

Umsetzung und Vergleich von GANs (Generative Adversarial Networks) zur Generierung von Bildern menschlicher Gesichter

Nawid Shadab

Bachelorarbeit • Studiengang Informatik • Fachbereich Informatik und Medien • 10.02.2022

Aufgabenstellung

Das Ziel dieser Arbeit ist die Implementierung von drei bekannten GAN-Modellen, nämlich Standard GAN (SGAN), Deep Convolutional GAN (DCGAN) und Wasserstein GAN with Gradient Penalty (WGAN-GP), zur Evaluierung und zum Vergleich ihrer Fähigkeiten bei der Bildsynthese (spezifischer, Generierung von menschlichen Gesichtsbildern).

Konzept

Generative Adversarial Networks (GANs) sind eine Unterklasse von generativen Modellen, die die KI revolutioniert haben und nun in der Lage sind, qualitativ hochwertige Bilder zu generieren. GANs bestehen aus zwei konkurrierenden Netzen, dem sogenannten Discriminator (D) und dem Generator (G) (vgl. Abb.1). Der G nimmt ein zufälliges Rauschen als Eingabe und lernt, aus diesem Rauschen neue Samples (hier Gesichtsbilder) zu generieren, die realen Daten (CelebA-Datensatz) ähnlich sind. Der D lernt, zwischen echten Bildern und von G generierten Bildern zu unterscheiden. D und G trainieren sich gegenseitig, bis sie ein Nash-Gleichgewicht erreichen [1].




Abb. 1: Generative Adversarial Networks (GANs) Struktur nach [2]

Implementierung

Im Rahmen der Arbeit wurden drei bekannte GAN-Modelle SGAN [1], DCGAN [3], und WGAN-GP [4] implementiert. Die Implementierung erfolgte in der Programmiersprache Python. Das PyTorch-Framework wurde zur Erstellung und Aktualisierung der neuronalen Netze dieser Modelle eingesetzt. Zur Visualisierung der Ausgabe-Daten und der Ergebnisse wurde TensorBoard verwendet. Das Training der GAN-Modelle wurde auf einer NVIDIA Titan RTX Grafikkarte mit CUDA 11.1 durchgeführt. Die Qualität der durch SGAN, DCGAN und WGAN-GP generierten Bilder wurde qualitativ und quantitativ überprüft. Die Fréchet Inception Distance (FID) Metrik wurde implementiert und für die quantitative Bewertung verwendet [5]. Die FID-Metrik verwendet das vortrainierte Inception-V3-Modell, um die Merkmale der realen und der generierten Daten zu extrahieren. Die extrahierten Merkmale bilden zwei multivariate Verteilungen. Die FID-Metrik berechnet den Abstand zwischen diesen beiden Verteilungen anhand ihrer Mittelwerte und ihrer Kovarianzen. Die qualitative Evaluierungsmethode erfolgt objektiv und auf menschlicher Basis. Hierfür wurde das Konzept der Rapid Scene Categorization [6] Methode verwendet.

Experimente und Ergebnisse

Die GAN-Modelle wurden 50-mal auf dem CelebA Dataset (200k Bilder von Prominenten) trainiert. Abbildung 3 illustriert einige Bilder, die nach dem Training von diesen Modellen generiert wurden. Nach dem Training der Modelle wurde die Qualität der generierten Bilder quantitativ (FID) und qualitativ (objektiv) evaluiert (vgl. Abb. 2 und Abb. 3). Die beide Bewertungsmethoden zeigten, dass das DCGAN-Modell bessere Bilder als WGAN-GP- und SGAN-Modell erzeugt.






Abb. 2: Bei der quantitative Evaluierung der GAN-Modelle weist ein niedrigerer FID-Wert auf eine bessere Qualität hin.

Abb. 3: Bei der qualitative Evaluierung der GAN-Modelle wurden durchschnittlich 21 von 30 durch DCGAN generierten Bildern von Testpersonen als real bewertet.




a: DCGAN



b: WGAN-GP



c: SGAN



d: Real

Abb.3: Die generierten Bilder durch a: DCGAN-, b: WGAN-GP- und c: SGAN-Modelle neben d: reale Bilder aus dem CelebA-Datensatz

Quellen

- [1] I. J. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville und Y. Bengio. Generative Adversarial Networks. 2014. arXiv:1406.2661 [stat.ML].
- [2] X. Mao und Q. Li. Generative Adversarial Networks for Image Generation. Springer Singapore, 2021, S. 2–4. isbn: 9789813360488. url:https://books.google.de/books?id=u9oeEAAAQBAJ.
- [3] A. Radford, L. Metz und S. Chintala. Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks. 2016. arXiv:1511.06434 [cs.LG].
- [4] I. Gulrajani, F. Ahmed, M. Arjovsky, V. Dumoulin und A. Courville. Improved Training of Wasserstein GANs. 2017. arXiv:1704.00028 [cs.LG].
- [5] M. Heusel, H. Ramsauer, T. Unterthiner, B. Nessler und S. Hochreiter. GANs Trained by a Two Time-Scale Update Rule Converge to a Local Nash Equilibrium. 2018. arXiv:1706.08500[cs.LG].
- [6] A. Borji. Pros and Cons of GAN Evaluation Measures. 2018. arXiv:1802.03446 [cs.CV].