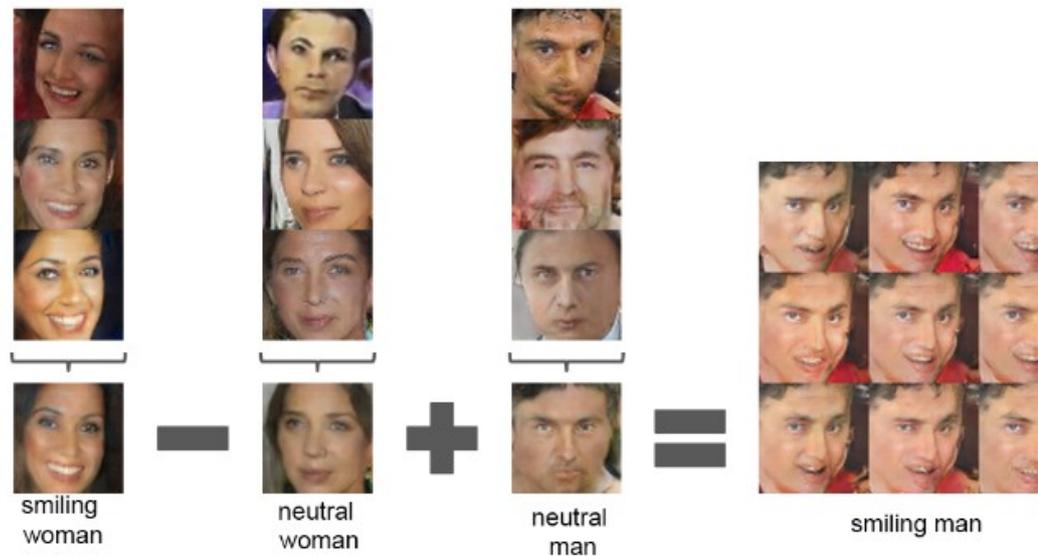
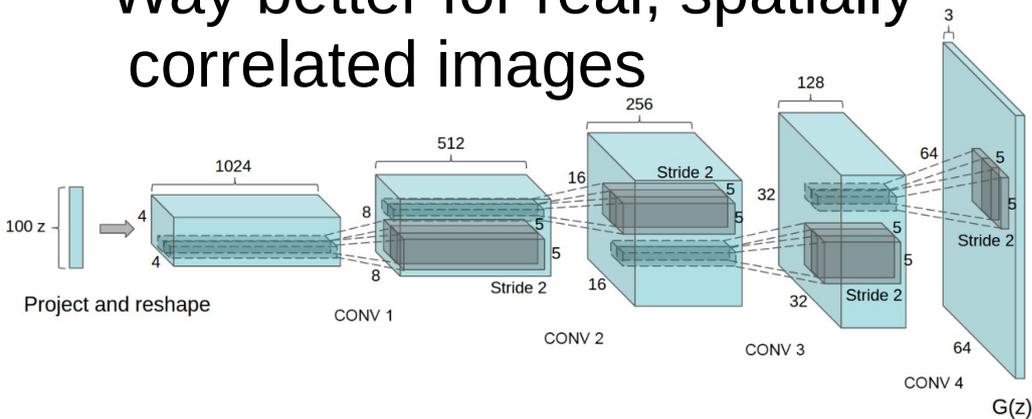
GANs und Semi-Supervised Learning

- Daten mit und ohne Klassen-Labels
- Diskriminator: unterscheidet K Klassen + Fake Klasse ($K + 1$ Klassen)
- Generator: generiert Bilder (gegeben Label)
- Diskriminator: kann nach Training die ungelabelten Daten zuordnen
- Anwendung: Semantic Segmentation



Deep Convolutional GANs (DCGANs)

- Ersetze fully connected layers
 - [De]Convolution
 - ReLu
 - BatchNorm
- Idee: Vector space arithmetics
- Way better for real, spatially correlated images

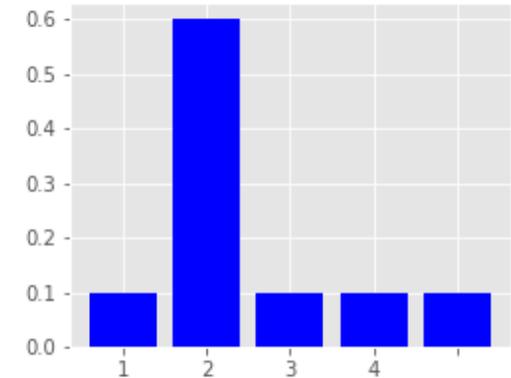
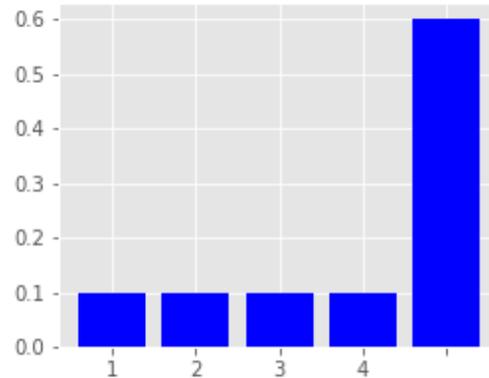
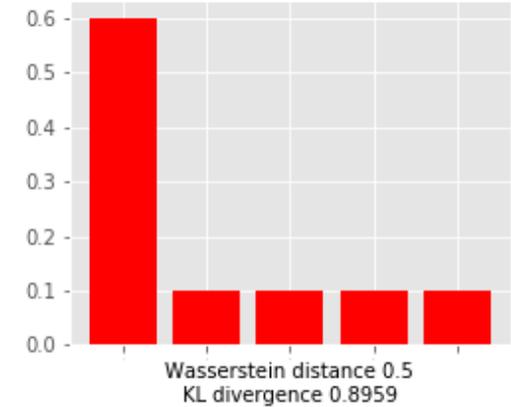
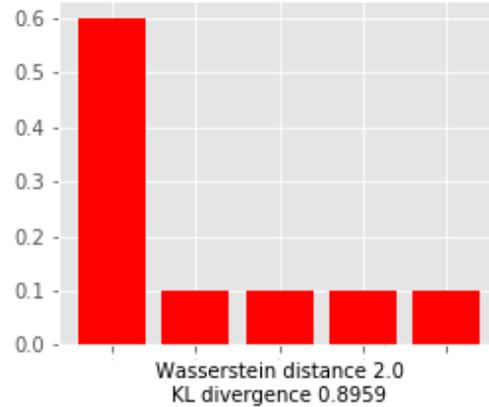


Improved Techniques for Training GANs

- Feature matching: High level features von real/fake müssen übereinstimmen
- Minibatch discrimination: Beziehe L1-Distanz in Loss ein
- Historical averaging: Online Ansatz, historischer cost-Wert
- One-sided label smoothing: Labels sind maximal 0.9 statt 1.0
- Virtual batch normalization: Es wird ein Durchschnitt über ein "virtuelles Batchset" berechnet

Wasserstein GAN / “Erdhaufen Verschiebungs-Distanz”

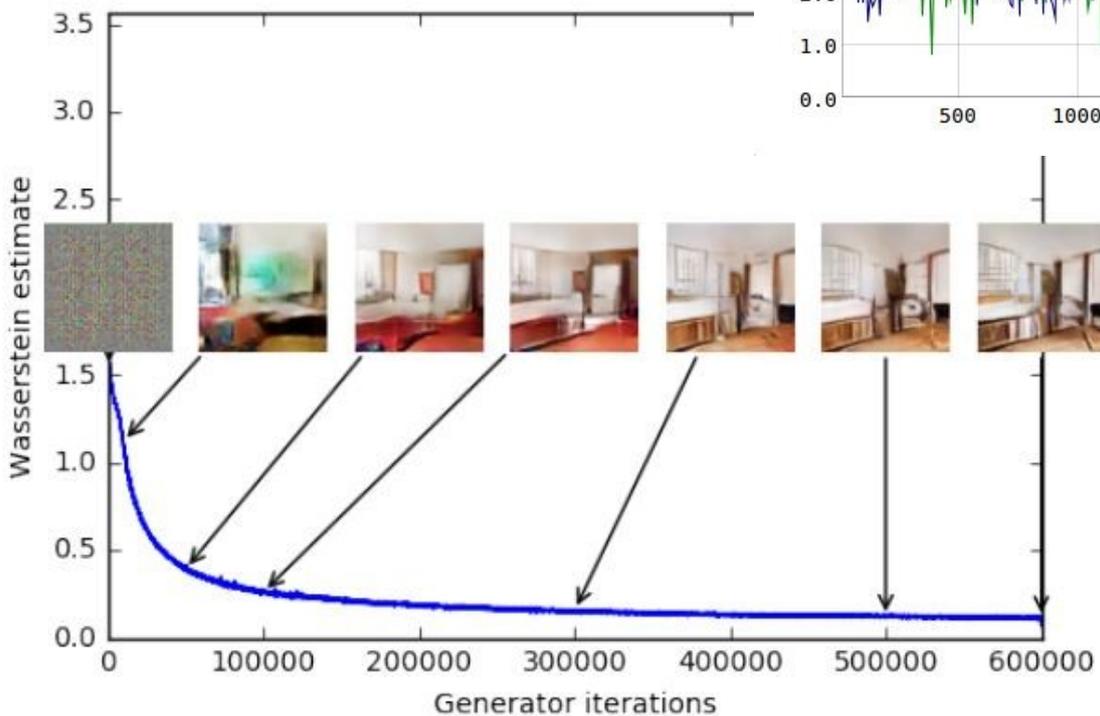
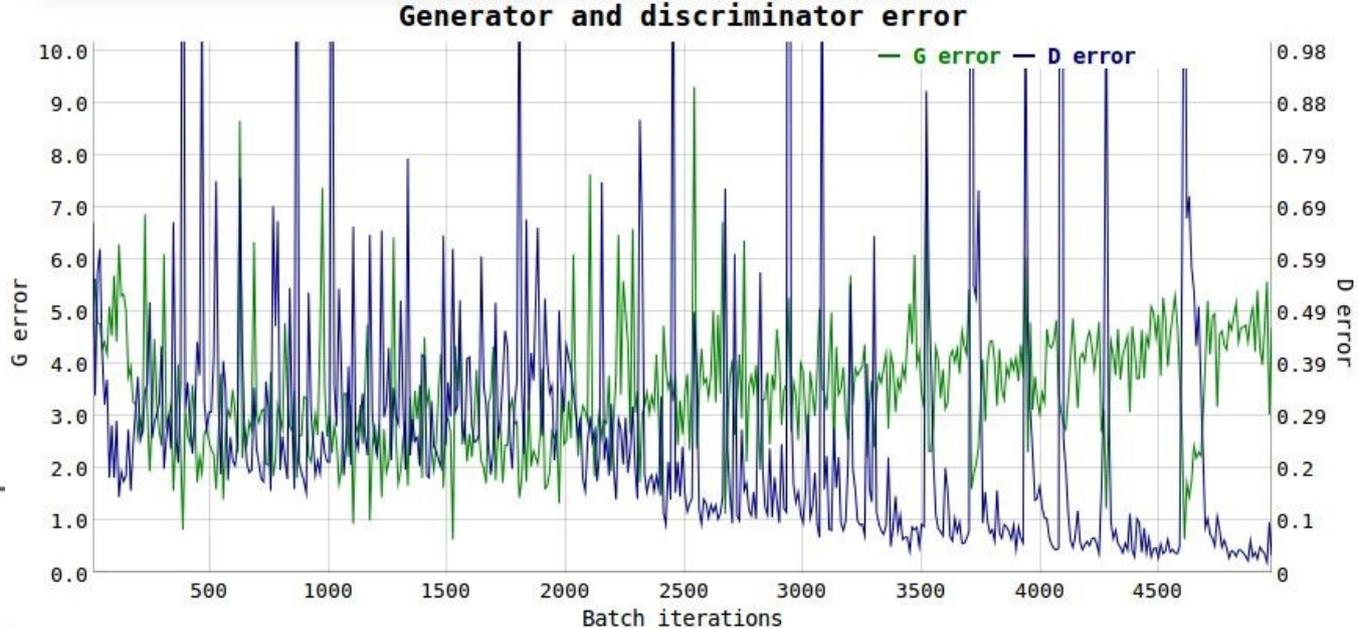
Aufwand einen Haufen Erde zu verschieben statt Differenz zwischen Soll und Ist



WGAN Loss

Gradient clipping →

↓ Gradient penalty



Probleme

- Discriminator ist besser als Generator und kann nicht aufholen
 - Wasserstein GAN
- Mode collapse – Es werden nur 5 verschiedene (gute) Bilder generiert
 - Zusätzlicher classifier der bewertet, ob verschiedene Batches ähnliche Repräsentationen haben (DCGAN)
 - Opposing modes (Coulomb GAN)
 - Gradient penalty (WGAN+)
- Konvergenz – Das dauert ja ewig...
 - Nur in sehr begrenzten Szenarios gegeben – aber da theoretisch bewiesen ([Two Time Update Rule](#))
 - Progressive training (Progressively Growing GAN)
- Verifizierbarkeit
 - Generator and Discriminator scores sind nur relativ zu einander

Fréchet Inception Distance - [Two Time Update Rule](#)

Gesichts-Alterung



Source: <https://arxiv.org/pdf/1702.01983.pdf>

Super-resolution



(a) HR

(b) bicubic

(c) our

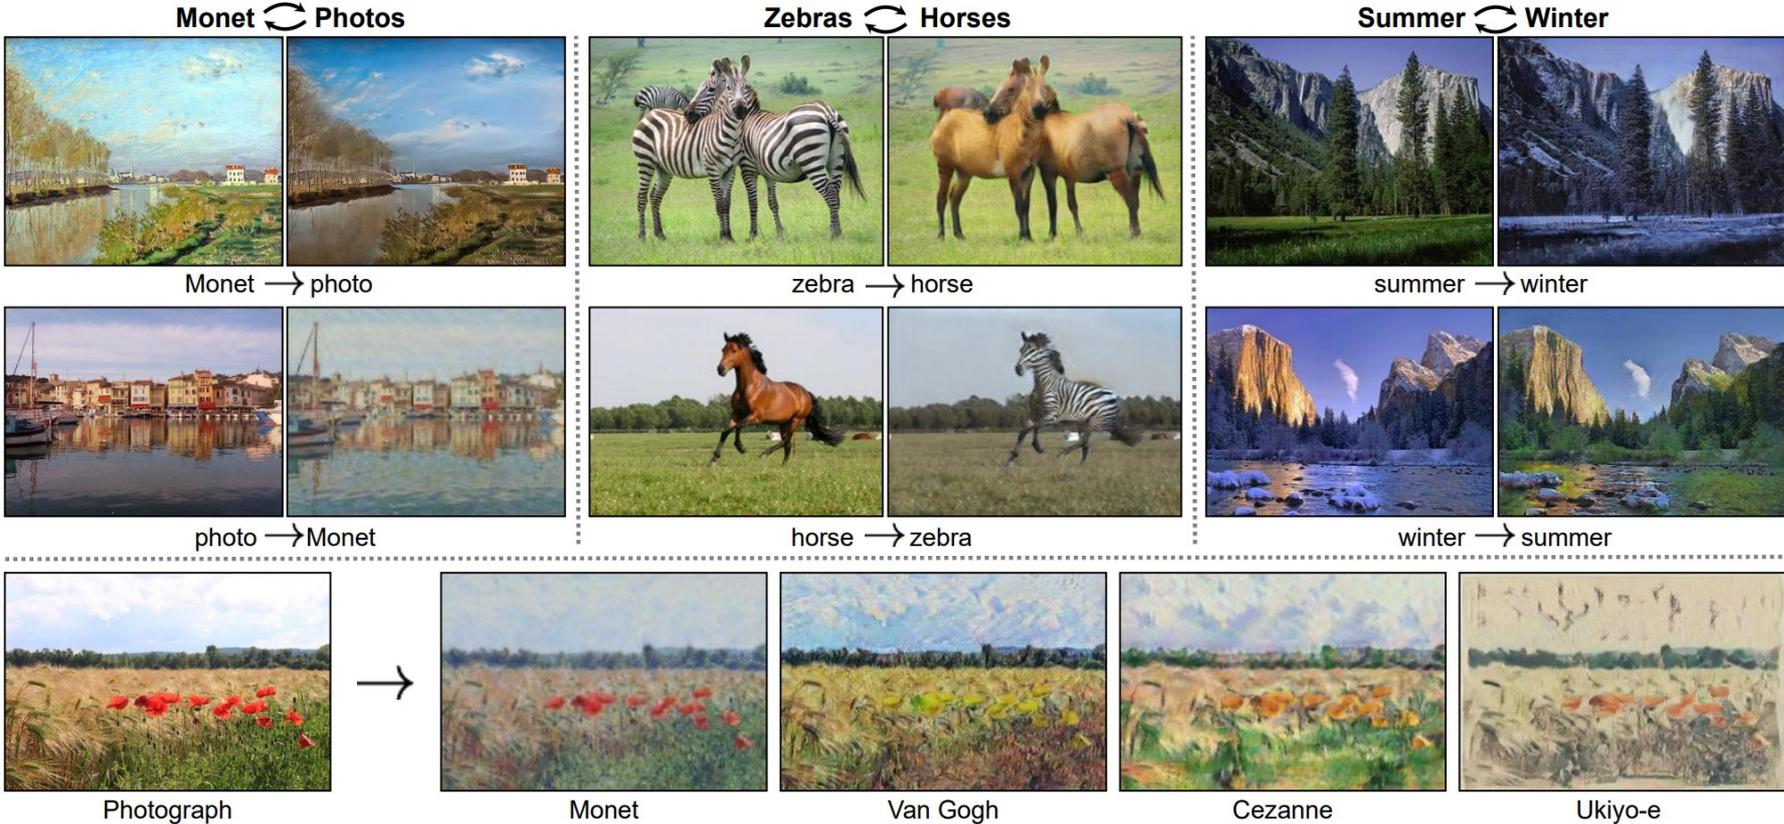
(d) HR

(e) bicubic

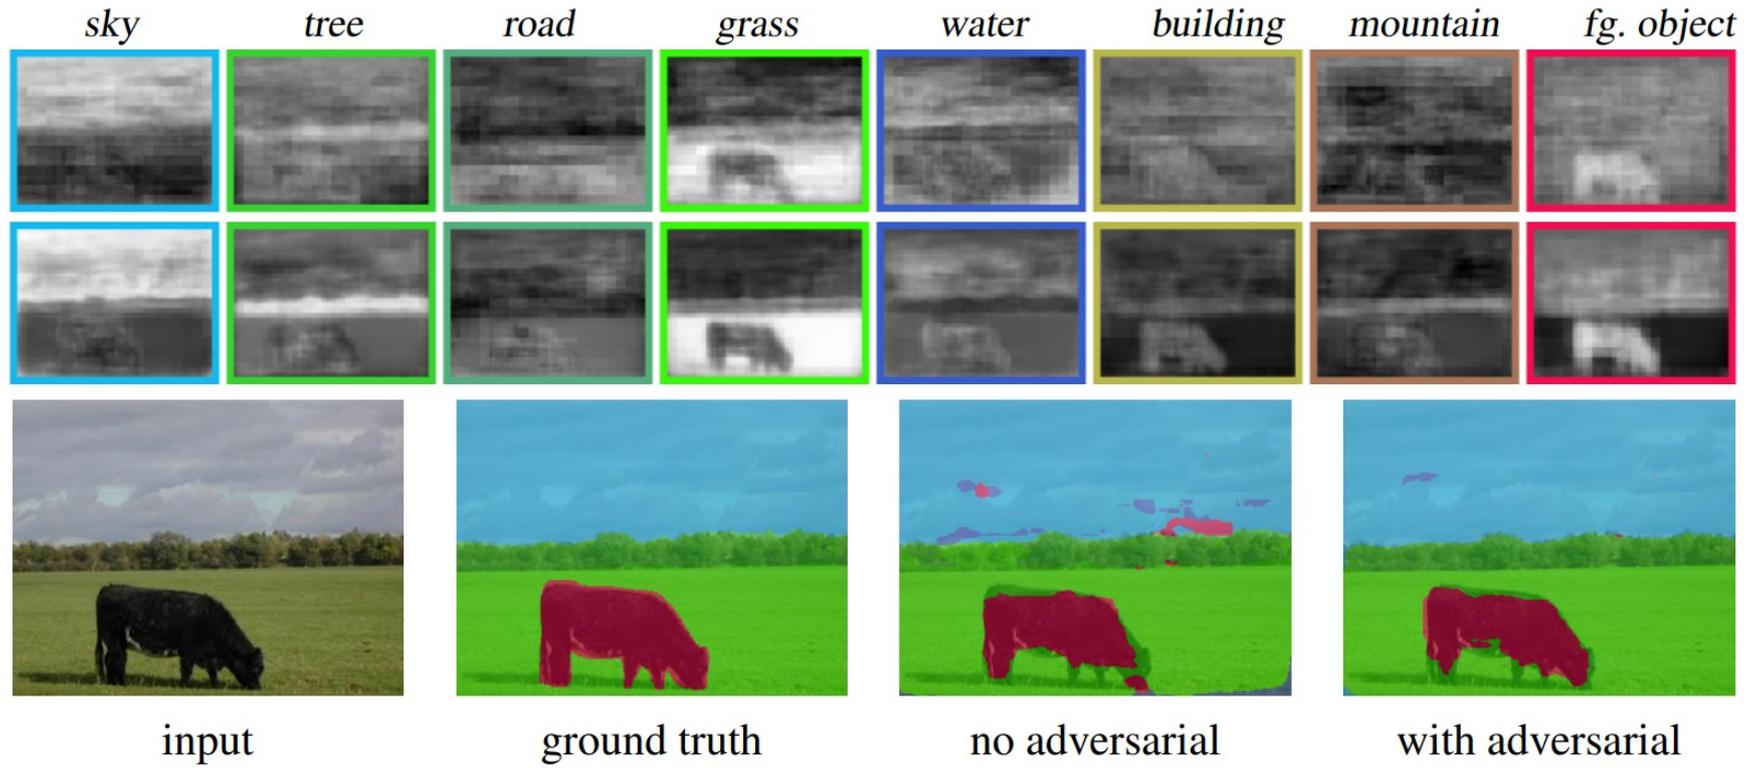
(f) ours

Source: <https://arxiv.org/pdf/1707.00737.pdf>

Cycle GAN



Semantische Segmentierung



Pix2Pix

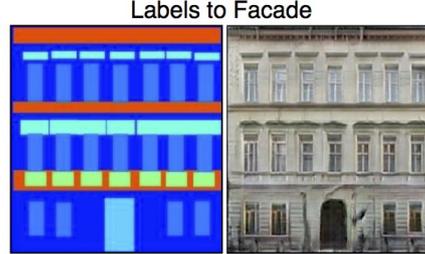
Segmentierung



input output



input output



input output



input output



input output



input output



Image Inpainting

