



Fluidität



Herausgegeben von
Hanni Geiger
Julian Stalter

München, 2023
Open Publishing LMU

Inhalt

Danksagung	5
Einleitung	7
Fluide Ordnung: Neuronale Netze als künstlerische Werkzeuge der De-Klassifikation	13
Das fluide Menschenbild. Digitale Ver- und Entkörperungen im Dazwischen	31
Fluide Architektur	51
On Bias and Interconnectedness – a Conversation about Fluidity with Entangled Others Studio	69

Danksagung

Wir möchten unsere Dankbarkeit und Anerkennung für alle Beteiligten am vorliegenden Heft „Fluidität“ zum Ausdruck bringen. Ohne deren wertvolle Beiträge, Engagement und Expertise wäre dieses Projekt nicht möglich gewesen. Ein besonderer Dank geht an Tenuh Arte, Sofia Crespo, Ilgin Eke, Entangled Others, Rainer Hörmann, Ben Kamis, Hubertus Kohle, Moritz Niederschweiberer und Ricarda Vollmer.

Einleitung

„Was den Begriff der Fluidität angeht, hier und da hat er für Verwirrung gesorgt, aber ich glaube, er strahlt ein ganz klares Bild von Flexibilität, Wandlungsfähigkeit, Nicht-Starrheit, Anpassungsfähigkeit, Subtilität, Bigsamkeit, Kontinuität, Glätte, Gleitfähigkeit, Geschmeidigkeit aus“¹ – so umschreibt Douglas Hofstadter 1995 das Fluide, und an der doch eher schwierigen Greifbarkeit des Begriffs hat sich bis heute nicht viel geändert. Wir können ihn materiell auffassen, als eine physikalische Eigenschaft von Flüssigkeiten und Gasen², wir können uns ihm metaphorisch nähern und die Einflüsse und Strömungen beispielsweise der Kunst und Kunstgeschichte beschreiben.³ Wir können Fluidität als Prozess begreifen, der dem Starren entgegensteht oder sich als dynamisches Geschehen manifestiert, als biologische Eigenschaft, die die Durchlässigkeit von Zellen beschreibt⁴, oder als „Material in Motion“, ein Phänomen, „that comprises manifold processes of change, movement, and agency in a wide range of contexts“⁵.

Dabei erfüllt das digitale Bild besonders letztere Eigenschaft. In seiner Prozessualität wird es – wie Boris Groys argumentiert – stets neu „performt“ und aufgeführt.⁶ Sobald der Rechner aufhört, die Hexadezimalstellen des codierten digitalen Bildes in farbige Pixel zu übersetzen, verpufft es, ohne Spuren zu hinterlassen. Aber eben jene ephemere Eigenschaft bedingt auch seine fluiden Charakteristika: Starre Kategorien, Identitäten, ja sogar digitale Wände verschwinden mit einem Mausklick oder

1 Douglas Hofstadter: *Fluid Concepts and Creative Analogies: Computer Models of the Fundamental Mechanisms of Thought*, New York 1995, S.2, Übersetzung Julian Stalter.

2 „Fluidität“. In: [www.spektrum.de](https://www.spektrum.de/lexikon/biologie/fluiditaet/25329), <https://www.spektrum.de/lexikon/biologie/fluiditaet/25329> [Stand 04/2023].

3 Christine Tauber und Ulrich Pfisterer (Hg.): *Einfluss, Strömung, Quelle. Aquatische Metaphern der Kunstgeschichte*, Bielefeld 2018.

4 Gerald Karp: *Molekulare Zellbiologie*, Berlin, Heidelberg und New York 2005, S.175.

5 Cassandra Nakas und Marcel Finke (Hg.): *Fluidity. Materials in Motion*, Berlin 2022, S.8.

6 Boris Groys: *Art Power*, Cambridge (Mass.) 2008, S.85.

lassen sich nach Belieben verformen. Das Fluide ist somit als Ausdruck einer ständig bewegten, sich im Wandel befindenden Welt zu verstehen. Fluidität – das kann auch der Übergang von einem Zustand in den nächsten sein oder ein Übergang ohne fix definierten Start- und Endpunkt, der wie Heraklits Fluss an uns vorbeifließt. Sicher scheint aber, dass das Fluide im Digitalen sein ideales Medium gefunden hat. Ob als Übergang von einem Avatar in den nächsten, das Verschmelzen zweier Kreaturen oder das Unstete eines digitalen Entwurfsprozesses – das Fluide fühlt sich wohl im Digitalen.

Dieses Heft widmet sich der Untersuchung fluider digitaler Bilder, die die anthropozentrisch und westlich gedachten Kategorien in Frage stellen: In drei Beiträgen, die Biologie, den menschlichen Körper und Architektur verhandeln, beleuchten die Autor*innen ausgewählte Erscheinungsformen der fluiden virtuellen Bilder. Aus der Perspektive unterschiedlicher Disziplinen wie den Naturwissenschaften, den Geistes- und Kulturwissenschaften sowie der Architekturtheorie wird der Vielschichtigkeit des materiell wie ideell, technisch wie naturalistisch, gestalterisch wie gesellschaftlich prägenden Phänomens nachgegangen. In den drei Beiträgen werden die Beispiele fluider digitaler Bilder mit Fragen und Antworten versehen, deren Überschneidungen trotz der fachlich und methodisch unterschiedlichen Zugänge bezeichnend sind. Ausgelotet wird etwa die Rolle der digitalen Technologien für Bilder, die von einer Nivellierung der Hierarchien und Ordnungssysteme zeugen. Inwiefern können diese – vor der Folie ihrer Veränderbarkeit und der Unterminierung traditioneller Verhältnisse – Aussagen zum aktuellen oder zukünftigen Zustand der Gesellschaft und ihres Umgangs mit der Natur treffen? Kann von einer Rückwirkung digitaler Bilder auf die Gesellschaft und ihr Denken und Handeln ausgegan-

gen werden? Komplettiert wird das Heft durch ein Interview mit dem Künstlerduo Entangled Others, das fluide Übergänge zwischen Natur und Technik in seinen Werken thematisiert.

Am Anfang des Hefts steht Julian Stalter mit einer Analyse von künstlichen neuronalen Netzen als Werkzeugen, mit deren Hilfe strenge Klassifizierungen aufgehoben und damit fluide gemacht werden. Wie werden Ordnungssysteme von Foucault bis hin zur künstlichen Intelligenz eingesetzt und welche Mittel bieten neuronale Netze, um eben diese zu stören? Hanni Geiger befragt gestalterische und narrative Aushandlungen fluider Körper im Digitalen seit den frühen 1990er Jahren. Die unterschiedlichen Körperentwürfe werden über die Analyse der angewandten technischen Gestaltungsmittel auf ihren utopischen wie dystopischen, postmodernen wie postkolonialen, trans- wie posthumanistischen Gehalt befragt. Vor der Folie eines sozio-ökologisch ins Wanken geratenen Glaubens an die zentrale Stellung des Menschseins werden überkommene Vorstellungen von Natur und Kultur im fluiden Körper destabilisiert. Dabei wird dem Potenzial der technisch induzierten Verflüssigung bis hin zur Aufgabe der Kategorien Mensch und Maschine, Gender, Kultur, Ethnie und schließlich auch Identität selbst nachgegangen. Sophie Ramm spürt Fluiditätskonzepten in der Architektur seit dem Aufkommen des digitalen Bildes nach. Sie zeigt, wie das Entwerfen entschieden prozesshafter wurde, während im Hinblick auf die gebaute Umsetzung meist nur eine Scheinfluidität erzeugt wurde. Existierten Ideen von Fluidität schon vor der Anwendung digitaler Formfindungsprozesse? Untersucht wird, inwiefern fluides Denken durch digitale Bilder befördert wird. Müsste dieses Konzept von „Anpassungsfähigkeit“ angesichts von Herausforderungen wie dem Klimawandel heute nicht als Leitmotiv gelten?

In diesem Heft haben wir uns auf eine Reise durch die Welt der fluiden digitalen Bilder begeben und ihre Auswirkungen auf verschiedene Bereiche untersucht. Wir haben gesehen, wie die Fluidität als Konzept und Phänomen die starren Grenzen und Hierarchien herausfordert und Veränderungen ermöglicht. Die Auseinandersetzung mit fluiden digitalen Bildern und ihren vielschichtigen Implikationen ist damit jedoch keineswegs abgeschlossen. Vielmehr sollen die hier präsentierten Beiträge und Diskussionen einen Anstoß geben, weiterhin über die Grenzen und Möglichkeiten dieser Konzepte und Technologien nachzudenken, und tragen hoffentlich dazu bei, den Dialog über Fluidität, Digitalität und ihre Folgen für unsere Lebenswelten anzuregen und unsere Sichtweisen zu erweitern.

Abb.1, Sofia Crespo: Permeable Circulation, © Sofia Crespo



Fluide Ordnung: Neuronale Netze als künstlerische Werkzeuge der De-Klassifikation

Artificial Natural History

Zellmembranen und Knospen, Blütenblätter und schuppige Texturen – sie alle verschmelzen in dem Werk *Permeable Circulation* aus der Reihe *Artificial Natural History* der Künstlerin Sofia Crespo (Abb. 1). Sie selbst beschreibt diese ineinander verschlungenen Kreaturen als „natural history book that never was“.¹ Immer wieder lassen sich Versatzstücke von bekannten Kompendien der Naturillustration erkennen: angefangen im frühen 18. Jahrhundert bei Albertus Sebas *Thesaurus*, über Louis Renards Fisch- und Krabbenzeichnungen bis hin zu Ernst Haeckels *Kunstformen der Natur* im 19. Jahrhundert.²

Doch die Illustrationen verschwimmen miteinander, erläuternder Text ist unlesbar und wellenartig über die Seite verteilt. Bestimmend für die visuelle Rezeption ist das fluide Verschmelzen der verschiedenen Lebewesen. So bilden sich hybride Formen, Chimären aus Lebewesen, deren Organe, Gliedmaßen und Oberflächen ineinander übergehen.

Auffällig ist die scheinbar gegensätzliche Funktion dieser Bildtafeln, verglichen mit den Kompendien Sebas, Renards oder Haeckels, die Ordnung schufen, Gattungen versammelten und Klassifikationen erstellten. Dabei beanspruchten sie sowohl visuell als auch in der Nomenklatur der Illustrationen wissen-

1 Grace Ebert: Neural Networks Create a Disturbing Record of Natural History in AI-Generated Illustrations by Sofia Crespo. In: Colossal, 30.09.2020, <https://www.thisiscolossal.com/2020/09/sofia-crespo-ai-natural-history/> [Stand 01/2023].

2 Albertus Seba: *Locupletissimi rerum naturalium thesauri accurata descriptio, et iconibus artificiosissimis expressio, per universam physices historiam*, Amsterdam 1734; Louis Renard: *Poissons, ecrevisses et crabes, de diverses couleurs et figures extraordinaires, que l'on trouve autour des isles Moluques et sur les côtes des terres Australes*, Amsterdam 1754; Ernst Haeckel: *Kunstformen der Natur*, Leipzig und Wien 1899.

schaftliche Genauigkeit für sich. Es scheint, als ob genau diese ursprüngliche Verwendung in den neu geschaffenen Werken Crespos unterlaufen wird und die Künstlerin Organismen mittels digitaler Werkzeuge erschafft, die wir nicht klassifizieren und eindeutig taxonomisch zuordnen können. „Our visual cortex recognizes the textures, but the brain is simultaneously aware that those don't belong to any arrangement of reality that it has access to“, sagt Sofia Crespo zu diesem kognitiven Prozess.³

Manipulation durch De-Klassifikation?

Im Folgenden möchte ich untersuchen, wie digitale Werkzeuge, spezifischer: sogenannte neuronale Netze der Ausprägung Generative Adversarial Networks (GANs) als künstlerisches Mittel genutzt werden, um starre Strukturen der Ordnung und Klassifikation zu unterlaufen. Ihre fluiden Eigenschaften bestehen dabei in eben jenem Ausweichen und Umgehen von festgelegten Taxonomien, normativen Klassifikationen und definitiven Unterscheidungen.

Meine These ist, dass zwei spezifische Eigenschaften von GANs eine solche Subversion von Klassifikationen begünstigen. In ihrer Anwendung können epistemische Praxen des Zu-Ordners durch künstlerische Intervention unterlaufen und fluide Bewegungen in Gang gesetzt werden. Bei GANs handelt es sich um synthetisierende Modelle, die aus dem Zusammenspiel zweier konvolutionaler neuronaler Netzwerke (CNNs) Inhalte generieren. Ihre Eigenschaft als potenziell bilderzeugende Werkzeuge macht sie dabei besonders interessant für Künstler*innen. So bauen sie zwar auch auf Kategorisierungen auf, können aber durch künstlerisch-technische Manipulation zur De-Klassifizierung zweckenfremdet werden. Diese An-

nahme soll an zwei Fallbeispielen gezeigt werden. Unter den Überschriften „Interpolation“ und „Spekulation“ werden zwei konkrete Szenarien untersucht, in denen das subversive Potenzial von GANs als deren spezifische Eigenschaft ersichtlich wird. Die Beispiele werden dabei jeweils mit einer Kontextualisierung ihrer jeweiligen Anwendung beziehungsweise der Klassifikationen, derer sie sich durch den Einsatz der neuronalen Netze entledigen, eingeführt. Beginnen möchte ich jedoch zunächst mit einer basalen Erläuterung der Funktionsweise der neuronalen Netze und deren technischer Bedingtheit.

Neuronale Netze als synthetisierende Werkzeuge

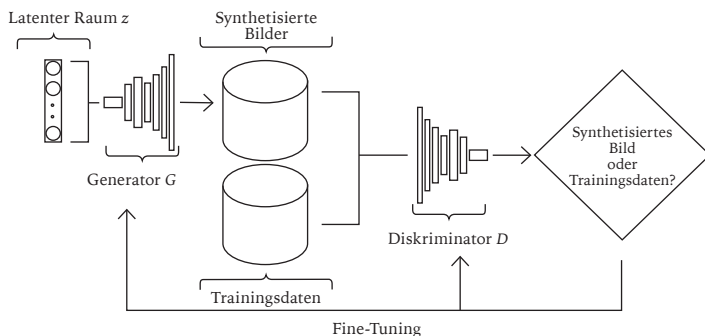
GANs wurden erstmals von der Forschungsgruppe um Ian Goodfellow 2014 vorgestellt und basieren auf dem Zusammenspiel zweier neuronaler Netze.⁴ Die Netze („networks“) treten dabei gegeneinander („adversarial“) an, um Bilder zu erzeugen („generative“), die Trainingsdaten möglichst entsprechen, aber keine Kopien sind, sondern von dem Modell selbst generiert wurden. Bei den Netzwerken handelt es sich erstens um ein generatives Netzwerk (G), welches aus zufälligen Datenverteilungen Bilder erzeugt, und zweitens um ein diskriminierendes Netzwerk (D), welches entscheidet, ob die von G generierten Verteilungen den Trainingsdaten ähneln, mit denen D trainiert wurde (Abb. 2). Um das Prinzip zu veranschaulichen, wählt Goodfellow den Vergleich mit Geldfälschern („counterfeiters“):

⁴ Ian Goodfellow, Jean Pouget-Abadie, Mehdi Mirza et al.: Generative Adversarial Nets. In: Advances in Neural Information Processing Systems 27, 2014, S. 2672–2680.

„The generative model can be thought of as analogous to a team of counterfeiters, trying to produce fake currency and use it without detection, while the discriminative model is analogous to the police, trying to detect the counterfeit currency. Competition in this game drives both teams to improve their methods until the counterfeits are indistinguishable from the genuine articles.“⁵

Gelingt es dem generativen Netzwerk (G) schließlich, ein Bild zu synthetisieren, welches das diskriminierende Netzwerk (D) überlistet, wird dieses als Ergebnis ausgeworfen: „[...] the generator neural network strives to create an entirely synthetic image that the discriminator neural network cannot distinguish from one of the photographic images that the system was trained on.“⁶ (Abb. 2)

Abb.2, Modell eines Generative Adversarial Network



Das von Goodfellow 2014 präsentierte GAN konnte in seiner Anlage keine multimodalen Daten mit zusätzlichen Informationen wie Kategorien verarbeiten. Dies änderte sich mit der Einführung konditioneller GANs ebenfalls im Jahr 2014.⁷

⁵ Ebd., S.2672.

⁶ Luke Skrebowski: Trevor Paglen's Adversarially Evolved Hallucinations. In: Cassandra Nakas und Marcel Finke (Hg.): Fluidity. Materials in Motion, Berlin 2022, S.149.

⁷ Mehdi Mirza und Simon Osindero: Conditional Generative Adversarial Nets, S.1-7, 06.11.2014, <http://arxiv.org/abs/1411.1784> [Stand 01/2023].

Diese können multimodale Daten aufnehmen und konditionell ausgeben. Zusätzlicher Input können dabei beispielsweise Kategorien sein:

„Generative adversarial nets can be extended to a conditional model if both the generator and discriminator are conditioned on some extra information y . y could be any kind of auxiliary information, such as class labels or data from other modalities.“⁸

So kann das GAN nun auch Bilder bestimmter Kategorien synthetisieren. Voraussetzung ist nur, dass diese Kategorien auch in den Trainingsdaten angelegt sind. Diese werden dann beim Trainieren des generativen Netzwerks in einem sogenannten latenten Raum (z) angelegt. Dieser besteht aus einem hochdimensionalen Vektorraum und kann als eine Form der Datenkompression gesehen werden.⁹ Dieser Raum startet im generativen Netzwerk mit einer randomisierten Verteilung („noise distribution“), die im latenten Raum angelegt wird. Durch das Training wird dieser Vektorraum mit Datenverteilungen gefüllt, mit deren Hilfe dann die Bilder synthetisiert werden. So bildet sich beispielsweise ein Punkt in dem dreidimensionalen Raum, der sowohl die Kategorie Apfel als auch Datenverteilungen enthält, die das Bild eines Apfels synthetisieren können. Diese Information ist wichtig, denn sie spielt in dem ersten Fallbeispiel der Interpolation eine entscheidende Rolle.

Interpolation – Klassifizieren in neuronalen Netzen

Das Erkennen – und damit Klassifizieren – von Objekten stellt eines der frühesten Vorhaben in der Entwicklung neuronaler Netze dar. Bereits in den späten 1950er Jahren stellte Frank

⁸ Ebd., S.2.

⁹ Siehe auch Matteo Pasquinelli und Vladan Joler: The Nooscope manifested: AI as instrument of knowledge extractivism. In: AI & SOCIETY, Bd.36, 2021, Heft-Nr.4, S.1263-1280, hier S.1272.

Rosenblatt mit seinem „perceptron“ einen Vorläufer heutiger neuronaler Netze vor.¹⁰ „Inspired by networks of neurons in the brain, Rosenblatt proposed that networks of perceptrons could perform visual tasks such as recognizing faces and objects.“¹¹ Bis heute ist Klassifizierung eine zentrale Aufgabe neuronaler Netze:

„Machine learning classification is usually employed to recognise a sign, an object, or a human face, and to assign a corresponding category (label) according to taxonomy or cultural convention. An input file [...] is run through the model to determine whether it falls within its statistical distribution or not. If so, it is assigned a corresponding output label.“¹²

Dabei lässt sich der semiotische Prozess der Zuweisung von Kategorien in zwei Anwendungsfälle unterscheiden: So brauchen die Modelle für ihr Training Datensätze, die von Menschen klassifiziert wurden. Dies beinhaltet sowohl die Anlage einer Hierarchie als auch die Auswahl der Klassifikationslabels: „To create a training set is to take an almost infinitely complex and varied world and fix it into taxonomies composed of discrete classification of individual data points.“¹³ Die Hierarchie eines bekannten Trainingsdatensatzes – ImageNet – ist beispielsweise stark verästelt und bewegt sich von generellen Konzepten hin zu spezifischen Kategorien.

Anlage und Auswahl von Klassifizierungskriterien können dabei problematisch sein. So können bestimmte Kategorien rassistisch, ableistisch, misogyn oder anderweitig diskriminierend sein.¹⁴ Auch können non-binäre Personen unter binären Kategorien klassifiziert werden. Ist dieser Bias einmal in den Trainingsdaten angelegt, überträgt er sich auch auf das Modell:

¹⁰ Frank Rosenblatt: The perceptron: A probabilistic model for information storage and organization in the brain. In: Psychological Review, Jg. 65, 1958, Heft-Nr. 6, S. 386-408.

¹¹ Melanie Mitchell: Artificial Intelligence. A Guide for Thinking Humans, London 2019, S. 15.

¹² Pasquinelli und Joler 2021 (s. Anm. 9), S. 1273.

¹³ Kate Crawford: Atlas of AI: Power, Politics, and the Planetary Costs of Artificial Intelligence, New Haven 2021, S. 135-136.

¹⁴ Kate Crawford und Trevor Paglen: Excavating AI: The Politics of Images in Machine Learning Training Sets, 19.09.2019, <https://excavating.ai> [Stand 10/2023].

*„Machine learning systems are designed to be able to generalize from a large training set of examples and to correctly classify new observations not included in the training data sets. In other words, machine learning systems can perform a type of induction, learning from specific examples“.*¹⁵

Klassifizierung in neuronalen Netzen geschieht also in zwei Anwendungsszenarien: Durch Menschen werden Kategorien angelegt und ausgewiesen; diese Datensätze werden dann zum Trainieren der neuronalen Modelle verwendet, woraufhin diese durch induktives Lernen selbst zum Beispiel Objekte kategorisieren können.

Auch multimodale GANs werden mit diesen Datensätzen trainiert und Kategorien, wie beschrieben, im latenten Raum angelegt. Anschließend an die Fragestellung soll nun gezeigt werden, wie diese Klassifizierungen unterlaufen werden können, um die starren Kategorien zu verflüssigen.

Ganimals

Im ersten Fallbeispiel soll eine technische Vorgehensweise präsentiert werden, die fluide Übergänge zwischen ebenjenen Kategorien ermöglicht. So kann mithilfe der sogenannten Interpolation in einem mit Kategorien versehenen konditionellen GAN zwischen Kategorien gewechselt werden, wobei diese stufenlos ineinander übergehen können. Dabei werden im latenten Raum (z) zwei Punkte festgelegt, die auf multimodalen Daten beruhen. Hierbei kann es sich um zwei Kategorien handeln, wie beispielsweise Apfel und Birne. Beim Training des GAN mithilfe kategorisierter Trainingsdaten hat dieses gelernt, den entsprechenden Bildern und beigefügten Kategorien Punkte im Vektorraum zuzuweisen. Durch Interpolation

kann nun ein Vektor zwischen dem Punkt „Apfel“ und dem Punkt „Birne“ gespannt werden. Auf dieser Achse ist es möglich, verschiedene Interpolationsvektoren zu berechnen und sich fluide zwischen beiden Klassifizierungen zu „bewegen“.

Um dies zu veranschaulichen, soll auf ein Projekt von Mitarbeiter*innen des Massachusetts Institute of Technology eingegangen werden. Es handelt sich dabei nicht um ein im eigentlichen Sinne künstlerisches Projekt; trotzdem ermöglicht es in seiner kreativen Ausformung, die fluide Dimension neuronaler Netze zu verdeutlichen. Unter dem Titel „Meet the Ganimals“ können Besucher*innen der entsprechenden Internetseite neue Spezies der sogenannten Ganimals erstellen: „Hidden within the neural network, there are millions of these ‚ganimals‘ that no one has ever seen before.“¹⁶ Als Ausgangspunkt für die Klassifikation und damit natürlich auch die Interpolation dienen Tierarten, die im multimodal trainierten GAN-Modell BigGAN angelegt sind: „we introduce one such [...] system [...] that allows users to selectively create new artificial hybrid species by interpolating categories matched by BigGAN.“¹⁷ Bei diesem Modell handelt es sich um ein 2019 vorgestelltes „class-conditional“ GAN, also ein konditionales GAN, bei dem Klassifizierungen in das Training einfließen.¹⁸ Dabei wurden 1.000 Klassifizierungen in einen hochdimensionalen latenten Raum eingebettet. Für „Meet the Ganimals“ wurden diese aber auf 396 Tierkategorien beschränkt.¹⁹ Durch das Verschmelzen von zwei Tierkategorien miteinander wird die oben beschriebene Interpolation erreicht (Abb. 3).

Der Raum kann nun „smoothly traversed“ werden, „such that images of mixed categories can be synthesized via interpolating the categories“.²⁰ Es wird also ein fluides Hybridwesen erzeugt, dessen Erscheinung zwischen den zwei Ausgangskategorien liegt und stufenlos eingestellt werden kann.

¹⁶ Meet the Ganimals, <https://ganimals.media.mit.edu/about/overview> [Stand 01/2023].

¹⁷ Ziv Epstein, Océane Boulais, Skylar Gordon und Matt Groh: Interpolating GANs to Scaffold Autotelic Creativity. In: Proceedings of the Joint Workshops of the ICCV 2020, S. E23.

¹⁸ Andrew Brock, Jeff Donahue und Karen Simonyan: Large Scale GAN Training for High Fidelity Natural Image Synthesis, 25.02.2019, S.1-35, hier S.2, <http://arxiv.org/abs/1809.11096> [Stand 01/2023].

¹⁹ Die Kategorien beruhen auf dem Trainingsdatensatz ImageNet, mit dem BigGAN trainiert wurde.

²⁰ Epstein 2020 (s. Anm. 17), S. E23.